

# RELATÓRIO TÉCNICO

## Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Variáveis de contexto, instrumentos & sensores, técnicas de pré-processamento e propriedades extraídas para reconhecimento automático de emoções.

### **PALAVRAS-CHAVE**

*Affective Computing*; detecção automática de emoções; inferência emocional; variáveis de contexto; instrumentos & sensores; técnicas de pré-processamento; propriedades extraídas.

## Survey of contributions for a pipeline of emotion recognition and awareness

Context variables, instruments & sensors, pre-processing techniques and extracted properties for automatic recognition of emotions.

### **KEYWORDS**

*Affective Computing*; automatic emotion detection; emotional inference; context variables; instruments & sensors; pre-processing techniques; extracted properties.

### **DATA**

2018-12-31

### **AUTORES**

Célio Carvalho, José Torres e Rui Moreira

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

## RESUMO

A avaliação emocional tem sido uma área de investigação, desde há muitos anos, na área da saúde e na área psicossocial. Foi a partir da década de 90 que o reconhecimento de emoções ganhou mais atenção por parte dos investigadores, tornando-se num importante tópico de investigação até aos dias de hoje (Basu, Bag, Mahadevappa, Mukherjee, & Guha, 2016).

Segundo Picard, o estudo das emoções moveu-se da psicologia para a área da computação, criando um novo campo de investigação chamado de *Affective Computing* (AC). Aliás, no seu livro “*Affective Computing*”, indica as bases para a criação de um sistema inteligente para deteção emocional de forma automática (R. W. Picard, 1995).

Nos últimos anos, tem-se presenciado a um aumento deste tipo de investigações, talvez pela necessidade de transformar a relação entre as coisas (e.g. *hardware*, *software* e produtos em geral) e as pessoas, numa interação mais inteligente e natural (R. Picard & Klein, 2002), transformando assim o AC num tópico importante de investigação (Bos, 2010).

Vários autores consideram que a deteção automática de emoções poderá ter um impacto positivo na vida das pessoas. Por exemplo, a área da psicologia poderá beneficiar, com menos subjetividade, de dados contínuos e menos diferidos no tempo; a saúde poderá ser avaliada com informação complementar à fisiológica; poderá ser mais fácil detetar delitos como atos de delinquência e atentados terroristas; e será mais fácil desenhar produtos especializados em provocar ou transmitir emoções no mundo virtual (Murad & Malkawi, 2012).

Poderá também ser possível criar sistemas inteligentes do ponto de vista afetivo, conscientes ao nível emocional, capazes de perceber e reagir às emoções dos utilizadores. Apesar de existirem já vários estudos com o objetivo de detetar automaticamente emoções, os autores acreditam que a correlação de variáveis sociais, culturais e religiosas, com as fisiológicas, poderá contribuir de forma positiva para a qualidade dos resultados obtidos.

Neste contexto, está-se a preparar uma experiência para detetar automaticamente o bem-estar nos trabalhadores de escritório. Pretende-se recolher variáveis de contexto de várias modalidades e, depois do respetivo pré-processamento, usar esses dados como *input* de algoritmos de *Machine Learning* (ML) para a respetiva classificação. O objetivo é verificar a possibilidade de criar sistemas inteligentes do ponto de vista afetivo, conscientes ao nível emocional, capazes de perceber e reagir às emoções dos funcionários de escritório.

Este relatório resume as obras estudadas pelos autores na área do AC na revisão bibliográfica sobre o tema. Sugere-se um sistema de *tokens* para melhor categorização da informação, e propõe-se também uma sistematização da informação através da organização desses *tokens* em quadros resumo, para permitir uma análise agregada das investigações.

Na secção seguinte são resumidas as variáveis de contexto e propriedades de domínio utilizadas pelos autores. Depois são apresentados os instrumentos & sensores utilizados na recolha das variáveis de contexto. Posteriormente são resumidas as técnicas de pré-processamento utilizadas. Conclui-se com uma enumeração das propriedades extraídas mais utilizadas nas obras estudadas.

### ABSTRACT

Emotional assessment has been a research area of health and psychosocial field, since many years. It was from 90's that the recognition of emotions gained more attention from the researchers, becoming an importante topic of research up to today (Basu, Bag, Mahadevappa, Mukherjee, & Guha, 2016).

According to Picard, the study of emotions moved from psychology to the area of computing, creating a new research field called Affective Computing (AC). In fact, in her book "Affective Computing", she indicates the basis for creating na intelligent system for automatic emotional detection (R. W. Picard, 1995).

In recent years, there has been an increase in this kind of research, perhaps due the need to transform the interaction between things (e.g. hardware, software and products in general) and people more natural and intelligent (R. Picard & Klein, 2002). This transformed the AC in an important research topic (Bos, 2010).

Several authors believe that the automatic emotional detection can have positive impacto on people's lives. As an exemple, the area of psychology may benefit with less subjectivity, continuous and less deferred data in time; health can be assessed with additional info besides physiological data; it may be easier to detect crimes such as acts of delinquency and terrorist attacks; and it will be easier to design products specialized in provoking or transmitting emotions in the virtual world (Murad & Malkawi, 2012).

It may also be possible to create intelligent affective systems. Emotion-aware systems that can understanding and react to people emotions. Although there are already several studies with the objective of automatically detecting emotions, the authors believe that the correlation of social, cultural and religious variables with physiological ones, may contribute positively to the quality of the results obtained.

In this context, an experiment is being prepared to automatically detect the well-being of office workers. It is intended to collect context variables of several modalities and, after the pre-processing phase, use that data as input to Machine Learning (ML) classification algorithms. The goal is to verify the possibility of creating intelligent systems from an affective point of view, conscious at the emotional level, capable of perceiving and reacting to the emotions of office workers.

This technical report summarizes the studied researchs by the authors during the bibliographic review on the AC topic. A token system is suggested for better categorization of information, and a systematization of information is also proposed through the organization of these tokens in summary tables, to allow an aggregated analysis of the investigations.

The following section summarizes the context variables and domain properties used by the authors. Then, the instruments & sensors used to collect the context variables are presented. Subsequently, the pre-processing techniques used are summarized. It concludes with an enumeration of the extracted properties most used in the studied works.

# 1. INTRODUÇÃO

O *Affective Computing* (AC) é uma área de investigação centrada na deteção de emoções das pessoas com base nas expressões facial, orais e gestuais, e noutros sinais vitais do corpo humano (Gogia, Singh, Mohatta, & Sreejith, 2016) (Zhai & Barreto, 2006) (Zucco, Calabrese, & Cannataro, 2017). A lista de áreas de aplicação inclui sistemas baseados em robótica, deteção de níveis de alerta e atenção (e.g. condutores), desenvolvimento de jogos (e.g. avaliação do nível de frustração dos jogadores), sistemas de eLearning para avaliação do estado emocional e de atenção dos alunos, etc. (Gogia et al., 2016) (Zhai & Barreto, 2006). Resumindo, as investigações de AC desenvolvem mecanismos para transformar os computadores em instrumentos mais empáticos (Bos, 2010) e conscientes do estado afetivo dos seus utilizadores (Zhai & Barreto, 2006).

Os sistemas AC assentam genericamente em três fases: i) aquisição e processamento de sinais (e.g. expressões (cf. faciais, orais ou gestuais), sinais fisiológicos, etc.); ii) combinação mono ou multimodal de sinais (i.e. considerando sinais de apenas um ou várias origens de contexto); e iii) classificação da emoção correspondente aos sinais recolhidos, processados e combinados (Gogia et al., 2016).

O reconhecimento emocional tem sido alvo de investigação em vários domínios, como por exemplo, na indústria automóvel, cinematográfica e jogos, *Human-Robot Interaction* (HRI), *Brain-Computer Interaction* (BCI), *Human-Computer Interaction* (HCI), etc. No entanto, os autores estão particularmente interessados nas investigações relacionadas com a deteção emocional em intersecção com as linhas de investigação do AC.

O stress da condução é importante para a indústria automóvel. Por e.g. os projetos de Paschero (Paschero et al., 2012) e Gutman (Gutmann, Grausberg, Kyamakya, & Klagenfurt, 2015) estudaram as emoções durante a condução. O primeiro focou-se diretamente no reconhecimento de stress através de imagens e, o segundo, estudou as várias emoções relacionadas com o ato de conduzir, a partir de variáveis fisiológicas.

Um dos objetivos atuais da indústria cinematográfica é conseguir provocar emoções através de histórias (Guillotel, Fleureau, Orlac, & Silveira, 2013). O objetivo da investigação de Guillotel (Guillotel et al., 2013) foi encontrar formas de recolher continuamente a resposta emocional durante a visualização de um filme e não apenas no final através de questionários. Na investigação de Canini (Canini, Benini, Migliorati, & Leonardi, 2009), os autores criaram um sistema automático para classificação emocional dos filmes. O objetivo do projeto foi a categorização multimédia através de uma identidade emocional que poderá servir, por exemplo, como filtro num processo de pesquisa.

Existem também vários projetos na área de investigação dos jogos digitais. Apenas como exemplo, a investigação de Mandryk e Atkins (Mandryk & Atkins, 2007) pretendeu melhorar a interação dos utilizadores com este tipo de aplicações. Os autores contribuíram com um sistema capaz de detetar e representar continuamente, numa linha temporal, os estados emocionais sentidos durante um jogo. Outro exemplo, e numa perspetiva diferente, os autores Hsu, Shih e Chen (Hsu, Shih, & Chen, 2012), pretenderam criar um jogo capaz de moldar as emoções dos jogadores, ensinando-os a transformar as emoções negativas em positivas.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	PROJETO	SÚMULA
Indústria automóvel	(Paschero et al., 2012)	Através de uma câmara de vídeo, os autores pretendem recolher imagens com o objetivo de detetar a existência de stress durante a condução. O objetivo do sistema é alertar o utilizador quando o seu stress atinge determinado nível, para evitar situações de perigo que podem por em risco a sua segurança e a segurança dos outros.
	(Gutmann et al., 2015)	Os autores recolhem o Eletroencefalograma (EEG), Eletrocardiograma (ECG), <i>Respiratory Inductance Plethysmography</i> (RIP), <i>Heart Rate</i> (HR), <i>Interbeat Interval</i> (IBI), <i>Skin Conductance Response</i> (SCR), aceleração e velocidade, para detetar as emoções relacionadas com a condução (e.g. ansiedade, nervosismo, ou stress) com o objetivo de identificar potenciais situações de risco nomeadamente aquelas que podem influenciar negativamente o desempenho do condutor.
Indústria cinematográfica	(Guillotel et al., 2013)	Neste projeto os autores pretendiam criar um instrumento para medir o impacto emocional de um filme no utilizador em tempo real. Com este objetivo, criaram um sistema para detetar emoções com base em <i>Galvanic Skin Response</i> (GSR) porque consideram que esta reação fisiológica contém informação não consciente das pessoas.
	(Canini et al., 2009)	A <i>framework</i> foi criada com o objetivo de conseguir caracterizar conteúdo multimédia com base na cor, movimento e áudio do próprio filme. Os autores usaram a base de dados <i>Internet Movie Database</i> (IMDb) ("IMDb.com," 2016) e a sua classificação oficial como verdade irrefutável no seu estudo.
Indústria de Jogos	(Mandryk & Atkins, 2007)	Os autores recolheram GSR, ECG, HR e o <i>Electromyography</i> (EMG) (do franzir da testa e do rir), para detetar emoções. Pretendiam encontrar uma forma mais objetiva e contínua de medir emoções durante o jogo, porque a resposta escalar no final como acontece com os questionários, poderia ser influenciada pelo resultado do próprio jogo.
	(Hsu et al., 2012)	O objetivo da investigação era criar um jogo 3D para racionalizar o estado emocional, ensinando a transformar as emoções negativas em positivas.
HRI	(Luefeng, Min, Mengtian, Jinhua, & Kaoru, 2016)	Os autores criaram um sistema para deteção emocional para amenizar a relação entre humanos e robots. O sistema baseia-se na avaliação em tempo real da expressão facial das pessoas com o objetivo de identificar as emoções que sentem a cada momento.
	(Angel & Bonarini, 2014)	O objetivo da investigação era encontrar formas dos robots transmitirem emoções sem recurso às expressões e formas corporais humanas (linguagem não verbal). Os autores elegeram a mudança de velocidade durante a movimentação do robot como forma de transmitir emoções às pessoas.
BCI	(Y. Liu, Sourina, & Nguyen, 2010)	A investigação baseia-se na recolha do EEG para a deteção de várias emoções como o medo, frustração, tristeza, alegria, etc. Os autores escolheram este sinal de <i>input</i> porque defendem que as pessoas não o conseguem adulterar como pode acontecer nas expressões faciais e na entoação da voz.
	(Bos, 2010)	O estudo pretendia também a deteção de emoções com base nos sinais produzidos pelo cérebro. Os autores escolheram este sinal pelo facto de a literatura defender que este será o sinal mais indicado para a deteção emocional (Choppin, 2000).
	(Chanel, 2009)	O autor estuda a presença emocional no processo de comunicação com base nos sinais EEG, GSR, respiração, temperatura e <i>Bood Volume Pulse</i> (BVP).
HCI	(Chandler & Cornes, 2012)	Os autores pretendiam medir as respostas emocionais no uso de programas de computador, como forma de promover um melhor desenho de interfaces. A expressão facial foi o sinal base recolhido para a deteção. No entanto, como pode ser manipulado pelos utilizadores, os investigadores resolveram correlacionar o sinal com o SCR, como forma de melhor garantir os resultados.
	(Jamshidnejad & Jamshidined, 2009)	Os autores apresentam um sistema de reconhecimento de emoções através das expressões faciais para utilização no mundo dos negócios online. Durante uma transação, o sistema criado consegue registar as emoções sentidas pelos compradores durante a compra.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

De forma semelhante, na robótica estudam-se formas para que os robots consigam perceber e expressar emoções, com o objetivo de suavizar a interação com as pessoas (Angel & Bonarini, 2014). Num projeto de Luefeng (Luefeng et al., 2016) os autores apresentaram robots que conseguiam identificar e reagir em tempo real às emoções das pessoas. A investigação de Angel e Bonarini (Angel & Bonarini, 2014) estudou formas dos robots conseguirem expressar emoções através de alterações de velocidade durante o movimento.

São também vários os estudos que tentam detetar emoções com base na atividade cerebral. Na investigação de Liu (Y. Liu et al., 2010) os autores propuseram uma deteção de emoções em tempo real a partir do eletroencefalograma (EEG) e representaram as emoções detetadas através de um avatar. Nos estudos de Bos (Bos, 2010) e Chanel (Chanel, 2009), os autores também recolheram o EEG para detetar emoções. No primeiro caso o objetivo era tornar o computador mais empático com os utilizadores e, no segundo, pretendia-se estudar as emoções enquanto componente do processo de comunicação.

A análise emocional tem sido também uma linha de investigação muito importante na área da HCI (Raudonis, 2013) (Mower, Matari, & Narayanan, 2011). O desenvolvimento das metodologias de avaliação de HCI tem origens diversas como as ciências cognitivas, psicologia, engenharia e ciências da computação (Norman, 2002). A investigação nesta área conta já com vários trabalhos, incluindo alguns dos já referenciados. Nesta área é importante conhecer emocionalmente a reação de um utilizador quando colocado em contacto com uma peça de informação (Chandler & Cornes, 2012). Saber se ficou satisfeito e esclarecido, confuso e frustrado, ou animado e divertido, é importante para o desenho de interfaces que vão de encontro às expectativas dos utilizadores (Lisetti & Nasoz, 2004) (Bakhtiyari & Husain, 2014).

Os autores Chandler e Cornes (Chandler & Cornes, 2012) defenderam que a capacidade dos utilizadores interagirem com sucesso com as aplicações é crucial. Por esse motivo, apresentaram um sistema onde as emoções sentidas durante a utilização de uma aplicação podem ser registadas para posterior análise. O projeto de Jamshidnejad (Jamshidnejad & Jamshidined, 2009) também estudou o reconhecimento emocional em HCI mas na perspetiva dos negócios online. Os autores defenderam a importância, por exemplo, de registar as emoções dos utilizadores enquanto navegam e compram produtos ou serviços num portal de comércio eletrónico.

Os sistemas em geral, apesar de mais autónomos, interagem cada vez mais com os humanos (Rani, Science, Sarkar, Smith, & Adams, 2003). Neste contexto, os investigadores de AC como Luefeng (Luefeng et al., 2016) e Rani (Rani et al., 2003), estudam formas de desenvolver sistemas capazes de reconhecer e exprimir afetos com o objetivo de melhorar o relacionamento entre Homem e máquina. Por esse motivo, são de esperar novas linhas de investigação interdisciplinares que olhem para a HCI, não só como uma forma de promover a melhor experiência de utilização possível, mas também para satisfazer as necessidades do utilizador ao nível emocional (Bos, 2010).

Os estudos relacionados com a deteção automática de emoções seguem uma sequência genérica de etapas transversal às diferentes investigações acerca do tema (Figura 1): i) seleção das variáveis de contexto a recolher; ii) escolha dos instrumentos e sensores suporte à recolha; iii) pré-processamento de dados do *dataset* (e.g. remoção de ruído, redimensionamento de dados, etc.); iv) seleção das propriedades a extrair; v) escolha dos algoritmos a utilizar na classificação de emoções; e vi) definição dos modelos representativos das emoções detetadas.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções




Figura 1 - Modelo genérico utilizado na investigação emocional

Este modelo genérico de investigação pode ser assumido como referência ao processo de desenvolvimento de um sistema de deteção emocional, já que a sua especificação resulta da condensação das etapas seguidas pelos projetos da área de reconhecimento automático de emoções, de forma padronizada. É com base neste modelo que os autores acreditam ser possível criar um sistema inteligente ao nível dos afetos: um sistema capaz de reconhecer as emoções dos trabalhadores de escritório e, eventualmente reagir, reconfigurando o ambiente com o objetivo de promover um melhor bem-estar no local de trabalho.

Nas secções seguintes, cada uma das etapas do modelo genérico é abordada com maior detalhe. Pretende-se resumir as estratégias seguidas por algumas das investigações de referência da área de deteção automática de emoções, fazendo um levantamento dos caminhos já seguidos e detetar lacunas a considerar no processo de criação de um sistema consciente ao nível emocional.

No âmbito deste levantamento bibliográfico, resolvemos analisar as investigações resumidas no quadro que a seguir se apresenta. Estas investigações foram escolhidas por se focarem na deteção automática de emoções na área em áreas limítrofes dos autores.

INVESTIGAÇÃO	RESUMO	EMOÇÕES
<b>Perdiz et al.</b> (Perdiz, Pires, & Nunes, 2017)	Propor uma framework que combine a utilização do eletromiograma (EMG) e do eletrooculograma (EOG) para detetar emoções.	Fúria, tristeza, alegria e neutral.
<b>S. H. Lee et al.</b> (S. H. Lee, Member, Ro, & Member, 2016)	Propor um novo método de reconhecimento dinâmico com base em expressões faciais para resolver o problema dos desencontros temporais em sequências de vídeo (e.g. duração das transições).	Fúria, desprezo, desgosto, medo, alegria, tristeza e surpresa.
<b>Eckert et al.</b> (Eckert, Gil, Zapatero, Meneses, & Martínez Ortega, 2016)	Apresentar um algoritmo rápido e simples <i>emotion awareness</i> , capaz de executar em <i>realtime</i> e em segundo plano, para ser reutilizado por outras aplicações (e.g. jogos).	Fúria, desgosto, medo, tristeza, alegria e surpresa.
<b>Matlovic et al.</b> (Matlovic, Gaspar, Moro, Simko, & Bielikova, 2016)	Comparar a deteção de emoções entre sensores eletroencefalograma (EEG) (e a atividade eletrodermal (EDA)) e reconhecimento de expressões faciais utilizando ferramentas já existentes.	Alegria, surpresa, tristeza, medo, desgosto, fúria e estado neutral. ( <i>representação no modelo bidimensional valence/arousal</i> ).
<b>Gogia et al.</b> (Gogia et al., 2016)	Propor um sistema multimodal de deteção emocional, para utilização em ambiente de aprendizagem.	<i>Estado de atenção</i> .
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	Apresentar uma base de dados emocional multimodal, multiétnica e bem anotada.	Alegria, surpresa, tristeza, susto, embaraço, medo, dor, fúria e desgosto.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	Estudar o impacto de vários fatores, como é o caso da interação social, no sono, stress, disposição, e bem-estar em geral.	Stress, disposição e bem-estar.
<b>Zhao et al.</b> (Zhao, Adib, & Katabi, 2016)	Inferir emoções humanas, usando a reflexão dos sinais <i>wireless</i> em substituição do eletrocardiograma (ECG) tradicional.	Alegria, prazer, tristeza e fúria.
<b>Zenonos et al.</b> (Zenonos et al., 2016)	Reconhecer a disposição das pessoas catalogando-a em 5 níveis de intensidade. Os investigadores vêm a disposição como o resultado das emoções sentidas.	Excitação, alegria, calma, cansaço, tédio, tristeza, stress e fúria.
<b>Basu et al.</b> (Basu et al., 2016)	Apresentar um sistema simples de reconhecimento emocional considerando nove sinais fisiológicos com recolha não-invasiva.	<i>Valence e arousal.</i>
<b>Aracena et al.</b> (Aracena, Basterrech, Snael, & Velasquez, 2016)	Apresentar uma abordagem de reconhecimento emocional com base na informação cedida pela pupila.	Estados emocionais: positivo, neutral e negativo.
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	Apresentar um classificador capaz de reconhecer estados afetivos complexos de forma categórica.	Receio, fúria, vergonha, tédio, decepção, desgosto, animação, frustração, alegria, mágoa, interesse, brincadeira, orgulho, tristeza, matreirice, surpresa, preocupação e neutral.
<b>Turan et al.</b> (Turan, Lam, & He, 2015)	Propor um algoritmo adaptativo de seleção baseado em descritores, capaz de determinar as duas melhores propriedades de cada classe de expressão, com os objetivos de as fundir e assim conseguir um melhor reconhecimento.	Fúria - desgosto, medo – surpresa, tristeza e alegria. <i>(autor usou a classificação em classes seguindo (Jack, Garrod, &amp; Schyns, 2014))</i>
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	Investigar o conteúdo emocional existente no discurso oral (enunciados lidos), usando os <i>Mel Frequency Cepstral Coefficients</i> (MFCC).	Alegria, fúria, tristeza e neutral.
<b>Lalitha et al.</b> (Lalitha, Mudupu, Nandyala, & Munagala, 2015)	Apresentar um método para identificar as propriedades <i>Discrete Wavelet Transform</i> (DWT), adequadas a um reconhecimento emocional com maior precisão.	Ansiedade, desgosto, alegria, tédio, tristeza, fúria e neutral.
<b>Singh et al.</b> (Singh, Sharma, Jain, & Bhall, 2015)	Propor um sistema que detete emoções e estado mental de uma pessoa através da sua postura corporal.	Disposição (aproximada), confusão e dúvida, calma e estado neutral, preguiça ou desinteresse e fúria.
<b>Murali et al.</b> (Murali, Rincon, & Atienza, 2015)	Apresentar um dispositivo vestível pequeno e leve, para monitorização da saúde física e emocional.	Modelo bidimensional <i>arousal/valence.</i>
<b>Jaques et al.</b> (Jaques et al., 2015)	Desenvolver um algoritmo de <i>machine learning</i> capaz de distinguir entre alunos alegres e não alegres, com o objetivo de prever a depressão.	Felicidade.
<b>Cruz et al.</b> (Cruz, Garcia, Pires, & Nunes, 2015)	Apresentar um sistema para reconhecimento automático da expressão emocional da face com base na movimentação dos olhos.	Emoções humanas.
<b>Saha et al.</b> (Saha, Datta, Konar, & Janarthanan, 2014)	Criar um sistema para classificar emoções com base em gestos do corpo humano.	Fúria, medo, alegria, tristeza e relaxamento.
<b>Matiko et al.</b> (Matiko, Beeby, & Tudor, 2014)	Apresentar um novo <i>fuzzy based algorithm</i> para classificar emoções positivas e negativas a partir do eletroencefalograma (EEG).	<i>Valence.</i>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	Propor um sistema não obstrutivo para reconhecimento do stress com base em métricas de comportamento.	Stress.
<b>Agrawal et al.</b> (Agrawal, Giripunje, & Bajaj, 2013)	Criar um sistema para deteção de fadiga e desatenção por parte do condutor, com base nos gestos da face e nas emoções deduzidas desses gestos.	Alegria, fúria, tristeza e surpresa.
<b>Soleymani et al.</b> (Soleymani, Asghari-esfeden, Pantic, & Fu, 2013)	Detetar a agradabilidade ( <i>Valence</i> ) de forma contínua durante a visualização de um vídeo, com base na análise simultânea do EEG e da expressão facial.	Valence. ( <i>eixo do modelo bidimensional arousal/valence (excitação ou energia / prazer ou agradabilidade)</i> ).
<b>Vermun et al.</b> (Vermun, Senapaty, Sankhla, Patnaik, & Routray, 2013)	Criar um sistema mais preciso para reconhecimento do estado afetivo e cognitivo com base em gestos.	Alegria, ansiedade, desgosto, irritação, interesse, nível de alerta, tédio e fadiga. ( <i>emoções positivas e negativas em ambiente de aprendizagem</i> ).
<b>Kusserow et al.</b> (Kusserow, Amft, & Troster, 2013)	Monitorizar o stress em oradores, músicos, atletas olímpicos e em pessoas comuns.	Stress.
<b>Alzoubi et al.</b> (Alzoubi, Fossati, D'Mello, & Calvo, 2013)	Estudar a variação no tempo das propriedades fisiológicas que permitem detetar o afeto.	Afeto; <i>Valence e arousal</i> .
<b>Nawasalkar et al.</b> (Nawasalkar, Lawange, Gupta, Butey, & Email, 2013)	Propor um sistema para reconhecer os efeitos de música clássica e rock no corpo humano.	Stress; ( <i>emoções provocadas: alegria, surpresa, tristeza e excitação</i> ).
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	Encontrar sinais fisiológicos ou de comportamento que funcionem como marcadores de stress.	Stress.
<b>Raudonis</b> (Raudonis, 2013)	Desenvolver um sistema de reconhecimento de emoções com base nos movimentos do olho.	Neutral, desgosto, diversão e interesse.
<b>Kawai et al.</b> (Kawai, Takano, & Nakamura, 2013)	Investigar a variação do diâmetro da pupila com o objetivo de conseguir medir o afeto positivo ou negativo de pessoas que não conseguem mover a cabeça ou mãos para comunicar de outra forma.	Afetos positivos e negativos.
<b>Babiker et al.</b> (Babiker, Faye, & Malik, 2013)	Identificar as diferenças de diâmetro da pupila resultantes dos estados emocionais individuais positivos ou negativos.	Emoções positivas e negativas.
<b>LikamWa et al.</b> (LiKamWa, Liu, Lane, & Zhong, 2013)	Desenvolver uma aplicação para <i>smartphone</i> ( <i>MoodScope</i> ) capaz de inferir a disposição do seu utilizador.	Disposição.
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	Detetar emoções humanas através de um modelo <i>neuro/fuzzy</i> .	Tristeza, alegria, medo, embaraço, desgosto, ansiedade, raiva, suspense, alívio, orgulho e diversão.
<b>C. Y. Chang et al.</b> (Chang, Lin, & Zheng, 2012)	Propor um sistema baseado em sinais fisiológicos para reconhecer a fúria.	Fúria.
<b>Bauer &amp; Lukowicz</b>	Apresentar um sistema para detetar situações de stress através de sensores de <i>smartphone</i> .	Stress.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Bauer & Lukowicz, 2012)		
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	Criar um <i>avatar</i> (imagem) representativo das emoções de um vídeo ou sequência de imagens.	Fúria, medo, alegria, alívio e tristeza.
<b>Dhall et al.</b> (Dhall, Asthana, Goecke, & Gedeon, 2011)	Propor um método de reconhecimento automático de emoções.	Fúria, medo, alegria, alívio e tristeza.
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	Detetar o stress através da análise da dimensão da pupila.	Stress.
<b>Hernandez et al.</b> (Hernandez, Morris, & Picard, 2011)	Medir o stress num ambiente de <i>call center</i> .	Stress.
<b>N. Lane et al.</b> (N. Lane, Mohammad, Lin, & Yang, 2011)	Propor uma aplicação ( <i>BeWell</i> ) que promova o estilo de vida saudável com base no comportamento diário do utilizador.	Bem-estar.
<b>H. Wang et al.</b> (H. Wang, Zhou, & Ying, 2010)	Propor um sistema eficiente para detetar a fadiga em condutores em tempo real com base no estado do olho.	Fadiga.
<b>Bos</b> (Bos, 2010)	Criar um sistema de baixo custo e de fácil instalação para reconhecimento emocional.	<i>Representação das emoções reconhecidas no modelo bidimensional arousal/valence.</i>
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	Criar um sistema de reconhecimento de emoções em tempo real. Representação das emoções reconhecidas através de um avatar.	Medo, frustração, tristeza, alegria, agradabilidade e satisfação. <i>(emoções determinadas a partir do modelo bidimensional arousal/valence)</i>
<b>Setz et al.</b> (Setz et al., 2010)	Distinguir stress de excesso de trabalho cognitivo em ambiente de escritório	Stress.
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	Investigar o potencial dos sinais fisiológicos no reconhecimento de emoções durante a audição de música.	<i>Valence e arousal.</i>
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	Estudar emoções durante a visualização de filmes através da recolha de parâmetros fisiológicos.	<i>Valence e arousal.</i>
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley, Miccoli, Escrig, & Lang, 2008)	Avaliar o efeito hedónico do <i>valence</i> e do <i>arousal</i> emocional nas respostas da pupila.	<i>Valence e arousal.</i>
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	Criar um sistema para reconhecimento afetivo mais preciso, com base na expressão facial e nos gestos da parte superior do corpo.	Ansiedade, fúria, desgosto, medo, alegria e incerteza.
<b>Castellano et al.</b> (Castellano, Villalba, & Camurri, 2007)	Descobrir quais as pistas do movimento do corpo que melhor classificam emoções, e criar um modelo para reconhecimento emocional com base na análise de vídeo.	Fúria, alegria, prazer e tristeza.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	Detetar e quantificar emoções no contexto de tecnologias afetivas (e.g. jogos digitais), para evitar a medição apenas no final através de questionários.	Tédio, desafio, excitação, frustração e diversão. <i>(emoções determinadas a partir do modelo bidimensional arousal/valence)</i>
<b>Sebe et al.</b> (Sebe, Cohen, Gevers, & Huang, 2006)	Conseguir mais precisão na inferência de estados emocionais através da combinação das pistas dadas pela expressão facial e informação vocal.	Alegria, surpresa, fúria, desgosto, medo, tristeza, interesse, tédio, confusão e frustração.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	Apresentar um sistema para deteção de stress com base em sinais fisiológicos recolhidos por sensores não intrusivos.	Stress.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	Apresentar métodos para recolher e analisar dados fisiológicos durante a condução real, com o objetivo de determinar o nível de stress.	Stress.
<b>Herbon et al.</b> (Herbon, Peter, Markert, & Meer, 2005)	Encontrar variáveis fisiológicas capazes de mapear para emoções de forma não ambígua, para utilização em sistemas digitais.	<i>Valence e arousal.</i>
<b>Partala et al.</b> (Partala, Surakka, & Vanhala, 2005)	Desenvolver um sistema automático que, em tempo real, consiga estimar emoções a partir do EMG da face.	<i>Valence.</i>
<b>Van Eck et al.</b> (van Eck, Berkhof, Nicolson, & Sulon, 2005)	Analisar os efeitos de stress percebido com estados de humor e eventos diários stressantes, nos níveis de cortisol na saliva.	Stress e disposição (humor).
<b>Busso et al.</b> (Busso et al., 2004)	Combinar os dados da expressão facial e oral com o objetivo de melhorar a precisão no reconhecimento de emoções.	Tristeza, fúria, alegria e estado neutral.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	Desenvolver um sistema HCI sensível às emoções dos utilizadores, capaz de responder às emoções do utilizador em função do contexto e da aplicação.	Tristeza, raiva, surpresa, medo, frustração e diversão.
<b>K. H. Kim et al.</b> (K. H. Kim, Bang, & Kim, 2004)	Desenvolver um sistema de reconhecimento de emoções independente do utilizador.	Tristeza, fúria, stress e surpresa.
<b>Haag et al.</b> (Haag, Goronzy, Schaich, & Williams, 2004)	Apresentar um procedimento para treinar computadores a reconhecer emoções a partir de vários tipos de biossensores.	<i>Arousal e valence.</i>
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	Estudar a variação do tamanho da pupila com a aplicação de estímulos sonoros.	<i>Valence e arousal.</i>
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	Estudar o efeito da serotonina em distúrbios emocionais.	Alegria, tristeza, medo, fúria e desgosto.
<b>Nwe et al.</b> (Nwe et al., 2001)	Propor um sistema para classificar automaticamente emoções com base no discurso oral.	Fúria, antipatia, medo, alegria, tristeza e surpresa.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)	Estudar o impacto do cortisol na memória humana, utilizando imagens para estimular o <i>arousal</i> emocional.	<i>Arousal.</i>
<b>Jennifer a Healey</b>	Estudar o stress durante a condução.	Stress durante a condução;

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Jennifer a Healey, Picard, & Smith, 2000)		(experiência preliminar) Raiva, ódio, tristeza, amor, alegria, reverência, e estado neutral.
<b>Vrijkotte et al.</b> (Vrijkotte, van Doornen, & de Geus, 2000)	Estudar o stress no trabalho.	Stress.
<b>Ritz et al.</b> (Ritz, Steptoe, DeWilde, & Costa, 2000)	Estudar o impacto de diferentes estados emocionais e stress na resistência oscilatória (ROS) em asmáticos e não asmáticos.	Ansiedade, fúria, depressão, alegria, felicidade, contentamento e neutral; Stress.
<b>L. S. Chen et al.</b> (L. S. Chen, Huang, Miyasato, & Nakatsu, 1998)	Integrar áudio e vídeo para promover um melhor reconhecimento de emoções.	Alegria, tristeza, fúria, antipatia, surpresa e medo.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	Apresentar um método para reconhecimento de padrões em dados de contexto, representativos de estados afetivos do utilizador.	Fúria, ódio, aflição, amor familiar, amor romântico, alegria, reverência (respeito profundo); <i>Arousal e valence.</i>
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	Detetar emoções no ser humano, utilizando EMG nos músculos da face e o EOG para monitorizar a movimentação vertical e horizontal do olho.	Medo, alegria, tristeza e raiva.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	Estudar as diferenças entre as emoções classificadas fisiologicamente e as reportadas, diferenciar emoções negativas e estudar as reações musculares da face.	Desgosto, fúria, prazer e alegria.
<b>R Sinha et al.</b> (R Sinha, Lovallo, & Parsons, 1992)	Estudar os padrões da atividade cardiovascular durante diferentes estados emocionais.	Alegria, tristeza, medo e fúria.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

## 2. VARIÁVEIS DE CONTEXTO E PROPRIEDADES DE DOMÍNIO

As emoções não podem ser medidas diretamente. Por esse motivo, os investigadores recolhem dados de contexto das pessoas para as descobrir (Kreibig, 2010). Estes sinais de entrada podem ser de origem multimodal: expressão facial, oral ou corporal; sinais fisiológicos do corpo humano; (Jerritta, Murugappan, Nagarajan, & Wan, 2011) (Sim, Jang, & Park, 2007) (Chang et al., 2012); e sentimentos subjetivos (Scherer & Ekman, 1984).

Nesta secção são apresentadas as variáveis de contexto recolhidas pelos autores das investigações analisadas. Além dos dados *raw* obtidos diretamente dos instrumentos e sensores de recolha, são também considerados nesta secção as propriedades de domínio (i.e. as propriedades extraídas diretamente a partir do sinal de entrada, cujo método de obtenção é confundível com o utilizado na aquisição do próprio sinal original) (e.g. *Heart Rate* (HR) é uma medida determinada automaticamente pelo instrumento de recolha (e.g. eletrocardiograma (ECG), fotopletismografia (PPG), etc.)). Como muitas destas medidas são calculadas automaticamente pelos próprios instrumentos de recolha, e os outros investigadores também as consideram como variáveis de contexto, decidimos também incluir estas propriedades na secção de variáveis de contexto e não na secção das propriedades extraídas (i.e. secção 5).

Decidiu-se usar a notação *OriginalSignal(DomainProperty)* para representar o encadeamento de sinais e respetivas propriedades de domínio (e.g. ECG(HR) e PPG(HR)).

O quadro seguinte resume as várias variáveis de contexto (e propriedades de domínio), utilizados pelos autores das investigações analisadas.

DESCRIÇÃO	ID	ORIGEM	GRUPO (modalidade ou categoria)
<b>EXPRESSÃO FACIAL, EXPRESSÃO ORAL E POSTURA CORPORAL</b>			
Arms (braços)	ARMS	Dados recolhidos a partir de imagem ou vídeo.	Postura corporal
Combined action units	CAU	Aglomerção de vários AU do sistema FACS.	Expressão facial
Cheeks (bochechas)	CHEEKS	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Chin (queixo)	CHIN	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Elbows (cotovelos)	ELBOWS	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
Eyebrows (sobrancelhas)	EYEBROWS	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Eyelids (pálpebras)	EYELIDS	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Eyes (olhos)	EYES	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Facial action coding system	FACS	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Fingers (dedos)	FINGERS	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
Fists (punhos)	FISTS	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
Forehead (testa)	FOREHEAD	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Frown (carranca)	FROWN	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Hands... (mãos)	HANDS	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
Head (cabeça)	HEAD	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial e gestual
Hip (quadril, anca)	HIP	Dados recolhidos a partir de imagem ou vídeo.	Postura corporal
Jaw (mandíbula)	JAW	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Knees (joelhos)	KNEES	Dados recolhidos a partir de imagem ou vídeo.	Postura corporal
Lips (lábios)	LIPS	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Mouth (boca)	MOUTH	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Neck (pescoço)	NECK	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
Nose (nariz)	NOSE	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
Palm (palmas da mão)	PALMS	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Pitch</b> (percepção da qualidade de som)	<b>PITCH</b>	Dados recolhidos a partir de áudio ou vídeo.	Expressão oral
<b>Shoulders</b> (ombros)	<b>SHOULDERS</b>	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
<b>Skin</b> (pele)	<b>SKIN</b>	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
<b>Speech</b> (discurso)	<b>SPEECH</b>	Dados recolhidos a partir de áudio ou vídeo.	Expressão oral
<b>Spine</b> (coluna vertebral)	<b>SPIN</b>	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
<b>Tone</b> (modo de falar)	<b>TONE</b>	Dados recolhidos a partir de áudio ou vídeo.	Expressão oral
<b>Volume</b> (energia, intensidade ou volume)	<b>VOLUME</b>	Dados recolhidos a partir de áudio ou vídeo.	Expressão oral
<b>Wrinkles</b> (rugas)	<b>WRINKLES</b>	Dados recolhidos a partir de imagem ou vídeo.	Expressão facial
<b>Wrists</b> (pulsos)	<b>WRISTS</b>	Dados recolhidos a partir de imagem ou vídeo.	Expressão gestual
<b>VARIÁVEIS DE CONTEXTO FISIOLÓGICO</b>			
<b>Blood pressure</b> (pressão sanguínea)	<b>BP</b>	Esfigmomanómetros, estetoscópios, fonocardiogramas e palpação eletrónica (Sorvoja & Myllylä, 2006)). Pode ser obtido a partir do PTT (Špulák, Čmejla, & Fabián, n.d.) (R. Wang, Wenyan Jia, Zhi-Hong Mao, Sciabassi, & Mingui Sun, 2014), do SBP e DBP, e do PPG (Chanel, 2009) (Kusserow et al., 2013), e da correlação de dados entre o EEG e o PPG (Špulák et al., n.d.).	Atividade cardíaca
<b>Blood volume pulse</b> (pulso volume de sangue)	<b>BVP</b>	PPG (Chanel, 2009) (Jennifer a Healey et al., 2000) (Peper, Harvey, Lin, Tylova, & Moss, 2007) (e.g. (Plux, 2017)).	Atividade cardíaca
<b>Cardiac output</b> (débito cardíaco)	<b>CO</b>	Pode ser estimado a partir do BP (Biopac Systems, 2017) ou dos dados do ICG (R Sinha et al., 1992). Geerts et al. apresenta vários métodos para medir o CO (Geerts, Aarts, & Jansen, 2011).	Atividade cardíaca
<b>Cortisol</b> (cortisol)	<b>CORT</b>	Os níveis podem ser medidos no sangue, urina ou saliva (Frazão, 2016a). Também pode ser medido através do cabelo (Gow, Thomson, Rieder, Van Uum, & Koren, 2010).	Atividade glandular
<b>Diastolic blood pressure</b> (pressão arterial sistólica)	<b>DBP</b>	Medido com base no BP (Sorvoja & Myllylä, 2006). Pode ser estimado a partir do PTT (R. Wang et al., 2014), ou do ECG e PPG (Špulák et al., n.d.).	Atividade cardíaca
<b>Electrocardiogram</b> (eletrocardiograma)	<b>ECG</b>	Sensor.	Atividade cardíaca
<b>Electrodermal activity</b> (atividade eletrodermal)	<b>EDA</b>	Recolha feita através de sensores colocados na pele, por exemplo, na palma da mão (Z. Zhang et al., 2016) ou nos dedos (J. Kim & André, 2008).	Pele
<b>Electroencephalogram</b> (eletroencefalograma)	<b>EEG</b>	Sensor.	Atividade cerebral
<b>Electromyogram</b> (eletromiograma)	<b>EMG</b>	Medição feita através de sensores que recolhem as voltagens elétricas da contração muscular (Jennifer a Healey et al., 2000) (J. Kim & André, 2008) (Lichtenstein, Antje; Oehme, 2008)	Atividade muscular
<b>Electrooculogram</b> (eletrooculograma)	<b>EOG</b>	Recolha feita através de elétrodos colocados na zona dos olhos, para detetar movimento com base na diferença de voltagem entre a córnea e a retina (J. Zhang, Guo, Hong, & Zhang, 2013).	Atividade ocular
<b>Heart rate</b> (frequência cardíaca)	<b>HR</b>	Pode ser extraído do ECG (Jennifer a Healey et al., 2000) (Kusserow et al., 2013) (Jennings et al., 1981) (Mandryk & Atkins, 2007), ICG ou do PPG (Kusserow et al., 2013). Pode ser deduzido do IBI (Chanel, 2009), do BP ou do BVP (Jennings et al., 1981) (Peper et al., 2007).	Atividade cardíaca
<b>Heart rate variability</b> (variabilidade da frequência cardíaca)	<b>HRV</b>	Pode ser retirado do ECG (Kusserow et al., 2013) (Jennifer a Healey et al., 2000) (Mandryk & Atkins, 2007) (Stephens, Christie, & Friedman, 2010).	Atividade cardíaca

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		Também pode ser deduzido do HR ou do IBI (Chanel, 2009).	
<b>Inter-beat interval</b> (intervalo entre batimentos)	<b>IBI</b>	Calculado com base no ECG (Stephens et al., 2010) (Chanel, 2009) (Mandryk & Atkins, 2007) (Kreibig, 2010).	Atividade cardíaca
<b>Impedance cardiogram</b> (cardiograma de impedância)	<b>ICG</b>	Sensor.	Atividade cardíaca
<b>Left ventricular ejection time</b> (tempo de ejeção do ventrículo esquerdo)	<b>LVET</b>	Calculado a partir do ICG (Stephens et al., 2010).	Atividade cardíaca
<b>Mean arterial pressure</b> (pressão arterial média)	<b>MAP</b>	Média de vários BP recolhidos num período de tempo (Chanel, 2009) (Solà i Carós, 2011).	Atividade cardíaca
<b>Melatonin</b> (melatonina)	<b>MELAT</b>	Os níveis podem ser medidos no sangue ou saliva (Frazão, 2016b).	Atividade glandular
<b>Non-invasive blood pressure</b> (pressão sanguínea com recolha não invasiva)	<b>NIBP</b>	Calculado a partir do PTT, ou diretamente do ICG ou do ECG (Murali et al., 2015).	Atividade cardíaca
<b>Nonspecific skin conductance response</b> (resposta de condutância da pele não específica)	<b>nSRR</b>	Sensor (ver EDA).	Pele
<b>Phonocardiogram</b> (fonocardiograma)	<b>PCG</b>	Sensor (sons do coração).	Atividade cardíaca
<b>Pre-ejection period</b> (período pré-ejeção)	<b>PEP</b>	Pode ser extraído a partir da conjugação do ECG e do ICG (Murali et al., 2015) (Backs, Navidzadeh, & Xu, 2000).	Atividade cardíaca
<b>Phtoplethysmography</b> (fotopletismografia)	<b>PPG</b>	Sensor.	Atividade cardíaca
<b>Pulse rate</b> (frequência de pulso)	<b>PR</b>	Sensor (e.g. (Harsono, 2012);	Atividade cardíaca
<b>Pulse Transit Time</b> (tempo da onda de pulso)	<b>PTT</b>	Pode ser calculado com base no <i>delay</i> entre o ECG e o ICG (Murali et al., 2015) (R. Wang et al., 2014), ou a partir do ECG e PPG medido no dedo (Hey et al., 2009).	Atividade cardíaca
<b>Pupil</b> (pupila)	<b>PUPIL</b>	O sensor que recolhe o movimento e dilatação da pupila (e.g. câmara infrared em conjunto com uma fonte de luz infrared (SR Research, 2017)) (Aracena et al., 2016) (Raudonis, 2013).	Atividade ocular
<b>Peripheral vascular resistance</b> (resistência vascular periférica)	<b>PVR</b>	Calculado, por exemplo, com base nos dados do ICG (R Sinha et al., 1992), mas existem vários métodos para a sua determinação (Müller & Martin, 1992).	Atividade cardíaca
<b>Breath depth</b> (profundidade de respiração)	<b>RDEP</b>	Determinado com base na quantidade de alongamento elástico da cinta que mede a expansão da cavidade do peito (J. Kim & André, 2008).	Atividade respiratória
<b>Respiration</b> (respiração)	<b>RESP</b>	Atividade respiratória medida através de sensores que quantificam o gás expelido dos pulmões, ou sensores de expansão da cavidade do peito (cinta) (Jennifer a Healey et al., 2000) (Z. Zhang et al., 2016).	Atividade respiratória
<b>Root-mean-square of successive differences</b> (raiz quadrada média das diferenças sucessivas)	<b>RMSSD</b>	Permite, por exemplo, determinar o HRV (Biopac Systems Inc, 2017b) (DeGiorgio et al., 2010) (Kreibig, 2010).	Atividade cardíaca
<b>Oscillatory resistance</b> (resistência oscilatória)	<b>ROS</b>	Sensor que mede a resistência ocorrida na respiração considerando também a resistência dos tecidos. Pode também ser calculada a partir de uma pletismografia às bochechas (variação do volume) (Ritz et al., 2000).	Atividade respiratória

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Respiration rate</b> (frequência de respiração)	<b>RR</b>	Sensor (ver RESP); Pode também ser deduzido do ICG removendo as oscilações de frequência alta do HR, as frequências baixas correspondem à frequência de respiração (Murali et al., 2015).	Atividade respiratória
<b>Systolic blood pressure</b> (pressão arterial sistólica)	<b>SBP</b>	Pode ser recolhido pelos métodos do BP (Sorvoja & Myllylä, 2006), estimado a partir do PTT (R. Wang et al., 2014), ou do ECG e PPG (Špulák et al., n.d.).	Atividade cardíaca
<b>Standard Deviation of NN Intervals</b> (desvio padrão dos intervalos NN)	<b>SDNN</b>	Pode ser calculado a partir do IBI é uma medida utilizada nos sistemas de reconhecimento emocional (e.g. Zhao et al. (Zhao et al., 2016)).	Atividade cardíaca
<b>Serotonin</b> (serotonina)	<b>SEROT</b>	Os níveis podem ser medidos no sangue ou urina (Visser et al., 2011) (Fonte, 2015) (Nichkova et al., 2012).	Atividade glandular
<b>Skin temperature</b> (temperatura da pele)	<b>ST</b>	Sensor (e.g. termómetro, câmara térmica (Z. Zhang et al., 2016)).	Pele
<b>Stroke volume</b> (volume sistólico)	<b>SV</b>	Pode ser extraído a partir do ICG (Willemsen, De Geus, Klaver, Van Doornen, & Carroll, 1996) (Kusserow et al., 2013) apesar de existirem ainda algumas reservas a este método (Stephens et al., 2010).	Atividade cardíaca
<b>Vagal tone</b> (tónus vagal)	<b>VAGAL</b>	Refere a atividade do vagus nerve, um importante componente do sistema parasimpático do sistema nervoso autónomo (Porges, 1995).	Atividade cardíaca
<b>Tidal volume</b> (volume de corrente)	<b>VT</b>	Calculado com base na quantidade de gás dispensado numa inspiração e expiração normal (sem esforço) (Murad & Malkawi, 2012).	Atividade respiratória
<b>VARIÁVEIS DE CONTEXTO PSICOSSOCIAL</b>			
<b>Academic Curricular Activity</b> (atividade curricular académica)	<b>ACADCL</b>	Questionário.	Reconhecimento (outros domínios)
<b>Academic degree</b> (grau académico)	<b>ACADDG</b>	Questionário.	Reconhecimento (outros domínios)
<b>Academic Extracurricular Activity</b> (atividade académica extracurricular)	<b>ACADEX</b>	Questionário.	Integração (outros domínios)
<b>Academic grades</b> (desempenho académico)	<b>ACADGR</b>	Questionário.	Reconhecimento (outros domínios)
<b>Academic Study Time</b> (tempo de estudo académico)	<b>ACADST</b>	Questionário.	Reconhecimento (outros domínios)
<b>Age</b> (idade)	<b>AGE</b>	Questionário.	Demográfica (domínio pessoal)
<b>Alcohol intake</b> (ingestão de álcool)	<b>ALCOH</b>	Questionário.	Integração (outros domínios)
<b>Alert felt, level of...</b> (nível de alerta)	<b>ALERT</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Anger felt, level of...</b> (nível de fúria sentido)	<b>ANGER</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Anxiety felt, level of...</b> (nível de ansiedade sentido)	<b>ANXIETY</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Apps usage</b> (utilização de aplicações)	<b>APPS</b>	Histórico de utilização do computador, <i>smartphone</i> , <i>smartwatch</i> ou <i>tablet</i> .	Rotina diária (domínio pessoal)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Body Mass Indice</b> (índice de massa corporal)	<b>BMI</b>	Questionário ou cálculo.	Reconhecimento (outros domínios)
<b>Browser usage</b> (utilização de <i>browsers</i> )	<b>BROWSER</b>	Histórico de utilização do computador, <i>smartphone</i> , <i>smartwatch</i> ou <i>tablet</i> .	Rotina diária (domínio pessoal)
<b>Caffeine intake</b> (ingestão de cafeína)	<b>CAFFEI</b>	Questionário.	Integração (outros domínios)
<b>Phonecalls</b> (chamadas telefónicas)	<b>CALL</b>	Histórico de chamadas do <i>smartphone</i> (e.g. MoodScope (LiKamWa et al., 2013), funf (Aharony & Gardner, 2011), etc.).	Interação (outros domínios)
<b>Calm felt, level of...</b> (nível de calma sentido)	<b>CALM</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Depression felt, level of...</b> (nível de depressão sentido)	<b>DEPRESSION</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Difficulties, life...</b> (dificuldades da vida)	<b>DIFFICULTIES</b>	Questionário ou entrevista.	Psicossocial (domínio pessoal)
<b>Drugs intake</b> (ingestão de álcool)	<b>DRUGS</b>	Questionário.	Integração (outros domínios)
<b>Electronic devices usage</b> (utilização de dispositivos eletrónicos)	<b>ELECTR</b>	Questionário ou sensores de consumo elétrico.	Rotina diária (domínio pessoal)
<b>Email</b> (correio eletrónico)	<b>EMAIL</b>	Histórico de e-mail do computador ou <i>smartphone</i> (e.g. MoodScope (LiKamWa et al., 2013), funf (Aharony & Gardner, 2011), etc.).	Interação (outros domínios)
<b>Emotions felt</b> (emoções sentidas)	<b>EMOTIONS</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Energy felt, level of...</b> (nível de energia sentido)	<b>ENERGY</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Ethnicity</b> (etnia)	<b>ETHNICITY</b>	Questionário.	Demográfica (domínio pessoal)
<b>Food, information about...</b> (informação acerca da alimentação)	<b>FOOD</b>	Questionário.	Integração (outros domínios)
<b>Gender</b> (género)	<b>GENDER</b>	Questionário.	Demográfica (domínio pessoal)
<b>Happiness felt, level of...</b> (nível de felicidade sentido)	<b>HAPPY</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Health status felt</b> (estado de saúde sentido)	<b>HEALTH</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Height</b> (altura)	<b>HEIGHT</b>	Questionário.	Reconhecimento (outros domínios)
<b>Job</b> (profissão)	<b>JOB</b>	Questionário.	Reconhecimento (outros domínios)
<b>Life events, recent landmark...</b> (eventos recentes marcantes)	<b>LIFEEVENTS</b>	Questionário ou entrevista.	Psicossocial (domínio pessoal)
<b>Living situation</b> (situação em que vive)	<b>LIVING</b>	Questionário.	Demográfica (domínio pessoal)
<b>Localization, geo...</b> (geolocalização)	<b>LOCAL</b>	<i>Global Position System</i> (GPS) ou <i>Wireless Fidelity</i> (WiFi) recolhidos a partir do <i>smartphone</i> ou outro equipamento com GPS ou WiFi.	Rotina diária (domínio pessoal)
<b>Mail, tradicional...</b> (correio tradicional)	<b>MAIL</b>	Questionário.	Interação

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			(outros domínios)
<b>Mood status felt</b> (estado de humor ou disposição sentido)	<b>MOOD</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Nap data</b> (dados acerca das sesta)	<b>NAP</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Personality data</b> (dados acerca da personalidade)	<b>PERSON</b>	Questionário (e.g. <i>Big Five Inventory Personality Traits</i> (McCrae & John, 1992))	Psicossocial (domínio pessoal)
<b>Physical activity</b> (atividade física)	<b>PHYSI</b>	Questionário.	Reconhecimento (outros domínios)
<b>Proximity interaction</b> (interação de proximidade)	<b>PROXIMITY</b>	Histórico de reconhecimento de novos equipamentos (e.g. <i>bluetooth discovering</i> ).	Interação (outros domínios)
<b>Race</b> (raça)	<b>RACE</b>	Questionário.	Demográfica (domínio pessoal)
<b>Study area in the school</b> (área de estudo na escola)	<b>SCHOOLA</b>	Questionário.	Demográfica (domínio pessoal)
<b>School year (actual)</b> (ano escolar)	<b>SCHOOLY</b>	Questionário.	Demográfica (domínio pessoal)
<b>Screen on and off, toggle...</b> (ativar e desativar a ecrã)	<b>SCREEN</b>	Histórico de utilização do <i>smartphone</i> , <i>smartwatch</i> ou <i>tablet</i> .	Rotina diária (domínio pessoal)
<b>Sleep data</b> (dados acerca do sono)	<b>SLEEP</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Smoking, information about...</b> (informação acerca do fumar)	<b>SMOKING</b>	Questionário.	Integração (outros domínios)
<b>SMS messages</b> (mensagens SMS)	<b>SMS</b>	Histórico de SMS do <i>smartphone</i> (e.g. MoodScope (LiKamWa et al., 2013); funf (Aharony & Gardner, 2011); etc.)	Interação (outros domínios)
<b>Social interactions, quality of...</b> (qualidade das interações sociais)	<b>SOCIAL</b>	Questionário.	Interação (outros domínios)
<b>Stress felt, level of...</b> (nível de stress)	<b>STRESS</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Talk, time of...</b> (tempo de conversação)	<b>TALK</b>	Histórico de utilização do microfone (e.g. do <i>smartphone</i> )	Interação (outros domínios)
<b>Technological experience</b> (experiência tecnológica)	<b>TECHEXP</b>	Questionário ou entrevista.	Rotina diária (domínio pessoal)
<b>Tired felt, level of...</b> (nível de cansaço)	<b>TIRED</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Waist size</b> (tamanho de cintura)	<b>WAIST</b>	Questionário.	Reconhecimento (outros domínios)
<b>Weight</b> (peso)	<b>WEIGHT</b>	Questionário.	Reconhecimento (outros domínios)
<b>Wellbeing felt, level of...</b> (nível de bem-estar sentido)	<b>WELLBEING</b>	Questionário.	Psicossocial (domínio pessoal)
<b>Work, years of...</b> (tempo de vida ativa)	<b>WORKYEARS</b>	Questionário.	Reconhecimento (outros domínios)
<b>OUTRAS VARIÁVEIS</b>			

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Temperature</b> (temperatura)	<b>TEMP</b>	Termómetro.	Outras variáveis
<b>Light, ambient...</b> (luz ambiente)	<b>LIGHT</b>	Sensores de luminosidade.	Outras variáveis
<b>Acclerometer</b> (acelerómetro)	<b>ACC</b>	(e.g. Toshiba Silmee™ W20/W21 (Toshiba, 2015))	Outras variáveis
<b>Weather conditions</b> (variações do tempo)	<b>WEATHER</b>	Determinado com base nos dados de sensores: de temperatura; ambiente; humidade; visibilidade; vento; quantidade de horas de sol e de chuva; etc.	Outras variáveis

## 2.1. EXPRESSÃO FACIAL, EXPRESSÃO ORAL E POSTURA CORPORAL

A voz é a forma de comunicação principal do ser humano (Nwe et al., 2001) e o seu conteúdo é decorado com a expressão corporal e entoação, com o objetivo de enriquecer a mensagem transmitida com adornos emocionais (Ekman, Paul; Freiesen, 2003) (Lisetti & Nasoz, 2004) (Birdwhistell, 1970).

A comunicação entre pessoas é constituída pelas vertentes verbal e não-verbal, e é essencialmente através da não-verbal que o ser humano comunica emoções (Singh et al., 2015) (Nawasalkar et al., 2013). A capacidade de as expressar pode ser considerada como essencial nos processos de comunicação e entendimento entre as pessoas (Lopes, Salovey, & Straus, 2003) (Raudonis, 2013).

São vários os investigadores que escolhem as propriedades da comunicação verbal e não-verbal como sinais de entrada nos seus sistemas de reconhecimento emocional. O motivo será a facilidade da recolha de dados nestas modalidades quando comparada com outras cujo processo de recolha será mais intrusivo (e.g. sinais fisiológicos).

### 2.1.1. Expressão facial

A expressão facial varia em função de algumas emoções e é uma das formas mais usadas pelos humanos para manifestar o que sentem (Recognition, 2009) (Chandler & Cornes, 2012). Esta forma de expressão e o movimento da cabeça são importantes fontes de informação para a comunicação do estado mental das pessoas (Adams & Robinson, 2015). Apesar da deteção de emoções com base neste tipo de expressão ter já uma longa histórica (Haag et al., 2004), continuam a surgir novos estudos na tentativa de melhorar a precisão de reconhecimento tendo por base a expressão facial (Eckert et al., 2016) (Matlovic et al., 2016).

Existem dois tipos de abordagens no reconhecimento emocional através da expressão facial. As baseadas na aparência em que os autores utilizam as descritores específicos e que serão abordados na secção 5 – Propriedades extraídas, e as baseadas na geométrica dos componentes da face que serão apresentadas de seguida.

As abordagens baseadas nas propriedades geométricas usam informação acerca da dinâmica dos elementos da face que alteram consoante o estado emocional e movimento das pessoas (Turan et al., 2015). Dos vários componentes da face (**FACE**) considerados pelos investigadores, serão mais utilizados: cabeça (**HEAD**); testa (**FOREHEAD**); olhos (**EYES**); sobrancelhas (**EYEBROWS**); pálpebras (**EYELIDS**); bochechas (**CHEEKS**); nariz (**NOSE**); boca (**MOUTH**); lábios (**LIPS**); queixo (**CHIN**); mandíbula (**JAW**); e pele (**SKIN**). Alguns autores analisam também a existência de rugas (e.g. formadas pela zona da boca, nariz e testa): ruga (**WRINKLES**); e olhar carregado (carranca) (**FROWN**).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

O sistema *Facial Action Coding System (FACS)* é um *standard* que define os contornos para o reconhecimento de emoções através da expressão facial (Fasel & Luetttin, 2003). A divisão da face em zonas torna possível a deteção de movimento interno localizado a partir da monitorização muscular (Ekman, Paul; Friesen, 1978). Os investigadores Eckert et al. (Eckert et al., 2016) apresentaram o conceito de *Combined Action Units (CAU)* que agrupam *Action Units (AU)* do sistema FACS. Por exemplo, o movimento muscular no grupo AU7, AU23 e AU24 significará fúria, e atividade no grupo AU9 e AU10 poderá significar desgosto (Eckert et al., 2016).

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	EXPRESSÃO FACIAL	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017)	HEAD.	<b>(A. MUSCULAR)</b> EMG. <b>(A. OCULAR)</b> EOG.
<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH).	
<b>Eckert et al.</b> (Eckert et al., 2016)	FACS, CAU, EYES, EYEBROWS, NOSE e MOUTH.	
<b>Matlovic et al.</b> (Matlovic et al., 2016)	<i>Autores usaram o FaceReader (Noldus, 2017) e Shore (Fraunhofer IIS, 2017) para reconhecer emoções a partir de expressões faciais. EYES (sinal não processado).</i>	<b>(A. CEREBRAL)</b> EEG. <b>(PELE)</b> EDA. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Gogia et al.</b> (Gogia et al., 2016)	HEAD.	<b>(A. CEREBRAL)</b> EEG.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	HEAD e FACS.	<b>(A. CARDÍACA)</b> BP(SBP, DBP), HR e PR. <b>(A. RESPIRATÓRIA)</b> RESP(RR). <b>(PELE)</b> EDA e ST. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	FACS (HEAD, EYES, EYEBROWS, EYELIDS, CHEEKS, WRINKLES, NOSE, LIPS, CHIN, JAW).	<b>(A. OCULAR)</b> GAZE.
<b>Turan et al.</b> (Turan et al., 2015)	FACE e EYES.	
<b>Agrawal et al.</b> (Agrawal et al., 2013)	EYES, MOUTH, LIPS e SKIN.	
<b>Soleymani et al.</b> (Soleymani et al., 2013)	HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH.	<b>(A. CEREBRAL)</b> EEG. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Vermun et al.</b> (Vermun et al., 2013)	HEAD, LIPS, MOUTH e EYEBROWS. <i>Os autores tratam estas variáveis como expressão gestual.</i>	<b>Expressão gestual e postura:</b> SHOC, HIP, KNEEL e KNER.
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	HEAD e FACE.	
<b>Dhall et al.</b> (Dhall et al., 2011)	FACE.	
<b>H. Wang et al.</b> (H. Wang et al., 2010)	EYES.	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD e JAW.	<b>Expressão gestual e postura:</b> SHOULDERS, HANDS, FINGERS, FISTS, PALMS e NECK.
<b>Sebe et al.</b> (Sebe et al., 2006)	HEAD, EYEBROWS, EYELIDS e MOUTH.	<b>Expressão oral:</b> VOLUME, SPEECH e PITCH.
<b>Busso et al.</b> (Busso et al., 2004)	FOREHEAD, EYEBROWS, EYES e CHEEKS.	<b>Expressão oral:</b> PITCH e VOLUME.
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	EYES, EYEBROWS, MOUTH, WRINKLES e FROWN.	<b>Expressão oral:</b> SPEECH e PITCH.

( ) representa um sinal raw

### 2.1.2. Expressão oral

Nos últimos anos tem sido várias as investigações que tem conjugado a expressão facial com o sinal da expressão oral, com o objetivo de melhorar a precisão no reconhecimento emocional (Jerritta et al., 2011).

O principal desafio colocado aos sistemas de reconhecimento de emoções a partir da **expressão oral** será a escolha dos dados a recolher do contexto. As propriedades devem ser independentes do orador e espelhar a parte emocional do conteúdo oral (Shegokar & Sircar, 2016).

Da entoação (**SPEECH**) é possível extrair várias propriedades relacionadas com a comunicação não-verbal (Rani & Sarkar, 2006). As emoções sentidas no momento da fala tendem a influenciar o tom, velocidade, qualidade e articulação de palavras (Cahn, 1990), tornando este conjunto de características acústicas um bom candidato a sinal de entrada de um sistema para reconhecimento afetivo (Rani & Sarkar, 2006) (Haritaoglu et al., 2001). Fazem parte deste conjunto as propriedades: o *pitch* (perceção da qualidade de som) (**PITCH**); a energia, intensidade ou volume (**VOLUME**); e o tom (**TONE**).

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	EXPRESSÃO ORAL	OUTRAS
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	SPEECH e VOLUME.	
<b>Lalitha et al.</b> (Lalitha et al., 2015)	SPEECH, PITCH e VOLUME.	
<b>Sebe et al.</b> (Sebe et al., 2006)	VOLUME, SPEECH e PITCH.	<b>Expressão facial:</b> HEAD, EYEBROWS, EYELIDS e MOUTH.
<b>Busso et al.</b> (Busso et al., 2004)	PITCH e VOLUME.	<b>Expressão facial:</b> FOREHEAD, EYEBROWS, EYES e CHEEKS.
<b>Nwe et al.</b> (Nwe et al., 2001)	SPEECH.	
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	SPEECH e PITCH.	<b>Expressão facial:</b> EYES, EYEBROWS, MOUTH, WRINKLES e FROWN.

( ) representa um sinal raw

### 2.1.3. Expressão gestual e postura

A **expressão gestual** é importante na comunicação e interação das pessoas, mas está muito dependente do contexto cultural e social (Rehm, Bee, & André, 2008), levantando problemas à generalização dos sistemas que se baseiam no reconhecimento emocional a partir dos gestos.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Ainda assim, é um importante indicador do estado mental das pessoas e, conseqüentemente, uma fonte de dados importante para um sistema de inferência emocional (Saha et al., 2014).

Os gestos são movimentos corporais expressivos e envolvem na grande maioria das vezes, apenas a cara e as mãos (Saha et al., 2014). Usando apenas informação dos membros superiores por acreditarem ser suficientes para o reconhecimento emocional, os investigadores Saha et al. utilizaram o Kinect (Leyvand, Meekhof, Wei, Sun, & Guo, 2011) para recolher os seguintes dados de contexto: cabeça (**HEAD**), coluna vertebral (**SPIN**), mãos (**HANDS**), pulsos (**WRISTS**), cotovelos (**ELBOWS**) e ombros (**SHOULDERS**). O estudo pretendia identificar gestos e mapeá-los com estados emocionais. O *input* do sistema baseava-se nas medidas geométricas determinadas com base nas coordenadas das articulações (cf. distâncias, aceleração e ângulos) (Saha et al., 2014).

Gunes e Piccardi também criou um sistema para reconhecimento emocional com base nos membros superiores do corpo, mas focou-se essencialmente nos sinais produzidos pela movimentação dos dedos (**FINGERS**), punho ou mão fechada (**FISTS**), palmas da mão (**PALMS**) e movimentação das mãos junto ao pescoço (**NECK**) (Gunes & Piccardi, 2007).

A **postura corporal** é também utilizada por alguns investigadores para avaliação emocional. Vermen et al. conjugou dados recolhidos da expressão gestual com a postura corporal para identificar estados afetivos e cognitivos de relevo em sala de aula (Vermun et al., 2013). Além de outros dados, os investigadores consideraram informação acerca da movimentação do quadril (**HIP**) e joelhos (**KNEES**).

A literatura indica que diferentes emoções estão associadas a diferentes tipos de movimento corporal. Neste contexto, os investigadores Catellano et al. recolheram dados relacionados com a movimentação dos braços (**ARMS**), para analisar as emoções a partir do gesto de os levantar no plano coronal (Castellano et al., 2007).

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	EXP. GESTUAL E POSTURA	OUTRAS
Singh et al. (Singh et al., 2015)	SHOULDERS e HANDS.	
Saha et al. (Saha et al., 2014)	HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS e SPIN.	(OUTRAS) ACC.
Vermun et al. (Vermun et al., 2013)	ARMS, SHOULDERS, HIP e KNEES.	<u>Expressão facial*</u> : HEAD, LIPS, MOUTH e EYEBROWS.  <i>*os autores tratam estas variáveis como expressão gestual.</i>
Gunes & Piccardi (Gunes & Piccardi, 2007)	SHOULDERS, HANDS, FINGERS, FISTS, PALMS e NECK.	<u>Expressão facial:</u> LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD e JAW.
Castellano et al. (Castellano et al., 2007)	ARMS.	

( ) representa um sinal raw

#### 2.1.4. Análise

São vários os desafios que enfrentam as investigações que se baseiam na expressão corporal como *input* dos sistemas de reconhecimento emocional.

Os humanos conseguem controlar as expressões faciais e a entoação (Y. Liu et al., 2010). As pessoas tendem a ocultar os sentimentos como forma de evitar a exposição ao grupo. Como

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

podem suprimir ou adulterar o conteúdo emocional das suas expressões ou da sua voz (K. H. Kim et al., 2004), esta fonte de dados de contexto poderá originar um reconhecimento errado de emoções pelos sistemas (Jerritta et al., 2011) (Chang et al., 2012).

Além disso, os sistemas que reconhecem emoções com base em expressões faciais, corporais ou na entoação de voz, não são sensíveis à idade, género e cultura das pessoas (Rani & Sarkar, 2006). Esta não independência dos utilizadores pode invalidar a generalização, podendo conduzir também ao reconhecimento errado de emoções.

Ainda relativamente às expressões faciais, apesar de darem pistas importantes acerca das emoções (Busso et al., 2004), o reconhecimento com base nestes sinais de entrada pode ficar comprometido na presença de barba ou bigode, quando são utilizados acessórios na face (e.g. óculos) ou quando existam alterações na intensidade luminosa, problemas na qualidade de imagem, posição ou movimento humano (Cruz et al., 2015) (H. Wang et al., 2010) (Chang et al., 2012) (Lai, Ramanathan, & Wechsler, 2008). No caso da expressão oral, os sistemas de reconhecimento podem ver o seu desempenho afetado por causa do ruído da zona envolvente ou da distância entre pessoas e dispositivos de captura de som (Sim et al., 2007). Por fim, a postura corporal é fácil de imitar e varia de pessoa para pessoa (Basu et al., 2016).

Com o objetivo de melhorar o desempenho e estabilização dos sistemas de reconhecimento emocional, alguns investigadores combinam diferentes tipos de dados de entrada (Park, Ryu, Sohn, & Cho, 2007). Por exemplo, Sebe et al. (Sebe et al., 2006) e Busso et al. (Busso et al., 2004) usam em conjunto dados relacionados com a expressão facial e oral, e Gunes e Piccardi (Gunes & Piccardi, 2007) combina os dados da expressão facial com a gestual.

Os resultados mais promissores considerando as modalidades em análise (cf. expressão facial, oral, gestual e postura corporal), foram conseguidos tendo por base os dados recolhidos a partir da expressão facial (Gunes & Piccardi, 2007). A modalidade mais investigada é a relacionada com a expressão facial. Em contraponto, a expressão gestual e postura corporal é a modalidade menos explorada (Castellano et al., 2007).

Analisando as mesmas investigações agora de forma agregada (ver tabela seguinte), são poucos os trabalhos que se focam no reconhecimento emocional com base na recolha de dados a partir de várias modalidades em simultâneo (Gunes & Piccardi, 2007) (Z. Zhang et al., 2016). A maior parte das abordagens multimodais presentes na literatura combinam os sinais obtidos a partir da expressão facial com a oral (Pantic, Sebe, Cohn, & Huang, 2005), são poucas as que combinam sinais com os produzidos pelo movimento do corpo (Castellano et al., 2007) (Gunes & Piccardi, 2007), e menos ainda as que combinam algum tipo de expressão corporal, com sinais de outros contextos como fisiológico ou social, como acontece no projeto *MeToo*.

Iniciado recentemente por Caballe, o projeto *MeToo* tem como objetivo melhorar as plataformas de *eLearning* para que consigam detetar, representar e adaptar-se às emoções dos alunos. O autor pretendeu combinar vários tipos de sinais de entrada: questionários psicológicos, expressões faciais e orais, expressão gestual e postura corporal, informação acerca da atividade cardíaca, pele, utilização de teclado e rato, etc. (Caballe, 2015).

INVESTIGAÇÃO	EXPRESSÃO FACIAL	EXPRESSÃO ORAL	EXPRESSÃO GESTUAL E POSTURA	OUTRAS
Perdiz et al. (Perdiz et al., 2017)	HEAD.			(A. MUSCULAR) EMG. (A. OCULAR) EOG.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH).			
<b>Eckert et al.</b> (Eckert et al., 2016)	FACS, CAU, EYES, EYEBROWS, NOSE e MOUTH.			
<b>Matlovic et al.</b> (Matlovic et al., 2016)	<i>FaceReader</i> (Noldus, 2017) e <i>Shore</i> (Fraunhofer IIS, 2017)			(A. CEREBRAL) EEG. (PELE) EDA. (PSICOSSOCIAL) EMOTIONS.
<b>Gogia et al.</b> (Gogia et al., 2016)	HEAD.			(A. CEREBRAL) EEG.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	HEAD e FACS.			(A. CARDÍACA) BP(SBP, DBP), HR e PR. (A. RESPIRATÓRIA) RESP(RR). (PELE) EDA e ST. (PSICOSSOCIAL) EMOTIONS.
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	FACS (HEAD, EYES, EYEBROWS, EYELIDS, CHEEKS, WRINKLES, NOSE, LIPS, CHIN, JAW).			(A. OCULAR) GAZE.
<b>Turan et al.</b> (Turan et al., 2015)	FACE e EYES.			
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)		SPEECH e VOLUME.		
<b>Lalitha et al.</b> (Lalitha et al., 2015)		SPEECH, PITCH e VOLUME.		
<b>Singh et al.</b> (Singh et al., 2015)			SHOULDERS e HANDS.	
<b>Saha et al.</b> (Saha et al., 2014)			HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS e SPIN.	(OUTRAS) ACC.
<b>Agrawal et al.</b> (Agrawal et al., 2013)	EYES, MOUTH, LIPS e SKIN.			
<b>Soleymani et al.</b> (Soleymani et al., 2013)	HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH.			(A. CEREBRAL) EEG. (PSICOSSOCIAL) EMOTIONS.
<b>Vermun et al.</b> (Vermun et al., 2013)	HEAD, LIPS, MOUTH e EYEBROWS.		ARMS, SHOULDERS, HIP e KNEES.	
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	HEAD e FACE.			
<b>Dhall et al.</b> (Dhall et al., 2011)	FACE.			
<b>H. Wang et al.</b> (H. Wang et al., 2010)	EYES.			
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	LIPS, MOUTH, EYES, EYEBROWS, EYELIDS,		SHOULDERS, HANDS, FINGERS, FISTS, PALMS e NECK.	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	NOSE, CHEEKS, FOREHEAD e JAW.			
Castellano et al. (Castellano et al., 2007)			ARMS.	
Sebe et al. (Sebe et al., 2006)	HEAD, EYEBROWS, EYELIDS e MOUTH.	VOLUME, SPEECH e PITCH.		
Busso et al. (Busso et al., 2004)	FOREHEAD, EYEBROWS, EYES e CHEEKS.	PITCH e VOLUME.		
Nwe et al. (Nwe et al., 2001)		SPEECH.		
L. S. Chen et al. (L. S. Chen et al., 1998)	EYES, EYEBROWS, MOUTH, WRINKLES e FROWN.	SPEECH e PITCH.		

() representa um sinal raw

## 2.2. VARIÁVEIS DE CONTEXTO FISIOLÓGICO

As máquinas são surdas e mudas i.e., não conseguem utilizar as modalidades naturais de comunicação utilizadas pelo ser humano (Haritaoglu et al., 2001). Como consequência, também não conseguem identificar diretamente as emoções a partir das expressões, tendo-se que recorrer à recolha e classificação dos dados de contexto para inferir o que sentem as pessoas.

Os sinais fisiológicos são involuntários e tendem a representar pontos objetivos de dados a analisar. Ao contrário da expressão corporal, podem funcionar como indicadores parciais de estados afetivos. Como muitos desses sinais são possíveis de medir através de sensores, os seus dados podem ser interpretados por algoritmos e classificados em emoções (Rani & Sarkar, 2006). Um sinal fisiológico pode ser definido como a descrição de um fenómeno fisiológico independentemente da natureza da descrição (Nawasalkar et al., 2013) .

As pessoas podem suprimir o conteúdo emocional da comunicação não-verbal transmitida pela expressão corporal (Y. Liu et al., 2010) (K. H. Kim et al., 2004). Contudo, o impacto fisiológico das emoções sentidas é inevitável já que o *Autonomous Nervous System* (ANS) é ativado aquando da excitação positiva ou negativa (Rani, Liu, Sarkar, & Vanman, 2006), provocando reações instintivas e inconscientes no corpo humano ao nível da atividade cerebral, cardíaca ou respiratória (Van Der Vloed & Berentsen, 2009) (Jerritta et al., 2011) (Alzoubi et al., 2013) (S. Kim, Anh, & Thi, 2016), etc.

### 2.2.1. Atividade cerebral

A **atividade cerebral** é uma variável de contexto muito utilizada nos sistemas de deteção emocional. A escolha do eletroencefalograma (**EEG**) como sinal de entrada estará relacionada com o aumento de investigações na área do BCI (Y. Liu et al., 2010), e também com o facto de a literatura estabelecer várias vezes correlação entre a atividade do cérebro e as emoções sentidas pelas pessoas (Bos, 2010). Por exemplo, as ondas-beta são típicas num estado mental relaxado mas em alerta, e são mais visíveis nos lóbulos parietal e occipital. Uma alta atividade alfa foi também já correlacionada com a inativação cerebral, tornando o rácio beta/alpha num importante indicador do *arousal* humano (Bos, 2010).

Os dados cedidos pelo cérebro humano são um importante *input* nos sistemas de deteção emocional, até porque o hipotálamo é responsável por processar os sinais chegados ao cérebro

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

e desencadear as respetivas respostas fisiológicas (e.g. aumentar o HR, ativar a resposta SCR, etc.) (Kandel, Schwartz, & Jessell, 2000).

Apesar da sua importância, o componente alfa do EEG aumenta com o simples fechar de olhos (Bos, 2010) e é influenciado pelo ruído muscular da face (e.g. piscar dos olhos) ou dos artefactos electrostáticos causados pela presença dos vários elétrodos utilizados na recolha (Bos, 2010) (Jerritta et al., 2011). Além disso o funcionamento do cérebro humano carece ainda de mais investigação. Por exemplo, os investigadores Niemic et al., Canli et al. e Jones defendem que uma maior atividade na região frontal esquerda do cérebro indica uma emoção positiva, e mais atividade na zona anterior do lóbulo direito está relacionada com uma emoção negativa (Niemic, Kirk, Brown, & Ph, 2002) (Canli, Desmond, Zhao, Glover, & Gabrieli, 1998) (Jones, 1992). No entanto os trabalhos de Y. Liu et al. e Lane et al. não sustentam estas conclusões, investigando até as hipóteses contrárias (Y. Liu et al., 2010) (R. D. Lane et al., 1997).

São vários os autores que usam este sinal como *input* dos seus sistemas. O quadro seguinte resume das variáveis extraídas em projetos onde é utilizado o sinal EEG.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	ATIVIDADE CEREBRAL	OUTRAS
Matlovic et al. (Matlovic et al., 2016)	EEG.	<b>Pele:</b> EDA.  <b>(EXP. FACIAL)</b> FaceReader (Noldus, 2017) e Shore (Fraunhofer IIS, 2017). <b>(PSICOSSOCIAL)</b> EMOTIONS.
Gogia et al. (Gogia et al., 2016)	EEG.	<b>(EXP. FACIAL)</b> HEAD.
Sano & Eng (Sano & Eng, 2016)	EEG.	<b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG. <b>Atividade ocular:</b> EOG. <b>Atividade glandular:</b> MELAT.  <b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA. <b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS. <b>(INTERAÇÃO)</b> CALL, SMS, EMAIL e SOCIAL. <b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR. <b>(INTEGRAÇÃO)</b> ACADDEX, CAFFEI, ALCOH e DRUGS. <b>(OUTRAS)</b> ACC e LIGHT.
Matiko et al. (Matiko et al., 2014)	EEG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.
Soleymani et al.	EEG.	<b>(EXP. FACIAL)</b>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Soleymani et al., 2013)		HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	EEG.	<b>Atividade cardíaca:</b> HR, HRV, PEP, SV e BP(SBP, DBP). <b>Atividade respiratória:</b> RESP(VT, ROS, RR). <b>Pele:</b> EDA, nSRR e ST.
<b>Bos</b> (Bos, 2010)	EEG.	
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	EEG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.

() representa um sinal raw

### 2.2.2. Atividade cardíaca

A **atividade cardíaca** pode ser medida através de vários instrumentos: eletrocardiograma (**ECG**); cardiograma de impedância (**ICG**); fotopletiografia (**PPG**); fonocardiograma (**PCG**); etc. A partir destes instrumentos é possível extrair várias variáveis de contexto utilizadas nos sistemas de detecção emocional: frequência cardíaca (**HR**); variabilidade da frequência cardíaca (**HRV**) (obtido a partir do ECG e PPG (K. H. Kim et al., 2004)); período pré-ejeção (**PEP**); volume sistólico (**SV**); pressão sanguínea ou pressão arterial (i.e. a pressão exercida pela circulação sanguínea nas paredes dos vasos sanguíneos, refere-se normalmente à pressão arterial (Nawasalkar et al., 2013)) (**BP**); pressão arterial sistólica (**SBP**); pressão arterial diastólica (**DBP**) (durante cada batimento cardíaco a pressão sanguínea varia entre um máximo (sistólica) e um mínimo (diastólica) (Nawasalkar et al., 2013)); pressão sanguínea com recolha não invasiva (**NIBP**); pressão arterial média (**MAP**); intervalo entre batimentos (**IBI**); pulso de volume sanguíneo (**BVP**); frequência de pulso (**PR**); raiz quadrada média das diferenças sucessivas (**RMSSD**); desvio padrão os intervalos NN (i.e. IBI) (**SDNN**); tempo de ejeção do ventrículo esquerdo (**LVET**); resistência vascular periférica (**PVR**); débito cardíaco (**CO**); *vagal tone* que espelha a atividade do *vagus nerve* (**VAGAL**); e tempo da onda de pulso (diferença temporal entre um pico da onda cardíaca e o vale da onda do pulso seguinte (Zenonos et al., 2016)) (**PTT**) ou (PWTT) (Ahlstrom, Johansson, Uhlin, L?nne, & Ask, 2005) (Pollak & Obrist, 1983).

O HR reflete atividade emocional e tem sido usado conjuntamente com a temperatura no dedo para diferenciar as emoções positivas das negativas (Mandryk & Atkins, 2007) (Winton, Putnam, & Krauss, 1984). Por exemplo, a frequência cardíaca varia com o medo e fúria (S R Vrana, Cuthbert, & Lang, 1986) (Lisetti & Nasoz, 2004), e também com o susto (Haag et al., 2004). O HRV, normalmente calculado com base no ECG, pode também ser estimado com base no PPG (Alqaraawi, Alwosheel, & Alasaad, 2016) (Oura Crew, 2017) (Janković & Stojanović, 2017) (Fergus, n.d.) (Mayampurath, Volchenbom, & Sanchez-Pinto, 2018). O HRV Reflete as alterações entre batimentos no HR ou IBI (Mokhayeri & Toosizadeh, 2011), e é conhecido por diminuir com a ansiedade e aumentar com a diversão (Murad & Malkawi, 2012), stress mental ou frustração (Haag et al., 2004). Já foi utilizado em estudos para medição do stress (Dishman et al., 2000) (Muaremi, Bexheti, Gravenhorst, Arnrich, & Tröster, 2014), para avaliação do esforço mental (Calvert, 1998) e, em conjunto com o EEG, como indicador do estado de atenção (D. Chen & Vertegaal, 2004). O PEP pode ser definido como o tempo que decorre entre uma Q-wave ECG onset e um B-point do ICG (Stephens et al., 2010). É conhecido por aumentar com a tristeza aguda, diminuir com a alegria (Murad & Malkawi, 2012), e diminuir com a fúria (R Sinha

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

et al., 1992). Já o SV responde ativamente às emoções negativas (e.g. diminui com o desgosto, medo e tristeza) e mantém-se inalterado às emoções positivas (Kreibig, 2010). O BP muito medido para avaliação geral do estado de saúde, varia com a medicação e atividade física, mas também com as emoções como o stress (R. Wang et al., 2014), medo e fúria (Schwartz, Weinberger, & Singer, 1981) (Ax, 1953). O BP representa a pressão exercida pela circulação do sangue nas paredes dos vasos sanguíneos. A cada batimento cardíaco a BP varia entre um valor máximo (i.e. SBP) e um valor mínimo de pressão (i.e. DBP) (Nawasalkar et al., 2013). O aumento do SBP está relacionado com o medo e a ansiedade (Murad & Malkawi, 2012) e aumenta com a fúria (R Sinha et al., 1992) (Schachter, 1957). O DBP é conhecido por aumentar com a fúria (R Sinha et al., 1992), ansiedade e desgosto, e diminuir com a tristeza aguda (Kreibig, 2010). O NIBP permite recolher de forma contínua o BP sem necessidade de colocar punhos pneumáticos ou outros dispositivos que apenas permitem recolhas escalares (i.e. incompletas) (Solà i Carós, 2011). O IBI representa o intervalo entre dois batimentos cardíacos seguidos, pode ser visto como outra forma de analisar o HR (Zenonos et al., 2016) e o seu significado é próximo do HRV (Kreibig, 2010). O BVP é um indicador relacionado com o stress (Jennifer a Healey et al., 2000) e permite medir a atividade do coração (e.g. HR) (Jennifer a Healey et al., 2000). O PR representa a leitura manual ou por sensor do HR no pulso, dedo, pescoço, etc. O RMSSD é uma medida do HRV e é usado para determinar o *vagal tone* (Vrijkotte et al., 2000). Reflete a integridade do *vagus nerve*, (componente ligado ao controlo autónomo do coração) e está associado à morte repentina em doentes de epilepsia (DeGiorgio et al., 2010). Lee et al., na sua investigação de reconhecimento de emoções correlacionou o RMSSD com o medo (C. Lee et al., 2005). O RMSSD é usado na medição da atividade do sistema nervoso parassimpático que controla o coração (Sztajzel, 2004). O SDNN é também uma métrica utilizada nos sistemas de reconhecimento emocional e refere-se ao desvio padrão dos intervalos entre batimentos (i.e. IBI) (Zhao et al., 2016), sendo um indicador válido do *vagal tone* (Electrophysiology, 1996a). O LVET é o tempo que decorre entre os pontos B e X do ICG (Stephens et al., 2010). É importante para avaliar o desempenho do ventrículo esquerdo (Weissler, Harris, & Schoenfeld, 1969) e pode ser visto como um marcador de stress cardíaco (Sela, Shinar, & Tavakolian, 2016). O LVET diminui com a fúria e com o medo (R Sinha et al., 1992). O PVR representa a resistência ao fluxo de sangue provocado pelos músculos vasculares e pelo diâmetro dos vasos sanguíneos (Mosby's Medical Dictionary, 2009). Um aumento do PVR tende a reduzir o CO (Haddy, Overbeck, & Daugherty, 1968). O PVR aumenta com a fúria (Schachter, 1957). A tristeza provoca um aumento moderado no PVR e uma diminuição no CO (R Sinha et al., 1992). O PTT tem sido relacionado com o stress (Fuke, 2013) (Zenonos et al., 2016) (Hey et al., 2009) e representa o tempo que o sangue demora a fluir entre dois pontos arteriais (Gao, Olivier, & Mukkamala, 2016), ou seja, o tempo que demora a viagem de uma onda de pulso entre dois pontos arteriais (e.g. desde a aorta até a ponta dos dedos) (R. P. Smith, Argod, Pépin, & Lévy, 1999) (Murali et al., 2015).

São vários os estudos que recolhem da atividade cardíaca dados para deteção emocional. O quadro seguinte faz o resumo de alguns dos mais importantes.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	ATIVIDADE CARDÍACA	OUTRAS
Z. Zhang et al. (Z. Zhang et al., 2016)	BP(SBP, DBP), HR e PR.	<b>Atividade respiratória:</b> RESP(RR). <b>Pele:</b> EDA e ST.  <b>(EXP. FACIAL)</b> HEAD e FACS.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(PSICOSSOCIAL) EMOTIONS.
<b>Zhao et al.</b> (Zhao et al., 2016)	ECG(HR)*, HR e IBI(RMSSD, SDNN).  * sinal recolhido para comparação dos dados HR conseguidos pelo dispositivo criado pelo autor.	<b>Atividade respiratória:</b> RR.  (PSICOSSOCIAL) EMOTIONS.
<b>Zenonos et al.</b> (Zenonos et al., 2016)	ECG(HR(IBE(RMSSD, SDNN)), HRV) e PPG(PR, PTT).	<b>Pele:</b> ST.  (PSICOSSOCIAL) MOOD e EMOTIONS. (OUTRAS) ACC.
<b>Basu et al.</b> (Basu et al., 2016)	ECG, HR e PR.	<b>Atividade respiratória:</b> RESP(RR). <b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG.
<b>Murali et al.</b> (Murali et al., 2015)	ECG e ICG(PEP, PTT) e NIBP.	<b>Atividade respiratória:</b> RESP(RR). <b>Pele:</b> EDA.
<b>Kusserow et al.</b> (Kusserow et al., 2013)	ECG(HR), HR e HR(HRV).  * várias experimentos com formas diferentes de recolha do HR.	<b>Pele:</b> EDA e ST.  (PSICOSSOCIAL) MOOD e STRESS. (OUTRAS) ACC.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	ECG(HRV).	<b>Atividade respiratória:</b> RESP. <b>Pele:</b> EDA. <b>Atividade muscular:</b> EMG.  (PSICOSSOCIAL) EMOTIONS.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	NIBP.	<b>Atividade respiratória</b> RESP(RR).
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	HR, HRV, PEP, SV e BP(SBP, DBP).	<b>Atividade cerebral:</b> EEG. <b>Atividade respiratória:</b> RESP(VT, ROS, RR). <b>Pele:</b> EDA, nSRR e ST.
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	ECG, PR e BVP.	<b>Pele:</b> EDA.  (PSICOSSOCIAL) EMOTIONS.
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	ECG(HRV) e PPG.	<b>Atividade ocular:</b> PUPIL.
<b>Setz et al.</b> (Setz et al., 2010)	ECG*.	<b>Atividade respiratória:</b> RESP*. <b>Pele:</b>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	<i>*sinais gravados mas não utilizados;</i>	EDA.
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	ECG(HR, HRV).	<b><u>Atividade respiratória:</u></b> RESP(RR, <i>Breathing Rate Variability</i> (BRV)). <b><u>Pele:</u></b> EDA. <b><u>Atividade muscular:</u></b> EMG.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	ECG(HR, HRV, IBI).	<b><u>Atividade respiratória:</u></b> RESP(RR, RDEP). <b><u>Pele:</u></b> EDA e ST. <b><u>Atividade muscular:</u></b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	ECG(HR, IBI).	<b><u>Pele:</u></b> EDA. <b><u>Atividade ocular:</u></b> PUPIL.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	ECG(HR).	<b><u>Pele:</u></b> EDA. <b><u>Atividade muscular:</u></b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	BVP(ABI).	<b><u>Pele:</u></b> EDA e ST. <b><u>Atividade ocular:</u></b> PUPIL.  <b>(OUTRAS)</b> TEMP e LIGHT.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	ECG(HR, HRV).	<b><u>Atividade respiratória:</u></b> RESP. <b><u>Pele:</u></b> EDA. <b><u>Atividade muscular:</u></b> EMG.  <b>(PSICOSSOCIAL)</b> STRESS.
<b>Herbon et al.</b> (Herbon et al., 2005)	HR.	<b><u>Pele:</u></b> EDA e ST. <b><u>Atividade ocular:</u></b> PUPIL.  <b>(DEMOGRÁF.)</b> AGE e GENDER. <b>(PSICOSSOCIAL)</b> HEALTH e EMOTIONS. <b>(ROT. DIÁRIA)</b> TECHEXPRT.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	HR.	<b><u>Pele:</u></b> EDA e ST.  <b>(DEMOGRÁF.)</b> AGE, GENDER e ETHNICITY. <b>(PSICOSSOCIAL)</b>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		EMOTIONS.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	ECG(HR, HRV) e PPG.	<b><u>Pele:</u></b> EDA e ST.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Haag et al.</b> (Haag et al., 2004)	PPG(BVP(HR)) e ECG(HR).	<b><u>Atividade respiratória:</u></b> RESP. <b><u>Pele:</u></b> EDA e ST. <b><u>Atividade muscular:</u></b> EMG.
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)	PPG(BVP(HR)) e ECG(HR, HRV).	<b><u>Atividade respiratória:</u></b> RESP. <b><u>Pele:</u></b> EDA. <b><u>Atividade muscular:</u></b> EMG.  <b>(PSICOSSOCIAL)</b> STRESS.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD(VAGAL))).	<b>(DEMOGRÁF.)</b> AGE. <b>(PSICOSSOCIAL)</b> PERSON, STRESS e MOOD. <b>(RECONHEC.)</b> ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST. <b>(INTEGRAÇÃO)</b> CAFFEI, ALCOH e SMOKING. <b>(OUTRAS)</b> ACC.
<b>Ritz et al.</b> (Ritz et al., 2000)	HR, BP(SBP, DBP).	<b><u>Atividade respiratória:</u></b> ROS, RR e VT. <b><u>Pele:</u></b> EDA.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	PPG(BVP(HR)).	<b><u>Atividade respiratória:</u></b> RESP. <b><u>Pele:</u></b> EDA. <b><u>Atividade muscular:</u></b> EMG.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	ECG(HR) e BP(SBP, DBP).	<b><u>Pele:</u></b> EDA e ST. <b><u>Atividade muscular:</u></b> EMG. <b><u>Atividade ocular:</u></b> EOG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	ECG(HR).	<b><u>Pele:</u></b> EDA. <b><u>Atividade muscular:</u></b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>R Rinha et al.</b> (R Sinha et al., 1992)	ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP) e PCG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.
---	--	------------------------------------

( ) representa um sinal raw

### 2.2.3. Atividade respiratória

A **atividade respiratória** é usada na avaliação psicológica e psicofisiológica das pessoas e a sua monitorização contínua pode ajudar na prevenção de problemas pulmonares e cardíacos (Ravichandran et al., 2015). Os dados da respiração são mais precisos se forem calculados com base na análise dos gases trocados pelos pulmões. Contudo, esta técnica de recolha de dados dificulta as atividades diárias das pessoas (e.g. correr, andar, conduzir, etc.) (Jennifer a Healey et al., 2000). Assim, é habitualmente substituída pela técnica de medição da expansão da cavidade peitoral durante a respiração (Jennifer a Healey et al., 2000). Alguns autores utilizam ainda técnicas baseadas em impedância para medir a respiração (e.g. Nawasalkar et al. (Nawasalkar et al., 2013)).

São várias as variáveis relacionadas com a respiração (**RESP**) utilizadas pelos investigadores nos sistemas de deteção emocional: volume de corrente (**VT**); resistência oscilatória (**ROS**); frequência de respiração (**RR**) (Murad & Malkawi, 2012); e profundidade de respiração (**RDEP**) (Lichtenstein, Antje; Oehme, 2008) (cálculo feito pelo autor com base na amplitude do sinal RR).

A informação acerca da respiração é usada em vários contextos, desde o estudo do sono (Long, Fonseca, Foussier, Haakma, & Aarts, 2014) (Sano & Eng, 2016), do riso (Fukumto & Nagamatsu, 2016), deteção de stress (J. A. Healey & Picard, 2005), monitorização de saúde emocional e física (Murali et al., 2015) e evolução emocional no tempo (Alzoubi et al., 2013). As emoções negativas podem alterar os padrões de respiração, e os estímulos intensos e repentinos podem causar interrupções momentâneas de respiração (Jennifer a Healey et al., 2000) (Frijda, 1986) (J. Kim & André, 2008).

A RR e a RDEP estão relacionados com a atividade física ou excitação emocional. São as medidas da modalidade respiração mais utilizadas pelos investigadores e podem influenciar outros sinais como a eletromiografia (EMG) e a condutância da pele (SCR), devido à forte relação da respiração com a função cardíaca (J. Kim & André, 2008). Por exemplo, o RDEP menos profundo e a menor RR podem significar relaxamento, descanso e tranquilidade (Frijda, 1986), enquanto o RDEP mais profundo e maior RR pode indicar excitação, fúria e, por vezes, alegria (Haag et al., 2004). Uma respiração rápida e com baixo VT pode indicar tensão como pânico, medo ou concentração (Haag et al., 2004). O ROS aumenta com os estados emocionais diferentes do neutral (Ritz et al., 2000).

De entre os estudos que utilizam estas variáveis, destacam-se os apresentados no quadro seguinte.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	ATIVIDADE RESPIRATÓRIA	OUTRAS
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	RESP(RR).	<b>Atividade cardíaca:</b> BP(SBP, DBP), HR e PR. <b>Pele:</b> EDA e ST. <b>(EXP. FACIAL)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		HEAD e FACS. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Zhao et al.</b> (Zhao et al., 2016)	RESP.	<b>Atividade cardíaca:</b> ECG(HR), HR e IBI(RMSSD, SDNN).  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Basu et al.</b> (Basu et al., 2016)	RESP(RR).	<b>Atividade cardíaca:</b> ECG, HR e PR. <b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG.
<b>Murali et al.</b> (Murali et al., 2015)	RESP(RR).	<b>Atividade cardíaca:</b> ECG e ICG(PEP, PTT) e NIBP. <b>Pele:</b> EDA.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	RESP.	<b>Atividade cardíaca:</b> ECG(HRV). <b>Pele:</b> EDA. <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	RESP(RR).	<b>Atividade cardíaca:</b> NIBP.
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	RESP(VT, ROS, RR).	<b>Atividade cerebral:</b> EEG. <b>Atividade cardíaca:</b> HR, HRV, PEP, SV e BP(SBP, DBP). <b>Pele:</b> EDA, nSRR e ST.
<b>Setz et al.</b> (Setz et al., 2010)	RESP*.  <i>*sinais gravados mas não utilizados;</i>	<b>Atividade cardíaca:</b> ECG*. <b>Pele:</b> EDA.
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	RESP(RR, <i>Breathing Rate Variability (BRV*)</i> ).  <i>* específico do autor</i>	<b>Atividade cardíaca:</b> ECG(HR, HRV). <b>Pele:</b> EDA. <b>Atividade muscular:</b> EMG.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	RESP(RR, RDEP).	<b>Atividade cardíaca:</b> ECG(HR, HRV, IBI). <b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	RESP.	<b>Atividade cardíaca:</b> ECG(HR, HRV). <b>Pele:</b> EDA. <b>Atividade muscular:</b> EMG.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(PSICOSSOCIAL) STRESS.
Haag et al. (Haag et al., 2004)	RESP.	<b>Atividade cardíaca:</b> PPG(BVP(HR)) e ECG(HR). <b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG.
Jennifer a Healey (Jennifer a Healey et al., 2000)	RESP.	<b>Atividade cardíaca:</b> PPG(BVP(HR)) e ECG(HR, HRV). <b>Pele:</b> EDA. <b>Atividade muscular:</b> EMG.  (PSICOSSOCIAL) STRESS.
Ritz et al. (Ritz et al., 2000)	ROS, RR e VT.	<b>Atividade cardíaca:</b> HR, BP(SBP, DBP). <b>Pele:</b> EDA.  (PSICOSSOCIAL) EMOTIONS.
J. Healey & Picard (J. Healey & Picard, 1998)	RESP.	<b>Atividade cardíaca:</b> PPG(BVP(HR)). <b>Pele:</b> EDA. <b>Atividade muscular:</b> EMG.

() representa um sinal raw

#### 2.2.4. Pele

A **pele** é o maior órgão do corpo humano e tem funções importantes como a proteção e regulação da temperatura corporal (Silva, 2014). A resposta não específica de condutância da pele (**nSRR**) pode ser usada para medir o nível de humidade da pele. A atividade eletrodermal (**EDA**), resposta de condutância da pele (*skin conductance response*) (SCR), resposta eletrodermal (*electrodermal response*) (EDR) ou resposta galvânica da pele (*galvanic skin response*) (GSR) são termos que se referem à condutância da pele (J. A. Healey & Picard, 2005) (Sano & Eng, 2016) (Boucsein, 2012). Quando uma pessoa é exposta a um estímulo excitante, a capacidade condutora (elétrica) da pele aumenta momentaneamente (i.e. acontece um pico seguido de uma diminuição exponencial) (Jaques et al., 2015). Esta característica, mensurável através de sensores, é um importante indicador da excitação psicológica ou fisiológica sendo, portanto, uma variável interessante no processo de deteção emocional (Murad & Malkawi, 2012).

Enquanto as respostas EDA são decorrentes de eventos que funcionam como estímulos emocionais externos, as respostas nSRR não resultam de um estímulo externo ou de uma atividade motora, ou seja, são de origem desconhecida acontecendo de forma espontânea (Christie, 1981) (IMotions, 2016) (Setz et al., 2010).

A EDA é uma das variáveis mais escolhidas pelos investigadores na deteção emocional, apesar de ser influenciável por fatores externos como a temperatura (Chandler & Cornes, 2012). Além

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

de ser recolhida através de sensores não intrusivos, está associada ao sistema nervoso simpático (SNS) (Poh, Swenson, & Picard, 2010), fazendo com que seja difícil ou impossível a sua manipulação pelos utilizadores (Sano & Picard, 2013b). A condutância da pele reflete a inervação sudomotora e a atividade da glândula do suor que aumentam com a atividade do SNS (S. Taylor et al., 2015) (Poh et al., 2010). Como o SNS é influenciado pelo hipotálamo e pelo sistema límbico e estas são estruturas relacionadas com as emoções, faz sentido considerar a EDA como sinal de entrada nos sistemas de inferência emocional (Jaques et al., 2015) (S. Taylor et al., 2015).

A EDA aumenta com a frustração (Lisetti & Nasoz, 2004), reage à excitação emocional (Chandler & Cornes, 2012), às emoções negativas (e.g. tédio) (Giakoumis et al., 2010), ao interesse (*arousal*) (Iwasaki, Miyaki, & Rekimoto, 2010), e tem uma forte correlação com a diversão (Mandryk & Atkins, 2007). A EDA é mais indicada para medir o *arousal* (calma versus excitado) do que o *valence* (negativo versus positivo) e é um bom indicador das situações de conflito porque denuncia situações de medo e raiva (Chandler & Cornes, 2012) (Khalifa, Isabelle, Jean-Pierre, & Manon, 2002). Além de se correlacionar de forma linear com o *arousal* (Peter J. Lang, 1995), também reflete atividade cognitiva (Mandryk & Atkins, 2007) (Boucsein, 2012).

A condutância da pele é uma variável utilizada em vários tipos de investigação: monitorização de condutores em estradas rurais (Helander, 1978); análise de desempenho de pilotos (Wilson, 2002); qualidade de sono (Sano & Picard, 2013a); etc. (J. A. Healey & Picard, 2005). É considerado um bio marcador do stress (Boucsein, 2012) (Jaques et al., 2015) (Sano & Picard, 2013b) e é usada como *input* em muitos sistemas de deteção emocional como mostra o quadro seguinte. No entanto, uma alteração de condutância também pode resultar de exercício físico, alterações de temperatura ou excesso de movimento (S. Taylor et al., 2015) (W. Chen et al., 2014) (Jaques et al., 2015) (Haag et al., 2004). Assim, com o objetivo de discriminar estas situações das resultantes da atividade do SNS, os investigadores conjugam a recolha da EDA com a temperatura da pele (**ST**), temperatura ambiente (TEMP) e com o acelerómetro (ACC). No entanto, existem outras formas de lidar com o problema: Taylor et al. desenvolveu um algoritmo de *machine learning* que deteta automaticamente artefactos da EDA, algoritmo entretanto utilizado por Sano et al. e Jaques et al. nas suas investigações (S. Taylor et al., 2015) (Sano & Eng, 2016) (Jaques et al., 2015).

A variação da ST acontece por causa do fluxo sanguíneo em consequência da resistência vascular e da pressão arterial (K. H. Kim et al., 2004). Apesar de poder também ser influenciada por fatores externos (Haag et al., 2004), também é uma variável importante na deteção emocional por si só. Por exemplo, a ST aumenta durante o sono (Sano & Eng, 2016) (Martinez-Nicolas, Ortiz-Tudela, Rol, & Madrid, 2013a), aumenta mais com a raiva do que com o medo (Levenson, Ekman, & Friesen, 1990) e do que com a alegria (P. Ekman, R. W. Levenson, 1983).

A ST não deve ser confundida com a temperatura corporal (*core body temperature*) (CBT) (Sano & Eng, 2016). Uma descida de CBT é normalmente precedida de um aumento de ST (Sarabia, Rol, Mendiola, & Madrid, 2008), e durante o ciclo circadiano existem alturas em que o comportamento de ambas é inverso (Gradisar & Lack, 2004) (Č, Škoda, Krbal, & Wasserbauer, 2016). Durante algum tempo, a CBT foi reconhecida como marcador fiável do ciclo circadiano (Aschoff, 1983).

São vários os tipos de investigação que correlacionam a ST com outras variáveis: classificar o estado acordado / dormir (Sano & Picard, 2014); estudar a felicidade de alunos (Jaques et al., 2015); investigar insónias e ritmo circadiano (Lack, Gradisar, Van Someren, Wright, & Lushington, 2008) (Martinez-Nicolas, Ortiz-Tudela, Rol, & Madrid, 2013b), avaliar o stress

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Kataoka et al., 1998), classificar emoções (Murad & Malkawi, 2012) (Levenson et al., 1990) (Lisetti & Nasoz, 2004), etc.

O quadro seguinte resume algumas das investigações que consideram a EDA e o ST nos seus sistemas.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	PELE	OUTRAS
<b>Matlovic et al.</b> (Matlovic et al., 2016)	EDA.	<b>Atividade cerebral:</b> EEG.  <b>(EXP. FACIAL)</b> FaceReader (Noldus, 2017) e Shore (Fraunhofer IIS, 2017). <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	EDA e ST.	<b>Atividade cardíaca:</b> BP(SBP, DBP), HR e PR. <b>Atividade respiratória:</b> RESP(RR).  <b>(EXP. FACIAL)</b> HEAD e FACS. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	EDA e ST.	<b>Atividade cerebral:</b> EEG. <b>Atividade muscular:</b> EMG. <b>Atividade ocular:</b> EOG. <b>Atividade glandular:</b> MELAT.  <b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA. <b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS. <b>(INTERAÇÃO)</b> CALL, SMS, EMAIL e SOCIAL. <b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS. <b>(OUTRAS)</b> ACC e LIGHT.
<b>Zenonos et al.</b> (Zenonos et al., 2016)	ST.	<b>Atividade cardíaca:</b> ECG(HR(IBI(RMSSD, SDNN)), HRV) e PPG(PR, PTT).  <b>(PSICOSSOCIAL)</b> MOOD e EMOTIONS. <b>(OUTRAS)</b> ACC.
<b>Basu et al.</b> (Basu et al., 2016)	EDA e ST.	<b>Atividade cardíaca:</b> ECG, HR e PR. <b>Atividade respiratória:</b> RESP(RR).

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<b>Atividade muscular:</b> EMG.
<b>Murali et al.</b> (Murali et al., 2015)	EDA.	<b>Atividade cardíaca:</b> ECG e ICG(PEP, PTT) e NIBP. <b>Atividade respiratória:</b> RESP(RR).
<b>Jaques et al.</b> (Jaques et al., 2015)	EDA e ST.	<b>(INTERAÇÃO)</b> CALL, SMS e SOCIAL. <b>(RECONHEC.)</b> ACADCL, ACADST e PHYSI. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS. <b>(PSICOSSOCIAL)</b> SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM e HAPPY. <b>(ROT. DIÁRIA)</b> LOCAL e SCREEN. <b>(OUTRAS)</b> ACC.
<b>Kusserow et al.</b> (Kusserow et al., 2013)	EDA e ST.	<b>Atividade cardíaca:</b> ECG(HR), HR e HR(HRV).  <b>(PSICOSSOCIAL)</b> MOOD e STRESS. <b>(OUTRAS)</b> ACC.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	EDA.	<b>Atividade cardíaca:</b> ECG(HRV). <b>Atividade respiratória:</b> RESP. <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	EDA.	<b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e ELECTR. <b>(INTERAÇÃO)</b> CALL e SMS. <b>(INTEGRAÇÃO)</b> ALCOH e CAFFEI. <b>(OUTRAS)</b> ACC.
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	EDA, nSRR e ST.	<b>Atividade cerebral:</b> EEG. <b>Atividade cardíaca:</b> HR, HRV, PEP, SV e BP(SBP, DBP). <b>Atividade respiratória:</b> RESP(VT, ROS, RR).
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	EDA.	<b>Atividade cardíaca:</b> ECG, PR e BVP.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Hernandez et al.</b> (Hernandez et al., 2011)	EDA.	<b>(PSICOSSOCIAL)</b> STRESS. <b>(INTERAÇÃO)</b> CALL.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Setz et al.</b> (Setz et al., 2010)	EDA.	<b>Atividade cardíaca:</b> ECG*. <b>Atividade respiratória:</b> RESP*.  <i>*sinais gravados mas não utilizados;</i>
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	EDA.	<b>Atividade cardíaca:</b> ECG(HR, HRV). <b>Atividade respiratória:</b> RESP(RR, BRV). <b>Atividade muscular:</b> EMG.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	EDA e ST.	<b>Atividade cardíaca:</b> ECG(HR, HRV, IBI). <b>Atividade respiratória:</b> RESP(RR, RDEP). <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	EDA.	<b>Atividade cardíaca:</b> ECG(HR, IBI). <b>Atividade ocular:</b> PUPIL.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	EDA.	<b>Atividade cardíaca:</b> ECG(HR). <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	EDA, ST.	<b>Atividade cardíaca:</b> BVP(IBI). <b>Atividade ocular:</b> PUPIL.  <b>(OUTRAS)</b> TEMP e LIGHT.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	EDA.	<b>Atividade cardíaca:</b> ECG(HR, HRV). <b>Atividade respiratória:</b> RESP. <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> STRESS.
<b>Herbon et al.</b> (Herbon et al., 2005)	EDA e ST.	<b>Atividade cardíaca:</b> HR. <b>Atividade ocular:</b> PUPIL.  <b>(DEMOGRÁF.)</b> AGE e GENDER. <b>(PSICOSSOCIAL)</b> HEALTH e EMOTIONS. <b>(ROT. DIÁRIA)</b> TECHEXPRT.
<b>Lisetti &amp; Nasoz</b>	EDA e ST.	<b>Atividade cardíaca:</b> HR.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Lisetti & Nasoz, 2004)		<b>(DEMOGRÁF.)</b> AGE, GENDER e ETHNICITY. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	EDA e ST.	<b>Atividade cardíaca:</b> ECG(HR, HRV) e PPG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Haag et al.</b> (Haag et al., 2004)	EDA e ST.	<b>Atividade cardíaca:</b> PPG(BVP(HR)) e ECG(HR). <b>Atividade respiratória:</b> RESP. <b>Atividade muscular:</b> EMG.
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)	EDA.	<b>Atividade cardíaca:</b> PPG(BVP(HR)) e ECG(HR, HRV). <b>Atividade respiratória:</b> RESP. <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> STRESS.
<b>Ritz et al.</b> (Ritz et al., 2000)	EDA.	<b>Atividade cardíaca:</b> HR, BP(SBP, DBP). <b>Atividade respiratória:</b> ROS, RR e VT.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	EDA.	<b>Atividade cardíaca:</b> PPG(BVP(HR)). <b>Atividade respiratória:</b> RESP. <b>Atividade muscular:</b> EMG.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	EDA e ST.	<b>Atividade cardíaca:</b> ECG(HR) e BP(SBP, DBP). <b>Atividade muscular:</b> EMG. <b>Atividade ocular:</b> EOG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	EDA.	<b>Atividade cardíaca:</b> ECG(HR). <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.

( ) representa um sinal raw

### 2.2.5. Atividade muscular

A **atividade muscular** tem sido usada na distinção entre emoções positivas e negativas (Mandryk & Atkins, 2007). O eletromiograma (**EMG**) é um método usado no diagnóstico de problemas

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

nervosos e musculares, e baseia-se na leitura das voltagens elétricas aquando da contração muscular (Jennifer a Healey et al., 2000) (J. Kim & André, 2008) (Lichtenstein, Antje; Oehme, 2008). O EMG pode ser medido à superfície da pele com a colocação de sensores sobre a zona do músculo (e.g. (J. Healey & Picard, 1998) e (Haag et al., 2004)); ou intramuscular através da utilização de pequenas agulhas (e.g. (McNulty W, Gevirtz R, Berkoff G, 1994)) (Chandler & Cornes, 2012).

Algumas investigações relacionadas com a deteção emocional utilizam o EMG na face para determinação do *valence* (aprazibilidade), recolhendo informação dos músculos: *zygomatic* (cantos da boca) e o *corrugator* (sobrancelhas) (Lichtenstein, Antje; Oehme, 2008), por serem estes os mais representativos de expressões emocionais (Perdiz et al., 2017) mais precisamente a componente *valence* (Partala et al., 2005). Por exemplo, o sorrir e o franzir da sobrancelha conseguem ser reconhecidos através do EMG, permitindo distinguir entre o *valence* positivo e negativo (Mandryk & Atkins, 2007) (Partala et al., 2005). O investigador Sloan utilizou EMG de superfície para medir a atividade do *zygomatic* e do *corrugator* com o objetivo de distinguir o sorrir do franzir (Sloan, 2004).

Perante o susto o corpo humano reage com suor na palma da mão, aumento de RR e HR, secura na boca, e reage também com o aumento da tensão muscular que é mensurável através do EMG (Haag et al., 2004). A menor atividade muscular na zona da sobrancelha em conjunto com uma maior atividade na zona das bochechas, está relacionada com emoções suavemente positivas (Cacioppo, J.T., Berntson, G.G., Larsen, J.T., Poehlmann, K.M., Ito, 2000). O EMG permite detetar o susto (Haag et al., 2004), correlaciona-se fortemente com o desafio (Mandryk & Atkins, 2007) e consegue discriminar o desgosto da fúria (Lisetti & Nasoz, 2004).

O EMG é utilizado em vários tipos de investigação: entretenimento (Mandryk & Inkpen, 2004) (Mandryk, Atkins, & Inkpen, 2006); reabilitação física de membros superiores (L. Liu et al., 2017) (Ehrampoosh, Yousefi-koma, & Mohtasebi, 2016); terapia ocupacional para sobreviventes de Acidente Vascular Cerebral (AVC) (Thielbar et al., 2016); etc. Também é utilizado por alguns sistemas de deteção emocional como demonstra o quadro seguinte.

Uma das desvantagens do sinal EMG medido à superfície é o ruído causado pela fala ou pela tosse. A alternativa é usar o método intramuscular. No entanto, por ser um processo intrusivo, pode não ser possível aplicar em todas as realidades. (Mandryk & Atkins, 2007).

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	ATIVIDADE MUSCULAR	OUTRAS
Perdiz et al. (Perdiz et al., 2017)	EMG.	<u>Atividade ocular:</u> EOG.  (EXP. FACIAL) HEAD.
Sano & Eng (Sano & Eng, 2016)	EMG.	<u>Atividade cerebral:</u> EEG. <u>Pele:</u> EDA e ST. <u>Atividade ocular:</u> EOG. <u>Atividade glandular:</u> MELAT.  (DEMOGRÁF.) LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<p><b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY.</p> <p><b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS.</p> <p><b>(INTERAÇÃO)</b> CALL, SMS, EMAIL e SOCIAL.</p> <p><b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR.</p> <p><b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS.</p> <p><b>(OUTRAS)</b> ACC e LIGHT.</p>
<p><b>Basu et al.</b> (Basu et al., 2016)</p>	EMG.	<p><b>Atividade cardíaca:</b> ECG, HR e PR.</p> <p><b>Atividade respiratória:</b> RESP(RR).</p> <p><b>Pele:</b> EDA e ST.</p>
<p><b>Alzoubi et al.</b> (Alzoubi et al., 2013)</p>	EMG.	<p><b>Atividade cardíaca:</b> ECG(HRV).</p> <p><b>Atividade respiratória:</b> RESP.</p> <p><b>Pele:</b> EDA.</p> <p><b>(PSICOSSOCIAL)</b> EMOTIONS.</p>
<p><b>J. Kim &amp; André</b> (J. Kim &amp; André, 2008)</p>	EMG.	<p><b>Atividade cardíaca:</b> ECG(HR, HRV).</p> <p><b>Atividade respiratória:</b> RESP(RR, BRV).</p> <p><b>Pele:</b> EDA.</p>
<p><b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)</p>	EMG.	<p><b>Atividade cardíaca:</b> ECG(HR, HRV, IBI).</p> <p><b>Atividade respiratória:</b> RESP(RR, RDEP).</p> <p><b>Pele:</b> EDA e ST.</p> <p><b>(PSICOSSOCIAL)</b> EMOTIONS.</p>
<p><b>Mandryk &amp; Atkins</b> (Mandryk &amp; Atkins, 2007)</p>	EMG.	<p><b>Atividade cardíaca:</b> ECG(HR).</p> <p><b>Pele:</b> EDA.</p> <p><b>(PSICOSSOCIAL)</b> EMOTIONS.</p>
<p><b>J. A. Healey &amp; Picard</b> (J. A. Healey &amp; Picard, 2005)</p>	EMG.	<p><b>Atividade cardíaca:</b> ECG(HR, HRV).</p> <p><b>Atividade respiratória:</b> RESP.</p> <p><b>Pele:</b> EDA.</p> <p><b>(PSICOSSOCIAL)</b> STRESS.</p>
<p><b>Partala et al.</b> (Partala et al., 2005)</p>	EMG.	<p><b>(PSICOSSOCIAL)</b> EMOTIONS.</p>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Haag et al.</b> (Haag et al., 2004)	EMG.	<b>Atividade cardíaca:</b> PPG(BVP(HR)) e ECG(HR). <b>Atividade respiratória:</b> RESP. <b>Pele:</b> EDA e ST.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)	EMG*. <i>Resultados reportados noutra documento.</i>	<b>Atividade glandular:</b> CORT.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)	EMG.	<b>Atividade cardíaca:</b> PPG(BVP(HR)) e ECG(HR, HRV). <b>Atividade respiratória:</b> RESP. <b>Pele:</b> EDA.  <b>(PSICOSSOCIAL)</b> STRESS.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	EMG.	<b>Atividade cardíaca:</b> PPG(BVP(HR)). <b>Atividade respiratória:</b> RESP. <b>Pele:</b> EDA.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	EMG.	<b>Atividade cardíaca:</b> ECG(HR) e BP(SBP, DBP). <b>Pele:</b> EDA e ST. <b>Atividade ocular:</b> EOG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	EMG.	<b>Atividade cardíaca:</b> ECG(HR). <b>Pele:</b> EDA.  <b>(PSICOSSOCIAL)</b> EMOTIONS.

(\*) representa um sinal raw

### 2.2.6. Atividade ocular

Apesar da **atividade ocular** ser involuntária não é possível determinar o estado emocional das pessoas apenas com base nos seus dados (Perdiz et al., 2017).

O eletrooculograma (**EOG**) monitoriza o movimento dos olhos através da análise da diferença de voltagem entre a córnea e a retina. A recolha é feita através da colocação de elétrodos na zona dos olhos (J. Zhang et al., 2013). Com base no EOG é possível medir o movimento vertical e horizontal do olho, a frequência do piscar de olhos, o taxa de fechamento longo, a amplitude do piscar de olhos, velocidade e frequência do movimento rápido dos olhos (*saccade*), etc. (Morris & Miller, 1996).

As investigações relacionadas com a deteção emocional usam geralmente o EOG em processos de remoção de ruído do EEG (Bos, 2010) (Fatourechi, Bashashatiemail, Wardemail, & Birchemail,

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

2007). Por esse motivo, é mais frequente encontrar o EOG em investigações de correlação multimodal (Perdiz et al., 2017), sendo poucos os estudos que o recolhem este sinal com o objetivo direto de, a partir dele, detetar emoções (Cruz et al., 2015).

O reconhecimento emocional com base no rastreamento dos olhos pode ser bastante útil para as investigações que incidem o seu estudo em indivíduos com problemas físicos ou psicológicos (Raudonis, 2013). Por exemplo, a forma de olhar, pode ser vista como um indicador de perturbações de ansiedade social (Schulze, Renneberg, & Lobmaier, 2013).

Além da remoção de ruído, o EOG é uma variável de contexto utilizada em várias realidades de investigação: estudo do cansaço durante simulação de voo (Morris & Miller, 1996); investigação do sono e classificação do estado acordado / dormir (Estrada et al., 2006); sistemas de segurança (Hossain, Huda, Rahman, & Ahmad, 2016); identificação de acidente vascular cerebral isquémico (Giri, Fanany, & Arymurthy, 2016); reconhecimento de expressões faciais (Cruz et al., 2015); etc.

A pupila (**PUPIL**) é utilizada em sistemas de deteção emocional. No entanto, o movimento do olho e o tamanho da pupila são diferentes entre pessoas, e dependem do estado emocional, mental e carga cognitiva (Raudonis, 2013) (Aracena et al., 2016). Além destes fatores, a constante adaptação da pupila à variação da luz e os ruídos causados pelo piscar e movimentos instantâneos do olhar (Aracena et al., 2016), representam um desafio à aplicação de algoritmos sobre o sinal (Raudonis, 2013). A pupila fornece vários dados de contexto: diâmetro (ou tamanho); velocidade (e aceleração) (Raudonis, 2013); fixação; *stimulus onset* e *offset* (Babiker et al., 2013); e tempo de variação de diâmetro (Kawai et al., 2013) (Babiker et al., 2013).

A posição do olhar (**GAZE**) é também recolhida pelos sistemas de inferência emocional (os movimentos rápidos do olho são conhecidos na literatura como *saccades*). Por e.g. Aracena et al. monitoriza este sinal em conjunto com o PUPIL durante a visualização de imagens coloridas, para reconhecer emoções (Aracena et al., 2016).

A espontaneidade da reação do diâmetro da pupila faz com que esta seja um bom *input* para um sistema de deteção emocional (Babiker et al., 2013). Espelha a atenção do utilizador (Kawai et al., 2013), correlaciona-se bem com o *valence* (Herbon et al., 2005) (Kawai et al., 2013), com o *arousal* emocional (Aracena et al., 2016) (Partala & Surakka, 2003) (Margaret M. Bradley et al., 2008), e cresce com o aumento do interesse (Murai, Nakayama, & Shimizu, 1998).

Hess et al. mostrou na sua investigação que, quando as emoções são provocadas por imagens desagradáveis, a pupila tende a diminuir de tamanho, e quando as imagens são agradáveis a pupila dilata (Hess & Polt, 1960). Contudo, mais recentemente, Kawai et al. e Babiker et al. concluíram o contrário (Kawai et al., 2013) (Babiker et al., 2013), e Partala et al. concluiu que a pupila é maior com estímulos positivos e negativos em comparação com o estado neutro (Partala & Surakka, 2003).

São várias as investigações que usam os seus dados de contexto da pupila nos seus sistemas: forma de comunicação alternativa (e.g. com pessoas que não podem mover a cabeça e braços) (Kawai et al., 2013); stress (Raudonis, 2013); etc. Talvez o motivo da escolha da pupila como sinal de entrada esteja relacionado com o facto de pertencer ao sistema nervoso autónomo (ANS) (Matsunaga, 1990) (Aracena et al., 2016) (Aracena et al., 2016), ou por se tratar de um método simples que não necessita da fixação de sensores para se conseguir boa precisão e confiabilidade (Babiker et al., 2013).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

O quadro seguinte apresenta algumas investigações onde as variáveis EOG e PUPIL são consideradas para deteção emocional.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	ATIVIDADE OCULAR	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017)	EOG.	<b>Atividade muscular:</b> EMG.  <b>(EXP. FACIAL)</b> HEAD.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	EOG.	<b>Atividade cerebral:</b> EEG. <b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG. <b>Atividade glandular:</b> MELAT.  <b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA. <b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS. <b>(INTERAÇÃO)</b> CALL, SMS, EMAIL e SOCIAL. <b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS. <b>(OUTRAS)</b> ACC e LIGHT.
<b>Aracena et al.</b> (Aracena et al., 2016)	PUPIL e GAZE.	
<b>Cruz et al.</b> (Cruz et al., 2015)	EOG.	<i>Parte de um sistema em desenvolvimento para reconhecimento de emoções que engloba os sinais (cf. EEG, EOG, EMG e EDA).</i>
<b>Raudonis</b> (Raudonis, 2013)	EYES, GAZE e PUPIL.	
<b>Kawai et al.</b> (Kawai et al., 2013)	PUPIL.	<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Babiker et al.</b> (Babiker et al., 2013)	EYES, GAZE e PUPIL.	<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	PUPIL.	<b>Atividade cardíaca:</b> ECG(HRV) e PPG.
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	PUPIL.	<b>Atividade cardíaca:</b> ECG(HR, IBI). <b>Pele:</b> EDA.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	PUPIL.	<b>Atividade cardíaca:</b> BVP(ABI). <b>Pele:</b> EDA e ST.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<b>(OUTRAS)</b> TEMP e LIGHT.
<b>Herbon et al.</b> (Herbon et al., 2005)	PUPIL.	<b>Atividade cardíaca:</b> HR. <b>Pele:</b> EDA e ST.  <b>(DEMOGRÁF.)</b> AGE e GENDER. <b>(PSICOSSOCIAL)</b> HEALTH e EMOTIONS. <b>(ROT. DIÁRIA)</b> TECHEXPRT.
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	PUPIL.	<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>R Rinha et al.</b> (R Sinha et al., 1992)	EOG.	<b>Atividade cardíaca:</b> ECG(HR) e BP(SBP, DBP). <b>Pele:</b> EDA e ST. <b>Atividade muscular:</b> EMG.  <b>(PSICOSSOCIAL)</b> EMOTIONS.

() representa um sinal raw

### 2.2.7. Atividade glandular

A **atividade glandular** é também utilizada em sistemas de detecção emocional (Omar, 2006). O cortisol (**CORT**) é produzido pelas glândulas suprarrenais (glândula pituitária e adrenal) e a secreção é controlada pelo hipotálamo (Hormone Health Network, 2016). O cortisol é importante para a saúde física e psicológica das pessoas (Dickerson & Kemeny, 2004). Serve para apoiar o organismo no equilíbrio dos níveis de açúcar e pressão arterial, e é importante no processo de redução de inflamações e para o sistema imunitário (Frazão, 2016a). Os níveis de CORT variam durante o dia porque estão relacionados com a atividade física e a serotonina (SEROT). Podem ser medidos através de uma amostra de sangue, urina ou saliva (Frazão, 2016a) e do cabelo (Gow, Thomson, Rieder, Van Uum, & Koren, 2010).

O CORT é conhecido como a hormona reguladora do stress (Smeets, Dziobek, & Wolf, 2009) (Kirschbaum, Pirke, & Hellhammer, 1993) (Ellenbogen, Schwartzman, Stewart, & Walker, 2002) (Dickerson & Kemeny, 2004). São vários os tipos de investigação que analisam a ativação de CORT: estudos relacionados com agressão social (Terburg, Morgan, & van Honk, 2009); estado de humor (van Eck et al., 2005); qualidade de memória (Buchanan & Lovullo, 2001); níveis de atenção (Ellenbogen et al., 2002); estudo do ciclo circadiano (Boudreau, Dumont, Kin, Walker, & Boivin, 2011); etc.

A ativação do CORT acontece perante situações negativas como o medo perante uma ameaça, hipótese de falhar, ou impedimento de atingir objetivos (Blascovich & Tomaka, 1996) (Dienstbier, 1989). Por exemplo, o cálculo mental, exames académicos e o discursar em público, podem aumentar os níveis de CORT porque funcionam como stressores psicológicos (Kirschbaum et al., 1993) (Biondi & Picardi, 1999) (Dickerson & Kemeny, 2004) (Smeets et al., 2009). No entanto, as diversas investigações existentes sugerem que os mesmos eventos

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

stressores podem não despoletar as mesmas alterações de CORT nas pessoas (Mason, 1968), realçando as diferenças e a unicidade de cada ser humano ao nível psicológico e fisiológico.

A melatonina (**MELAT**) é uma hormona natural produzida pela glândula pineal do cérebro para regular o ritmo biológico do corpo e pode ser medido a partir do sangue ou da saliva (Salimetrics, n.d.) (Frazão, 2016b). A MELAT é o maior antioxidante produzido de forma natural (Markho, 2016), e permite a adaptação do corpo a novos fusos horários ou a novos turnos de trabalho. Como regula o sono e este correlaciona-se com a disposição (humor), o ciclo circadiano é, de forma indireta, importante para os sistemas de deteção emocional (Sano & Eng, 2016). A MELAT é conhecida como a hormona do sono (Markho, 2016).

A relação da MELAT com o ciclo circadiano e com o sono é bem perceptível pelas muitas investigações que existem da área: Lewy et al. (Lewy & Sack, 1989); Sano et al. (Sano & Eng, 2016); Gil et al. (Gil, Aubert, & Beersma, 2014); Curcio et al. (Curcio et al., 2016); Sugiura et al. (Sugiura, Eto, Takada, & Kinoshita, 2016); Boudreau et al. (Boudreau et al., 2011); Lee et al. (Y. C. Lee, Chou, Fang, & Huang, 2011); etc. A MELAT é também estudada noutra tipo de investigações: efeito da exposição do sinal Wi-Fi na produção de MELAT (Markho, 2016); relação com o cancro da mama (Hermida, Halberg, & Chavarria, 1988); estudo do efeito de cores na atividade do cérebro (Sroykham, Promraksa, Wongsathikun, & Wongsawat, 2015); etc.

A produção da melatonina depende da alternância entre luz do dia e escuridão da noite (Č et al., 2016) (Sroykham & Wongsawat, 2013). Inicia normalmente algumas horas antes da hora habitual de dormir e termina com o aparecimento da luminosidade (Sano & Eng, 2016), mas também é possível que a sua secreção aconteça apenas depois do início do sono (Č et al., 2016). O melhor dormir acontece quando a temperatura corporal (*core body temperature*) (CBT) diminui e a melatonina aumenta (Č et al., 2016).

A luz funciona como fator de treino do período de sono no ciclo circadiano do corpo humano (Czeisler et al., 1986) (Sano & Eng, 2016). Por esse motivo, são vários os investigadores que estudam o impacto da luz artificial dos dispositivos eletrónicos no sono (quando utilizados antes de dormir). A luz emanada pelos monitores provoca uma diminuição de MELAT, aumentando o nível de alerta e diminuindo a sensação de sonolência (Curcio et al., 2016) (Sroykham & Wongsawat, 2013) (Czeisler et al., 1986). No entanto Sugiura et al. argumentou o oposto, ou seja, que a inibição de sono confortável após a leitura de um livro no tablet não resulta da supressão da secreção da MELAT mas de outros fatores (Sugiura et al., 2016).

A serotonina (**SEROT**) está relacionada com o bem-estar e com o prazer (Fonte, 2015) (Frazão, 2016a). É também produzida pela glândula pineal e é conhecida como a hormona do humor (Markho, 2016). Implica a disposição e a cognição (Merens, Willem Van der Does, & Spinhoven, 2007) e pode ser medida a partir de uma amostra de sangue ou urina (Visser et al., 2011) (Fonte, 2015).

A menor presença da SEROT no organismo está relacionada com a depressão, apatia e com distúrbios psiquiátricos (Markho, 2016). O aumento através de fármacos em pessoas deprimidas pode melhorar a disposição (Moskowitz, Pinard, Zuroff, Annable, & Young, 2001). Por exemplo, as pessoas com comportamentos violentos (e.g. condenados por crimes violentos, incendiários, etc.) tem menores taxas de SEROT no seu organismo (Virkkunen, 1994). Quando tratados com drogas para aumentar o SEROT reduzem a agressividade (Fuller, 1996) (Virkkunen, 1994).

A SEROT desempenha portanto, um papel importante no comportamento afetivo e social dos humanos (C J Harmer et al., 2003), aumenta o sentimento de domínio (assertividade), diminui a

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

hostilidade (Moskowitz et al., 2001), aumenta a cooperação em situações de resolução de problemas, reduz o sentimento de afetos negativos (Knutson et al., 1998), facilita a tomada de decisões (Merens et al., 2007), etc.

A glândula pineal é responsável pelo balanceamento entre a SEROT e a MELAT. Durante a noite produz a MELAT para promover o sono e, durante o dia, aumenta a produção da SEROT (Markho, 2016). A SEROT está presente com várias investigações relacionadas com o processamento emocional (Merens et al., 2007): disposição (humor) (Merens et al., 2007); depressão (C J Harmer et al., 2003); ansiedade (Catherine J. Harmer, Shelley, Cowen, & Goodwin, 2004); etc. No entanto, está presente também noutros tipos de investigação: impacto do sinal Wi-Fi na produção de SEROT (Markho, 2016); agressividade (Knutson et al., 1998) (Moskowitz et al., 2001); interações sociais e domínio (Moskowitz et al., 2001); timidez da infância (Battaglia et al., 2005); distúrbios emocionais (C J Harmer et al., 2003); etc.

O quadro seguinte apresenta algumas investigações onde as variáveis CORT, MELAT e SEROT são utilizadas para deteção emocional.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	ATIVIDADE GLANDULAR	OUTRAS
Sano & Eng (Sano & Eng, 2016)	MELAT.	<p><b>Atividade cerebral:</b> EEG.</p> <p><b>Pele:</b> EDA e ST.</p> <p><b>Atividade muscular:</b> EMG.</p> <p><b>Atividade ocular:</b> EOG.</p> <p><b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA.</p> <p><b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY.</p> <p><b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS.</p> <p><b>(INTERAÇÃO)</b> CALL, SMS, EMAIL e SOCIAL.</p> <p><b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR.</p> <p><b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS.</p> <p><b>(OUTRAS)</b> ACC e LIGHT.</p>
Van Eck et al. (van Eck et al., 2005)	CORT.	<p><b>(PSICOSSOCIAL)</b> LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS e EMOTIONS.</p> <p><b>(RECONHEC.)</b> PHYSI.</p> <p><b>(INTEGRAÇÃO)</b> SMOKING, FOOD, CAFFEI e ALCOH.</p>
C J Harmer et al. (C J Harmer et al., 2003)	SEROT. <i>Reconhecimento facial não envolveu meios tecnológicos.</i>	<p><b>(PSICOSSOCIAL)</b> MOOD, ENERGY, ANXIETY e EMOTIONS.</p>
Buchanan & Lovallo	CORT.	<p><b>Atividade muscular:</b> EMG*.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Buchanan & Lovallo, 2001)		<b>(PSICOSSOCIAL)</b> EMOTIONS.  *Resultados reportados noutra documento.
----------------------------	--	--

() representa um sinal raw

#### 2.2.8. Análise

As emoções afetam o sistema cardiovascular, respiratório, eletrodermal e muscular (Basu et al., 2016). Apesar de serem de natureza mais subjetiva e complexa, a impossibilidade de manipulação dos sinais fisiológicos por parte das pessoas, torna-os num bom *input* para um sistema de deteção emocional pelo facto de serem blindados ao mascaramento social (K. H. Kim et al., 2004) (J. Kim & André, 2008). Além disso, é possível recolhê-los em tempo real sem que as pessoas se tenham que expressar, alargando assim o âmbito de aplicação (e.g. pessoas doentes, trabalhadores a operar máquinas, etc.) (Rani & Sarkar, 2006) (Poole & Ball, 2005).

No entanto, apesar dos avanços recentes na tecnologia de sensores (Wu, Batalin, Au, Bui, & Kaiser, 2007), há ainda a necessidade de aumentar a precisão e a diversidade de dados recolhidos. Além disso, o ruído cruzado entre sinais constitui um desafio na recolha e tratamento da informação de contexto (e.g. ruído muscular presente no EEG possível de detetar através do EOG e EMG) (Soleymani et al., 2013). A presença de artefactos pode conduzir à distorção da interpretação do sinal original (Coburn & Moreno, 1988). A natureza obstrutiva da recolha é também um problema. Pode representar restrições ao movimento e desconforto na utilização, pode ser impossível utilizar durante longos períodos de tempo, pode interferir com outros sinais (e.g. a geração de calor pode ativar o suor), etc. (Tran et al., 2007) (Barea, Boquete, Rodriguez-Ascariz, Ortega, & López, 2011). Apesar de existirem avanços da tecnologia para uma recolha mais discreta e não obstrutiva (Wu et al., 2008) (Wu et al., 2007), há ainda um caminho a percorrer no sentido da miniaturização, portabilidade e comunicação sem fios.

Podem também existir problemas na generalização por causa da dependência do utilizador. A reação fisiológica perante um evento não é igual entre pessoas (e.g. os stressores atuam de forma diferente entre indivíduos) (Manuck, Cohen, Rabin, Muldoon, & Bachen, 1991). Talvez a percepção subjetiva individual de cada situação em concreto seja o principal determinante no padrão de resposta psicoendocrina (Biondi & Picardi, 1999). Um bombeiro estará mais habituado a lidar com traumatismos. Perante um acidente, o seu corpo reagirá de forma diferente do que, por exemplo, um professor. Um jovem poderá ser mais suscetível à vergonha do que um adulto. As pessoas que vivem em zonas de conflito continuado terão mais facilidade em lidar com armas e com a morte.

Analisando as mesmas investigações de forma agregada (ver tabela seguinte), são muitas as investigações que recolhem dados fisiológicos para reconhecimento emocional. No entanto, a maioria foca-se na análise dos dados relacionados com a atividade cardíaca, respiratória, cerebral e pele, e são poucas que usam como *input* nos seus sistemas várias modalidades em simultâneo (e.g. Chandler et al. correlaciona sinais musculares e da pele com dados da expressão facial (Chandler & Cornes, 2012), Sano et al. correlaciona dados da pele com os do acelerómetro, atividade social e dados pessoais (Sano & Picard, 2013b)).

Com o surgimento de mais sensores com maior precisão de leitura, e de dispositivos com grande capacidade computacional, esperam-se mais investigações na área da deteção emocional,

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

correlacionando variáveis de várias modalidades, com o objetivo de aumentar a precisão dos sistemas de reconhecimento de emoções (Gogia et al., 2016).

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO FISIOLÓGICO							
	ATIVIDADE CEREBRAL	ATIVIDADE CARDÍACA	ATIVIDADE RESPIRATORIA	PELE	ATIVIDADE MUSCULAR	ATIVIDADE OCULAR	ATIVIDADE GLANDULAR	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017)					EMG.	EOG.		<b>(EXP. FACIAL)</b> HEAD.
<b>Matlovic et al.</b> (Matlovic et al., 2016)	EEG.			EDA.				<b>(EXP. FACIAL)</b> FaceReader (Noldus, 2017) e Shore (Fraunhofer IIS, 2017). <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Gogia et al.</b> (Gogia et al., 2016)	EEG.							<b>(EXP. FACIAL)</b> HEAD.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)		BP(SBP, DBP), HR e PR.	RESP(R R).	EDA e ST.				<b>(EXP. FACIAL)</b> HEAD e FACS. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	EEG.			EDA e ST.	EMG.	EOG.	MELAT.	<b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA. <b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS. <b>(INTERAÇÃO)</b> CALL, SMS, EMAIL e SOCIAL. <b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS. <b>(OUTRAS)</b> ACC e LIGHT.
<b>Zhao et al.</b> (Zhao et al., 2016)		ECG(HR)* , HR e IBI(RMSSD, SDNN).	RESP.					<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Zenonos et al.</b> (Zenonos et al., 2016)		ECG(HR( I BI(RMSSD , SDNN)), HRV) e PPG(PR, PTT).		ST.				<b>(PSICOSSOCIAL)</b> MOOD e EMOTIONS. <b>(OUTRAS)</b> ACC.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Basu et al.</b> (Basu et al., 2016)		ECG, HR e PR.	RESP(R R).	EDA e ST.	EMG.			
<b>Aracena et al.</b> (Aracena et al., 2016)						PUPIL e GAZE.		
<b>Murali et al.</b> (Murali et al., 2015)		ECG e ICG(PEP, PTT) e NIBP.	RESP(R R).	EDA.				
<b>Jaques et al.</b> (Jaques et al., 2015)				EDA e ST.				<b>(PSICOSSOCIAL)</b> SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM e HAPPY. <b>(ROT. DIÁRIA)</b> LOCAL e SCREEN. <b>(INTERAÇÃO)</b> CALL, SMS e SOCIAL. <b>(RECONHEC.)</b> ACADCL, ACADST e PHYSI. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS. <b>(OUTRAS)</b> ACC.
<b>Cruz et al.</b> (Cruz et al., 2015)						EOG.		
<b>Matiko et al.</b> (Matiko et al., 2014)	EEG.							<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Soleymani et al.</b> (Soleymani et al., 2013)	EEG.							<b>(EXP. FACIAL)</b> HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Kusserow et al.</b> (Kusserow et al., 2013)		ECG(HR), HR e HR(HRV).		EDA e ST.				<b>(PSICOSSOCIAL)</b> MOOD e STRESS. <b>(OUTRAS)</b> ACC.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)		ECG(HRV)	RESP.	EDA.	EMG.			<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)		NIBP.	RESP(R R).					
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)				EDA.				<b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e ELECTR. <b>(INTERAÇÃO)</b> CALL e SMS. <b>(INTEGRAÇÃO)</b> ALCOH e CAFFEI.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

								(OUTRAS) ACC.
<b>Raudonis</b> (Raudonis, 2013)						EYES, GAZE e PUPIL.		
<b>Kawai et al.</b> (Kawai et al., 2013)						PUPIL.		(PSICOSSOCIAL) EMOTIONS.
<b>Babiker et al.</b> (Babiker et al., 2013)						EYES, GAZE e PUPIL.		(PSICOSSOCIAL) EMOTIONS.
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	EEG.	HR, HRV, PEP, SV e BP(SBP, DBP).	RESP(V T, ROS, RR).	EDA, nSRR e ST.				
<b>C. Y. Chang et al.</b> (Chang et al., 2012)		ECG, PR e BVP.		EDA.				(PSICOSSOCIAL) EMOTIONS.
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)		ECG(HRV) e PPG.				PUPIL.		
<b>Hernandez et al.</b> (Hernandez et al., 2011)				EDA.				(PSICOSSOCIAL) STRESS. (INTERAÇÃO) CALL.
<b>Bos</b> (Bos, 2010)	EEG.							
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	EEG.							(PSICOSSOCIAL) EMOTIONS.
<b>Setz et al.</b> (Setz et al., 2010)				EDA.				
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)		ECG(HR, HRV).	RESP(R R, BRV).	EDA.	EMG.			
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)		ECG(HR, HRV, IBI).	RESP(R R, RDEP).	EDA e ST.	EMG.			(PSICOSSOCIAL) EMOTIONS.
<b>Margaret M.</b> (Margaret M. Bradley et al., 2008)		ECG(HR, IBI).		EDA.		PUPIL.		
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)		ECG(HR).		EDA.	EMG.			(PSICOSSOCIAL) EMOTIONS.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)		BVP(IBI).		EDA e ST.		PUPIL		(OUTRAS) TEMP e LIGHT.
<b>J. A. Healey</b> (J. A. Healey & Picard, 2005)		ECG(HR, HRV).	RESP.	EDA.	EMG.			(PSICOSSOCIAL) STRESS.
<b>Herbon et al.</b> (Herbon et al., 2005)		HR.		EDA e ST.		PUPIL.		(DEMOGRÁF.) AGE e GENDER. (PSICOSSOCIAL) HEALTH e EMOTIONS. (ROT. DIÁRIA) TECHEXPERT.
<b>Partala et al.</b> (Partala et al., 2005)					EMG.			(PSICOSSOCIAL) EMOTIONS.
<b>Van Eck et al.</b>							CORT.	(PSICOSSOCIAL)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(van Eck et al., 2005)								LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS e EMOTIONS. <b>(RECONHEC.)</b> PHYSI. <b>(INTEGRAÇÃO)</b> SMOKING, FOOD, CAFFEI e ALCOH.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)		HR.		EDA e ST.				<b>(DEMOGRÁF.)</b> AGE, GENDER e ETHNICITY. <b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		ECG(HR, HRV) e PPG.		EDA e ST.				<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Haag et al.</b> (Haag et al., 2004)		PPG(BVP(HR)) e ECG(HR).	RESP.	EDA e ST.	EMG.			
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)						PUPIL.		<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)							SEROT.	<b>(PSICOSSOCIAL)</b> MOOD, ENERGY, ANXIETY e EMOTIONS.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)					EMG.		CORT.	<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)		PPG(BVP(HR)) e ECG(HR, HRV).	RESP.	EDA.	EMG.			<b>(PSICOSSOCIAL)</b> STRESS.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)		BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD(VAGAL))).						<b>(DEMOGRÁF.)</b> AGE. <b>(PSICOSSOCIAL)</b> PERSON, STRESS e MOOD. <b>(RECONHEC.)</b> ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST. <b>(INTEGRAÇÃO)</b> CAFFEI, ALCOH e SMOKING. <b>(OUTRAS)</b> ACC.
<b>Ritz et al.</b> (Ritz et al., 2000)		HR, BP(SBP, DBP).	ROS, RR e VT.	EDA.				<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)		PPG(BVP(HR)).	RESP.	EDA.	EMG.			

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Rajita Sinha</b> (Rajita Sinha, 1996)		ECG(HR) e BP(SBP, DBP).		EDA e ST.	EMG.	EOG.		<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)		ECG(HR).		EDA.	EMG.			<b>(PSICOSSOCIAL)</b> EMOTIONS.
<b>R Sinha et al.</b> (R Sinha et al., 1992)		ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP) e PCG.						<b>(PSICOSSOCIAL)</b> EMOTIONS.

( ) representa um sinal raw

### 2.3. VARIÁVEIS DE CONTEXTO SOCIAL E PSICOLÓGICO

Os computadores são socialmente ignorantes (Pentland, 2005). São vistos como ferramentas lógicas e racionais logo incompatíveis com a natureza irracional e ilógica das emoções do ser humano (Rosalind W. Picard, 2000).

Medir emoções é um dos maiores problemas da ciência afetiva e do estudo da apazibilidade. A grande quantidade de fatores que afetam o estado emocional como a fisiologia, experiência subjetiva, antecedentes e comportamento (Babiker et al., 2013), fazem com que as emoções não possam ser medidas diretamente (Nawasalkar et al., 2013), porque cada pessoa pode reagir de forma diferente ao mesmo estímulo emocional (Raudonis, 2013). A forma como se experiencia uma emoção varia em função do tempo e do espaço, e da componente social e cultural, etc. (J. Kim & André, 2008) (Dong, Lepri, & Pentland, 2011).

As emoções são as bases da interação humana (Basu et al., 2016). O homem é um ser coletivo e as emoções que sente influenciam e são influenciadas pela sua vida em grupo (Dickerson & Kemeny, 2004) (Ekman, 1989). Por exemplo, perante uma tarefa em que o desempenho pessoal é posto à prova (e.g. falar em público, cálculo mental, etc.), as pessoas sentem ameaça por causa da avaliação que possa ser feita pelos outros (Dickerson & Kemeny, 2004) provocando um aumento de CORT e, conseqüentemente, um aumento de stress (Kirschbaum et al., 1993). No entanto, os humanos são seres complexos e podem exprimir emoções de forma ambígua. A tristeza provocada pelo fracasso pode (ou não) levar ao choro mas, algumas pessoas choram de felicidade em reação a um evento positivo, e outras sorriem enquanto experienciam uma emoção negativa (Basu et al., 2016). Neste caso, perante o fracasso, o sorriso não significaria felicidade mas sim desconforto, desilusão, mal-estar ou tristeza (Ekman, 1989). Esta ambiguidade humana torna muito difícil a deteção de emoções apenas analisando os dados de uma única modalidade (Basu et al., 2016), como fazem muitas investigações relacionadas com a deteção emocional (Z. Zhang et al., 2016).

As variáveis de contexto social são consideradas em estudos de interação homem-máquina (HCI) (e.g. (Pantic et al., 2005)), e também em investigações do âmbito emocional: qualidade de vida (J. L. Pais-Ribeiro, 1999); bem-estar físico e psicológico (Heitzmann & Kaplan, 1988) (Hohaus & Berah, 1996); humor (disposição) (Moturu, Khayal, Aharony, Pan, & Pentland, 2011); stress (Bogomolov et al., 2014) (Sano & Picard, 2013b); depressão (George, Blazer, Hughes, & Fowler, 1989) ; alegria e bem-estar (Seligman, 2011); saúde em geral (Madan, Cebrian, Moturu, Farrahi, & Pentland, 2012); estudo de emoções sociais e emoções *self-conscious* como a vergonha,

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

ciúmes, inveja, embaraço, orgulho, etc. (Hareli, Shlomo; Parkinson, 2017) (Burnett, Bird, Moll, Frith, & Blakemore, 2009) (Robbins & Parlavecchio, 2006) (Robins & Tracy, 2004); etc.

O suporte social é um conceito da psicologia da saúde (Dunbar, Ford, & Hunt, 1998), e é um determinante importante para o bem-estar ao longo da vida (Kahn & Antonucci, 1980). As relações sociais são o principal instigador das emoções (T. D. Kemper, 1978) (Lazarus & Launier, 1978) (T. P. Kemper, 1991) e as emoções são respostas a eventos do contexto (Arnold, 1970). Algumas resultam de relações sociais reais, mas outras são resultado de relações imaginadas ou lembradas (T. D. Kemper, 1978).

Um indivíduo com suporte social é alguém que tem pessoas em quem pode confiar, que gostam de si, valorizam e se preocupam consigo (Sarason, Sarason, Shearin, & Pierce, 1987). A relação do suporte social com a saúde tem sido muito discutida na literatura (Wallston, Devellis, & Devellis, 1983) (Heitzmann & Kaplan, 1988): inibe o desenvolvimento e apoia a recuperação de doenças (Sheldon Cohen & Herbert, 1996); alivia o stress (distress) (Heitzmann & Kaplan, 1988) (Rodin & Salovey, 1989) (J. L. Pais-Ribeiro, 1999) (S Cohen & Wills, 1985); protege da depressão (Peirce, Frone, Russell, Cooper, & Mudar, 2000); reduz a sensação de mal-estar (Sarason, Sarason, Potter, & Antoni, 1985); aumenta a satisfação com a vida (Hohaus & Berah, 1996); pode prevenir o risco de perturbações mentais (Ornelas, 1996) (Kessler, Price, & Wortman, 1985) como a depressão, ansiedade e o suicídio (Hawkley & Cacioppo, 2010); promove o envelhecimento saudável (Antonucci, 2001); etc.

São vários os autores que estudam o suporte social. Kahn e Antonucci defenderam que cada ser humano é rodeado por uma rede pessoal de pessoas em que existe suporte social dado e recebido cuja qualidade e composição é moldada ao longo do tempo em resultado da interação com fatores de contexto situacional (e.g. expectativas e pedidos da família, trabalho ou de outros papéis desempenhados na rede), e do contexto pessoal (e.g. idade, personalidade, características demográficas, etc.). No modelo *convoy*, Antonucci representa o conjunto de relacionamentos do ser humano através de um conjunto de círculos concêntricos. O mais interno representa o próprio indivíduo e os restantes três o *convoy* de relacionamentos, ou seja, as pessoas importantes ao nível do suporte social, para esse indivíduo. A ordenação de círculos representa a proximidade dos elementos da rede num determinado momento da vida, sendo o externo o que representa os membros mais afastados. O ciclo mais interno representa o contexto pessoal do indivíduo, o seguinte representa os familiares e amigos próximos (e.g. esposa, filhos, etc.), segue-se o círculo que representa os restantes familiares e amigos e, por fim, o círculo que representa os vizinhos, colegas de trabalho, supervisores, etc. (Kahn & Antonucci, 1980) (Antonucci, 2001).

Dunst et al., que dividiu a origem do suporte social em informal (i.e. interação com família, amigos, vizinhos, associações, igreja, etc.) e formal (i.e. interação com serviços de saúde, médicos, assistentes sociais, etc.), propôs também um conjunto de dimensões de suporte social com relevância para o bem-estar: i) tamanho da rede social (número de pessoas que fazem parte do grupo de relacionamento); ii) existência de relações sociais particulares (e.g. casamento) e gerais (e.g. clubes, associações, empresa); iii) frequência de contactos com os elementos da sua rede); iv) necessidade do suporte social expresso pelo próprio indivíduo; v) suporte disponibilizado pelos elementos da sua rede (tipo e quantidade); vi) congruência entre o suporte social disponibilizado pelo grupo e aquele que o indivíduo necessita; vii) utilização por parte do indivíduo do suporte social disponibilizado pela rede; viii) confiança do indivíduo na obtenção de suporte social quando necessitar; ix) reciprocidade, i.e. o equilíbrio entre o suporte recebido

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

e o fornecido à rede; x) proximidade sentida para com os fornecedores de suporte social; e xi) satisfação, i.e. a utilidade sentida pelo indivíduo do suporte social recebido (Dunst & Trivette, C. M., 1990).

Weiss defendeu que as diferentes relações sociais de um indivíduo desempenham várias funções no suporte social: i) intimidade (*attachment*) fornecido por pessoas próximas (e.g. esposa, família e amigos chegados); ii) integração social que caracteriza o suporte providenciado pelas atividades em grupo; iii) suporte afetivo (*opportunity for nurturance*) por exemplo, dos filhos; iv) mérito (*reassurance of worth*) reconhecimento de competências (e.g. colegas de trabalho); v) aliança (*reliable alliance*) fornecida por parentes; e vi) orientação (*guidance*) (Weiss, 1974) (Fiori, Antonucci, & Cortina, 2006).

Pais Ribeiro, na investigação que apresenta a escala de satisfação com o suporte social (ESSS) recebido, propõe quatro fatores para a caracterizar o suporte social das pessoas: i) satisfação com os amigos, que mede a satisfação com as amizades; ii) intimidade, que contempla a satisfação com suporte social íntimo (e.g. conjúgue); iii) satisfação com a família, que mede a satisfação com o suporte social fornecido pela família; e iv) atividades sociais, que contempla a satisfação com as atividades sociais realizadas (J. L. Pais-Ribeiro, 1999).

Inspirando-nos no modelo de círculos concêntricos do modelo *convoy* de Antonucci (Kahn & Antonucci, 1980), nos fatores de Pais Ribeiro (J. L. Pais-Ribeiro, 1999), e noutras investigações da área, decidiu-se dividir em domínios e categorias as variáveis de contexto social *input* dos sistemas de deteção emocional. Os domínios representam a proximidade e relevância social de cada variável, e a categorização resulta de um agrupamento pessoal das diferentes variáveis atendendo à sua natureza, pertinência e papel na promoção do relacionamento com os outros elementos da rede.

O domínio pessoal representa o contexto individual de cada pessoa e é composto pelas categorias demográfica, psicossocial e rotina diária. As categorias interação, reconhecimento e integração, representam o suporte social dado e recebido do indivíduo, nos domínios privado, próximo e público. Agrupam-se os três domínios num único (i.e. outros domínios), porque as suas variáveis de contexto psicossocial podem estar presentes transversalmente em qualquer nível de relacionamento dentro da rede.

#### 2.3.1. Domínio pessoal (demográfica, psicossocial e rotina diária)

O domínio pessoal representa o contexto individual de cada pessoa e engloba as categorias de variáveis: **demográfica** (informação pessoal diversa); **psicossocial** (autoapreciação subjetiva diversa); e **rotina diária** (informação relacionada com as suas tarefas diárias).

Na categoria demográfica incluem-se as variáveis: idade (**AGE**); género (**GENDER**); etnia (**ETHNICITY**); raça (**RACE**); com quem vive (**LIVING**) (i.e. se vive sozinho, com família, amigos, etc.); ano escolar (**SCHOOLY**); e área de estudo (**SCHOOLA**).

Na categoria psicossocial agrupa-se a informação relativa: ao sono (**SLEEP**) (e.g. hora de acordar ou deitar, tempo a dormir e a tentar adormecer, número de interrupções do sono durante a noite, etc.); sesta (**NAP**) (e.g. quantidade e tempo); personalidade (**PERSON**); autoapreciação subjetiva do estado de saúde (**HEALTH**), humor (**MOOD**), nível de alerta (**ALERT**), cansaço (**TIRED**), stress (**STRESS**), felicidade (**HAPPY**), energia (**ENERGY**), calma (**CALM**), bem-estar (**WELLBEING**), depressão (**DEPRESSION**), ansiedade (**ANXIETY**) e fúria (**ANGER**); emoções em

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

geral (**EMOTIONS**) (e.g. *valence* e *arousal*, emoções positivas ou negativas, ou intensidade sentida de uma lista fechada de emoções ou de uma emoção em particular); existência de eventos marcantes recentes (**LIFEEVENTS**) (e.g. morte de alguém chegado, divórcio, etc.); ou complicações na vida (**DIFFICULTIES**) (e.g. problemas no trabalho ou em casa, problemas de dinheiro ou de família).

A categoria rotina diária engloba: a localização (**LOCAL**) (*Global Position System* (GPS) ou *Wireless Fidelity* (WiFi)); tempo de utilização de dispositivos através do *screen on/off* (**SCREEN**); utilização de aplicações (**APPS**) (e.g. entretenimento, produtividade, tempo de utilização, etc.); utilização de *web browsers* (**BROWSER**); utilização de equipamentos eletrónicos (**ELECTR**) (e.g. se utiliza, última hora de utilização de tablet, smartphone, televisão, computador, etc.); e experiência com computadores, internet e tecnologia em geral (**TECHEXP**).

O quadro seguinte apresenta algumas das investigações que utilizam variáveis das categorias demográfica, psicossocial e rotinas diárias, nos seus processos de reconhecimento emocional.

INVESTIGAÇÃO	DOMÍNIO PESSOAL			
	DEMOGRÁF.	PSICOSSOCIAL	ROT. DIÁRIA	OUTRAS
Matlovic et al. (Matlovic et al., 2016)		EMOTIONS*.		(EXP. FACIAL) <i>FaceReader</i> (Noldus, 2017) e <i>Shore</i> (Fraunhofer IIS, 2017) (A. CEREBRAL) EEG. (PELE) EDA.
Z. Zhang et al. (Z. Zhang et al., 2016)		EMOTIONS*.		(EXP. FACIAL) HEAD e FACS. (A. CARDÍACA) BP(SBP, DBP), HR e PR. (A. RESPIRATÓRIA) RESP(RR). (PELE) EDA e ST. (PSICOSSOCIAL) EMOTIONS.
Sano & Eng (Sano & Eng, 2016)	LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA.	PERSON, SLEEP*, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS* e ANXIETY.	LOCAL, SCREEN e APPS.	<b>INTERAÇÃO:</b> CALL, SMS, EMAIL, FTF e SOCIAL. <b>RECONHEC.:</b> PHYSI, ACADDG, ACADCL e ACADGR. <b>INTEGRAÇÃO:</b> ACADEX, CAFFEI, ALCOH e DRUGS.  (A. CEREBRAL) EEG. (PELE) EDA e ST. (A. MUSCULAR) EMG. (A. OCULAR) EOG. (A. GLANDULAR) MELAT. (OUTRAS) ACC e LIGHT.
Zhao et al.		EMOTIONS*.		(A. CARDÍACA)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Zhao et al., 2016)				ECG(HR)*, HR e IBI(RMSSD, SDNN). <b>(A. RESPIRATÓRIA)</b> RESP.
<b>Zenonos et al.</b> (Zenonos et al., 2016)		MOOD** e EMOTIONS*.  <i>** medida através da intensidade das emoções sentidas.</i>		<b>(A. CARDÍACA)</b> ECG(HR(IBE(RMSSD, SDNN)), HRV) e PPG(PR, PTT). <b>(PELE)</b> ST. <b>(OUTRAS)</b> ACC.
<b>Jaques et al.</b> (Jaques et al., 2015)		SLEEP, NAP, STRESS*, HEALTH*, ENERGY*, ALERT*, CALM e HAPPY*.	LOCAL e SCREEN.	<b>INTERAÇÃO:</b> CALL, SMS e SOCIAL. <b>RECONHEC.:</b> ACADCL, ACADST e PHYSI. <b>INTEGRAÇÃO:</b> ACADEX, CAFFEI, ALCOH e DRUGS.  <b>(PELE)</b> EDA e ST. <b>(OUTRAS)</b> ACC.
<b>Matiko et al.</b> (Matiko et al., 2014)		EMOTIONS*.		<b>(A. CEREBRAL)</b> EEG.
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)		PERSON e STRESS.		<b>INTERAÇÃO:</b> CALL, SMS e PROXIMITY.  <b>(OUTRAS)</b> WEATHER.
<b>Soleymani et al.</b> (Soleymani et al., 2013)		EMOTIONS*.		<b>(EXP. FACIAL)</b> HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH. <b>(A. CEREBRAL)</b> EEG.
<b>Kusserow et al.</b> (Kusserow et al., 2013)		MOOD e STRESS*.		<b>(A. CARDÍACA)</b> ECG(HR), HR e HR(HRV). <b>(PELE)</b> EDA e ST. <b>(OUTRAS)</b> ACC.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG(HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS.	LOCAL, SCREEN e ELECTR.	<b>INTERAÇÃO:</b> CALL e SMS. <b>INTEGRAÇÃO:</b> ALCOH e CAFFEI.  <b>(PELE)</b> EDA. <b>(OUTRAS)</b> ACC.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Kawai et al.</b> (Kawai et al., 2013)		EMOTIONS*.		<b>(A. OCULAR)</b> PUPIL.
<b>Babiker et al.</b> (Babiker et al., 2013)		EMOTIONS*.		<b>(A. OCULAR)</b> EYES, GAZE e PUPIL.
<b>LikamWa et al.</b> (LiKamWa et al., 2013)		MOOD*.	APPS, BROWSER e LOCAL.	<b>INTERAÇÃO:</b> SMS, EMAIL e CALL.
<b>C. Y. Chang et al.</b> (Chang et al., 2012)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG, PR e BVP. <b>(PELE)</b> EDA.
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)			LOCAL.	<b>INTERAÇÃO:</b> PROXIMITY, CALL e SMS.  <i>*Não foi recolhida ground-truth porque a experiência foi feita durante a época de exames.</i>
<b>Hernandez et al.</b> (Hernandez et al., 2011)		STRESS*.		<b>INTERAÇÃO:</b> CALL.  <b>(PELE)</b> EDA.
<b>N. Lane et al.</b> (N. Lane et al., 2011)		SLEEP, DEPRESSION e WELLBEING.  <i>Informação produzida pelo BeWell com base nos momentos de recarga e períodos de silêncio.</i>	LOCAL.	<b>RECONHEC.:</b> PHYSI. <b>INTERAÇÃO:</b> TALK.  <b>(OUTRAS)</b> ACC.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)		EMOTIONS*.		<b>(A. CEREBRAL)</b> EEG.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG(HR, HRV, IBI). <b>(A. RESPIRATÓRIA)</b> RESP(RR, RDEP). <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG(HR). <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)		STRESS*.		<b>(A. CARDÍACA)</b> ECG(HR, HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				EDA. <b>(A. MUSCULAR)</b> EMG.
<b>Herbon et al.</b> (Herbon et al., 2005)	AGE e GENDER.	HEALTH e EMOTIONS*.	TECHEXPER T.	<b>(A. CARDÍACA)</b> HR. <b>(PELE)</b> EDA e ST. <b>(A. OCULAR)</b> PUPIL.
<b>Partala et al.</b> (Partala et al., 2005)		EMOTIONS*.		<b>(A. MUSCULAR)</b> EMG.
<b>Van Eck et al.</b> (van Eck et al., 2005)		LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD*, WELLBEING, STRESS* e EMOTIONS.		<b>RECONHEC.:</b> PHYSI. <b>INTEGRAÇÃO:</b> SMOKING, FOOD, CAFFEI e ALCOH.  <b>(A. GLANDULAR)</b> CORT.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	AGE, GENDER e ETHNICITY.	EMOTIONS*.		<b>(A. CARDÍACA)</b> HR. <b>(PELE)</b> EDA e ST.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG(HR, HRV) e PPG. <b>(PELE)</b> EDA e ST.
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)		EMOTIONS*.		<b>(A. OCULAR)</b> PUPIL.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)		MOOD, ENERGY, ANXIETY e EMOTIONS*.		<b>(A. GLANDULAR)</b> SEROT.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)		EMOTIONS*.		<b>(A. MUSCULAR)</b> EMG. <b>(A. GLANDULAR)</b> CORT.
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)		STRESS*.		<b>(A. CARDÍACA)</b> PPG(BVP(HR)) e ECG(HR, HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	AGE.	PERSON, STRESS* e MOOD.		<b>RECONHEC.:</b> ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST. <b>INTEGRAÇÃO:</b> CAFFEI, ALCOH e SMOKING.  <b>(A. CARDÍACA)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD(VAGAL))). <b>(OUTRAS)</b> ACC.
<b>Ritz et al.</b> (Ritz et al., 2000)		EMOTIONS*.		<b>(A. CARDÍACA)</b> HR, BP(SBP, DBP). <b>(A. RESPIRATÓRIA)</b> ROS, RR e VT. <b>(PELE)</b> EDA.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG(HR) e BP(SBP, DBP). <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG. <b>(A. OCULAR)</b> EOG.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ECG(HR). <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>R Sinha et al.</b> (R Sinha et al., 1992)		EMOTIONS*.		<b>(A. CARDÍACA)</b> ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP) e PCG.

() representa um sinal raw

\* provavelmente utilizado como ground truth na avaliação

### 2.3.2. Outros domínios (interação, reconhecimento e integração)

Nos outros domínios incluem-se os domínios: privado (familiares de primeira linha como e.g. filhos e amigos íntimos); próximo (restantes familiares e amigos); e público (vizinhos, colegas de trabalho ou da escola, supervisores ou professores, etc.). Os três domínios são aqui agregados num único (cf. outros domínios), porque as suas categorias são comuns, i.e., podem existir em qualquer nível da rede.

Neste agrupamento de domínios incluem-se as categorias que representam o suporte social dado e recebido: **interação** (variáveis relacionadas com a manutenção do contacto entre elementos da rede); **reconhecimento** (características ou propriedades que os outros elementos da rede interpretam como sinal de prestígio, competências ou qualidades); e **integração** (atividades sociais ou comportamentos adquiridos a partir da rede ou promotores da integração entre elementos da rede).

Na categoria interação consideram-se: as chamadas telefónicas (**CALL**); correspondência tradicional (**MAIL**) ou eletrónica (**EMAIL**); mensagens escritas (**SMS**) e interações cara-a-cara (**FTF**). Incluem-se também nesta categoria informação subjetiva como: autoapreciação da qualidade das interações sociais (**SOCIAL**) ao longo ou em momentos específicos do dia (e.g. dia positivo ou negativo do ponto de vista social, número interações positivas e negativas antes de dormir e com elementos de que domínio, etc.); conversação (**TALK**) detetada pelo *smartphone* (e.g. tempo de voz); e também a interação de proximidade (**PROXIMITY**) registada através da descoberta de dispositivos próximos (e.g. *bluetooth*), assumindo que cada um desses

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

dispositivos pertence a outra pessoa distinta (Bauer & Lukowicz, 2012) (método utilizado nas investigações de Eagle et al. (Eagle & Pentland, 2006), Weppner et al. (Weppner & Lukowicz, 2011) e Nicolai et al. (Nicolai & Kenn, 2007)).

A categoria do reconhecimento engloba: o desempenho acadêmico (**ACADGR**) (e.g. notas, diplomas, etc.); grau acadêmico (**ACADDG**); atividade física (**PHYSI**) (e.g. número de idas ao ginásio, número de passos, tempo de corrida, etc.); peso (**WEIGHT**); altura (**HEIGHT**); índice de massa corporal (**BMI**); tamanho da cintura (**WAIST**); tempo de trabalho (**WORKYEARS**) (i.e. tempo de vida ativa); profissão (**JOB**). Incluem-se também variáveis que conduzem à obtenção de competências e, por consequência, maior reconhecimento: tempo de estudo (**ACADST**) (e.g. número de períodos, duração, etc.); e atividade acadêmica curricular (**ACADCL**) (e.g. número e tempo de aulas); etc.

A categoria da integração inclui: informação acerca da alimentação (**FOOD**); consumo de álcool (**ALCOH**); bebidas com cafeína (**CAFFEI**); cigarros ou charutos fumados (**SMOKING**) e drogas (**DRUGS**) (e.g. quantidade, hora da última ingestão, etc.); e atividade acadêmica extracurricular (**ACADEX**) (e.g. número e tempo total).

O quadro seguinte apresenta algumas das investigações que utilizam variáveis das categorias interação, reconhecimento e integração, nos seus processos de deteção emocional.

INVESTIGAÇÃO	DOMÍNIO PRIVADO, PRÓXIMO E PÚBLICO			
	INTERAÇÃO	RECONHEC.	INTEGRAÇÃO	OUTRAS
Sano & Eng (Sano & Eng, 2016)	CALL, SMS, EMAIL, FTF e SOCIAL.	PHYSI, ACADDG, ACADCL e ACADGR.	ACADEX, CAFFEI, ALCOH e DRUGS.	<p><b>DEMOGRÁF:</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA.</p> <p><b>PSICOSSOCIAL:</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY.</p> <p><b>ROT. DIÁRIA:</b> LOCAL, SCREEN e APPS.</p> <p><b>(A. CEREBRAL)</b> EEG.</p> <p><b>(PELE)</b> EDA e ST.</p> <p><b>(A. MUSCULAR)</b> EMG.</p> <p><b>(A. OCULAR)</b> EOG.</p> <p><b>(A. GLANDULAR)</b> MELAT.</p> <p><b>(OUTRAS)</b> ACC e LIGHT.</p>
Jaques et al. (Jaques et al., 2015)	CALL, SMS e SOCIAL.	ACADCL, ACADST e PHYSI.	ACADEX, CAFFEI, ALCOH e DRUGS.	<p><b>PSICOSSOCIAL:</b> SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM e HAPPY.</p> <p><b>ROT. DIÁRIA:</b> LOCAL e SCREEN.</p> <p><b>(PELE)</b> EDA e ST.</p> <p><b>(OUTRAS)</b> ACC.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	CALL, SMS e PROXIMITY.			<b>PSICOSSOCIAL:</b> PERSON e STRESS.  <b>(OUTRAS)</b> WEATHER.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	CALL e SMS.		ALCOH e CAFFEI.	<b>PSICOSSOCIAL:</b> PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS. <b>ROT. DIÁRIA:</b> LOCAL, SCREEN e ELECTR.  <b>(PELE)</b> EDA. <b>(OUTRAS)</b> ACC.
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	SMS, EMAIL e CALL.			<b>PSICOSSOCIAL:</b> MOOD. <b>ROT. DIÁRIA:</b> APPS, BROWSER e LOCAL.
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)	PROXIMITY, CALL e SMS.			<b>ROT. DIÁRIA:</b> LOCAL.
<b>Hernandez et al.</b> (Hernandez et al., 2011)	CALL.			<b>PSICOSSOCIAL:</b> STRESS.  <b>(PELE)</b> EDA.
<b>N. Lane et al.</b> (N. Lane et al., 2011)		PHYSI.	TALK.	<b>PSICOSSOCIAL:</b> SLEEP, DEPRESSION e WELLBEING. <b>ROT. DIÁRIA:</b> LOCAL.  <b>(OUTRAS)</b> ACC.
<b>Van Eck et al.</b> (van Eck et al., 2005)		PHYSI.	SMOKING, FOOD, CAFFEI e ALCOH.	<b>PSICOSSOCIAL:</b> LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS e EMOTIONS.  <b>(A. GLANDULAR)</b> CORT.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)		ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST.	CAFFEI, ALCOH e SMOKING.	<b>DEMOGRÁF.:</b> AGE. <b>PSICOSSOCIAL:</b> PERSON, STRESS e MOOD.  <b>(A. CARDÍACA)</b> BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD(VAGAL))). <b>(OUTRAS)</b> ACC.

( ) representa um sinal raw

### 2.3.3. Análise

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

As relações sociais positivas têm sido identificadas ao longo dos tempos e culturas, como o fator mais relevante para o bem-estar das pessoas (H. T. Reis, Gable, Keyes, & Haidt, 2003), confirmando a importância dos dados de origem social para um sistema de detecção emocional.

Realçando a influência do suporte social na saúde das pessoas, a Organização Mundial de Saúde (OMS) define saúde como sendo o estado completo de bem-estar físico, social e mental (OMS, 2016). No entanto, e apesar da importância da componente social enquanto determinante da saúde, é difícil o consenso acerca da melhor forma de avaliar o suporte social de alguém (J. L. Pais-Ribeiro, 1999). Perante a inexistência de uma forma direta, precisa e global de o medir (J. L. Pais-Ribeiro, 1999) (Heitzmann & Kaplan, 1988), os investigadores recolhem variáveis de contexto relacionadas com o comportamento do homem enquanto ser social (Bauer & Lukowicz, 2012) para utilização como *input* nos seus sistemas.

Neste contexto, o *smartphone* é muito utilizado como meio para obter dados de contexto para avaliação do suporte social. Esta escolha estará relacionada com o facto de estes dispositivos já fazerem parte da vida das pessoas, permitindo a recolha mais precisa e a observação de comportamentos espontâneos (Rachuri, Mascolo, Rentfrow, & Longworth, 2010). Além de não haver necessidade de acrescentar mais sensores para recolher dados de contexto (Bauer & Lukowicz, 2012) e de apenas ser necessário instalar uma aplicação no seu *of-the-shelf smartphone* (N. Lane et al., 2011), o esforço adicional para o utilizador é quase nulo já que grande parte dos dados a recolher já existem no dispositivo fruto da sua habitual atividade social (e.g. CALL, SMS, EMAIL, etc.).

No entanto, além de nem todas as pessoas usarem *smartphone* (e.g. os mais velhos podem ter dificuldades na sua manipulação), há também a necessidade de considerar a existência de ruído nos dados recolhidos: podem haver CALL, SMS e EMAIL, resultantes de erros de digitação ou digitação inadvertida ou de ações de publicidade, remetendo para o desafio tecnológico da análise de conteúdo oral e escrito; a análise de interação social com base na PROXIMITY pode ser induzida em erro pela descoberta de vários dispositivos pertencentes à mesma pessoa da rede; a manipulação do dispositivo poderá não ser exclusiva de um utilizador podendo levar à existência de dados errados acerca da sua utilização (e.g. BROWSER e APPS); etc.

Por outro lado, muitas investigações usam como *input* dados recolhidos a partir de questionários ao utilizador (e.g. ALERT, TIRED, etc.). A inexistência de outros mecanismos de inferência automática conferem um certo grau de fraqueza aos sistemas que usam esta informação subjetiva como *input* dos seus sistemas (Muaremi, Arnrich, & Tröster, 2012). Além disso, e atendendo ao carácter confidencial dos dados processados, podem surgir questões de ordem ética havendo, por exemplo, a necessidade de garantir o funcionamento do sistema sem necessidade de persistência dos dados *raw* recolhidos (Rachuri et al., 2010) (N. Lane et al., 2011).

Analisando as investigações apresentadas agora de forma agregada (ver tabela seguinte), são poucas as investigações que diversificam dados de contexto psicossocial e são também poucas as que desafiam correlações com dados provenientes de outras modalidades.

INVESTIGAÇÃO	DOMÍNIO PESSOAL			DOMÍNIO PRIVADO, PRÓXIMO E PÚBLICO			OUTRAS
	DEMOGRÁF.	PSICOSSOCIAL	ROT. DIÁRIA	INTERAÇÃO	RECONHEC.	INTEGRAÇÃO	
Matlovic et al. (Matlovic et al., 2016)		EMOTIONS.					(EXP. FACIAL) FaceReader (Noldus, 2017) e Shore (Fraunhofer IIS, 2017)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

							(A. CEREBRAL) EEG. (PELE) EDA.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)		EMOTIONS.					(EXP. FACIAL) HEAD e FACS. (A. CARDÍACA) BP(SBP, DBP), HR e PR. (A. RESPIRATÓRIA) RESP(RR). (PELE) EDA e ST.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA.	PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY.	LOCAL, SCREEN e APPS.	CALL, SMS, EMAIL, FTF e SOCIAL.	PHYSI, ACADDG, ACADCL e ACADGR.	ACADEX, CAFFEI, ALCOH e DRUGS.	(A. CEREBRAL) EEG. (PELE) EDA e ST. (A. MUSCULAR) EMG. (A. OCULAR) EOG. (A. GLANDULAR) MELAT. (OUTRAS) ACC e LIGHT.
<b>Zhao et al.</b> (Zhao et al., 2016)		EMOTIONS.					(A. CARDÍACA) ECG(HR)*, HR e IBI(RMSSD, SDNN). (A. RESPIRATÓRIA) RESP.
<b>Zenonos et al.</b> (Zenonos et al., 2016)		MOOD e EMOTIONS.					(A. CARDÍACA) ECG(HR(IBE(RMSSD, SDNN)), HRV) e PPG(PR, PTT). (PELE) ST. (OUTRAS) ACC.
<b>Jaques et al.</b> (Jaques et al., 2015)		SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM e HAPPY.	LOCAL e SCREEN.	CALL, SMS e SOCIAL.	ACADCL, ACADST e PHYSI.	ACADEX, CAFFEI, ALCOH e DRUGS.	(PELE) EDA e ST. (OUTRAS) ACC.
<b>Matiko et al.</b> (Matiko et al., 2014)		EMOTIONS.					(A. CEREBRAL) EEG.
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)		PERSON e STRESS.		CALL, SMS e PROXIMITY.			(OUTRAS) WEATHER.
<b>Soleymani et al.</b> (Soleymani et al., 2013)		EMOTIONS.					(EXP. FACIAL) HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH. (A. CEREBRAL) EEG.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Kusserow et al.</b> (Kusserow et al., 2013)		MOOD e STRESS.					<b>(A. CARDÍACA)</b> ECG(HR), HR e HR(HRV). <b>(PELE)</b> EDA e ST. <b>(OUTRAS)</b> ACC.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)		EMOTIONS.					<b>(A. CARDÍACA)</b> ECG(HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS.	LOCAL, SCREEN e ELECTR.	CALL e SMS.		ALCOH e CAFFEI.	<b>(PELE)</b> EDA. <b>(OUTRAS)</b> ACC.
<b>Kawai et al.</b> (Kawai et al., 2013)		EMOTIONS.					<b>(A. OCULAR)</b> PUPIL.
<b>Babiker et al.</b> (Babiker et al., 2013)		EMOTIONS.					<b>(A. OCULAR)</b> EYES, GAZE e PUPIL.
<b>LikamWa et al.</b> (LiKamWa et al., 2013)		MOOD.	APPS, BROWSER e LOCAL.	SMS, EMAIL e CALL.			
<b>C. Y. Chang et al.</b> (Chang et al., 2012)		EMOTIONS.					<b>(A. CARDÍACA)</b> ECG, PR e BVP. <b>(PELE)</b> EDA.
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)			LOCAL.	PROXIMITY, CALL e SMS.			
<b>Hernandez et al.</b> (Hernandez et al., 2011)		STRESS.		CALL.			<b>(PELE)</b> EDA.
<b>N. Lane et al.</b> (N. Lane et al., 2011)		SLEEP, DEPRESSION e WELLBEING.	LOCAL.	TALK.	PHYSI.		<b>(OUTRAS)</b> ACC.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)		EMOTIONS.					<b>(A. CEREBRAL)</b> EEG.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje;		EMOTIONS.					<b>(A. CARDÍACA)</b> ECG(HR, HRV, IBI). <b>(A. RESPIRATÓRIA)</b> RESP(RR, RDEP).

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Oehme, 2008)							(PELE) EDA e ST. (A. MUSCULAR) EMG.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)		EMOTIONS.					(A. CARDÍACA) ECG(HR). (PELE) EDA. (A. MUSCULAR) EMG.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)		STRESS.					(A. CARDÍACA) ECG(HR, HRV). (A. RESPIRATÓRIA) RESP. (PELE) EDA. (A. MUSCULAR) EMG.
<b>Herbon et al.</b> (Herbon et al., 2005)	AGE e GENDER.	HEALTH e EMOTIONS.	TECHEXPERT.				(A. CARDÍACA) HR. (PELE) EDA e ST. (A. OCULAR) PUPIL.
<b>Partala et al.</b> (Partala et al., 2005)		EMOTIONS.					(A. MUSCULAR) EMG.
<b>Van Eck et al.</b> (van Eck et al., 2005)		LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS e EMOTIONS.			PHYSI.	SMOKING, FOOD, CAFFEI e ALCOH.	(A. GLANDULAR) CORT.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	AGE, GENDER e ETHNICITY.	EMOTIONS.					(A. CARDÍACA) HR. (PELE) EDA e ST.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		EMOTIONS.					(A. CARDÍACA) ECG(HR, HRV) e PPG. (PELE) EDA e ST.
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)		EMOTIONS.					(A. OCULAR) PUPIL.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)		MOOD, ENERGY, ANXIETY e EMOTIONS.					(A. GLANDULAR) SEROT.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)		EMOTIONS.					<b>(A. MUSCULAR)</b> EMG. <b>(A. GLANDULAR)</b> CORT.
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)		STRESS.					<b>(A. CARDÍACA)</b> PPG(BVP(HR)) e ECG(HR, HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	AGE.	PERSON, STRESS e MOOD.			ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST.	CAFFEI, ALCOH e SMOKING.	<b>(A. CARDÍACA)</b> BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD (VAGAL))). <b>(OUTRAS)</b> ACC.
<b>Ritz et al.</b> (Ritz et al., 2000)		EMOTIONS.					<b>(A. CARDÍACA)</b> HR, BP(SBP, DBP). <b>(A. RESPIRATÓRIA)</b> ROS, RR e VT. <b>(PELE)</b> EDA.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)		EMOTIONS.					<b>(A. CARDÍACA)</b> ECG(HR) e BP(SBP, DBP). <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG. <b>(A. OCULAR)</b> EOG.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)		EMOTIONS.					<b>(A. CARDÍACA)</b> ECG(HR). <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.
<b>R Sinha et al.</b> (R Sinha et al., 1992)		EMOTIONS.					<b>(A. CARDÍACA)</b> ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP) e PCG.

( ) representa um sinal raw

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

### 2.4. OUTRAS VARIÁVEIS

Nesta secção apresentam-se variáveis usadas como suporte ao tratamento de ruído de outros sinais ou menos utilizadas pelos sistemas de deteção automática de emoções.

A temperatura (**TEMP**) e a luz ambiente (**LIGHT**) são consideradas por alguns autores como variáveis de mascaramento (Martinez-Nicolas et al., 2013a), porque podem influenciar outros dados de contexto recolhidos. A TEMP pode influenciar o *core body temperature* (CBT) (Wakamura & Tokura, 2002) e, por esse motivo, é utilizada pelos investigadores para discriminar o aumento de ST causado por origem emocional ou ambiental (Jaques et al., 2015) (Lisetti & Nasoz, 2004) (ver página 34). A TEMP é também utilizada em investigações relacionadas com casas inteligentes e bem-estar (Suryadevara, Member, & Mukhopadhyay, 2012). A LIGHT tem sido usada em estudos relacionados com o bem-estar e no sono (Sander, Markvart, Kessel, Argyraki, & Johnsen, 2015) (Sano & Eng, 2016) (Harb, Hidalgo, & Martau, 2014). A luz pode influenciar sinais fisiológicos como o HR (Scheer, van Doornen, & Buijs, 1999) e o EEG (Cajochen, Zeitzer, Czeisler, & Dijk, 1999). Pode reduzir a atividade ocular e a sensação de sonolência por causa da menor produção de MELAT em consequência do aumento da luminosidade (Scheer et al., 1999) (Cajochen et al., 1999).

A aceleração (**ACC**) permite reconhecer atividade física como o andar, sentar, subir cadeiras, contar passos (Jaques et al., 2015) (Sano & Eng, 2016), padrões de sono (Ancoli-Israel et al., 2003) (Sano & Eng, 2016), etc. O ACC é também utilizado pelos investigadores para detetar variações de ST por causa do aumento da atividade física das pessoas e não por reação emocional (S. Taylor et al., 2015) (Jaques et al., 2015). No entanto, o ACC é utilizado também diretamente para correlação em sistemas de deteção emocional: disposição (Zenonos et al., 2016); stress (Garica-Ceja, Osmani, & Mayora, 2015) (Sano & Picard, 2013b) (Kusserow et al., 2013); etc.

As variações do tempo (**WEATHER**) estão associadas a problemas no estado de humor (Denissen, Butalid, Penke, & van Aken, 2008) (Sanders & Brizzolara, 1982), sono, fadiga, descontentamento, (Faust, Weidmann, & Wehner, 1974), saúde (Sanders & Brizzolara, 1982), etc. As investigações do WEATHER utilizam várias variáveis meteorológicas: tempo de sol; precipitação; vento; humidade; pressão barométrica; etc. (Howarth & Hoffman, 1984) (Denissen et al., 2008) (Sanders & Brizzolara, 1982). O WEATHER é também utilizado pelas investigações de deteção emocional: stress (Bogomolov et al., 2014); disposição (humor) (Howarth & Hoffman, 1984) (Denissen et al., 2008) (Sanders & Brizzolara, 1982) (Hardt & Gerbershagen, 1999); etc.

O quadro seguinte apresenta algumas investigações que utilizam estas variáveis no processo de deteção emocional.

INVESTIGAÇÃO	VARIÁVEIS DE CONTEXTO	
	OUTRAS	ANTERIORES
Sano & Eng (Sano & Eng, 2016)	ACC e LIGHT.	(ATIVIDADE CEREBRAL) EEG. (PELE) EDA e ST. (ATIVIDADE MUSCULAR) EMG. (ATIVIDADE OCULAR) EOG.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<p><b>(ATIVIDADE GLANDULAR)</b> MELAT.</p> <p><b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA.</p> <p><b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY.</p> <p><b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS.</p> <p><b>(INTERAÇÃO)</b> CALL, SMS, EMAIL, FTF e SOCIAL.</p> <p><b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR.</p> <p><b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS.</p>
Zenonos et al. (Zenonos et al., 2016)	ACC.	<p><b>(ATIVIDADE CARDÍACA)</b> ECG(HR(IBMSSD, SDNN)), HRV) e PPG(PR, PTT).</p> <p><b>(PELE)</b> ST.</p> <p><b>(PSICOSSOCIAL)</b> MOOD e EMOTIONS.</p>
Jaques et al. (Jaques et al., 2015)	ACC.	<p><b>(PELE)</b> EDA e ST.</p> <p><b>(PSICOSSOCIAL)</b> SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM e HAPPY.</p> <p><b>(ROT. DIÁRIA)</b> LOCAL e SCREEN.</p> <p><b>(INTERAÇÃO)</b> CALL, SMS e SOCIAL.</p> <p><b>(RECONHEC.)</b> ACADCL, ACADST e PHYSI.</p> <p><b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS.</p>
Saha et al. (Saha et al., 2014)	ACC.	<p><b>(EXP. GESTUAL E POST.)</b> HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS e SPIN.</p>
Bogomolov et al. (Bogomolov et al., 2014)	WEATHER.	<p><b>(PSICOSSOCIAL)</b> PERSON e STRESS.</p> <p><b>(INTERAÇÃO)</b> CALL, SMS e PROXIMITY.</p>
Kusserow et al. (Kusserow et al., 2013)	ACC.	<p><b>(ATIVIDADE CARDÍACA)</b> ECG(HR), HR e HR(HRV).</p> <p><b>(PELE)</b> EDA e ST.</p> <p><b>(PSICOSSOCIAL)</b> MOOD e STRESS.</p>
Sano & Picard (Sano & Picard, 2013b)	ACC.	<p><b>(PELE)</b> EDA.</p> <p><b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS.</p> <p><b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e ELECTR.</p> <p><b>(INTERAÇÃO)</b> CALL e SMS.</p> <p><b>(INTEGRAÇÃO)</b> ALCOH e CAFFEI.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>N. Lane et al.</b> (N. Lane et al., 2011)	ACC.	<b>(INTERAÇÃO)</b> TALK. <b>(RECONHEC.)</b> PHYSI. <b>(PSICOSSOCIAL)</b> SLEEP, DEPRESSION e WELLBEING. <b>(ROT. DIÁRIA)</b> LOCAL.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	TEMP e LIGHT.	<b>(ATIVIDADE CARDÍACA)</b> BVP(IBI). <b>(PELE)</b> EDA e ST. <b>(ATIVIDADE OCULAR)</b> PUPIL.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	ACC.	<b>(ATIVIDADE CARDÍACA)</b> BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD(VAGAL))). <b>(DEMOGRÁF.)</b> AGE. <b>(PSICOSSOCIAL)</b> PERSON, STRESS e MOOD. <b>(RECONHEC.)</b> ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST. <b>(INTEGRAÇÃO)</b> CAFFEI, ALCOH e SMOKING.

( ) representa um sinal raw

## 2.5. ANÁLISE

O quadro seguinte resume as variáveis de contexto utilizadas pelas investigações analisadas, agora de forma agrupada por modalidade.

São várias as investigações que se focam na recolha de dados da expressão facial, oral e postura corporal para inferir emoções, talvez por ser essencialmente através da expressão não-verbal que o ser humano comunica emoções (Singh et al., 2015) (Nawasalkar et al., 2013). No entanto, os problemas da generalização dos sistemas causados pela dependência da cultura, género e idade (Rani & Sarkar, 2006), a erraticidade provocada pelo possível fingimento do utilizador (K. H. Kim et al., 2004) (L. S. Chen et al., 1998) (Chang et al., 2012), e a ambiguidade na interpretação de emoções a partir da forma como as pessoas se exprimem não-verbalmente (e.g. choro de alegria ou sorriso de vergonha) (Ekman, 1989), tornam este sinal um pouco desinteressante para *input* de um sistema de deteção emocional.

Como é possível constatar pela análise do quadro seguinte, são muitos os estudos que recorrem à recolha de variáveis de contexto fisiológico. As variáveis escolhidas habitualmente pelos investigadores para deteção emocional, são as que garantem à partida alguma taxa de sucesso (Lisetti & Nasoz, 2004). Tipicamente são as de contexto fisiológico pelo facto de existirem já sensores eficientes capazes de as medir de forma objetiva, e pelo facto de a informação ter origem no *autonomous nervous system* (ANS), ou seja, não ser suscetível de ser despoletada ou manipulada de forma intencional (Jerritta et al., 2011) (Van Der Vloed & Berentsen, 2009). No entanto a utilização destes sinais como *input* também tem desvantagens: a obstrutividade causada pela necessidade de medir através de sensores; a complexidade da tarefa de mapear padrões fisiológicos para emoções específicas (J. Kim & André, 2008); e a necessidade de prever e tratar o ruído presente em alguns sinais (e.g. EMG e EOG no EEG) (Soleymani et al., 2013). Por

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

fim, notar o número reduzido de investigações que utilizam dados da atividade glandular nos seus sistemas talvez pelo caráter intrusivo dos métodos atuais de recolha de urina, sangue ou saliva. Contudo, a relação da SEROT com o bem-estar (Fonte, 2015), do CORT com o stress (Smeets et al., 2009) (Kirschbaum et al., 1993) (Ellenbogen et al., 2002) (Dickerson & Kemeny, 2004) e da MELAT com o humor e nível de alerta (Sano & Eng, 2016) (Curcio et al., 2016), tornam estes dados em sinais interessantes para *input* de um sistema de inferência emocional. Com a evolução tecnológica e aparecimento de sensores ou métodos de medição hormonal não intrusivos, é de esperar que mais investigações recorram à informação glandular para detetar emoções automaticamente.

A solidez da relação do suporte social com o bem-estar e a saúde em geral (Kahn & Antonucci, 1980) (Sarason et al., 1985) (Hohaus & Berah, 1996) (Heitzmann & Kaplan, 1988) (Seligman, 2011), fazem deste sinal um importante *input* para os sistemas de reconhecimento de emoções. Talvez por ainda não existir uma forma aceite para medir o suporte social (J. L. Pais-Ribeiro, 1999) (Heitzmann & Kaplan, 1988), falta diversificação na recolha de dados de contexto psicossocial como é possível verificar pela análise visual do quadro abaixo apresentado. É convicção dos autores que a recolha de mais variáveis de contexto psicossocial pode contribuir de forma positiva para a qualidade dos sistemas de inferência emocional.

No domínio pessoal ao nível da categoria demográfica existem outros dados cuja correlação deve ser testada: estado civil; religião praticada; participação ativa em partidos políticos, associações ou desempenho de papéis de relevância na sociedade; relações amorosas (e.g. número de casamentos ou namoros, intervalo entre relações, etc.); filhos (idades, relação de parentesco, quantidade de dependentes a viver na mesma casa, dependentes a viver noutra casa, dependência financeira, dependentes com necessidades especiais, etc.); faltas e atrasos ao trabalho (por doença, assistência à família, etc.); horas extras (i.e. trabalho suplementar); férias gozadas e não gozadas; créditos obtidos (e.g. quantidade, valor e objeto (e.g. casa, carro, etc.)); titularidade e tipo de habitação (i.e. apartamento, moradia ou quinta); ambiente habitacional (cidade ou campo); distância até ao trabalho; tipo de transporte até ao trabalho; tipo de vizinhança; compras efetuadas (número de compras e valor); etc. Na categoria psicossocial outros dados podem também ser considerados: autoapreciação do suporte social dado e recebido; qualidade do relacionamento nos diferentes domínios (cf. privado, próximo e público); sentimento de solidão e isolamento; nível de satisfação e realização pessoal com o emprego; vontade de mudar de emprego ou profissão; intensidade laboral; apreciação geral da saúde dos elementos do domínio privado; complicações de saúde atuais e superadas (próprias e dos elementos do domínio privado); autoapreciação da sua felicidade e dos seus filhos; otimismo quanto ao futuro e independência financeira dos filhos; momentos de adormecer e acordar, duração das várias fases do sono; etc. Também se sugerem outras variáveis para a categoria da rotina diária: fármacos ingeridos (e.g. quantidade, número de tomas, princípio ativo, etc.); tempo despendido a ver televisão, a jogar sozinho, em leitura de lazer e em contacto com a natureza; refeições (número diário, equilíbrio alimentar, tipo (i.e. carne, peixe, vegetariana, outro) e intervalo entre refeições); quantidade de passos; ginásio (visitas agendadas, concretizadas e faltas); ócio acordado (tempo de sofá, cama ou mesa); atividades domésticas (e.g. jardinagem, arrumar a casa, preparar refeições); higiene pessoal e vestir (tempo e número de vezes); etc.

Nos outros domínios (cf. privado, próximo e público) mais concretamente ao nível da categoria da interação, faltam correlacionar variáveis que podem representar contacto entre elementos da rede: conversação face a face; conversação através de *instant messaging* (IM) (e.g.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

quantidade das interações recebidas e efetuadas, por períodos do dia, duração, tipo de destinatários mediante o domínio a que pertencem, etc.); convívio com elementos do domínio privado (e.g. tempo, regularidade, etc.); visitas de e a elementos da rede (e.g. número e tempo); entretenimento (e.g. jogos em grupo, passeios, viagens, visitas ao centro comercial e parques de diversão, etc.); atividade nas redes sociais; existência de relações amorosas informais (e.g. existência de amizades coloridas, utilização de instrumentos facilitadores de encontros ou participações em grupos de diversificação sexual); qualidade das interações sociais ocorridas através das CALL e SMS; quantidade de caracteres e palavras nas SMS; etc. Na categoria do reconhecimento existem também outras variáveis que podem influenciar o prestígio reconhecido pelos outros elementos da rede: participação em associações, partidos políticos ou grupos religiosos; desempenho de cargos de relevo em empresas, organizações ou religião; classe social; nível de rendimentos auferidos; etc. Por fim, ao nível da categoria da integração, os autores identificam também outras variáveis que podem aferir acerca da integração no grupo: dieta para manutenção ou melhoria do aspeto físico; hobbies, *smartphone* (tipo, sistema operativo, regularidade de troca); carro ou moto (tipo, quantidade, etc.); forma de vestir; participação em eventos culturais; idas ao cinema; tempo ao ar livre; etc.

A inclusão de novos e melhores sensores em *smartphones*, *smartwatches* e outros *wearables*, irá permitir que as investigações correlacionem mais dados de contexto social e aumentem a precisão de inferência (Zenonos et al., 2016). No entanto, é também necessária mais investigação para encontrar formas de substituir os formulários de autorresposta (e.g. ALERT, TIRED, ENERGY, CALM, etc.) por métodos de inferência automática a partir da informação de contexto.

Por fim, sugerem-se também outras variáveis de contexto ambiental que podem ser consideradas para correlação em sistemas de deteção emocional: nível de ruído, humidade, luminosidade, temperatura, O<sub>2</sub> e CO<sub>2</sub>, enquanto acordado e durante o sono; nível de raios ultravioleta, humidade, pressão atmosférica, etc. fora de casa.

O reconhecimento automático de emoções é um desafio (Gunes & Piccardi, 2007) (L. S. Chen et al., 1998), porque uma emoção é um constructo produzido de forma sistemática por processos cognitivos, sentimentos subjetivos, excitação fisiológica, tendências motivacionais e reações comportamentais (J. Kim & André, 2008). Apesar do aumento de precisão dos sistemas de inferência emocional resultante da diversificação de origens de dados de contexto (Bakhtiyari & Husain, 2014), os autores acreditam que a correlação com dados de contexto social, cultural e religioso, poderá contribuir de forma positiva para a precisão de um sistema de deteção emocional. Também é nossa convicção que as emoções não podem ser inferidas apenas recolhendo dados de contexto de uma única modalidade. Com o aumento da capacidade computacional e da tecnologia de sensores, é de esperar o crescimento do número de investigações multimodalidade relacionadas com a deteção emocional (Gogia et al., 2016). Tentar inferir emoções apenas com base em sensores fisiológicos, ou na expressão facial, oral, postura, etc., será algo muito redutor do verdadeiro significado emocional. Portanto, consideramos necessário correlacionar dados de várias modalidades incluindo dados de contexto subjetivo (cf. social, cultural, religioso, pessoal, etc.) com o objetivo de aumentar a fiabilidade dos sistemas de deteção emocional.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

INVESTIGAÇÃO	EXP. FACIAL E ORAL, E POSTURA CORPORAL	CONTEXTO FISIOLÓGICO	CONTEXTO PSICOSSOCIAL	OUTRAS VARIÁVEIS
Perdiz et al. (Perdiz et al., 2017)	<b>(EXP. FACIAL)</b> HEAD.	<b>(A. MUSCULAR)</b> EMG. <b>(A. OCULAR)</b> EOG.		
S. H. Lee et al. (S. H. Lee et al., 2016)	<b>(EXP. FACIAL)</b> FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH).			
Eckert et al. (Eckert et al., 2016)	<b>(EXP. FACIAL)</b> FACS, CAU, EYES, EYEBROWS, NOSE e MOUTH.			
Matlovic et al. (Matlovic et al., 2016)	<b>(EXP. FACIAL)</b> <i>FaceReader</i> (Noldus, 2017) e <i>Shore</i> (Fraunhofer IIS, 2017)	<b>(A. CEREBRAL)</b> EEG. <b>(PELE)</b> EDA.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
Gogia et al. (Gogia et al., 2016)	<b>(EXP. FACIAL)</b> HEAD.	<b>(A. CEREBRAL)</b> EEG.		
Z. Zhang et al. (Z. Zhang et al., 2016)	<b>(EXP. FACIAL)</b> HEAD e FACS.	<b>(A. CARDÍACA)</b> BP(SBP, DBP), HR e PR. <b>(A. RESPIRATÓRIA)</b> RESP(RR). <b>(PELE)</b> EDA e ST.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
Sano & Eng (Sano & Eng, 2016)		<b>(A. CEREBRAL)</b> EEG. <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG. <b>(A. OCULAR)</b> EOG. <b>(A. GLANDULAR)</b> MELAT.	<b>(DEMOGRÁF.)</b> LIVING, AGE, GENDER, ETHNICITY, RACE, SCHOOLY e SCHOOLA. <b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, HAPPY, ALERT, ENERGY, CALM, STRESS e ANXIETY. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e APPS. <b>(INTERAÇÃO)</b> CALL, SMS, EMAIL, FTF e SOCIAL. <b>(RECONHEC.)</b> PHYSI, ACADDG, ACADCL e ACADGR. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS.	<b>(OUTRAS)</b> ACC e LIGHT.
Zhao et al. (Zhao et al., 2016)		<b>(A. CARDÍACA)</b> ECG(HR), HR e IBI(RMSSD, SDNN). <b>(A. RESPIRATÓRIA)</b> RESP.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
Zenonos et al. (Zenonos et al., 2016)		<b>(A. CARDÍACA)</b> ECG(HR(IBE(RMSSD, SDNN)), HRV) e PPG(PR, PTT).	<b>(PSICOSSOCIAL)</b> MOOD e EMOTIONS.	<b>(OUTRAS)</b> ACC.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<b>(PELE)</b> ST.		
<b>Basu et al.</b> (Basu et al., 2016)		<b>(A. CARDÍACA)</b> ECG, HR e PR. <b>(A. RESPIRATÓRIA)</b> RESP(RR). <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG.		
<b>Aracena et al.</b> (Aracena et al., 2016)		<b>(A. OCULAR)</b> PUPIL e GAZE.		
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	<b>(EXP. FACIAL)</b> FACS (HEAD, EYES, EYEBROWS, EYELIDS, CHEEKS, WRINKLES, NOSE, LIPS, CHIN, JAW).	<b>(A. OCULAR)</b> GAZE.		
<b>Turan et al.</b> (Turan et al., 2015)	<b>(EXP. FACIAL)</b> FACE e EYES.			
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	<b>(EXP. ORAL)</b> SPEECH e VOLUME.			
<b>Lalitha et al.</b> (Lalitha et al., 2015)	<b>(EXP. ORAL)</b> SPEECH, PITCH e VOLUME.			
<b>Singh et al.</b> (Singh et al., 2015)	<b>(EXP. GESTUAL E POST.)</b> SHOULDERS e HANDS.			
<b>Murali et al.</b> (Murali et al., 2015)		<b>(A. CARDÍACA)</b> ECG e ICG(PEP, PTT) e NIBP. <b>(A. RESPIRATÓRIA)</b> RESP(RR). <b>(PELE)</b> EDA.		
<b>Jaques et al.</b> (Jaques et al., 2015)		<b>(PELE)</b> EDA e ST.	<b>(PSICOSSOCIAL)</b> SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM e HAPPY. <b>(ROT. DIÁRIA)</b> LOCAL e SCREEN. <b>(INTERAÇÃO)</b> CALL, SMS e SOCIAL. <b>(RECONHEC.)</b> ACADCL, ACADST e PHYSI. <b>(INTEGRAÇÃO)</b> ACADEX, CAFFEI, ALCOH e DRUGS.	<b>(OUTRAS)</b> ACC.
<b>Cruz et al.</b> (Cruz et al., 2015)		<b>(A. OCULAR)</b> EOG.		
<b>Saha et al.</b>	<b>(EXP. GESTUAL E POST.)</b>			<b>(OUTRAS)</b> ACC.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Saha et al., 2014)	HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS e SPIN.			
<b>Matiko et al.</b> (Matiko et al., 2014)		<b>(A. CEREBRAL)</b> EEG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)			<b>(PSICOSSOCIAL)</b> PERSON e STRESS. <b>(INTERAÇÃO)</b> CALL, SMS e PROXIMITY.	<b>(OUTRAS)</b> WEATHER.
<b>Agrawal et al.</b> (Agrawal et al., 2013)	<b>(EXP. FACIAL)</b> EYES, MOUTH, LIPS e SKIN.			
<b>Soleymani et al.</b> (Soleymani et al., 2013)	<b>(EXP. FACIAL)</b> HEAD, EYES, NOSE, EYEBROWS, LIPS e MOUTH.	<b>(A. CEREBRAL)</b> EEG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Vermun et al.</b> (Vermun et al., 2013)	<b>(EXP. GESTUAL E POST.)</b> HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP e KNEES.			
<b>Kusserow et al.</b> (Kusserow et al., 2013)		<b>(A. CARDÍACA)</b> ECG(HR), HR e HR(HRV). <b>(PELE)</b> EDA e ST.	<b>(PSICOSSOCIAL)</b> MOOD e STRESS.	<b>(OUTRAS)</b> ACC.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)		<b>(A. CARDÍACA)</b> ECG(HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)		<b>(A. CARDÍACA)</b> NIBP. <b>(A. RESPIRATÓRIA)</b> RESP(RR).		
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		<b>(PELE)</b> EDA.	<b>(PSICOSSOCIAL)</b> PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED e STRESS. <b>(ROT. DIÁRIA)</b> LOCAL, SCREEN e ELECTR. <b>(INTERAÇÃO)</b> CALL e SMS. <b>(INTEGRAÇÃO)</b> ALCOH e CAFFEI.	<b>(OUTRAS)</b> ACC.
<b>Raudonis</b> (Raudonis, 2013)		<b>(A. OCULAR)</b> EYES, GAZE e PUPIL.		
<b>Kawai et al.</b> (Kawai et al., 2013)		<b>(A. OCULAR)</b> PUPIL.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Babiker et al.</b>		<b>(A. OCULAR)</b>	<b>(PSICOSSOCIAL)</b>	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Babiker et al., 2013)		EYES, GAZE e PUPIL.	EMOTIONS.	
<b>LikamWa et al.</b> (LiKamWa et al., 2013)			<b>(PSICOSSOCIAL)</b> MOOD. <b>(ROT. DIÁRIA)</b> APPS, BROWSER e LOCAL. <b>(INTERAÇÃO)</b> SMS, EMAIL e CALL.	
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)		<b>(A. CEREBRAL)</b> EEG. <b>(A. CARDÍACA)</b> HR, HRV, PEP, SV e BP(SBP, DBP). <b>(A. RESPIRATÓRIA)</b> RESP(VT, ROS, RR). <b>(PELE)</b> EDA, nSRR e ST.		
<b>C. Y. Chang et al.</b> (Chang et al., 2012)		<b>(A. CARDÍACA)</b> ECG, PR e BVP. <b>(PELE)</b> EDA.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)			<b>(ROT. DIÁRIA)</b> LOCAL. <b>(INTERAÇÃO)</b> PROXIMITY, CALL e SMS.	
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	<b>(EXP. FACIAL)</b> HEAD e FACE.			
<b>Dhall et al.</b> (Dhall et al., 2011)	<b>(EXP. FACIAL)</b> FACE.			
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)		<b>(A. CARDÍACA)</b> ECG(HRV) e PPG. <b>(A. OCULAR)</b> PUPIL.		
<b>Hernandez et al.</b> (Hernandez et al., 2011)		<b>(PELE)</b> EDA.	<b>(PSICOSSOCIAL)</b> STRESS. <b>(INTERAÇÃO)</b> CALL.	
<b>N. Lane et al.</b> (N. Lane et al., 2011)			<b>(PSICOSSOCIAL)</b> SLEEP, DEPRESSION e WELLBEING. <b>(ROT. DIÁRIA)</b> LOCAL. <b>(INTERAÇÃO)</b> TALK. <b>(RECONHEC.)</b> PHYSI.	<b>(OUTRAS)</b> ACC.
<b>H. Wang et al.</b> (H. Wang et al., 2010)	<b>(EXP. FACIAL)</b> EYES.			
<b>Bos</b> (Bos, 2010)		<b>(A. CEREBRAL)</b> EEG.		

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Y. Liu et al.</b> (Y. Liu et al., 2010)		<b>(A. CEREBRAL)</b> EEG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Setz et al.</b> (Setz et al., 2010)		<b>(PELE)</b> EDA.		
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)		<b>(A. CARDÍACA)</b> ECG(HR, HRV). <b>(A. RESPIRATÓRIA)</b> RESP(RR, BRV). <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.		
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)		<b>(A. CARDÍACA)</b> ECG(HR, HRV, IBI). <b>(A. RESPIRATÓRIA)</b> RESP(RR, RDEP). <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)		<b>(A. CARDÍACA)</b> ECG(HR, IBI). <b>(PELE)</b> EDA. <b>(A. OCULAR)</b> PUPIL.		
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	<b>(EXP. FACIAL)</b> LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD e JAW. <b>(EXP. GESTUAL E POST.)</b> SHOULDERS, HANDS, FINGERS, FISTS, PALMS e NECK.			
<b>Castellano et al.</b> (Castellano et al., 2007)	<b>(EXP. GESTUAL E POST.)</b> ARMS.			
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)		<b>(A. CARDÍACA)</b> ECG(HR). <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Sebe et al.</b> (Sebe et al., 2006)	<b>(EXP. FACIAL)</b> HEAD, EYEBROWS, EYELIDS e MOUTH. <b>(EXP. ORAL)</b> VOLUME, SPEECH e PITCH.			
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)		<b>(A. CARDÍACA)</b> BVP(ABI). <b>(PELE)</b> EDA e ST.		<b>(OUTRAS)</b> TEMP e LIGHT.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<b>(A. OCULAR)</b> PUPIL.		
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)		<b>(A. CARDÍACA)</b> ECG(HR, HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> STRESS.	
<b>Herbon et al.</b> (Herbon et al., 2005)		<b>(A. CARDÍACA)</b> HR. <b>(PELE)</b> EDA e ST. <b>(A. OCULAR)</b> PUPIL.	<b>(DEMOGRÁF.)</b> AGE e GENDER. <b>(PSICOSSOCIAL)</b> HEALTH e EMOTIONS. <b>(ROT. DIÁRIA)</b> TECHEXPRT.	
<b>Partala et al.</b> (Partala et al., 2005)		<b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Van Eck et al.</b> (van Eck et al., 2005)		<b>(A. GLANDULAR)</b> CORT.	<b>(PSICOSSOCIAL)</b> LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS e EMOTIONS. <b>(RECONHEC.)</b> PHYSI. <b>(INTEGRAÇÃO)</b> SMOKING, FOOD, CAFFEI e ALCOH.	
<b>Busso et al.</b> (Busso et al., 2004)	<b>(EXP. FACIAL)</b> FOREHEAD, EYEBROWS, EYES e CHEEKS. <b>(EXP. ORAL)</b> PITCH e VOLUME.			
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)		<b>(A. CARDÍACA)</b> HR. <b>(PELE)</b> EDA e ST.	<b>(DEMOGRÁF.)</b> AGE, GENDER, e ETHNICITY. <b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		<b>(A. CARDÍACA)</b> ECG(HR, HRV) e PPG. <b>(PELE)</b> EDA e ST.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Haag et al.</b> (Haag et al., 2004)		<b>(A. CARDÍACA)</b> PPG(BVP(HR)) e ECG(HR). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG.		
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)		<b>(A. OCULAR)</b> PUPIL.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>C J Harmer et al.</b> (C J Harmer et al., 2003)		<b>(A. GLANDULAR)</b> SEROT.	<b>(PSICOSSOCIAL)</b> MOOD, ENERGY, ANXIETY e EMOTIONS*.	
<b>Nwe et al.</b> (Nwe et al., 2001)	<b>(EXP. ORAL)</b> SPEECH.			
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)		<b>(A. MUSCULAR)</b> EMG. <b>(A. GLANDULAR)</b> CORT.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)		<b>(A. CARDÍACA)</b> PPG(BVP(HR)) e ECG(HR, HRV). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> STRESS.	
<b>Vrijotte et al.</b> (Vrijotte et al., 2000)		<b>(A. CARDÍACA)</b> BP(SBP, DBP) e ECG(HR, HRV, IBI(RMSSD (VAGAL))).	<b>(DEMOGRÁF.)</b> AGE. <b>(PSICOSSOCIAL)</b> PERSON, STRESS e MOOD. <b>(RECONHEC.)</b> ACADDG, PHYSI, WORKYEARS, WEIGHT, HEIGHT, BMI e WAIST. <b>(INTEGRAÇÃO)</b> CAFFEI, ALCOH e SMOKING.	<b>(OUTRAS)</b> ACC.
<b>Ritz et al.</b> (Ritz et al., 2000)		<b>(A. CARDÍACA)</b> HR, BP(SBP, DBP). <b>(A. RESPIRATÓRIA)</b> ROS, RR e VT. <b>(PELE)</b> EDA.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	<b>(EXP. FACIAL)</b> EYES, EYEBROWS, MOUTH, WRINKLES e FROWN. <b>(EXP. ORAL)</b> SPEECH e PITCH.			
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)		<b>(A. CARDÍACA)</b> PPG(BVP(HR)). <b>(A. RESPIRATÓRIA)</b> RESP. <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.		
<b>Rajita Sinha</b> (Rajita Sinha, 1996)		<b>(A. CARDÍACA)</b> ECG(HR) e BP(SBP, DBP). <b>(PELE)</b> EDA e ST. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<b>(A. OCULAR)</b> EOG.		
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)		<b>(A. CARDÍACA)</b> ECG(HR). <b>(PELE)</b> EDA. <b>(A. MUSCULAR)</b> EMG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	
<b>R Sinha et al.</b> (R Sinha et al., 1992)		<b>(A. CARDÍACA)</b> ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP) e PCG.	<b>(PSICOSSOCIAL)</b> EMOTIONS.	

() representa um sinal raw

### 3. INSTRUMENTOS & SENSORES DE RECOLHA

O reconhecimento emocional é uma área de investigação interdisciplinar que envolve vários campos do conhecimento: ciências da computação, ciências cognitivas e psicologia (Aracena et al., 2016). A capacidade dos sistemas reconhecerem as emoções das pessoas e adequar as suas ações em função desse reconhecimento, é uma área de investigação de *Human-Computer Interaction* (HCI) (Gunes & Piccardi, 2007) (Jerritta et al., 2011). Dotar os computadores e robots com a capacidade de entender emoções é uma área de estudo do *Affective Computing* (AC) (Gogia et al., 2016) (Zhai & Barreto, 2006), e será um passo importante para facilitar a interação entre dispositivos e pessoas (Jerritta et al., 2011) (Alabdulkarim, 2015) (Rani & Sarkar, 2006).

Perante a incapacidade de medir as emoções diretamente (Nawasalkar et al., 2013), os investigadores recorrem a instrumentos e sensores para recolher dados de contexto a serem correlacionados pelos sistemas de deteção emocional (Sano & Eng, 2016). Apesar do carácter objetivo dos dados recolhidos pelos dispositivos, o seu significado emocional não é direto, conhecendo-se apenas a sua influência bidirecional nas emoções (i.e. as emoções são influenciadas e podem influenciar os sinais de contexto) (Rani & Sarkar, 2006). Os questionários, por seu lado, permitem a recolha de informação direta do que se pretende avaliar (e.g. emoções), mas o teor subjetivo das respostas dadas pelas pessoas pode conduzir a medições imprecisas (Caballe, 2015) (Sano & Eng, 2016) (Johnston, Propper, & Shields, 2009). Neste contexto, os investigadores optam pela recolha de dados de ambos os tipos (cf. medição objetiva e subjetiva), com o objetivo de os correlacionar e daí extrair a dedução automática de emoções (Rani & Sarkar, 2006) (Nawasalkar et al., 2013) (Gogia et al., 2016).

Os instrumentos de medição objetiva, apesar de recolherem dados com precisão, implicam investimento e a utilização de sensores que podem ser obstrutivos ou intrusivos (Guinot Jimeno, Yuste Bielsa, Cuadros Fernández, Lorente Rodríguez, & Mercadé Bellido, 2011). Já a medição subjetiva obtida pelos questionários e entrevistas, facilitam de alguma forma a generalização (e.g. o *Product Emotion Measurement Instrument* (PrEmo) permite que os respondentes não tenham que verbalizar as emoções sentidas (Wassink, 2013)) e são as técnicas mais utilizadas para a avaliação emocional (Fulton & Medlock, 2003) (Mandryk & Atkins, 2007). Neste contexto, decidimos resumir os instrumentos e sensores das investigações em estudo, agrupando-os pelo tipo de medição que efetuam, i.e. objetiva ou subjetiva.

Com o objetivo de facilitar a leitura dos dados, decidimos identificar os instrumentos utilizados pelos autores entre chavetas (i.e. {}) indicando tratar-se de um instrumento e o sinal recolhido dentro de parêntesis curvos (i.e. ()) simbolizando dados recolhidos do contexto (i.e. *raw*).

O quadro seguinte resume os vários instrumentos utilizados pelos investigadores considerados no presente levantamento bibliográfico.

DESCRIÇÃO	ID	OBJETIVO	TIPO
<b>MEDIÇÃO OBJETIVA</b>			
<b>Grass 78B</b>	<b>78B</b>	Dispositivo utilizado na medição de sinais fisiológicos.	T. obstrutivas
<b>Câmara Infrared A655sc</b>	<b>A655SC</b>	Câmara para recolha de imagens térmicas de alta resolução.	T. não obstrutivas
<b>Biosemi Active II</b>	<b>ACTIVEII</b>	Dispositivo para recolher sinais a partir de elétrodos.	T. obstrutivas

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Affectiva Q</b>	<b>AFFECTIVAQ</b>	Permite a recolha do EDA, ST e ACC sem fios.	T. pouco obstrutivas
<b>App</b>	<b>APP</b>	Aplicação referenciada e não totalmente identificada pelo autor.	T. não obstrutivas
<b>Applied Science Laboratories 4000</b>	<b>ASL4000</b>	Dispositivo para monitorização da PUPIL.	T. obstrutivas
<b>Applied Science Laboratories 504</b>	<b>ASL504</b>	Câmara e fonte infrared para rastreamento ocular.	T. obstrutivas
<b>Audio</b>	<b>AUDIO</b>	Sequências de audio pré-gravadas ou capturadas em tempo real.	T. não obstrutivas
<b>BeWell</b>	<b>BEWELL</b>	Aplicação que promove a saúde e bem-estar pessoal do utilizador.	T. não obstrutivas
<b>Zephyr BioHarness</b>	<b>BIOHARNESS</b>	Dispositivo <i>wireless</i> para recolha do ECG e RESP.	T. pouco obstrutivas
<b>Brainquiry PET</b>	<b>BQPET</b>	Dispositivo para recolher o EEG.	T. pouco obstrutivas
<b>High Fidelity 3D Facial Image Capture</b>	<b>DI3D</b>	Sistema de captura de imagem.	T. não obstrutivas
<b>EyeLink 1000</b>	<b>EL1000</b>	Rastreador ocular utilizado na recolha de dados da PUPIL.	T. obstrutivas
<b>Emotion-Board</b>	<b>EMOTIONBOARD</b>	Dispositivo para medir o EDA nos dedos.	T. pouco obstrutivas
<b>EmotionSense</b>	<b>EMOTIONSENSE</b>	Aplicação utilizada em estudos de psicologia social para deteção emocional.	T. não obstrutivas
<b>Emotiv Epop</b>	<b>EPOC</b>	Dispositivo para recolha do EEG.	T. obstrutivas
<b>EQ-Radio</b>	<b>EQ-RADIO</b>	Sistema de reconhecimento emocional com base no sinal WiFi.	T. não obstrutivas
<b>Existing data (dados existentes)</b>	<b>EXISTINGDATA</b>	Dados obtidos a partir de outras fontes de informação (e.g. outros sistemas).	T. não obstrutivas
<b>FaceReader</b>	<b>FACEREADER</b>	Sistema de deteção emocional para imagens ou vídeos.	T. não obstrutivas
<b>Cambridge Face Tracker</b>	<b>FACETRACKER</b>	Sistema de reconhecimento facial.	T. não obstrutivas
<b>ADInstruments FE-116 GSR</b>	<b>FE116</b>	Dispositivo utilizado na recolha do EDA.	T. obstrutivas
<b>Hans Rudolph flow head 3803</b>	<b>FH3803</b>	Dispositivo utilizado na medição do VT e RR.	T. obstrutivas
<b>TNO Biomedical Instrumentation IV</b>	<b>FINAPRESS4</b>	Instrumento utilizado para recolher dados da atividade cardíaca.	T. obstrutivas
<b>FlexComp Infiniti</b>	<b>FLEXCOMP</b>	Sistema de aquisição e monitorização para sinais de contexto fisiológico.	T. obstrutivas
<b>Funf</b>	<b>FUNF</b>	Aplicação para recolha de dados de contexto do utilizador do smartphone.	T. não obstrutivas
<b>GM Instruments CS5</b>	<b>GMCS5</b>	Dispositivo utilizado na medição do VT e RR.	T. obstrutivas
<b>Koralewski Health Lab</b>	<b>HEALTHLAB</b>	Sistema para recolha de dados de contexto fisiológico.	T. obstrutivas
<b>Herbon (Herbon et al., 2005)</b>	<b>HERBON</b>	Dispositivo criado pelo autor para recolha de dados da PUPIL.	T. pouco obstrutivas
<b>I-cortisol</b>	<b>I-CORTISOL</b>	Dispositivo utilizado no processo de medição do CORT.	T. obstrutivas

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Jawbone</b>	<b>JAWBONE</b>	Pulseira para recolha de atividades, padrões de sono, atividade cardíaca, etc.	T. pouco obstrutivas
<b>Kinect Sensor</b>	<b>KINECT</b>	Sensor de movimento criado para interação gestual.	T. não obstrutivas
<b>Kusserow (Kusserow et al., 2013)</b>	<b>KUSSEROW2</b>	Sistema para monitorizar a prestação dos violoncelistas.	T. pouco obstrutivas
<b>Kusserow (Kusserow et al., 2013)</b>	<b>KUSSEROW3</b>	Sistema para monitorizar a prestação de atletas ( <i>ski jumping</i> ).	T. pouco obstrutivas
<b>Kusserow (Kusserow et al., 2013)</b>	<b>KUSSEROW4</b>	Sistema para monitorizar o stress em tarefas diárias.	T. pouco obstrutivas
<b>Manual</b>	<b>MANUAL</b>	Atividade manual (habitual) sem recurso a utilização de dispositivo.	T. obstrutivas
<b>Neurosky MindWave</b>	<b>MINDWAVE</b>	Dispositivo para recolha do sinal EEG.	T. pouco obstrutivas
<b>ADInstruments ML-135</b>	<b>ML135</b>	Dispositivo utilizado na recolha de dados fisiológicos.	T. obstrutivas
<b>ADInstruments ML-309</b>	<b>ML309</b>	Dispositivo utilizado na recolha da temperatura.	T. obstrutivas
<b>ADInstruments ML870 PowerLab 8/30</b>	<b>ML870</b>	Dispositivo utilizado na recolha de dados fisiológicos.	T. obstrutivas
<b>g.MOBilab+</b>	<b>MOBILAB</b>	Sistema portátil de aquisição de sinais fisiológicos (e.g. EEG, EMG, EOG, etc.)	T. obstrutivas
<b>Grass Model15</b>	<b>MODEL15</b>	Dispositivo utilizado na recolha de dados de contexto (e.g. CORT).	T. obstrutivas
<b>MoodScope</b>	<b>MOODSCOPE</b>	Aplicação para inferir a disposição do utilizador.	T. não obstrutivas
<b>Motion Logger</b>	<b>MOTIONLOGGER</b>	Dispositivo utilizado para estimação do sono e recolha de dados ambientais.	T. pouco obstrutivas
<b>BioPac MP100</b>	<b>MP100</b>	Dispositivo utilizado na recolha de dados fisiológicos.	T. obstrutivas
<b>BioPac MP150</b>	<b>MP150</b>	Dispositivo utilizado na recolha de dados fisiológicos.	T. obstrutivas
<b>Murali (Murali et al., 2015)</b>	<b>MURALI</b>	Sistema para recolha de dados fisiológicos (e.g. ECG, ICG, etc.)	T. obstrutivas
<b>BioPac NIBP100D</b>	<b>NIBP100D</b>	Sistema de monitorização não invasiva de BP.	T. obstrutivas
<b>Pictures (imagens)</b>	<b>PICTURES</b>	Sequência de imagens pré-gravadas ou capturadas em tempo real.	T. não obstrutivas
<b>Procomp Infiniti</b>	<b>PROCOMP</b>	Dispositivo para recolha de vários sinais fisiológicos (e.g. EMG, EDA, ECG e RESP).	T. obstrutivas
<b>Raudonis (Raudonis, 2013)</b>	<b>RAUDONIS</b>	Dispositivo criado pelo autor para rastrear o olhar.	T. pouco obstrutivas
<b>Coulbourn S71-22</b>	<b>S71-22</b>	Dispositivo utilizado para recolher dados fisiológicos.	T. obstrutivas
<b>Coulbourn S75-01 Hi Gain Bioamplifier S75-01</b>	<b>S75-01</b>	Dispositivo utilizado para recolher dados fisiológicos.	T. obstrutivas
<b>Spacelabs 90207</b>	<b>S90207</b>	Permite a medição de BP em ambulatório	T. obstrutivas
<b>Sarstedt Salivette</b>	<b>SALIVETTE</b>	Dispositivo utilizado na recolha de saliva.	T. obstrutivas
<b>Shore</b>	<b>SHORE</b>	Sistema para deteção emocional em tempo real.	T. não obstrutivas
<b>Toshiba Silmee Bar Type</b>	<b>SILMEEBTYP</b>	Dispositivo para recolha ECG, PPG e BP	T. pouco obstrutivas

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Tohisba Silmee W20/W21	SILMEEW2X	Pulseira utilizada para rastreamento da atividade física (recolhe o ST e HR).	T. pouco obstrutivas
Siemens Siregnost FD 5	SIREGNOSTFD5	Dispositivo utilizado na medição do ROS.	T. obstrutivas
Talk Assistant	TALKASSIST	Sistema criado para monitorizar a prestação do orador durante o discurso.	T. pouco obstrutivas
T-Sens GSR	TGSR	Dispositivo para recolha de EDA através dos dedos.	T. obstrutivas
Tobii Pro TX300	TX300	Sistema utilizado para recolha de informação relacionada com a PUPIL.	T. não obstrutivas
Undefined<tag> (indefinido<etiqueta>)	UNDEFINED<TAG >	Dispositivo não referenciado para recolha do sinal indicado em <TAG>.	T. obstrutivas
Video	VIDEO	Sequências de vídeo pré-gravadas ou capturadas em tempo real.	T. não obstrutivas
VU-MAS	VU-MAS	Sistema para aquisição de sinais de contexto fisiológico (e.g. HR).	T. obstrutivas
Sony XC-EI30	XCEI30	Câmara de vídeo profissional para recolha de imagem.	T. não obstrutivas
Zhang (J. Zhang et al., 2013)	ZHANG	Sistema específico do autor para recolha do EOG através de eléctrodos.	T. pouco obstrutivas
<b>MEDIÇÃO SUBJETIVA</b>			
Affect Grid	AFFECTGRID	Questionário não-verbal baseado no CIRCUMPLEX para recolha de EMOTIONS.	Questionários formais
Affect Intensity Measure	AIM	Questionário utilizado para avaliar EMOTIONS em eventos da vida.	Questionários formais
Beck Depression Inventory	BDI	Questionário usado para avaliar a DEPRESSION.	Questionários formais
Beck Depression Inventory	BDI	Questionário para avaliar a DEPRESSION.	Questionários formais
Big Five Inventory Personality Test	BFIPT	Questionário para avaliar a PERSON.	Questionários formais
Befindlichkeits Scale (Zerssen Mood Scale)	BFS	Questionário para medir a MOOD.	Questionários formais
Circumplex Model of Affect	CIRCUMPLEX	Questionário não-verbal utilizado para representar emoções (adaptado por LikamWa et al. (LiKamWa et al., 2013) para recolha de EMOTIONS).	Questionários formais
Differential Emotion Scale	DES	Questionário utilizado para medir EMOTIONS.	Questionários formais
Effort-Reward Imbalance	ERI	Questionário utilizado para medir o STRESS relacionado com o trabalho.	Questionários formais
Escala de Satisfação com o Suporte Social	ESSS	Questionário para avaliação do suporte social recebido.	Questionários formais
Goldberg Anxiety and Depression Scale	GADS	Questionário para avaliação da DEPRESSION e ANXIETY.	Questionários formais
HealthyOffice	HEALTHYOFFICE	App para smartphone para <i>self-reporting</i> da MOOD.	Questionários formais
Informal questionnaire	INFORMAL	Questionário com validade não verificada.	Questionários informais

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Long-term Difficulties Inventory</b>	<b>LDI</b>	Questionário para avaliação das DIFICULTIES diárias.	Questionários formais
<b>List of Threatening Experiences</b>	<b>LTE</b>	Questionário para avaliar a exposição a ameaças e eventos de vida marcantes (LIFEEVENTS)	Questionários formais
<b>Myers Briggs Type Indicator</b>	<b>MBTI</b>	Questionário para categorizar PERSON.	Questionários formais
<b>Marlowe-Crowne Social Desirability Scale</b>	<b>MCSDS</b>	Questionário utilizado para medir a desejabilidade social	Questionários formais
<b>Minnesota Multiphasic Personality Inventory</b>	<b>MMPI</b>	Questionário utilizado para avaliar PERSON.	Questionários formais
<b>Oxford Happiness Questionnaire</b>	<b>OHQ</b>	Questionário para medir a HAPPY.	Questionários formais
<b>Positive And Negative Affect Schedule</b>	<b>PANAS</b>	Questionário para medir EMOTIONS.	Questionários formais
<b>Positive And Negative Affect Schedule – Expanded Form</b>	<b>PANAS-X</b>	Versão expandida do questionário PANAS.	Questionários formais
<b>Patient Health Questionnaire</b>	<b>PHQ-9</b>	Questionário para avaliação da DEPRESSION.	Questionários formais
<b>Profile Of Mood States</b>	<b>POMS</b>	Questionário para avaliar a MOOD.	Questionários formais
<b>Emotion Measurement Instrument</b>	<b>PREMO</b>	Questionário não-verbal para avaliar EMOTIONS.	Questionários formais
<b>Psychosomatic Symptom Checklist</b>	<b>PSC</b>	Questionário utilizado para medir a HEALTH.	Questionários formais
<b>Pittsburgh Sleep Quality Index</b>	<b>PSQI</b>	Questionário para medir a qualidade e padrões do SLEEP.	Questionários formais
<b>Perceived Stress Scale</b>	<b>PSS</b>	Questionário utilizado para medir o STRESS.	Questionários formais
<b>Questionnaire for Mental Imagery</b>	<b>QMI</b>	Questionário para avaliar a capacidade de interpretação de imagens.	Questionários formais
<b>Rosenberg Self-Esteem Scale</b>	<b>RSES</b>	Questionário utilizado na avaliação da auto-estima.	Questionários formais
<b>Self-Assessment Manikin</b>	<b>SAM</b>	Questionário não-verbal para medir EMOTIONS.	Questionários formais
<b>Self-assessment Morningness-Eveningness</b>	<b>SAME</b>	Questionário para recolher informação acerca dos ciclos circadianos (e.g. SLEEP).	Questionários formais
<b>Zung Self-rating Depression Scale</b>	<b>SDS</b>	Questionário para avaliar a DEPRESSION.	Questionários formais
<b>Short-Form 12</b>	<b>SF-12</b>	Questionário para medir a qualidade de vida relacionada com a HEALTH.	Questionários formais
<b>Social Readjustment Rating Scale</b>	<b>SRRS</b>	Questionário para medição de eventos stressantes da vida.	Questionários formais
<b>State-Trait Anxiety Inventory</b>	<b>STAI</b>	Questionário utilizado na medição da ANXIETY.	Questionários formais
<b>Spielberger State-Trait Anger Scale</b>	<b>STAS</b>	Escala utilizada para medir a ANGER.	Questionários formais

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Toronto Alexithymia Scale	TAS	Questionário para avaliar a capacidade de interpretação de emoções.	Questionários formais
<b>OUTROS INSTRUMENTOS</b>			
Biopac AcqKnowledge	ACQK	Aplicação para tratamento da informação proveniente de instrumentos de recolha.	Outros Instrumentos
BioExplorer	BIOEXPLORER	Aplicação para <i>neurofeedback</i> e <i>biofeedback</i> .	Outros Instrumentos
BioGraph Infinity	BIOGRAPH	Aplicação utilizada como suporte à gravação e análise de dados de forma gráfica.	Outros Instrumentos
Captiv	CAPTIV	Aplicação que facilita o processo de gravação de dados.	Outros Instrumentos
Hitachi MS-DS400	DS400	Utilizado para apoiar na gravação de vídeo.	Outros Instrumentos
Emotion Avatar Images	EAI	Utilizado para simular comportamentos através de imagens de avatar.	Outros Instrumentos
Epoc SDK	EPOC-SDK	SDK para permitir a integração com o EPOC-SDK.	Outros Instrumentos
Human Activity Recognition	HAR	Algoritmo para reconhecimento de atividades humanas (e.g. andar, sentar, etc.)	Outros Instrumentos
Matlab HRVAS	HRVAS	<i>AddOn</i> do MATLAB para extração do HRV.	Outros Instrumentos
Interview (entrevista)	INTERVIEW	Técnica utilizada para recolha de dados e <i>screening</i> .	Outros Instrumentos
Kinect SDK	KINECT-SDK	SDK para permitir a integração com o KINECT.	Outros Instrumentos
ADInstruments LabChart	LABCHART	Aplicação utilizada para suporte à aquisição de dados e pré-processamento.	Outros Instrumentos
Grass Link15	LINK15	Aplicação que apoia no processo de gravação de dados do MODEL15.	Outros Instrumentos
Mindwave SDK	MINDWAVE-SDK	SDK para permitir a integração com o MINDWAVE.	Outros Instrumentos
Observation (observação)	OBSERVATION	Técnica utilizada para recolha de dados.	Outros Instrumentos
PsyScope	PSYSCOPE	Ferramenta utilizada no controlo experimental.	Outros Instrumentos
Tobii Studio	TSTUDIO	Aplicação utilizada nas investigações com sinais relacionados com o contexto ocular.	Outros Instrumentos

### 3.1. MEDIÇÃO OBJETIVA

Os dados obtidos pelos dispositivos tendem a representar pontos objetivos de dados de contexto (Rani & Sarkar, 2006) (e.g. o valor HR, ST ou número de CALL, representam de forma objetiva medições do contexto cardíaco, da pele e da interação social). Apesar de não ser possível mapear esses dados diretamente em emoções, podem fornecer informação importante para a inferência do estado cognitivo e emocional das pessoas (Schumm et al., 2010).

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

A necessidade de recolher dados de contexto significa instalar meios de recolha (e.g. dispositivos e sensores) que podem obstruir os hábitos diários do utilizador. No entanto, para ser possível a recolha imparcial e precisa de dados de contexto, as pessoas têm que estar inconscientes da presença desses instrumentos (Ouwerkerk, Pasveer, & Langereis, 2008) (Alabdulkarim, 2015). Neste contexto a obstrutividade dos dispositivos assume um papel importante a ter em conta no momento de decidir quais utilizar porque, se influenciarem o ambiente natural do utilizador, podem também estar a diminuir qualidade dos dados recolhidos subtraindo-lhes imparcialidade (Ouwerkerk et al., 2008). A intrusividade é também um aspeto importante a ter em conta atendendo a que se recolhem dados de cariz privado. Inspeccionar o contexto significa aceder a informação sensível e particular dos utilizadores havendo questões de segurança e de ordem ética a assegurar. Não obstante a importância da intrusividade, é na obstrutividade dos dispositivos que pretendemos incidir o estudo nesta secção por causa da necessidade de assegurar a qualidade dos dados recolhidos, reduzindo a possibilidade de contaminação. Neste contexto, utilizaremos o termo obstrutividade para representar o possível bloqueio das atividades normais das pessoas, causado pela utilização de instrumentos de recolha.

As abordagens obstrutivas alteram os hábitos dos utilizadores, utilizam dispositivos e sensores incómodos, ou necessitam de inserção manual de dados perturbando as atividades normais das pessoas (Z. Chen et al., 2013). Mas a obstrutividade também deve ser analisada noutro prisma: quanto menor for o grau de obstrutividade, mais fácil será a predisposição das pessoas para aceitarem a recolha de dados do seu contexto (Schumm et al., 2010). Assim, dada a importância da obstrutividade no processo de recolha de dados, decidimos classificar os diferentes dispositivos e sensores de medição objetiva presentes nas investigações analisadas, em função dessa característica: técnicas não obstrutivas; técnicas pouco obstrutivas; e técnicas obstrutivas.

Esta categorização baseia-se na nossa avaliação subjetiva da obstrutividade causada por cada dispositivo relatado, e pretende suportar o processo de seleção de instrumentos e sensores a utilizar durante a fase experimental da nossa investigação. Pretendemos selecionar instrumentos cuja utilização passe o mais despercebido possível para o utilizador, não obstruindo a sua normal atividade e assim, diminuir o risco de interferência nos valores recolhidos, conferindo-lhes qualidade.

#### 3.1.1. Técnicas não obstrutivas

Nesta secção abordam-se as técnicas que não implicam obstrutividade para os utilizadores ou que apresentam um grau tão baixo que pode ser considerado negligenciável (e.g. quebra ligeira de desempenho causada pela instalação de uma nova aplicação no *smartphone* ou computador). Incluem-se também nesta secção os dispositivos que, apesar de terem sido utilizados nas investigações em ambientes controlados e, por esse facto, apresentarem alguma obstrutividade em fase de experimentação, a sua implementação real poderá representar um nível de obstrutividade nulo ou muito residual (e.g. câmeras de vídeo). Por fim, incluem-se também os dados de contexto provenientes de bases de dados existentes tipicamente administradas e alimentadas por organizações públicas ou organismos estatais (e.g. Instituto Português do Mar e da Atmosfera (IPMA)).

Para recolher dados são necessários dispositivos e sensores. A única forma de conseguir este objetivo sem influenciar o ambiente das pessoas, será utilizando ou melhorando dispositivos ou sensores que já fazem parte do seu quotidiano. Assim, é incontornável analisar a utilização dos

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

*smartphones* como meio para recolher dados de contexto. Os *smartphones* são plataformas pervasivas para *sensing* oportunista de comportamentos e de opiniões (Madan et al., 2012). Como ocupam atualmente um lugar fixo na vida do ser humano (Eckert et al., 2016) (N. D. Lane et al., 2010) e são utilizados por milhões de pessoas, os *smartphones* são a ferramenta mais adequada para suportar a recolha não obstrutiva de dados em investigações da área social ou psicofisiológica (Rachuri et al., 2010). Os *smartphones* podem ser vistos como plataformas programáveis para monitorização e rastreamento do bem-estar das pessoas (N. D. Lane et al., 2010). Atualmente já é possível a inferência em tempo real de comportamentos permitindo, por exemplo, que os utilizadores recebam *feedback* acerca das suas escolhas relacionadas com o *lifestyle* ou saúde (N. Lane et al., 2011). Apesar de já serem distribuídos com vários sensores embebidos (e.g. acelerómetro, giroscópio, GPS, câmara, microfone, etc.) é de esperar que a evolução tecnológica promova o aumento do número de sensores que integram os *smartphones*, alargando de forma iterativa no tempo o leque de possíveis aplicações (N. Lane et al., 2011) (N. D. Lane et al., 2010). Assim, é expectável o aumento do número de aplicações relacionadas com a monitorização e avaliação do bem-estar físico, social e mental dos utilizadores (N. Lane et al., 2011).

São várias as variáveis de contexto possíveis de extrair do *smartphone* (e.g. CALL, SMS, lista de contactos, localização, proximidade, humidade, etc.) (Jaques et al., 2015) (Bogomolov et al., 2014) (Sano & Eng, 2016) (Sano & Picard, 2013b), permitindo uma análise das interações sociais de forma contínua, e conseguindo maior precisão do que os métodos tradicionais na avaliação social (e.g. questionários, entrevistas e observação) (Madan et al., 2012). Com base nos *logs* do *smartphone*, os investigadores conseguem criar nova informação relacionada com a vida dos utilizadores: Bogomolov et al., estudou formas de reconhecer automaticamente a felicidade das pessoas (Bogomolov, Lepri, & Pianesi, 2013); Moturu et al. estudou a relação entre o sono, disposição e os dados da interação social (Moturu et al., 2011); Dong et al. criou um modelo para definir a estrutura das interações sociais num dormitório de alunos (Dong et al., 2011); Li et al., criou um sistema para reconhecimento da solidão (Li, Shi, Wang, & Liu, 2016); Sano et al., Bogomolov et al. e Bauer et al., estudaram o stress e formas de o prever (Sano & Picard, 2013b) (Bogomolov et al., 2014) (Bauer & Lukowicz, 2012); Chet et al. utilizou o *smartphone* para monitorizar o sono de forma não obstrutiva (Z. Chen et al., 2013); etc.

São várias as aplicações de *smartphone* usadas pelos investigadores para recolher e processar dados de contexto: o *MoodScope* {**MOODSCOPE**} infere a disposição do utilizador com base em dados de utilização do *smartphone* (cf. SMS, EMAIL, CALL, APPS, BROWSER e LOCAL) (LiKamWa et al., 2013); o *EmotionSense* {**EMOTIONSENSE**} é uma plataforma para estudos da psicologia social que tem a capacidade de detetar atividades e emoções do utilizador, e interações verbais e de proximidade entre elementos de grupos sociais (Rachuri et al., 2010); o *funf* {**FUNF**} é uma plataforma de *sensing* utilizada para recolha de dados de contexto social a partir do *smartphone* (e.g. CALL, SMS, etc.) (Aharony & Gardner, 2011); e o *BeWell* {**BEWELL**} é uma aplicação que promove a saúde pessoal ajudando o utilizador na gestão do seu bem-estar através da monitorização da atividade física, interação social e padrões de sono (N. Lane et al., 2011). Além destas, existem outras aplicações referenciadas nas investigações que não são totalmente identificadas pelos autores {**APP**} (e.g. (Muaremi et al., 2012), (Eckert et al., 2016), etc.) ou que são modificadas a partir de outras já existentes (e.g. Sano et al. modificou o FUNF na sua investigação (Sano & Eng, 2016)).

Outra forma de recolher dados de forma não obstrutiva será através da utilização de sensores já existentes no ambiente natural dos utilizadores (e.g. câmaras, microfones, sinal WiFi, etc.).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Consideram-se neste grupo os dispositivos que permitem a recolha passiva de **vídeo**, **áudio** e **imagem**, e que não significam qualquer ação ou alteração de comportamentos pelo utilizador. A literatura relata várias experiências com utilização de instrumentos relacionados com vídeo **{VIDEO}**, áudio **{AUDIO}** ou imagem **{PICTURES}** que, apesar de significarem a obstrutividade natural de um experimento em laboratório, podem significar baixa ou nenhuma obstrutividade em implementações reais (e.g. (S. H. Lee et al., 2016)). Incluem-se nestes grupos os recursos pré-recolhidos (e.g. sequências de vídeo, trechos de áudio ou fotografias) ou recolhidos no momento do processamento (cf. câmeras, microfones ou máquinas fotográficas). A categoria VIDEO inclui o processamento de vídeo *frame a frame* (e.g. (Singh et al., 2015), (Agrawal et al., 2013)) e qualquer tipo de vídeo: com ou sem áudio, 2D, 3D, 4D, térmico (e.g. (Z. Zhang et al., 2016), etc.). A categoria AUDIO inclui: conversas, falas (voz), discursos ou enunciados pronunciados (e.g. (Korkmaz & Atasoy, 2015)).

De entre os instrumentos presentes na literatura enumerámos os utilizados nas investigações por nós analisadas: o *Cambridge Face Tracker* **{FACETRACKER}** é um sistema para reconhecimento facial através de redes neuronais a partir de propriedades de vídeo (Thomas, Baltrušaitis, Robinson, & Vivian, 2016); o *High Fidelity 3D Facial Image Capture* **{DI3D}** é um sistema de captura de imagem passivo de alta resolução em 3D, possível de utilizar com qualquer tipo de câmeras digitais (Dimensional Imaging LTD, 2017); a câmara *infrared A655sc* **{A655SC}** da FLIR permite a recolha de imagens térmicas com alta resolução (cf. 640x480) em temperaturas no intervalo [-40;150]°C (FLIR Systems, n.d.); o *Kinect Sensor* **{KINECT}** é um sensor de movimento criado para interagir com jogadores da Xbox 360 da *Microsoft* através de gestos e comandos verbais (existem também uma versão para Windows) (Leyvand et al., 2011) (Vermun et al., 2013); o *FaceReader* da *Noldus* **{FACEREADER}** é um sistema de deteção emocional com base no reconhecimento facial em imagens ou vídeos *offline* ou *livestream* (Noldus, 2017) (Matlovic et al., 2016); o *Shore* **{SHORE}** é o sistema da *Fraunhofer* que também faz deteção emocional através de reconhecimento facial, e que permite a deteção e análise facial em tempo real (Fraunhofer IIS, 2017); o EQ-Radio **{EQ-RADIO}** criado por Zhao et al., é um sistema para reconhecimento emocional com base no sinal WiFi, capaz de detetar batimentos cardíacos a partir da reflexão do sinal RF com uma precisão semelhante à do ECG corporal (Zhao et al., 2016); a Sony XC-EI30 **{XCEI30}** é uma câmara de vídeo profissional muito utilizada no processamento de imagem (Sony Inc., 2010); o Tobii Pro TX300 **{TX300}** é um sistema de grande precisão que recolhe dados acerca do olhar mesmo com movimentos consideráveis da cabeça, permite detetar e recolher dados acerca da PUPIL, do movimento do olho, etc. (Tobii AB, 2015);

Algumas investigações recorrem também a dados já existentes **{EXISTINGDATA}** (e.g. bases de dados públicas: o Instituto Português do Mar e da Atmosfera (IPMA) pode fornecer dados de contexto ambiental; o Instituto Nacional de Estatística (INE) e o serviço PORDATA pode fornecer dados de cariz económico e demográfico, etc.). Existem investigações que utilizam dados disponíveis noutros sistemas: Bogomolov et al. utilizou o *Wolfram Alpha* (Wolfram Alpha, 2013) para obter dados diariamente acerca do WEATHER (e.g. temperatura ambiente, pressão, precipitação, humidade, visibilidade, vento, etc.) (Bogomolov et al., 2014); Hernandez et al. utilizou registos de chamadas de um call center para estudar os colaboradores (Hernandez et al., 2011), etc.

INVESTIGAÇÃO	INSTRUMENTOS & SENSORES	
	TECNICAS NÃO OBSTRUTIVAS	OUTRAS

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	{VIDEO} (FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, NOSE, LIPS, CHEEKS, JAW, MOUTH).	
<b>Eckert et al.</b> (Eckert et al., 2016)	{APP, PICTURES} (FACS, CAU, EYES, EYEBROWS, NOSE, MOUTH).	
<b>Matlovic et al.</b> (Matlovic et al., 2016)	{FACEREADER, SHORE}.	<b>T. obstrutivas:</b> {EPOC} (EEG) e {TGSR} (EDA).  <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {TSTUDIO, CAPTIV}.
<b>Gogia et al.</b> (Gogia et al., 2016)	{KINECT, VIDEO} (HEAD).	<b>T. pouco obstrutivas:</b> {MINDWAVE} (EEG).  <b>(OUTROS)</b> {MINDWAVE-SDK, KINECT-SDK}.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	{DI3D, A655SC, VIDEO} (HEAD, FACS, ST).	<b>T. obstrutivas:</b> {MP150, NIBP100D} (BP(SBP, DBP), HR, PR, RESP(RR)) e {Undefined(EDA)} (EDA).  <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	{FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL).	<b>T. pouco obstrutivas:</b> {AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT). <b>T. obstrutivas:</b> {Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).  <b>(Q. FORMAIS)</b> {SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), PSS (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY). <b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, FTF, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).
<b>Zhao et al.</b> (Zhao et al., 2016)	{EQ-RADIO} (HR(IBM/RMSSD, SDNN)), RESP e {VIDEO***}.  *** utilizado para confrontar os resultados obtidos com o <i>Cognitive Services da Microsoft</i> (Microsoft, 2017b).	<b>T. obstrutivas:</b> {Undefined(ECG)} (ECG(HR)).  <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	{FACETRACKER} (FACS (HEAD, EYELIDS, EYEBROWS, CHEEKS, EYES, NOSE, WRINKLES, LIPS, CHIN, JAW), GAZE).	
<b>Turan et al.</b> (Turan et al., 2015)	{PICTURES, VIDEO} (FACE, EYES).	
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	{AUDIO} (SPEECH, VOLUME).	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Lalitha et al.</b> (Lalitha et al., 2015)	{AUDIO} ( <i>SPEECH, PITCH e VOLUME</i> ).	
<b>Singh et al.</b> (Singh et al., 2015)	{VIDEO} ( <i>SHOULDERS, HANDS</i> ).	
<b>Jaques et al.</b> (Jaques et al., 2015)	{APP} ( <i>CALL, SMS, SCREEN, LOCAL</i> ).	<b>T. pouco obstrutivas:</b> {AFFECTIVAQ} ( <i>EDA, ST, ACC</i> ).  <b>(Q. INFORMAIS)</b> {INFORMAL} ( <i>HAPPY, ACADCL, ACADEX, ACADST, PHYSI, SOCIAL, CAFFEI, ALCOH, DRUGS, STRESS, HEALTH, ENERGY, ALERT, CALM, SLEEP, NAP</i> ).
<b>Saha et al.</b> (Saha et al., 2014)	{KINECT} ( <i>HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN, ACC</i> ).	<b>(OUTROS)</b> {KINECT-SDK}.
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	{APP} ( <i>CALL, SMS, PROXIMITY</i> ) e {EXISTINGDATA} ( <i>WEATHER</i> ).	<b>(Q. FORMAIS)</b> {BFIPT} ( <i>PERSON</i> ). <b>(Q. INFORMAIS)</b> {INFORMAL} ( <i>STRESS</i> ).
<b>Agrawal et al.</b> (Agrawal et al., 2013)	{VIDEO} ( <i>EYES, MOUTH, LIPS, SKIN</i> ).	
<b>Soleymani et al.</b> (Soleymani et al., 2013)	{VIDEO} ( <i>HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH</i> ).	<b>T. obstrutivas:</b> {ACTIVEII} ( <i>EEG</i> ).  <b>(OUTROS)</b> {OBSERVATION} ( <i>EMOTIONS</i> ).
<b>Vermun et al.</b> (Vermun et al., 2013)	{KINECT} ( <i>HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP, KNEES</i> ).	
<b>Kawai et al.</b> (Kawai et al., 2013)	{XCEI30} ( <i>PUPIL</i> ).	<b>(Q. INFORMAIS)</b> {INFORMAL} ( <i>EMOTIONS</i> ). <b>(OUTROS)</b> {DS400}.
<b>Babiker et al.</b> (Babiker et al., 2013)	{TX300} ( <i>EYES, GAZE, PUPIL</i> ).	<b>(Q. FORMAIS)</b> {PANAS-X} ( <i>EMOTIONS</i> ).
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	{MOODSCOPE} ( <i>SMS, EMAIL, CALL, APPS, BROWSER, LOCAL</i> ).	<b>(Q. FORMAIS)</b> {CIRCUMPLEX} ( <i>MOOD</i> ).
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)	{APP} ( <i>LOCAL, PROXIMITY, CALL, SMS</i> ).	
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	{VIDEO} ( <i>HEAD, FACE</i> ).	<b>(OUTROS)</b> {EAI}.
<b>Dhall et al.</b> (Dhall et al., 2011)	{PICTURES, VIDEO} ( <i>FACE</i> ).	
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	{VIDEO} ( <i>PUPIL</i> ).	<b>T. obstrutivas:</b> {ML870} ( <i>ECG(HRV), PPG</i> ).
<b>Hernandez et al.</b>	{EXISTINGDATA} ( <i>CALL</i> ).	<b>T. pouco obstrutivas:</b> {AFFECTIVAQ} ( <i>EDA</i> ).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Hernandez et al., 2011)		<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>N. Lane et al.</b> (N. Lane et al., 2011)	{BEWELL} (SLEEP, PHYSI, TALK, LOCAL, ACC).	<b>(Q. INFORMAIS)</b> {INFORMAL} (DEPRESSION, SLEEP, WELLBEING). <b>(OUTROS)</b> {HAR}.
<b>H. Wang et al.</b> (H. Wang et al., 2010)	{VIDEO} (EYES).	
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	{VIDEO} (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, CHEEKS, FOREHEAD, JAW, NOSE, HANDS, FINGERS, FISTS, PALMS, SHOULDERS, NECK).	
<b>Castellano et al.</b> (Castellano et al., 2007)	{VIDEO} (ARMS).	
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	{VIDEO, AUDIO}***. *** apenas recolhidos.	<b>T. obstrutivas:</b> {PROCOMP} (EDA, ECG(HR), EMG).  <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {BIOGRAPH}.
<b>Sebe et al.</b> (Sebe et al., 2006)	{VIDEO} (HEAD, EYEBROWS, EYELIDS, MOUTH) e {AUDIO} (VOLUME, SPEECH, PITCH).	
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	{VIDEO***}. *** utilizado em conjunto com a OBSERVATION para provocação.	<b>T. obstrutivas:</b> {FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESP).  <b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>Busso et al.</b> (Busso et al., 2004)	{VIDEO} (FOREHEAD, EYEBROWS, EYES, CHEEKS) e {AUDIO} (PITCH, VOLUME).	
<b>Nwe et al.</b> (Nwe et al., 2001)	{AUDIO} (SPEECH).	
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	{AUDIO} (SPEECH, PITCH) e {VIDEO} (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN).	

() representa um sinal raw; e {} um instrumento.

### 3.1.2. Técnicas pouco obstrutivas

Os autores acreditam que o grau de obstrutividade não é igual para todos os dispositivos e sensores que influenciam a normal atividade das pessoas. Por exemplo, uma cinta para medição da expansão da cavidade peitoral será menos obstrutiva do que a utilização de máscaras para determinar a quantidade de gases trocados pelos pulmões (Jennifer a Healey et al., 2000).

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

Apesar de ambas medirem a respiração, a primeira opção não impede que o utilizador continue a desempenhar as suas tarefas normais, i.e. não é totalmente obstrutiva. Existem ainda outros dispositivos que, apesar de terem sido apenas utilizados em ambiente experimental, aparentam estar próximo de uma versão implementável na vida real. Por exemplo J. Zhang apresenta uns óculos para recolha do EOG e transmissão via *Wireless Fidelity* (WiFi). Com alguma miniaturização (e.g. transmissor WiFi), o dispositivo poderia ser utilizado pelas pessoas de forma muito próxima aos óculos normais.

A existência de sensores com alguma obstrutividade mas cuja utilização pode ser esquecida durante a recolha motivou-nos para a criação do grupo dos dispositivos pouco obstrutivos. Assim, nesta secção, apresentam-se as técnicas que cuja medição vai-se tornando transparente com a sua utilização (i.e. a tecnologia que desaparece no *background*), promovendo a qualidade e integridade dos dados de contexto recolhidos (Weiser, 1991) (Weiser & Brown, 1996).

Nas investigações analisadas foram vários os instrumentos classificados como pouco obstrutivos: J. Zhang et al. criou um sistema *wearable* barato e fácil de utilizar **{ZHANG}**, capaz de recolher EOG usando eléctrodos e transmitir os dados recolhidos para um computador através de WiFi (J. Zhang et al., 2013); Raudonis montou sobre uma armadura ocular **{RAUDONIS1}**, um dispositivo para rastreamento do olhar composto por um emissor de luz *infrared* (IR) e uma câmara de vídeo pequena (Raudonis, 2013); de forma similar, Herbon et al. montou num capacete uma câmara para recolha de imagem da PUPIL **{HERBON}** (Herbon et al., 2005); o *Zephyr BioHarness* **{BIOHARNES}** é um dispositivo *wireless* que permite a recolha do sinal ECG e dados relacionados com a RESP (Zephyr Technology, 2012); o *Neurosky MindWave* **{MINDWAVE}** também mede o EEG mas é um *headset* leve, com alimentação autónoma e comunicação sem fios (Neurosky, 2017); o sensor de pulso *Q* da *Affectiva* **{AFFECTIVAQ}** (convertido em produto) comunica sem fios, e permite a recolha do EDA e ST (inclui também ACC) (Affectiva Inc., 2014) (Affectiva Inc., 2013); A *Emotion-Board* **{EMOTIONBOARD}** mede o EDA nos dedos utilizando pequenas cintas (os pequenos ACC integrados permitem medir também informação acerca do movimento de dedos e mãos) (Schumm et al., 2008); o *Motion Logger* **{MOTIONLOGGER}** da AMI é um *actigraph* que permite estimar o sono em simultâneo com a recolha de dados de contexto ambientais (Ambulatory Monitoring, n.d.) (Mill, Road, Ardsley, & York, n.d.); a pulseira *Tohisba Silmee W20/W21* **{SILMEEW2X}** faz rastreamento da atividade física (e.g. número de passos, distâncias percorridas, etc.) e também consegue medir a ST, HR, qualidade do sono etc. (o modelo W21 também tem GPS) (Toshiba, 2015) (Linder, 2015); o *Silmee Bar Type* **{SILMEEBTYPE}** também da *Toshiba* é um pequeno dispositivo para colocar no peito, capaz de recolher ECG, PPG, BP (através do PWTT), etc. (Silmee, n.d.) (Fuke, 2013); o *Talk Assistant* **{TALKASSIST}** criado por Kusserow et al. foi desenvolvido com o objetivo de monitorizar e dar feedback os oradores públicos em simultâneo com as suas apresentações, é composto por vários sensores (e.g. HR, EDA, ACC, etc.) (Kusserow et al., 2013); o sistema vestível criado por Kusserow **{KUSSEROW2}** para monitorizar e analisar violoncelistas durante atuações, é composto por um ECG com eléctrodos no peito e ACC de pulso (Kusserow et al., 2013); Kusserow et al. desenvolveu também um sistema vestível de análise da atividade cardíaca para ser utilizado por atletas de *ski jumping* **{KUSSEROW3}**, que recolhe ECG e ACC através de sensores miniatura colocados no peito (Kusserow et al., 2013); a *framework* multimodal de Kusserow **{KUSSEROW4}**, consegue estimar o stress nas várias atividades diárias (cf. início, duração e intensidade) (Kusserow et al., 2013); o *Brainquiry PET* **{BQPET}** é um instrumento portátil e sem fios pouco obstrutivo que recolhe o EEG (atualmente existem duas versões: dois e quatro eléctrodos), EMG ou ECG (Brainquiry, n.d.) (Brainquiry, 2017); as pulseiras *Jawbone*

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

{JAWBONE}, permitem a recolha de atividades, padrões de sono, monitorização cardíaca, etc. (e.g. Lisetti e Nasoz utilizou o sensor *BodyMedia SenseWear* (atualmente *Jawbone*) para recolher EDA, HR e ST (Lisetti & Nasoz, 2004)) (Jawbone, 2017); e medidor de inércia {IMU} permite medir o movimento linear e angular (utilizado em conjunto com giroscópios e acelerómetros) (xsens, n.d.).

INVESTIGAÇÃO	INSTRUMENTOS & SENSORES	
	TECNICAS POUCO OBSTRUTIVAS	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017)	{IMU} (HEAD).	<b>T. obstrutivas:</b> {Undefined(EMG), Undefined(EOG)} (EMG, EOG).
<b>Gogia et al.</b> (Gogia et al., 2016)	{MINDWAVE} (EEG).	<b>T. não obstrutivas:</b> {KINECT, VIDEO} (HEAD).  <b>(OUTROS)</b> {MINDWAVE-SDK, KINECT-SDK}.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	{AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT).	<b>T. não obstrutivas:</b> {FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL).  <b>T. obstrutivas:</b> {Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).  <b>(Q. FORMAIS)</b> {SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), PSS (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY). <b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, FTF, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADDEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).
<b>Zenonos et al.</b> (Zenonos et al., 2016)	{SILMEEW2X, SILMEEBTYPE} (ECG(HR(IBMSSD, SDNN)), HRV***), PPG(PR, PTT), ST).  *** obtido através do HRVAS.	<b>(Q. FORMAIS)</b> {HEALTHYOFFICE} (MOOD, EMOTIONS).  <b>(OUTROS)</b> {HRVAS} (HRV)*** e {HAR} (ACC).
<b>Basu et al.</b> (Basu et al., 2016)	{BIOHARNESS} (ECG, HR, PR, RESP(RR)).	<b>T. obstrutivas:</b> {ML870, FE116, ML135, ML309} (EDA, ST) e {Undefined(EMG)} (EMG).  <b>(OUTROS)</b> {LABCHART}.
<b>Jaques et al.</b> (Jaques et al., 2015)	{AFFECTIVAQ} (EDA, ST, ACC)	<b>T. não obstrutivas:</b> {APP} (CALL, SMS, SCREEN, LOCAL).  <b>(Q. INFORMAIS)</b> {INFORMAL} (HAPPY, ACADCL, ACADDEX, ACADST, PHYSI, SOCIAL, CAFFEI, ALCOH, DRUGS, STRESS, HEALTH, ENERGY, ALERT, CALM, SLEEP, NAP).
<b>Kusserow et al.</b> (Kusserow et al., 2013)	{TALKASSIST} (HR(HRV), EDA, ACC, ST), {KUSSEROW2} (ECG(HR), ACC), {KUSSEROW3} (ECG(HR), ACC) e {KUSSEROW4} (HR, ACC).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS, MOOD).
<b>Sano &amp; Picard</b>	{AFFECTIVAQ} (EDA, ACC) e	<b>(Q. FORMAIS)</b> {PSS} (STRESS), {PSQI} (SLEEP) e {BFIPT} (PERSON).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Sano & Picard, 2013b)	{FUNF} (CALL, SMS, LOCAL, SCREEN).	<b>(Q. INFORMAIS)</b> {INFORMAL} (SLEEP, ELECTR, HEALTH, MOOD, ALERT, TIRED, STRESS, NAP, CAFFEI, ALCOH).
<b>Raudonis</b> (Raudonis, 2013)	{RAUDONIS1} (GAZE, EYES, PUPIL).	
<b>Hernandez et al.</b> (Hernandez et al., 2011)	{AFFECTIVAQ} (EDA).	<b>T. não obstrutivas:</b> {EXISTINGDATA} (CALL).  <b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>Bos</b> (Bos, 2010)	{BQPET} (EEG).	<b>(OUTROS)</b> {BIOEXPLORER}.
<b>Setz et al.</b> (Setz et al., 2010)	{EMOTIONBOARD} (EDA).	
<b>Herbon et al.</b> (Herbon et al., 2005)	{HERBON} (PUPIL).	<b>T. obstrutivas:</b> {Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).  <b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (GENDER, AGE, HEALTH, TECHEXPERT).
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	{JAWBONE} (EDA, HR, ST).	<b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, ETHNICITY, EMOTIONS).

() representa um sinal raw; e {} um instrumento.

### 3.1.3. Técnicas obstrutivas

Na secção das técnicas obstrutivas apresentam-se os dispositivos e sensores não incluídos nas duas primeiras categorias (cf. técnicas não obstrutivas ou pouco obstrutivas). São instrumentos que afetam a vida das pessoas e cuja implementação real seria difícil. Por exemplo, a utilização diária de eléctrodos para medição do ECG, EEG ou EMG, seria complicada de implementar por causa do constrangimento ao desempenho das atividades normais das pessoas. Consideram-se também nesta secção as técnicas cuja medição é feita sem recurso a instrumentos de recolha (e. g. administração de medicamentos em que a contagem é feita na toma) **{MANUAL}**, e os instrumentos que dificilmente os utilizadores perderiam a noção da sua utilização ao longo do tempo mesmo que os utilizassem de forma regular, i.e., os instrumentos cuja utilização pode significar a diminuição da imparcialidade dos dados que recolhem.

Algumas investigações não identificam de forma concreta os dispositivos utilizados (i.e. marca, fabricante, etc.), utilizando apenas uma designação genérica reconhecida cientificamente (e.g. ECG, EEG, etc.). Outras referenciam dispositivos cuja antiguidade inviabiliza por si a adoção em investigações atuais. Outras ainda não especificam o instrumento mas apenas o sinal recolhido (e.g. EDA). Assim, decidiu-se utilizar a notação **{Undefined<tag>}**, em que *tag* pode assumir o termo utilizado pelos investigadores para identificar um sinal cujo dispositivo de recolha não foi identificado (e.g. **{Undefined<EMG>}** refere-se a um instrumento não especificado para recolha do sinal EMG), ou pode assumir um nome genérico utilizado para um dispositivo de recolha quando o autor não identifica de forma concreta a sua marca ou fabricante (e.g.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

{*Undefined*<ECG>} refere-se a um ECG cuja marca não foi mencionada). São vários os dispositivos utilizados pelos investigadores nestas condições: o *Electrocardiogram* {*Undefined*(ECG)} (também conhecido por EKG) permite medir a atividade elétrica do coração (Mandryk & Atkins, 2007) (J. Kim & André, 2008) (através dele é possível extrair variáveis como HR, HRV, etc. (Jennifer a Healey et al., 2000) (Mandryk & Atkins, 2007); o *Impedance Cardiography* {*Undefined*(ICG)} mede as variações na impedância causadas pelas alterações no volume de sangue e a velocidade na aorta a cada batimento cardíaco, sendo útil para recolher informação acerca da atividade muscular do coração (Murali et al., 2015); o *Phthoplethysmography* {*Undefined*(PPG)} é uma técnica ótica e não invasiva, de medição das alterações de volume sanguíneo (venoso e arterial) ocorridas nos vasos sanguíneos próximos da pele (Malik, 2009) (medido na ponta do dedo mostra a flutuação de volume sanguíneo naquele ponto refletindo a modulação simpática das arteríolas do dedo) (G. S. H. Chan, Middleton, Lovell, & Celler, 2005); o *Phonocardiogram* {*Undefined*(PCG)} é usado para análise dos sons produzidos pelo coração (e.g. diagnóstico cardiovascular, autenticação biométrica, reconhecimento do stress, etc.) (Varghees & Ramachandran, 2016); o *Electrooculogram* {*Undefined*(EOG)} é usado para recolher o movimento do olho através da colocação de elétrodos na zona dos olhos (J. Zhang et al., 2013); o *Electromyogram* {*Undefined*(EMG)} é utilizado para medir a atividade muscular à superfície da pele através da colocação de sensores sobre os músculos, ou intramuscular através da utilização de agulhas (Lichtenstein, Antje; Oehme, 2008) (Haag et al., 2004) (Chandler & Cornes, 2012); o instrumento para medir a atividade eletrodermal {*Undefined*(EDA)}, i.e. a capacidade condutora da pele que aumenta momentaneamente aquando da exposição da pessoa a um estímulo excitante (e.g. Zhang et al. utilizou um sensor interligado a um relógio de pulso (Z. Zhang et al., 2016)) (Jaques et al., 2015); o *Polysomnography* {*Undefined*(PSG)} é uma técnica utilizada no estudo do sono através da monitorização de vários sinais (Armon, 2016).

As investigações analisadas relatam a utilização de vários dispositivos que implicam obstrutividade para os seus utilizadores: o *Procomp Infiniti* {**PROCOMP**} é um dispositivo da *Thought Technology Ltd.*, composto por vários biossensores (cf. EMG, EDA, ECG e RESP) (Infiniti, 2008b) (Infiniti, 2008a); o *Epoc da Emotiv* {**EPOC**} é um *headset* de custos baixos composto por 14 elétrodos mais 2 de referência (Linh, 2008) (Ramirez, Ramirez, & Vamvakousis, 2015) que devem ser colocados respeitando o sistema internacional 10-20 (Trans Cranial Technologies Ltd., 2012) (Niedermeyer & Silva, 2005); o *Grass 78B* {**78B**} *Polygraph* permite a medição de sinais fisiológicos (e.g. Sinha (Rajita Sinha, 1996)); o *Grass Model15* {**MODEL15**} é um amplificador digital criado em 1994, foi utilizado para guardar os dados relacionados com a atividade do EMG (e.g. (Partala et al., 2005)) e, apesar de já não ser um produto distribuído pelo proprietário atual da marca, foi inspiração para sistemas atuais (ERIKG Group, 2011) (Natus Medical Inc., 2017); o kit *Orion Diagnostica* {**ORION**} da *Espoo* (tecnologia atualmente da *Cisbio Bioassays* (Rissanen, 2013) (Business Wire, 2007)) permite a medição das concentrações de CORT na saliva através da técnica *radioimmunoassay* (Buchanan et al. utilizou este kit em conjunto com o *Salivette* {**SALIVETTE**} da *Sarstedt* para facilitar o processo de recolha (Sarstedt, n.d.) (Buchanan & Lovallo, 2001) (Cisbio, 2016)); O *I-cortisol* {**I-CORTISOL**} utilizado por Van Eck et al. em conjunto com *SALIVETTE*, também utiliza a técnica *radioimmunoassay* (van Eck et al., 2005); vários instrumentos da *ADInstruments* como *ML870 PowerLab 8/30* {**ML870**} para recolha de dados (ADInstruments, n.d.-d), *FE-116 GSR* {**FE116**} para recolha do EDA (ADInstruments, n.d.-a), *ML-309*{**ML309**} para recolha de temperatura (e.g. ST) (ADInstruments, n.d.-c), e o amplificador *ML-135* {**ML135**} para sinais fisiológicos (ADInstruments, n.d.-b); o *EyeLink 1000* {**EL1000**} é um rastreador ocular que permite recolher dados acerca do olhar e do tamanho da pupila, é

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

composto por uma câmera e uma luz *infrared* (SR Research Ltd, 2013); o modelo 504 **{ASL504}** composto por uma câmera e uma fonte de infravermelhos, e os sistemas da serie 4000 *Applied Science Laboratories* **{ASL4000}** (e.g. 4000SU) permitem o rastreamento ocular e monitorização da pupila (Applied Science Laboratories, 2006)(LabX, 2017); o dispositivo conhecido como *Siemens Siregnost FD 5* **{SIREGNOSTFD5}** permite medir a ROS através de oscilações forçadas (referenciado por vários investigadores, por e.g. (Gimeno, van der Weele, Koëter, de Monchy, & van Altena, 1993), (Pleger, Wilke, Glaser, Müller, & Vogel, 1989), etc.); o *Hans Rudolph* (Rudolph & Pnt, 2004) *flow head 3803* **{FH3803}** e o integrador CS5 **{GMCS5}** da *GM Instruments* (GM Instruments, 2015), referenciados por Ritz et al (Ritz et al., 2000) para medição do VT e RR; a *cuff Finapres* (acrónimo para *FINger Arterial PRESure* (Imholz, Wieling, Van Montfrans, & Wesseling, 1998)) modelo IV **{FINAPRESS4}** da *TNO Biomedical Instrumentation* para medir o HR, BP, SBP e DBP de forma contínua (renomeado para *Ohmeda 2300 Finapres BP monitor* (Imholz et al., 1988) atualmente a tecnologia foi aplicada no *Finapres NOVA* (Finapres Medical Systems BV, 2012)); o sistema *Biosemi Active II* **{ACTIVEII}** mede sinais a partir de eléctrodos (e.g. Soleymani et al. recolheu o EEG com 32 eléctrodos (Soleymani et al., 2013)) (Biosemi, n.d.); o *Coulbourn S75-01 Hi Gain Bioamplifier* **{S75-01}** e o *Coulbourn S71-22* **{S71-22}** *Skin Conductance Coupler*, dispositivos utilizados por Vrana para recolher o ECG e o EDA (Scott R. Vrana, 1993); a *BioPac* fornece dispositivos para medição ou suporte à medição fisiológica (Biopac Systems Inc, 2017a) como o *MP100* **{MP100}** e o *MP150* **{MP150}** para processamento de sinais de contexto como o ECG, RESP, EDA, ST, etc. (entretanto descontinuados e substituídos pelo *MP160* (Linton Instrumentation, 2011)), e o *NIBP100D* **{NIBP100D}** que é um sistema para monitorização contínua não invasiva da BP, SDP, DBP, PR, etc. (Biopac Systems Inc, 2017c) (Biopac Systems Inc, 2017e) (Toruzyne, 2001) (Blood & Monitoring, 2017) (Biopac Systems Inc, 2017d) (Fortin et al., 2006); o dispositivo multiparamétrico para a aquisição de sinais vitais criado por Murali et al. **{MURALI}**, é pequeno e leve, composto por eléctrodos não invasivos e uma cinta de peito, e contém um pequeno computador que pode recolher, processar e guardar de forma contínua dados do ECG, ICG, EDA e RESP (Murali et al., 2015); o *T-Sens GSR* **{TGSR}** é um pequeno dispositivo para medição do EDA através de dois eléctrodos colocados na ponta de dois dedos (TEA, 2017); o g.MOBilab+ **{MOBILAB}** é um sistema portátil de aquisição multimodal de sinais fisiológicos (e.g. EEG, EMG, EOG, RESP, EDA, etc.) (Cornelissen & Waterman, 2016) (g.tec, 2017); o Health Lab **{HEALTHLAB}** da *Koralewski* permite a recolha de dados de contexto fisiológico (e.g. Lichtenstein et al. utilizou para recolher RESP através de uma cinta de peito, ST através de uma cinta de pulso, e ECG, EMG e EDA através de eléctrodos (Lichtenstein, Antje; Oehme, 2008)) (Koralewski, n.d.); o *FlexComp Infiniti* **{FLEXCOMP}** da *Thought Technology Ltd.*, é um sistema de aquisição e monitorização para sinais de contexto fisiológico (utilizado por e.g. por Healey et al. (J. A. Healey & Picard, 2005)) (Thought Technology Ltd., 2016a); o sistema *Spacelabs 90207* **{S90207}** permite a medição do BP em ambulatório (utilizado por e.g. por Vrijkotte et al. (Vrijkotte et al., 2000)) (SpaceLabs Healthcare, 2008); o VU-MAS **{VU-MAS}** é um sistema de monitorização em ambulatório que permite a recolha de dados fisiológicos (e.g. HR em Vrijkotte et al. (Vrijkotte et al., 2000)) (Vrije Universiteit, n.d.).

INVESTIGAÇÃO	INSTRUMENTOS & SENSORES	
	TECNICAS OBSTRUTIVAS	OUTRAS
Perdiz et al. (Perdiz et al., 2017)	{Undefined(EMG), Undefined(EOG)} (EMG, EOG).	<u>T. pouco obstrutivas:</u> {IMU} (HEAD).
Matlovic et al.	{EPOC} (EEG) e {TGSR} (EDA).	<u>T. não obstrutivas:</u> {FACEREADER, SHORE}.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Matlovic et al., 2016)		<p><b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).</p> <p><b>(OUTRAS)</b> {TSTUDIO, CAPTIV}.</p>
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	{MP150, NIBP100D} (BP(SBP, DBP), HR, PR, RESP(RR)) e {Undefined(EDA)} (EDA).	<p><b>T. não obstrutivas:</b> {DI3D, A655SC, VIDEO} (HEAD, FACS, ST).</p> <p><b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).</p>
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	{Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).	<p><b>T. não obstrutivas:</b> {FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL).</p> <p><b>T. pouco obstrutivas:</b> {AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT).</p> <p><b>(Q. FORMAIS)</b> {SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), {PSS} (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY).</p> <p><b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, FTF, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).</p>
<b>Zhao et al.</b> (Zhao et al., 2016)	{Undefined(ECG)} (ECG(HR)).	<p><b>T. não obstrutivas:</b> {EQ-RADIO} (HR(ABI(RMSSD, SDNN)), RESP) e {VIDEO}.</p> <p><b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).</p>
<b>Basu et al.</b> (Basu et al., 2016)	{ML870, FE116, ML135, ML309} (EDA, ST) e {Undefined(EMG)} (EMG).	<p><b>T. pouco obstrutivas:</b> {BIOHARNESS} (ECG, HR, PR, RESP(RR)).</p> <p><b>(OUTROS)</b> {LABCHART}.</p>
<b>Aracena et al.</b> (Aracena et al., 2016)	{EL1000} (PUPIL, GAZE).	
<b>Murali et al.</b> (Murali et al., 2015)	{MURALI} ((ECG, ICG)(PEP, PTT), NIBP, EDA, RESP(RR)).	
<b>Cruz et al.</b> (Cruz et al., 2015)	{MOBILAB} (EOG).	
<b>Matiko et al.</b> (Matiko et al., 2014)	{Undefined(EEG)} (EEG).	<p><b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).</p>
<b>Soleymani et al.</b> (Soleymani et al., 2013)	{ACTIVEII} (EEG).	<p><b>T. não obstrutivas:</b> {VIDEO} (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH).</p> <p><b>(OUTROS)</b> {OBSERVATION} (EMOTIONS).</p>
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	{MP150} (ECG(HRV), EMG, EDA, RESP).	<p><b>(Q. FORMAIS)</b> {AFFECTGRID} (EMOTIONS).</p> <p><b>(OUTROS)</b> {ACQK}.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	{Undefined(NIBP), Undefined(RESPI)} (NIBP, RESPI(RR)).	
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	{Undefined(EEG), Undefined(HR), Undefined(HRV), Undefined(PEP), Undefined(SV), Undefined(BP), Undefined(RESPI), Undefined(EDA), Undefined(nSRR), Undefined(ST)} (EEG, HR, HRV, PEP, SV, BP(SBP, DBP), RESPI(VT, ROS, RR), EDA, nSRR, ST).	
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	{ML870} (ECG, BVP, PR, EDA).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS).
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	{ML870} (ECG(HRV), PPG).	<b>T. não obstrutivas:</b> {VIDEO} (PUPIL).
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	{EPOC} (EEG).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {EPOC-SDK}.
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	{PROCOMP} (EMG, EDA, ECG(HR, HRV), RESPI(RR, BRV)).	
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	{HEALTHLAB} (RESPI(RR, RDEP), EDA, ECG(HR, HRV, IBI), EMG, ST).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	{ASL504} (PUPIL), {S71-22} (EDA) e {S75-01} (ECG(HR, IBI)).	
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	{PROCOMP} (EDA, ECG(HR), EMG).	<b>T. não obstrutivas:</b> {VIDEO, AUDIO}.  <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {BIOGRAPH}.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	{Undefined(EDA), Undefined(BVP), Undefined(PUPIL), Undefined(ST), Undefined(LIGHT), Undefined(TEMP)} (EDA, BVP(IBI), PUPIL, ST, LIGHT***, TEMP***).  *** dados não utilizados na correlação	
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	{FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESPI).	<b>T. não obstrutivas:</b> {VIDEO}.  <b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS). <b>(OUTROS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		{OBSERVATION} (STRESS).
<b>Herbon et al.</b> (Herbon et al., 2005)	{Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).	<b>T. pouco obstrutivas:</b> {HERBON} (PUPIL).  <b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (GENDER, AGE, HEALTH, TECHEXPERT).
<b>Partala et al.</b> (Partala et al., 2005)	{MODEL15} (EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {LINK15}.
<b>Van Eck et al.</b> (van Eck et al., 2005)	{I-CORTISOL, SALIVETTE} (CORT).	<b>(Q. FORMAIS)</b> {PSS} (STRESS), {LTE} (LIFEEVENTS), {LDI} (DIFFICULTIES), {PSC} (HEALTH), {SDS} (DEPRESSION), {STAI} (ANXIETY) e {STAS} (ANGER). <b>(Q. INFORMAIS)</b> {INFORMAL} (MOOD, WELLBEING, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH, EMOTIONS).
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	{MP100} (ECG(HR,HRV), PPG, ST, EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Haag et al.</b> (Haag et al., 2004)	{PROCOMP} (EMG, EDA, ST, PPG(BVP(HR)), ECG(HR), RESP).	
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	{ASL4000} (PUPIL).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {PSYSCOPE}.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	{MANUAL}*** (SEROT).  *** administração de citalopram (WebMD Drugs & Medications, 2017a).	<b>(Q. FORMAIS)</b> {BFS} (MOOD). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS, ENERGY, ANXIETY). <b>(OUTROS)</b> {INTERVIEW}.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)	{ORION, SALIVETTE}*** (CORT) e {Undefined(EMG)} (EMG).  *** administração de hydrocortisone (WebMD Drugs & Medications, 2017b)	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)	{PROCOMP} (EDA, PPG(BVP(HR)), EMG, RESP) e {Undefined(ECG)} (ECG(HR, HRV)).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	{S90207} (BP(SBP, DBP)) e {VU-MAS} (ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC).	<b>(Q. FORMAIS)</b> {ERI} (STRESS) e {POMS} (MOOD). <b>(Q. INFORMAIS)</b> {INFORMAL} (PERSON, AGE, WORKYEARS, ACADDG, PHYSI, BMI, HEIGHT, WEIGHT, WAIST, CAFFEI, ALCOH, SMOKING).
<b>Ritz et al.</b> (Ritz et al., 2000)	{SIREGNOSTFD5} (ROS), {FH3803, GMCSS} (VT, RR), {FINAPRESS4} (HR, BP(SBP, DBP)) e {Undefined(EDA)} (EDA).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS), {AIM, TAS, MCSDS}. <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>J. Healey &amp; Picard</b>	{PROCOMP} (EDA, PPG(BVP(HR)), RESP, EMG).	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(J. Healey & Picard, 1998)		
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	{78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG).	<b>(Q. FORMAIS)</b> {MMPI, QMI, TAS, BDI, STAI} e {DES} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {INTERVIEW}.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	{S75-01} (ECG(HR)), {Undefined(EMG)} (EMG) e {S71-22} (EDA).	<b>(Q. FORMAIS)</b> {QMI}. <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>R Rinha et al.</b> (R Sinha et al., 1992)	{Undefined(BP)} (BP(SBP, DBP)), {Undefined(ICG)} (ICG(SV, CO, PVR, PEP, LVET)), {Undefined(ECG)} (ECG(HR)) e {Undefined(PCG)} (PCG).	<b>(Q. FORMAIS)</b> {QMI, TAS} e DES} (EMOTIONS), <b>(OUTROS)</b> {INTERVIEW, OBSERVATION}.

() representa um sinal raw; e {} um instrumento.

### 3.1.4. Análise

A tecnologia tem ainda um longo caminho a percorrer para promover a recolha com baixa ou nula obstrutividade. O ideal seria que fosse possível inspecionar todo o contexto de forma livre (i.e. de forma totalmente não obstrutiva), impercetível para os utilizadores, e que os dados fossem transmitidos para as unidades de processamento em tempo real com ausência total de cablagem (Ouwerkerk et al., 2008). Por enquanto, os investigadores vão desenhando os seus sistemas de deteção emocional recorrendo aos instrumentos e sensores existentes (Ouwerkerk et al., 2008).

As técnicas não obstrutivas identificadas na literatura focam-se essencialmente na recolha e processamento de VIDEO e AUDIO. A grande vantagem destas técnicas é a reutilização de instrumentos já existentes no quotidiano dos utilizadores. No entanto, não são imunes aos problemas e desafios já enumerados na secção das variáveis de contexto relacionadas com a expressão facial (cf. utilização de adornos (Cruz et al., 2015) (H. Wang et al., 2010), insensibilidade à idade, género e cultura (Rani & Sarkar, 2006), e mascaramento (J. Kim & André, 2008) (Y. Liu et al., 2010)). Contudo são técnicas que tendem a desaparecer no *background* do utilizador (Weiser & Brown, 1996). Assim, considerados os constrangimentos legais e éticos relativos à captura de imagem e som de pessoas, esta será uma forma viável de introspecionar o contexto do utilizador, principalmente se os dados forem recolhidos com o seu alheamento.

Ainda relativamente às técnicas não obstrutivas, o *smartphone* é o instrumento mais utilizado para recolha de dados de contexto social. São várias as vantagens na reutilização deste instrumento para recolha de dados de contexto: é um instrumento utilizado diariamente de forma natural e generalizada pelas pessoas (Eckert et al., 2016) (N. D. Lane et al., 2010); não há a necessidade de alterar os padrões de utilização dos dispositivos para gerar nova informação, porque os dados a recolher já existem no dispositivo de forma natural; e os dados *raw* recolhidos representam de forma direta e objetiva interações sociais. No entanto, nem todas as pessoas utilizam *smartphones* (e.g. os mais idosos podem utilizar telefones mais básicos) e as características de processamento de cada dispositivo devem ser atendidas na análise de obstrutividade causada pelas aplicações de *logging*. Além das questões de ordem ética relativa à recolha de dados dos utilizadores, o uso do *smartphone* também tem outras contra indicações:

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

o tempo excessivo de utilização pode causar ANXIETY e insónias (Cheever, Rosen, Carrier, & Chavez, 2014) o que pode conduzir a longo prazo a uma situação de DEPRESSION (Thomé, Härenstam, & Hagberg, 2011); e a exposição à luz dos ecrãs ao final do dia pode suprimir a secreção de MELAT, aumentando o nível de alerta (Chellappa et al., 2011) (Sano & Eng, 2016).

As técnicas classificadas como pouco obstrutivas baseiam-se essencialmente na utilização de pulseiras e pequenos dispositivos de recolha de dados de contexto. A principal vantagem será a possibilidade de recolher sinais de contexto fisiológico com dispositivos que representam baixa obstrutividade. Não existindo ainda muita tecnologia para a recolha deste tipo de sinais de forma não obstrutiva, resta utilizar dispositivos cuja utilização vai-se tornando transparente e esquecida com o tempo, promovendo, dentro do possível, a qualidade e integridade dos dados recolhidos (Weiser, 1991) (Weiser & Brown, 1996). Apesar de pouco obstrutivos, a utilização regular destes dispositivos depende dos esquecimentos do utilizador. Não se tratando de um dispositivo do quotidiano das pessoas como são os *smartphones*, o esquecimento pode interromper a recolha de dados comprometendo o sucesso e a validade dos sistemas de deteção emocional. Talvez o desenvolvimento da tecnologia dos *Smart Textiles* venha a contribuir para a solução do problema. O uso de sensores literalmente vestíveis (Haag et al., 2004), poderá trazer a naturalidade e transparência necessária ao processo de recolha de dados de contexto fisiológico como acontece atualmente com os *smartphones* contexto (Capineri, 2014) (M. Chan, Estève, Fourniols, Escriba, & Campo, 2012).

Apesar de se notar no passado mais recente um esforço dos investigadores em utilizar dispositivos com pouca ou nenhuma obstrutividade, são muitos os dispositivos utilizados nas investigações de deteção emocional com obstrutividade. Trata-se de dispositivos cuja implementação na vida real seria difícil por causa do constrangimento à sua utilização, seja pelo facto de serem utilizados apenas em laboratórios ou ambientes clínicos, ou porque implicam a alteração da vida diária e normal das pessoas. Com a evolução tecnológica e a miniaturização de sensores, é de esperar que o número dos dispositivos com obstrutividade continue a diminuir. No entanto, enquanto tal não acontece, há que considerar a possível imparcialidade dos dados recolhidos através destes instrumentos.

Espera-se que a evolução tecnológica dos *contactless sensors* venha a permitir a diminuição da obstrutividade dos dispositivos e a possibilidade de recolha diária em ambientes reais (Ouwerkerk et al., 2008). Enquanto isso não acontece, alguns investigadores têm vindo a apontar estratégias criativas no sentido de diminuir a obstrutividade de sensores existentes: Schumm et al., Ouwerkerk et al., Lim et al. e Steffen et al. instalaram sensores obstrutivos em assentos dos bancos para medir sinais fisiológicos (e.g. ECG) enquanto as pessoas estão sentadas (Schumm & Arnrich, 2012) (Ouwerkerk et al., 2008) (Lim, Kim, & Park, 2006) (Steffen & Leonhardt, 2008); Zakrzewski et al. e Suzuki et al. estudaram a hipótese de detetar o HR através de sistemas de radar (Zakrzewski, Kolinummi, & Vanhala, 2006) (Suzuki et al., 2008), ou seja, sem a necessidade de utilização de técnicas obstrutivas; Schumm et al. pensou em integrar elétrodos nas meias para medir ECG e de EDA nos membros inferiores (*textile sensor integration*) evitando assim a colocação de sensores obstrutivos de recolha nos dedos das mãos (Schumm et al., 2010); Zhao et al. criou o EQ-RADIO que consegue detetar os batimentos cardíacos a partir da reflexão do sinal WiFi (Zhao et al., 2016); etc.

INVESTIGAÇÃO	TÉCNICAS NÃO OBSTRUTIVAS	TÉCNICAS POUCO OBSTRUTIVAS	TÉCNICAS OBSTRUTIVAS	OUTRAS
Perdiz et al.		{IMU} (HEAD).	{Undefined}(EMG),	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Perdiz et al., 2017)			Undefined(EOG) (EMG, EOG).	
<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	{VIDEO} (FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, NOSE, LIPS, CHEEKS, JAW, MOUTH).			
<b>Eckert et al.</b> (Eckert et al., 2016)	{APP, PICTURES} (FACS, CAU, EYES, EYEBROWS, NOSE, MOUTH).			
<b>Matlovic et al.</b> (Matlovic et al., 2016)	{FACEREADER, SHORE}.		{EPOC} (EEG) e {TGSR} (EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {TSTUDIO, CAPTIV}.
<b>Gogia et al.</b> (Gogia et al., 2016)	{KINECT, VIDEO} (HEAD).	{MINDWAVE} (EEG).		<b>(OUTROS)</b> {MINDWAVE-SDK, KINECT-SDK}.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	{DI3D, A655SC, VIDEO} (HEAD, FACS, ST).		{MP150, NIBP100D} (BP(SBP, DBP), HR, PR, RESP(RR)) e {Undefined(EDA)} (EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	{FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL).	{AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT).	{Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).	<b>(Q. FORMAIS)</b> {SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), {PSS} (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY). <b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, FTF, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).
<b>Zhao et al.</b> (Zhao et al., 2016)	{EQ-RADIO} (HR(ABI(RMSSD, SDNN)), RESP) e {VIDEO}.		{Undefined(ECG)} (ECG(HR)).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Zenonos et al.</b> (Zenonos et al., 2016)		{SILMEEW2X, SILMEEBTYPE} (ECG(HR(ABI(RMSSD, SDNN)), HRV), PPG(PR, PTT), ST).		<b>(Q. FORMAIS)</b> {HEALTHYOFFICE} (MOOD, EMOTIONS). <b>(OUTROS)</b> {HRVAS} (HRV) e {HAR} (ACC).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Basu et al.</b> (Basu et al., 2016)		{BIOHARNESS} (ECG, HR, PR, RESP(RR)).	{ML870, FE116, ML135, ML309} (EDA, ST) e {Undefined(EMG)} (EMG).	<b>(OUTROS)</b> {LABCHART}.
<b>Aracena et al.</b> (Aracena et al., 2016)			{EL1000} (PUPIL, GAZE).	
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	{FACETRACKER} (FACS (HEAD, EYELIDS, EYEBROWS, CHEEKS, EYES, NOSE, WRINKLES, LIPS, CHIN, JAW), GAZE).			
<b>Turan et al.</b> (Turan et al., 2015)	{PICTURES, VIDEO} (FACE, EYES).			
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	{AUDIO} (SPEECH, VOLUME).			
<b>Lalitha et al.</b> (Lalitha et al., 2015)	{AUDIO} (SPEECH, PITCH e VOLUME).			
<b>Singh et al.</b> (Singh et al., 2015)	{VIDEO} (SHOULDERS, HANDS).			
<b>Murali et al.</b> (Murali et al., 2015)			{MURALI} ((ECG, ICG))(PEP, PTT), NIBP, EDA, RESP(RR)).	
<b>Jaques et al.</b> (Jaques et al., 2015)	{APP} (CALL, SMS, SCREEN, LOCAL).	{AFFECTIVAQ} (EDA, ST, ACC)		<b>(Q. INFORMAIS)</b> {INFORMAL} (HAPPY, ACADCL, ACADEX, ACADST, PHYSI, SOCIAL, CAFFEI, ALCOH, DRUGS, STRESS, HEALTH, ENERGY, ALERT, CALM, SLEEP, NAP).
<b>Cruz et al.</b> (Cruz et al., 2015)			{MOBILAB} (EOG).	
<b>Saha et al.</b> (Saha et al., 2014)	{KINECT} (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN, ACC).			<b>(OUTROS)</b> {KINECT-SDK}.
<b>Matiko et al.</b> (Matiko et al., 2014)			{Undefined(EEG)} (EEG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	{APP} (CALL, SMS, PROXIMITY) e {EXISTINGDATA} (WEATHER).			<b>(Q. FORMAIS)</b> {BFIPT} (PERSON). <b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).
<b>Agrawal et al.</b> (Agrawal et al., 2013)	{VIDEO} (EYES, MOUTH, LIPS, SKIN).			
<b>Soleymani et al.</b> (Soleymani et al., 2013)	{VIDEO} (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH).		{ACTIVEII} (EEG).	<b>(OUTROS)</b> {OBSERVATION} (EMOTIONS).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Vermun et al.</b> (Vermun et al., 2013)	{KINECT} (HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP, KNEES).			
<b>Kusserow et al.</b> (Kusserow et al., 2013)		{TALKASSIST} (HR(HRV), EDA, ACC, ST), {KUSSEROW2} (ECG(HR), ACC), {KUSSEROW3} (ECG(HR), ACC) e {KUSSEROW4} (HR, ACC).		<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS, MOOD).
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)			{MP150} (ECG(HRV), EMG, EDA, RESP).	<b>(Q. FORMAIS)</b> {AFFECTGRID} (EMOTIONS). <b>(OUTROS)</b> {ACQK}.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)			{Undefined(NIBP), Undefined(RESPI)} (NIBP, RESP(RR)).	
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		{AFFECTIVAQ} (EDA, ACC) e {FUNF} (CALL, SMS, LOCAL, SCREEN).		<b>(Q. FORMAIS)</b> {PSS} (STRESS), {PSQI} (SLEEP) e {BFIPT} (PERSON). <b>(Q. INFORMAIS)</b> {INFORMAL} (SLEEP, ELECTR, HEALTH, MOOD, ALERT, TIRED, STRESS, NAP, CAFFEI, ALCOH).
<b>Raudonis</b> (Raudonis, 2013)		{RAUDONIS1} (GAZE, EYES, PUPIL).		
<b>Kawai et al.</b> (Kawai et al., 2013)	{XCEI30} (PUPIL).			<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {DS400}.
<b>Babiker et al.</b> (Babiker et al., 2013)	{TX300} (EYES, GAZE, PUPIL).			<b>(Q. FORMAIS)</b> {PANAS-X} (EMOTIONS).
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	{MOODSCOPE} (SMS, EMAIL, CALL, APPS, BROWSER, LOCAL).			<b>(Q. FORMAIS)</b> {CIRCUMPLEX} (MOOD).
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)			{Undefined(EEG), Undefined(HR), Undefined(HRV), Undefined(PEP), Undefined(SV), Undefined(BP), Undefined(RESPI), Undefined(EDA), Undefined(nSRR), Undefined(ST)} (EEG, HR, HRV, PEP, SV, BP(SBP, DBP), RESP(VT, ROS, RR), EDA, nSRR, ST).	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>C. Y. Chang et al.</b> (Chang et al., 2012)			{ML870} (ECG, BVP, PR, EDA).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS).
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)	{APP} (LOCAL, PROXIMITY, CALL, SMS).			
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	{VIDEO} (HEAD, FACE).			<b>(OUTROS)</b> {EAI}.
<b>Dhall et al.</b> (Dhall et al., 2011)	{PICTURES, VIDEO} (FACE).			
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	{VIDEO} (PUPIL).		{ML870} (ECG(HRV), PPG).	
<b>Hernandez et al.</b> (Hernandez et al., 2011)	{EXISTINGDATA} (CALL).	{AFFECTIVAQ} (EDA).		<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>N. Lane et al.</b> (N. Lane et al., 2011)	{BEWELL} (SLEEP, PHYSI, TALK, LOCAL, ACC).			<b>(Q. INFORMAIS)</b> {INFORMAL} (DEPRESSION, SLEEP, WELLBEING). <b>(OUTROS)</b> {HAR}.
<b>H. Wang et al.</b> (H. Wang et al., 2010)	{VIDEO} (EYES).			
<b>Bos</b> (Bos, 2010)		{BQPET} (EEG).		<b>(OUTROS)</b> {BIOEXPLORER}.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)			{EPOC} (EEG).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {EPOC-SDK}.
<b>Setz et al.</b> (Setz et al., 2010)		{EMOTIONBOARD} (EDA).		
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)			{PROCOMP} (EMG, EDA, ECG(HR, HRV), RESP(RR, BRV)).	
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)			{HEALTHLAB} (RESP(RR, RDEP), EDA, ECG(HR, HRV, IBI), EMG, ST).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)			{ASL504} (PUPIL), {S71-22} (EDA) e {S75-01} (ECG(HR, IBI)).	
<b>Gunes &amp; Piccardi</b>	{VIDEO} (LIPS, MOUTH, EYES,			

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Gunes & Piccardi, 2007)	EYEBROWS, EYELIDS, CHEEKS, FOREHEAD, JAW, NOSE, HANDS, FINGERS, FISTS, PALMS, SHOULDERS, NECK).			
Castellano et al. (Castellano et al., 2007)	{VIDEO} (ARMS).			
Mandryk & Atkins (Mandryk & Atkins, 2007)	{VIDEO, AUDIO}.		{PROCOMP} (EDA, ECG(HR), EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {BIOGRAPH}.
Sebe et al. (Sebe et al., 2006)	{VIDEO} (HEAD, EYEBROWS, EYELIDS, MOUTH) e {AUDIO} (VOLUME, SPEECH, PITCH).			
Zhai & Barreto (Zhai & Barreto, 2006)			{Undefined(EDA), Undefined(BVP), Undefined(PUPIL), Undefined(ST), Undefined(LIGHT), Undefined(TEMP)} (EDA, BVP(IBI), PUPIL, ST, LIGHT, TEMP).	
J. A. Healey & Picard (J. A. Healey & Picard, 2005)	{VIDEO}.		{FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESP).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
Herbon et al. (Herbon et al., 2005)		{HERBON} (PUPIL).	{Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (GENDER, AGE, HEALTH, TECHEXPERT).
Partala et al. (Partala et al., 2005)			{MODEL15} (EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {LINK15}.
Van Eck et al. (van Eck et al., 2005)			{I-CORTISOL, SALIVETTE} (CORT).	<b>(Q. FORMAIS)</b> {PSS} (STRESS), {LTE} (LIFEEVENTS), {LDI} (DIFFICULTIES), {PSC} (HEALTH), {SDS} (DEPRESSION), {STAI} (ANXIETY) e {STAS} (ANGER). <b>(Q. INFORMAIS)</b> {INFORMAL} (MOOD, WELLBEING, PHYSI, SMOKING, FOOD,

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				CAFFEI, ALCOH, EMOTIONS).
<b>Busso et al.</b> (Busso et al., 2004)	{VIDEO} (FOREHEAD, EYEBROWS, EYES, CHEEKS) e {AUDIO} (PITCH, VOLUME).			
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)		{JAWBONE} (EDA, HR, ST).		<b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, ETHNICITY, EMOTIONS).
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)			{MP100} (ECG(HR,HRV), PPG, ST, EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Haag et al.</b> (Haag et al., 2004)			{PROCOMP} (EMG, EDA, ST, PPG(BVP(HR)), ECG(HR), RESP).	
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)			{ASL4000} (PUPIL).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>(OUTROS)</b> {PSYSCOPE}.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)			{MANUAL} (SEROT).	<b>(Q. FORMAIS)</b> {BFS} (MOOD). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS, ENERGY, ANXIETY). <b>(OUTROS)</b> {INTERVIEW}.
<b>Nwe et al.</b> (Nwe et al., 2001)	{AUDIO} (SPEECH).			
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)			{ORION, SALIVETTE} (CORT) e {Undefined(EMG)} (EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)			{PROCOMP} (EDA, PPG(BVP(HR)), EMG, RESP) e {Undefined(ECG)} (ECG(HR, HRV)).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)			{S90207} (BP(SBP, DBP)) e {VU-MAS} (ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC).	<b>(Q. FORMAIS)</b> {ERI} (STRESS) e {POMS} (MOOD). <b>(Q. INFORMAIS)</b> {INFORMAL} (PERSON, AGE, WORKYEARS, ACADDG, PHYSI, BMI, HEIGHT, WEIGHT, WAIST, CAFFEI, ALCOH, SMOKING).
<b>Ritz et al.</b> (Ritz et al., 2000)			{SIREGNOSTFD5} (ROS), {FH3803, GMCS5} (VT, RR),	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS), {AIM, TAS, MCSDS}.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			{FINAPRESS4} (HR, BP(SBP, DBP)) e {Undefined(EDA)} (EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	{AUDIO} (SPEECH, PITCH) e {VIDEO} (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN).			
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)			{PROCOMP} (EDA, PPG(BVP(HR)), RESP, EMG).	
<b>Rajita Sinha</b> (Rajita Sinha, 1996)			{78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG).	<b>(Q. FORMAIS)</b> {MMPI, QMI, TAS, BDI, STAI} e {DES} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS). <b>{OUTROS}</b> {INTERVIEW}.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)			{S75-01} (ECG(HR)), {Undefined(EMG)} (EMG) e {S71-22} (EDA).	<b>(Q. FORMAIS)</b> {QMI}. <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>R Rinha et al.</b> (R Sinha et al., 1992)			{Undefined(BP)} (BP(SBP, DBP)), {Undefined(ICG)} (ICG(SV, CO, PVR, PEP, LVET)), {Undefined(ECG)} (ECG(HR)) e Undefined(PCG)} (PCG).	<b>(Q. FORMAIS)</b> {QMI, TAS} e {DES} (EMOTIONS). <b>{OUTROS}</b> {INTERVIEW, OBSERVATION}.

() representa um sinal raw; e {} um instrumento.

### 3.2. MEDIÇÃO SUBJETIVA

Os investigadores das ciências comportamentais utilizam questionários e observação como técnicas de medição, e recorrem muito pouco à tecnologia (Rachuri et al., 2010). Os questionários são instrumentos de medição subjetiva (Kusserow et al., 2013), são interessantes para entender as atitudes dos utilizadores (R. Pagulayan et al., 2012), e são muito usados na avaliação emocional (Fulton & Medlock, 2003) (Mandryk & Atkins, 2007). Além de permitirem mais facilmente a generalização e a análise estatística (Mandryk et al., 2006) os questionários recolhem informação direta daquilo que se pretende avaliar, apesar da subjetividade das respostas poder originar medições erradas e conduzir a resultados incorretos (Caballe, 2015) (Sano & Eng, 2016) (Johnston et al., 2009). Ainda assim os questionários são aceites pela literatura como formas de medir emoções (Babiker et al., 2013).

Os questionários utilizados habitualmente na deteção emocional são de autorresposta ou administrados por especialistas, e podem ser divididos em dois tipos: os de recolha verbal, i.e. são constituídos por perguntas (cf. frases ou palavras) (e.g. SF-12 (Ware, Kosinski, & Keller, 1996), PANAS-X (David Watson & Clark, 1999)); e os de recolha não-verbal que são respondidos com base em imagens com o objetivo de diminuir a subjetividade da interpretação textual (e.g. SAM (Margaret M. Bradley & Lang, 1994) e PREMO (P. Desmet, 2003)) (Babiker et al., 2013).

Cada ser humano pode reagir de forma diferente ao mesmo estímulo emocional (Raudonis, 2013) (e.g. a reação fisiológica perante um evento pode ser diferente entre pessoas (Manuck et al., 1991)). A experiência passada, ambiente e personalidade, fazem com que cada pessoa seja única, justificando a diferença nas suas respostas emocionais (Bos, 2010). É neste contexto que os questionários podem ser uma ferramenta importante para os sistemas de reconhecimento emocional (Bos, 2010). Através dos questionários, pode conseguir-se a recolha de dados de contexto de forma mais compatível e comparável entre indivíduos, já que o inquirido pode responder num nível de maior abstração da sua especificidade pessoal.

São várias as utilizações dadas pelos investigadores aos questionários: i) suportar o processo de seleção de candidatos a participar nas investigações (*screening*) (e.g. Rajita Sinha utilizou o QMI e o TAS para avaliar a capacidade dos candidatos em interpretar imagens e expressar as suas emoções (Rajita Sinha, 1996), van Eck et al. utilizou o PSS para selecionar os participantes (van Eck et al., 2005), etc.); ii) recolha de dados de contexto para correlação com outras variáveis; e iii) recolha de dados *ground truth* (i.e. dados considerados como verdade incontestável) (e.g. Chen et al., Zenonos et al. e Sano et al. utilizaram questionários para recolher *ground truth* (Z. Chen et al., 2013) (Zenonos et al., 2016) (Sano & Picard, 2013b). Alguns autores optaram pela substituição da recolha do *ground truth*, pela utilização de bases de dados de imagens, sons ou vídeos pré-etiquetados com as emoções que provocam (e.g. *International Affective Picture System* (IAPS) (P.J. Lang, Bradley, & Cuthbert, 2005), *International Affective Digitized Sounds* (IADS) (M.M. Bradley & Lang, 1999), etc.).

A questão da obstrutividade também poderia ser levantada na análise dos questionários. No entanto, como a sua aplicação é escalar no tempo e tipicamente são respondidos no início ou fim de ciclos experimentais, decidiu-se por não tratar a obstrutividade destes instrumentos. Ainda assim, alguns investigadores optaram pela digitalização do questionário com o objetivo de facilitar o processo de resposta pelos inquiridos. Por exemplo: Chittaranjan et al. implementou o BFIPT numa aplicação para *smartphone* (Chittaranjan, Jan, & Gatica-Perez, 2011); e Zenonos et al. criou um questionário no *smartphone* para recolher a disposição do

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

utilizador com base na quantificação de várias emoções sentidas pelo utilizador (Zenonos et al., 2016).

São muitos os investigadores que utilizam questionários estatisticamente validados, cujo reconhecimento científico é comprovado pelas sucessivas reutilizações noutras investigações (e.g. SAM (Margaret M. Bradley & Lang, 1994), PSS (S. Cohen, Kamarck, & Mermelstein, 1983), etc.). No entanto, alguns investigadores utilizam também os questionários de forma mais informal (e.g. o questionário de fim de estudo de Sano et al. (Sano & Eng, 2016)). Neste contexto decidimos dividir também os questionários presentes na literatura analisada. Inicialmente apresentamos os questionários formais cuja validade é comprovada pelas diferentes reutilizações em várias investigações, seguindo-se os outros questionários para os quais não encontramos reutilização noutras investigações ou evidências académicas que comprovem a sua formalidade (i.e. questionários desenhados propositadamente para colmatar necessidades específicas de informação da investigação onde surgem).

#### 3.2.1. Questionários formais

Nesta secção analisam-se os questionários estatisticamente validados, i.e. aqueles cuja reutilização por vários investigadores providencia validade científica. Além dos questionários presentes nas investigações analisados para recolha de dados de contexto e *ground truth* (cf. verbal e não-verbal), são também abordados questionários utilizados nos processos de *screening*, ou outros ainda que podem vir a ser úteis para a recolha de dados de contexto para deteção emocional.

São vários os questionários de resposta **verbal** utilizados: o *Perceived Stress Scale* **{PSS}** é um dos instrumentos da psicologia mais utilizados para medir a perceção do STRESS (S. Cohen et al., 1983); o *Effort-Reward Imbalance* **{ERI}** é um questionário usado para medir o STRESS crónico relacionado com o trabalho (Vrijkotte et al., 2000) através da avaliação do esforço, recompensa e superação (Siegrist et al., 2004); o *Long-term Difficulties Inventory* **{LDI}** (Hendriks, Ormel, & van de Willige, 1990) faz uma avaliação das dificuldades diárias (DIFFICULTIES) (e.g. problemas no trabalho, escola, casa, finanças pessoais, relações sociais com elementos da rede, etc.) e é utilizado na avaliação do stress crónico (Rosmalen, Bos, & de Jonge, 2012); o *Psychosomatic Symptom Checklist* **{PSC}** (Attanasio, Andrasik, Blanchard, & Arena, 1984) usado para avaliar queixas habituais de saúde das pessoas (HEALTH) (e.g. dores de cabeça e costas, náuseas, etc. (van Eck et al., 2005)); o *Short-Form 12* **{SF-12}** (versão reduzida do *Short-Form 36* (SF-36)) é um instrumento que mede a qualidade de vida relacionada com a saúde física e mental (HEALTH) (Sano & Eng, 2016), e é composto por perguntas relacionadas com o sentimento de CALM, energia, DEPRESSION e ANXIETY (Ware et al., 1996); a escala *Zung Self-rating Depression Scale* **{SDS}** é uma técnica para avaliar o nível de DEPRESSION das pessoas (ZUNG, 1965); o *Beck Depression Inventory* **{BDI}** (atualmente na segunda versão (BDI-II) (Beck, A.T.; Steer, R.A.; Brown, 1996)) é um dos instrumentos mais utilizados para avaliar a DEPRESSION (Gorestein, 1998), em que o respondente indica a intensidade de um conjunto de itens que medem atitudes e sintomas relacionados com a depressão (Leonetti & Foderaro, 2007) (Aaron T. Beck, 1967); o *State-Trait Anxiety Inventory* **{STAI}** de Spielberger permite medir a ANXIETY (CD Spielberger, 1983) (Cd Spielberger, Gorsuch, Lushene, & Vagg, 1983); ainda do mesmo autor, *Spielberger State-Trait Anger Scale* **{STAS}** é uma escala para medir a ANGER e, em conjunto com *Anger Expression* (AX), deu origem à *State-Trait Anger Expression Inventory* (STAXI) (C. D. Spielberger, 2010a) (C. D. Spielberger, 2010b); o *Pittsburgh Sleep Quality Index* **{PSQI}** é um instrumento para medir a

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

qualidade e padrões de sono (SLEEP) (Buysse, Reynolds, Monk, Berman, & Kupfer, 1989); o *Big Five Inventory Personality Test* {**BIPT**} é um inventário que mede as cinco dimensões da personalidade (PERSON) de uma pessoa (cf. *Extraversion, Agreeableness, Conscientiousness, Neuroticism* e *Openness to experience*) (McCrae & John, 1992) (John, O. P., & Srivastava, 1999); o Myers Briggs Type Indicator {**MBTI**} é um instrumento utilizado para medir e categorizar personalidades e comportamento (Briggs, 2015) (Myers & Briggs, n.d.) (C. Reis, 2016); o *Positive And Negative Affect Schedule* {**PANAS**} baseia-se na ideia que é possível que alguém sinta algo positivo e negativo em simultâneo (LiKamWa et al., 2013) (J. T. Larsen, McGraw, & Cacioppo, 2001), e funciona com base numa lista de palavras que descrevem diferentes sentimentos e emoções (representativos das dimensões: *Positive Affect* (PA); e *Negative Affect* (NA)), que o respondente deve classificar numa escala de cinco pontos representativos da intensidade sentida em cada emoção (EMOTIONS) (D Watson, Clark, & Tellegen, 1988); o *Positive And Negative Affect Schedule – Expanded Form* {**PANAS-X**} é uma versão expandida do PANAS que acrescenta um segundo nível de avaliação da disposição com a medição de onze emoções específicas consideradas pelos psicólogos como emoções básicas (Babiker et al., 2013) (cf. medo, tristeza, culpa, hostilidade, timidez, fadiga, surpresa, jovialidade (bom-humor), autoconfiança, atenção e serenidade) (EMOTIONS) (David Watson & Clark, 1999); o *Profile Of Mood States* {**POMS**} (McNair, Lorr, & Droppleman, 1989) é composto por vários adjetivos relacionados com emoções e avalia a disposição (MOOD) através do sentimento de tensão, depressão, fúria, vigor, fadiga e confusão (Sano & Eng, 2016); a *Befindlichkeits Scale* {**BFS**}, também conhecida como *Zerssen Mood Scale* é constituída por adjetivos relacionados com emoções e é utilizada para recolher a disposição (MOOD) dos respondentes (Heimann, Bobon-Schrod, Schmocker, & Bobon, 1975) (C J Harmer et al., 2003) (von Zerssen, Strian, & Schwarz, 1974); o *HealthyOffice* {**HEALTHYOFFICE**} é uma aplicação para *smartphone* apresentada por Zenonos et al. desenhada para facilitar o *self-reporting* da disposição (MOOD) a partir da inserção da intensidade das emoções sentidas pelo utilizador (a aplicação foi criada ao abrigo do projeto europeu *IES Cities* e inclui um sistema de lembretes para o preenchimento) (KWMC, 2016) (IES Cities Project, 2016) (Zenonos et al., 2016); o *Beck Depression Inventory* {**BDI**} (atualmente na versão 2 (BDI-II) (Beck, A.T.; Steer, R.A., Brown, 1996)) é um dos instrumentos mais utilizados para avaliar a DEPRESSION (Gorestein, 1998), em que o respondente classifica a intensidade sentida relativamente a um conjunto de itens para medição de atitudes e sintomas relacionados com a depressão (Leonetti & Foderaro, 2007) (Aaron T. Beck, 1967); o questionário *List of Threatening Experiences* {**LTE**}, também referenciado na literatura como LTE-Q para diferenciar a lista de ameaças de Brugha et al. do questionário (Q) que utiliza essa lista (T. S. Brugha & Cragg, 1990), avalia os eventos de vida marcantes (LIFEEVENTS) (e.g. morte de família, divórcio, etc.) (van Eck et al., 2005), através de um conjunto de itens em que os respondentes indicam o respetivo nível de ameaça que representa (T. Brugha, Bebbington, Tennant, & Hurry, 1985) (Rosmalen et al., 2012); e o questionário *Self-assessment Morningness-Eveningness* {**SAME**} de Horne et al. permite recolher informação relacionada com os ciclos circadianos dos respondentes (Horne & Ostberg, 1976).

Além dos questionários de resposta escrita, existem também os de resposta **não-verbal**: o *Self-Assessment Manikin* {**SAM**} (Margaret M. Bradley & Lang, 1994) é uma técnica para medir a reação emocional de uma pessoa (EMOTIONS) a um determinado estímulo (cf. dimensões: *valence, arousal* e *dominance*), através de manequins (i.e. imagens) representativos de estados emocionais (cf. *happy/unhappy, excited/calm* e *controlled/uncontrolled*) (Herbon et al., 2005)) (Margaret M. Bradley & Lang, 1994); o nome do *Circumplex Model of Affect* {**CIRCUMPLEX**} dado por Russel (Russell, 1980) advém do padrão circular desenhado pela estrutura de emoções

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

discretas identificadas no plano bidimensional com base no respetivo grau de *valence* e *arousal* (EMOTIONS) (Herbon et al., 2005) e, apesar de ser um modelo simples e rápido de administrar, consegue representar muitos estados emocionais (LiKamWa et al. utilizou o conceito do CIRCUMPLEX para questionar o utilizador através de duas *input bars* acerca do *valence* e *arousal* sentido) (LiKamWa et al., 2013); o *Affect Grid* **{AFFECTGRID}**, criado com base no CIRCUMPLEX, é uma escala desenhada também por Russel et al. para avaliar o afeto nas dimensões do espaço *arousal/valence* (AV) (cf. *pleasure/displeasure* e *arousal/sleepiness*) de forma simples e rápida (Russell, Weiss, & Mendelsohn, 1989), e é respondida através da colocação de marcas nos quadrados da grelha AV (Mandryk & Atkins, 2007) (Alzoubi et al. utilizou o AFFECTGRID como instrumento de recolha de níveis de *valence* e *arousal* sentidos (EMOTIONS) (Alzoubi et al., 2013));

Identificaram-se ainda nas investigações analisadas, questionários utilizados como suporte aos processos de **screening**: o *Marlowe-Crowne Social Desirability Scale* **{MCSDS}** é um questionário bastante usado para avaliar a desejabilidade social, i.e. a necessidade de aprovação social sentida por um individuo (Leite, 2005) (D P Crowne & Marlowe, 1960) (Douglas P. Crowne & Marlowe, 1960); o *Affect Intensity Measure* **{AIM}** foi desenvolvido por Larsen (R. J. Larsen, 1984), é um questionário desenhado para medir a intensidade das emoções sentidas a eventos típicos da vida (EMOTIONS) (Larsen, 1993) (Weinfurt, Bryant, & Yarnold, 1994) (Randy J. Larsen & Diener, 1987); o *Differential Emotion Scale* **{DES}** é um instrumento composto por uma lista de adjetivos para avaliar a subjetividade das descrições verbais dos respondentes, solicitando a classificação da intensidade de uma palavra para descrever determinado sentimento no momento da resposta (EMOTIONS) (Izard E., 1972) (Boyle, 1984); o *Minnesota Multiphasic Personality Inventory* **{MMPI}** (posteriormente MMPI-2) avalia a personalidade do respondente (PERSON) e tem várias versões (e.g. avaliação forense, seleção para emprego, adolescentes (MMPI-A), etc.) (Schiele, Baker, & Hathaway, 1943) (Buutcher et al., 2001); o *Questionnaire for Mental Imagery* **{QMI}** permite avaliar a capacidade de interpretação de imagens pelos respondentes (utilizado essencialmente nos processos de *screening*) (Sheehan, 1967); e o *Toronto Alexithymia Scale* **{TAS}** é instrumento para avaliar a capacidade de interpretação de emoções a partir de imagens (também utilizado nos processos de *screening*) (G. J. Taylor, Ryan, & Bagby, 1985) (Bagby, Parker, & Taylor, 1994).

INVESTIGAÇÃO	INSTRUMENTOS & SENSORES	
	QUESTIONÁRIOS FORMAIS	OUTROS
Sano & Eng (Sano & Eng, 2016)	{SAME, PSQI} (SLEEP*), {MBTI, BFIPT} (PERSON), {PSS} (STRESS*), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY).	<b>Q. informais:</b> {INFORMAL} (AGE, GENDER, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).  <b>(T. NÃO OBSTRUTIVAS)</b> {FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT). <b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Zenonos et al.</b> (Zenonos et al., 2016)	{HEALTHYOFFICE} (MOOD*, EMOTIONS*).	<b>(T. POUCO OBSTRUTIVAS)</b> {SILMEEW2X, SILMEEBTYPE} (ECG(HR(IBMSSD, SDNN)), HRV), PPG(PR, PTT), ST).  <b>(OUTROS)</b> {HRVAS} (HRV) e {HAR} (ACC).
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	{BFIPT} (PERSON).	<b>Q. informais:</b> {INFORMAL} (STRESS).  <b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, PROXIMITY) e {EXISTINGDATA} (WEATHER).
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	{AFFECTGRID} (EMOTIONS*).	<b>(T. OBSTRUTIVAS)</b> {MP150} (ECG(HRV), EMG, EDA, RESP).  <b>(OUTROS)</b> {ACQK}.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	{PSS**} (STRESS*), {PSQI**} (SLEEP) e {BFIPT**} (PERSON).	<b>Q. informais:</b> {INFORMAL} (SLEEP, ELECTR, HEALTH, MOOD, ALERT, TIRED, STRESS, NAP, CAFFEI, ALCOH).  <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ACC) e {FUNF} (CALL, SMS, LOCAL, SCREEN).
<b>Babiker et al.</b> (Babiker et al., 2013)	{PANAS-X} (EMOTIONS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {TX300} (EYES, GAZE, PUPIL).
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	{CIRCUMPLEX***} (MOOD*). *** adaptação do autor	<b>(T. NÃO OBSTRUTIVAS)</b> {MOODSCOPE} (SMS, EMAIL, CALL, APPS, BROWSER, LOCAL).
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	{SAM} (EMOTIONS*).	<b>(T. OBSTRUTIVAS)</b> {ML870} (ECG, BVP, PR, EDA).
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	{SAM} (EMOTIONS*).	<b>Q. informais:</b> {INFORMAL} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG). <b>(OUTROS)</b> {EPOC-SDK}.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	{SAM} (EMOTIONS*).	<b>Q. informais:</b> {INFORMAL} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {HEALTHLAB} (RESP(RR, RDEP), EDA, ECG(HR, HRV, IBI), EMG, ST).
<b>Herbon et al.</b> (Herbon et al., 2005)	{SAM} (EMOTIONS*).	<b>Q. informais:</b> {INFORMAL} (GENDER, AGE, HEALTH, TECHEXPERT).  <b>(T. POUCO OBSTRUTIVAS)</b> {HERBON} (PUPIL). <b>(T. OBSTRUTIVAS)</b> {Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).
<b>Van Eck et al.</b> (van Eck et al., 2005)	{PSS**} (STRESS*), {LTE} (LIFEEVENTS), {LDI} (DIFFICULTIES), {PSC} (HEALTH), {SDS}	<b>Q. informais:</b> {INFORMAL} (MOOD, WELLBEING, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH, EMOTIONS).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	(DEPRESSION), {STAI} (ANXIETY) e {STAS} (ANGER).	<b>(T. OBSTRUTIVAS)</b> {I-CORTISOL, SALIVETTE} (CORT).
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	{BFS} (MOOD).	<b>Q. informais:</b> {INFORMAL} (EMOTIONS, ENERGY, ANXIETY).  <b>(T. OBSTRUTIVAS)</b> {MANUAL} (SEROT). <b>(OUTROS)</b> {INTERVIEW}.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	{ERI} (STRESS*) e {POMS} (MOOD).	<b>Q. informais:</b> {INFORMAL} (PERSON, AGE, WORKYEARS, ACADDG, PHYSI, BMI, HEIGHT, WEIGHT, WAIST, CAFFEI, ALCOH, SMOKING).  <b>(T. OBSTRUTIVAS)</b> {S90207} (BP(SBP, DBP)) e {VU-MAS} (ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC).
<b>Ritz et al.</b> (Ritz et al., 2000)	{SAM} (EMOTIONS), {AIM, TAS, MCSDS}**.	<b>Q. informais:</b> {INFORMAL} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {SIREGNOSTFD5} (ROS), {FH3803, GMCS5} (VT, RR), {FINAPRESS4} (HR, BP(SBP, DBP)) e {Undefined(EDA)} (EDA).
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	{MMPI, QMI, TAS, BDI, STAI}** e {DES} (EMOTIONS).	<b>Q. informais:</b> {INFORMAL} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG). <b>(OUTROS)</b> {INTERVIEW}.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	{QMI}**.	<b>Q. informais:</b> {INFORMAL} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {S75-01} (ECG(HR)), {Undefined(EMG)} (EMG) e {S71-22} (EDA).
<b>R Rinha et al.</b> (R Sinha et al., 1992)	{QMI, TAS}** e {DES} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {Undefined(BP)} (BP(SBP, DBP)), {Undefined(ICG)} (ICG(SV, CO, PVR, PEP, LVET)), {Undefined(ECG)} (ECG(HR)) e {Undefined(PCG)} (PCG). <b>(OUTROS)</b> {INTERVIEW, OBSERVATION}.

() representa um sinal raw; {} um instrumento; \* provavelmente utilizado para recolha de ground truth; \*\*utilizado no processo de screening.

### 3.2.2. Questionários informais

A necessidade de recolha de informação específica no contexto de uma investigação, leva a que os investigadores utilizem questionários específicos nas suas investigações. Nesta secção são apresentados os questionários presentes nas investigações analisadas, cuja validade não foi possível verificar tendo por base evidências científicas ou reutilização por outros investigadores. Incluem-se nesta categoria os dados recolhidos a partir de diários ou outro tipo de anotações solicitadas às pessoas.

Os investigadores utilizam questionários informais (**INFORMAL**) essencialmente para recolher informação acerca das emoções sentidas (EMOTIONS): Matlovic et al. utilizou um questionário com questões relacionadas com as emoções sentidas pelos participantes na visualização de vídeos (e.g. *“How strong was the emotion that you felt? (arousal)”*, *“How positive was the emotion that you felt? (valence)”* e *“What emotion did you feel the most?”*) (Matlovic et al., 2016); Z. Zhang et al. pediu aos participantes da sua experiência que indicassem num *tablet* as emoções sentidas a partir de uma lista fechada de opções (e.g. *“relaxed”*, *“surprised”*, *“sad”*, *“happy/amusement”*, etc.) e a respetiva intensidade sentida através de uma escala de likert (Z. Zhang et al., 2016); C J Harmer et al. utilizou *visual analogue scales* para recolher informação emocional diversa (e.g. felicidade, tristeza, medo, desgosto, fúria, etc.) (C J Harmer et al., 2003); Lisetti & Nasoz solicitou aos participantes que, a cada cena de vídeo visualizada, indicassem a emoção sentida a partir de uma lista fechada de opções (permitia ainda assim a inserção manual de uma emoção não prevista), a intensidade sentida dessa emoção, e se existiu outra emoção sentida com relevo além da selecionada (Lisetti & Nasoz, 2004); Rajita Sinha utilizou um questionário de suporte à criação do cenário da sua experiência onde era pedido que os participantes descrevessem uma situação das suas vidas que provocasse a emoção sentida para cada imagem visualizada (lembrar uma situação da sua vida cuja emoção fosse equivalente ao sentimento causado pela imagem visualizada) (Rajita Sinha, 1996); e Y. Liu et al. além de ter utilizado o SAM apenas para recolher dois domínios (cf. *arousal* e *valence*), solicitou aos participantes da sua experiência a anotação por palavras próprias das emoções sentidas aquando da audição de sons da base de dados *International Affective Digitized Sounds* (IADS) (apresentada mais à frente neste documento) (Y. Liu et al., 2010).

No entanto, os questionários informais também são utilizados pelos investigadores para recolher outros dados de origem psicossocial: Sano et al. utilizou o *smartphone* para colocar questões aos participantes relacionadas com o sono (SLEEP), nível de alerta (ALERT), stress (STRESS), cansaço (TIRED), etc. (Sano & Picard, 2013b); Sano et al. depois de analisar alguns questionários formais, preteriu da sua utilização por causa da sua dimensão, optando pela utilização de escalas simples respondidas através de sliders [0:100] (e.g. Sad-Happy (HAPPY); Sleepy-Alert (ALERT); Sick-Healthy (HEALTH); etc.) (Sano & Eng, 2016); Hernandez et al. com o objetivo de avaliar a qualidade das interações sociais das chamadas telefónicas (SOCIAL), pediu aos participantes da sua experiência que respondessem em dois segundos à questão *“How was the last call?”*, utilizando uma escala de *likert* de sete pontos representativos do stress provocado (Hernandez et al., 2011); Jaques et al. usou um questionário para recolher dados acerca da duração das atividades académicas curriculares (ACADCL), exercício físico (PHYSI), tempo de estudo (ACADST), sono (SLEEP), sesta (NAP), consumo de álcool (ALCOH), ingestão de cafeína (CAFFEI), etc. (Jaques et al., 2015); Healey et al. utilizou um questionário com perguntas para medir o STRESS de motoristas em eventos relacionados com a condução (J. A. Healey & Picard, 2005); e Jennifer a Healey et al. criou um questionário específico para recolher dados relacionados com a atividade de conduzir (e.g. *“How often do you usually drive?”*, *“Do you*

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

own a car or have a car you can use frequently?”, “In generak, do you feel you are more stressed than others, less stressed than others, or at about the same level as others?”, etc.) (Jennifer a Healey et al., 2000).

INVESTIGAÇÃO	INSTRUMENTOS & SENSORES	
	QUESTIONÁRIOS INFORMAIS	OUTROS
<b>Matlovic et al.</b> (Matlovic et al., 2016)	{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {FACEREADER, SHORE}. <b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG) e {TGSRR} (EDA). <b>(OUTROS)</b> {TSTUDIO, CAPTIV}.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {DI3D, A655SC, VIDEO} (HEAD, FACS, ST). <b>(T. OBSTRUTIVAS)</b> {MP150, NIBP100D} (BP(SBP, DBP), HR, PR, RESP(RR)) e {Undefined(EDA)} (EDA).
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	{INFORMAL**} (AGE, GENDER, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).	<b>Q. formais:</b> {SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), {PSS} (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY). <b>(T. NÃO OBSTRUTIVAS)</b> {FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT). <b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).
<b>Zhao et al.</b> (Zhao et al., 2016)	{INFORMAL} (EMOTIONS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {EQ-RADIO} (HR(ABI(RMSSD, SDNN)), RESP) e {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {Undefined(ECG)} (ECG(HR)).
<b>Jaques et al.</b> (Jaques et al., 2015)	{INFORMAL} (HAPPY*, ACADCL, ACADEX, ACADST, PHYSI, SOCIAL, CAFFEI, ALCOH, DRUGS, STRESS, HEALTH, ENERGY, ALERT, CALM, SLEEP, NAP).	<b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, SCREEN, LOCAL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC).
<b>Matiko et al.</b> (Matiko et al., 2014)	{INFORMAL} (EMOTIONS*).	<b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG).
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	{INFORMAL} (STRESS*).	<b>Q. formais:</b> {BFIPT} (PERSON). <b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, PROXIMITY) e {EXISTINGDATA} (WEATHER).
<b>Kusserow et al.</b> (Kusserow et al., 2013)	{INFORMAL} (STRESS*, MOOD).	<b>(T. POUCO OBSTRUTIVAS)</b> {TALKASSIST} (HR(HRV), EDA, ACC, ST), {KUSSEROW2} (ECG(HR), ACC), {KUSSEROW3} (ECG(HR), ACC) e {KUSSEROW4} (HR, ACC).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	{INFORMAL} (SLEEP, ELECTR, HEALTH, MOOD, ALERT, TIRED, STRESS, NAP, CAFFEI, ALCOH).	<b>Q. formais:</b> {PSS} (STRESS), {PSQI} (SLEEP) e {BFIPT} (PERSON).  <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ACC) e {FUNF} (CALL, SMS, LOCAL, SCREEN).
<b>Kawai et al.</b> (Kawai et al., 2013)	{INFORMAL} (EMOTIONS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {XCEI30} (PUPIL). <b>(OUTROS)</b> {DS400}.
<b>Hernandez et al.</b> (Hernandez et al., 2011)	{INFORMAL} (STRESS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {EXISTINGDATA} (CALL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>N. Lane et al.</b> (N. Lane et al., 2011)	{INFORMAL} (DEPRESSION, SLEEP, WELLBEING*).	<b>(T. NÃO OBSTRUTIVAS)</b> {BEWELL} (SLEEP, PHYSI, TALK, LOCAL, ACC). <b>(OUTROS)</b> {HAR}.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	{INFORMAL} (EMOTIONS).	<b>Q. formais:</b> {SAM} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG). <b>(OUTROS)</b> {EPOC-SDK}.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	{INFORMAL} (EMOTIONS*).	<b>Q. formais:</b> {SAM} (EMOTIONS).  <b>(T. OBSTRUTIVAS)</b> {HEALTHLAB} (RESP(RR, RDEP), EDA, ECG(HR, HRV, IBI), EMG, ST).
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	{INFORMAL} (EMOTIONS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO, AUDIO}. <b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, ECG(HR), EMG). <b>(OUTROS)</b> {BIOGRAPH}.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	{INFORMAL} (STRESS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESP). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>Herbon et al.</b> (Herbon et al., 2005)	{INFORMAL} (GENDER, AGE, HEALTH, TECHEXPERT).	<b>Q. formais:</b> {SAM} (EMOTIONS).  <b>(T. POUCO OBSTRUTIVAS)</b> {HERBON} (PUPIL). <b>(T. OBSTRUTIVAS)</b> {Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).
<b>Partala et al.</b> (Partala et al., 2005)	{INFORMAL} (EMOTIONS*).	<b>(T. OBSTRUTIVAS)</b> {MODEL15} (EMG). <b>(OUTROS)</b> {LINK15}.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Van Eck et al.</b> (van Eck et al., 2005)</p>	<p>{INFORMAL} (MOOD*, WELLBEING, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH, EMOTIONS*).</p>	<p><b>Q. formais:</b> {PSS} (STRESS), {LTE} (LIFEEVENTS), {LDI} (DIFFICULTIES), {PSC} (HEALTH), {SDS} (DEPRESSION), {STAI} (ANXIETY) e {STAS} (ANGER).</p> <p><b>(T. OBSTRUTIVAS)</b> {I-CORTISOL, SALIVETTE} (CORT).</p>
<p><b>Lisetti &amp; Nasoz</b> (Lisetti &amp; Nasoz, 2004)</p>	<p>{INFORMAL} (AGE, GENDER, ETHNICITY, EMOTIONS).</p>	<p><b>(T. POUCO OBSTRUTIVAS)</b> {JAWBONE} (EDA, HR, ST).</p>
<p><b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)</p>	<p>{INFORMAL} (EMOTIONS).</p>	<p><b>(T. OBSTRUTIVAS)</b> {MP100} (ECG(HR,HRV), PPG, ST, EDA).</p>
<p><b>Partala &amp; Surakka</b> (Partala &amp; Surakka, 2003)</p>	<p>{INFORMAL} (EMOTIONS).</p>	<p><b>(T. OBSTRUTIVAS)</b> {ASL4000} (PUPIL).</p> <p><b>(OUTROS)</b> {PSYSCOPE}.</p>
<p><b>C J Harmer et al.</b> (C J Harmer et al., 2003)</p>	<p>{INFORMAL} (EMOTIONS, ENERGY, ANXIETY).</p>	<p><b>Q. formais:</b> {BFS} (MOOD).</p> <p><b>(T. OBSTRUTIVAS)</b> {MANUAL} (SEROT).</p> <p><b>(OUTROS)</b> {INTERVIEW}.</p>
<p><b>Buchanan &amp; Lovallo</b> (Buchanan &amp; Lovallo, 2001)</p>	<p>{INFORMAL} (EMOTIONS).</p>	<p><b>(T. OBSTRUTIVAS)</b> {ORION, SALIVETTE} (CORT) e {Undefined(EMG)} (EMG).</p>
<p><b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)</p>	<p>{INFORMAL} (STRESS*).</p>	<p><b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, PPG(BVP(HR))), EMG, RESP) e {Undefined(ECG)} (ECG(HR, HRV)).</p>
<p><b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)</p>	<p>{INFORMAL} (PERSON, AGE, WORKYEARS, ACADDG, PHYSI, BMI, HEIGHT, WEIGHT, WAIST, CAFFEI, ALCOH, SMOKING).</p>	<p><b>Q. formais:</b> {ERI} (STRESS) e {POMS} (MOOD).</p> <p><b>(T. OBSTRUTIVAS)</b> {S90207} (BP(SBP, DBP)) e {VU-MAS} (ECG(HR, HRV, IB(RMSSD(VAGAL))), ACC).</p>
<p><b>Ritz et al.</b> (Ritz et al., 2000)</p>	<p>{INFORMAL} (EMOTIONS).</p>	<p><b>Q. formais:</b> {SAM} (EMOTIONS), {AIM, TAS, MCSDS}.</p> <p><b>(T. OBSTRUTIVAS)</b> {SIREGNOSTFD5} (ROS), {FH3803, GMCS5} (VT, RR), {FINAPRESS4} (HR, BP(SBP, DBP)) e {Undefined(EDA)} (EDA).</p>
<p><b>Rajita Sinha</b> (Rajita Sinha, 1996)</p>	<p>{INFORMAL} (EMOTIONS).</p>	<p><b>Q. formais:</b> {MMPI, QMI, TAS, BDI, STAI} e {DES} (EMOTIONS).</p> <p><b>(T. OBSTRUTIVAS)</b> {78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG).</p> <p><b>(OUTROS)</b> {INTERVIEW}.</p>
<p><b>Scott R. Vrana</b> (Scott R. Vrana, 1993)</p>	<p>{INFORMAL} (EMOTIONS).</p>	<p><b>Q. formais:</b> {QMI}.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(T. OBSTRUTIVAS) {S75-01} (ECG(HR)), {Undefined(EMG)} (EMG) e {S71-22} (EDA).
--	--	--

() representa um sinal raw; {} um instrumento; \* provavelmente utilizado para recolha de ground truth; \*\*utilizado no processo de screening.

### 3.2.3. Análise

Os psicólogos usam normalmente questionários para aferir estados emocionais. Estes instrumentos são considerados válidos pela literatura e são muito utilizados pela comunidade médica e científica. Contudo, os questionários não são instrumentos adequados à recolha de informação volátil por causa da constante confrontação das pessoas com diferentes estímulos potencialmente geradores de alterações emocionais (Matlovic et al., 2016). Além disso não são imunes aos problemas de subjetividade e influências que possam advir do contexto (Johnston et al., 2009) (R. J. Pagulayan, Keecker, Wixon, Romero, & Fuller, 2012). Mas além da subjetividade, os questionários apresentam outros problemas: não atendem às características individuais do inquirido porque não consideram que as pessoas percebem as emoções de forma distinta entre si (Zenonos et al., 2016) (Raudonis, 2013) (Canini et al., 2009) (Bago d’Uva, Van Doorslaer, Lindeboom, & O’Donnell, 2008); medem de forma diferida e escalar no tempo (Tran et al., 2007); a simples presença dos inquiridores pode causar a sensação de menor gravidade e de maior equilíbrio emocional (Wikia, n.d.); etc.

Os investigadores têm tendência a desconfiar dos questionários (Tran et al., 2007) (Bound, 1991). Além de serem técnicas de medição subjetiva, são limitados porque não permitem a captura de dados em tempo real. Como implicam a interrupção de tarefas para que a recolha de dados aconteça, podem ser consideradas técnicas disruptivas que acrescentam ruído e subtraem qualidade aos dados recolhidos (Tran et al., 2007) (Mandryk & Atkins, 2007) já que os dados podem ser corrompidos em resultado da interrupção do estímulo cuja reação se pretendia medir (experiências conduzidas por Mandryk et al. mostraram que o ato de preencher um questionário ou comunicar com o inquiridor, causava uma alteração nos sinais fisiológicos nos participantes da sua experiência (Mandryk & Atkins, 2007)). No entanto, e apesar de existirem poucas evidências que os dados dos questionários são significativos, são muitos os investigadores que os utilizam (Oswald & Wu, 2010) porque permitem entender as atitudes e comportamentos dos utilizadores (R. Pagulayan et al., 2012).

São muitos os questionários formais utilizados pelos investigadores, seja nos processos de *screening* ou de recolha de dados de contexto. A grande vantagem na utilização de questionários formais nas investigações é a aceitação pela comunidade científica porque se tratam de instrumentos reconhecidos pela literatura. Os diferentes testes e diversas reutilizações em diferentes investigações e contextos conferem validade ao método e aos dados recolhidos por ele. No entanto, as investigações analisadas neste levantamento não esclarecem a utilização de versões aferidas para a população representada na amostra utilizada nas experiências, levantando questões relacionadas com a validade dos dados recolhidos. Por exemplo, as respostas dadas a um questionário para recolha do estado de saúde (HEALTH) (e.g. SF-12), podem ser influenciadas por vários fatores: conceito individual de saúde; sistema de *healthcare* disponível; educação; condições socioeconómicas; rendimento mensal; compreensão das perguntas do questionário; etc. Como todos estes fatores podem variar em função da localização geográfica, faz sentido acautelar as especificidades demográficas utilizando

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

questionários (ou versões de questionários) aferidos para cada população (Bago d’Uva et al., 2008) (Johnston et al., 2009).

Os investigadores também recorrem à utilização de questionários informais para recolher dados para utilização nos seus sistemas. Talvez o número elevado de investigações que recorrem a esta técnica seja justificado pela necessidade de obtenção de dados específicos não previstos pelos questionários formais, ou pelo facto destes serem de preenchimento mais demorado ou não estarem totalmente enquadrados nos objetivos dos investigadores. A grande vantagem da utilização de questionários informais será a liberdade na adequação do instrumento à investigação, sendo possível recolher diretamente a medida subjetiva pretendida. No entanto, a ausência de evidências que sustentem a qualidade do instrumento como a realização de pré-testes, coloca em causa a validade dos dados recolhidos e, conseqüentemente, dos resultados obtidos pelos sistemas.

INVESTIGAÇÃO	QUESTIONÁRIOS FORMAIS	QUESTIONÁRIOS INFORMAIS	OUTRAS
<b>Matlovic et al.</b> (Matlovic et al., 2016)		{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {FACEREADER, SHORE}. <b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG) e {TGSR} (EDA). <b>(OUTROS)</b> {TSTUDIO, CAPTIV}.
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)		{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {DI3D, A655SC, VIDEO} (HEAD, FACS, ST). <b>(T. OBSTRUTIVAS)</b> {MP150, NIBP100D} (BP(SBP, DBP), HR, PR, RESP(RR)) e {Undefined(EDA)} (EDA).
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	{SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), {PSS} (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY).	{INFORMAL} (AGE, GENDER, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI, ACADCL, ACADGR, ACADDEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).	<b>(T. NÃO OBSTRUTIVAS)</b> {FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT). <b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG), {Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).
<b>Zhao et al.</b> (Zhao et al., 2016)		{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {EQ-RADIO} (HR(IBI(RMSSD, SDNN)), RESP) e {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {Undefined(ECG)} (ECG(HR)).
<b>Zenonos et al.</b> (Zenonos et al., 2016)	{HEALTHYOFFICE} (MOOD, EMOTIONS).		<b>(T. POUCO OBSTRUTIVAS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			{SILMEEW2X, SILMEEBTYPE} (ECG(HR(IBI(RMSSD, SDNN)), HRV), PPG(PR, PTT), ST). <b>(OUTROS)</b> {HRVAS} (HRV) e {HAR} (ACC).
<b>Jaques et al.</b> (Jaques et al., 2015)		{INFORMAL} (HAPPY, ACADCL, ACADEX, ACADST, PHYSI, SOCIAL, CAFFEI, ALCOH, DRUGS, STRESS, HEALTH, ENERGY, ALERT, CALM, SLEEP, NAP).	<b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, SCREEN, LOCAL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC).
<b>Matiko et al.</b> (Matiko et al., 2014)		{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG).
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	{BFIPT} (PERSON).	{INFORMAL} (STRESS).	<b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, PROXIMITY) e {EXISTINGDATA} (WEATHER).
<b>Kusserow et al.</b> (Kusserow et al., 2013)		{INFORMAL} (STRESS, MOOD).	<b>(T. POUCO OBSTRUTIVAS)</b> {TALKASSIST} (HR(HRV), EDA, ACC, ST), {KUSSEROW2} (ECG(HR), ACC), {KUSSEROW3} (ECG(HR), ACC) e {KUSSEROW4} (HR, ACC).
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	{AFFECTGRID} (EMOTIONS).		<b>(T. OBSTRUTIVAS)</b> {MP150} (ECG(HRV), EMG, EDA, RESP). <b>(OUTROS)</b> {ACQK}.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	{PSS} (STRESS), {PSQI} (SLEEP) e {BFIPT} (PERSON).	{INFORMAL} (SLEEP, ELECTR, HEALTH, MOOD, ALERT, TIRED, STRESS, NAP, CAFFEI, ALCOH).	<b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ACC) e {FUNF} (CALL, SMS, LOCAL, SCREEN).
<b>Kawai et al.</b> (Kawai et al., 2013)		{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {XCEI30} (PUPIL). <b>(OUTROS)</b> {DS400}.
<b>Babiker et al.</b> (Babiker et al., 2013)	{PANAS-X} (EMOTIONS).		<b>(T. NÃO OBSTRUTIVAS)</b> {TX300} (EYES, GAZE, PUPIL).
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	{CIRCUMPLEX} (MOOD).		<b>(T. NÃO OBSTRUTIVAS)</b> {MOODSCOPE} (SMS, EMAIL, CALL, APPS, BROWSER, LOCAL).
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	{SAM} (EMOTIONS).		<b>(T. OBSTRUTIVAS)</b> {ML870} (ECG, BVP, PR, EDA).
<b>Hernandez et al.</b>		{INFORMAL} (STRESS).	<b>(T. NÃO OBSTRUTIVAS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Hernandez et al., 2011)			{EXISTINGDATA} (CALL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>N. Lane et al.</b> (N. Lane et al., 2011)		{INFORMAL} (DEPRESSION, SLEEP, WELLBEING).	<b>(T. NÃO OBSTRUTIVAS)</b> {BEWELL} (SLEEP, PHYSI, TALK, LOCAL, ACC). <b>(OUTROS)</b> HAR).
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	{SAM} (EMOTIONS).	{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG). <b>(OUTROS)</b> {EPOC-SDK}.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	{SAM} (EMOTIONS).	{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {HEALTHLAB} (RESP(RR, RDEP), EDA, ECG(HR, HRV, IBI), EMG, ST).
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)		{INFORMAL} (EMOTIONS).	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO, AUDIO}. <b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, ECG(HR), EMG). <b>(OUTROS)</b> {BIOGRAPH}.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)		{INFORMAL} (STRESS).	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESP). <b>(OUTROS)</b> {OBSERVATION} (STRESS).
<b>Herbon et al.</b> (Herbon et al., 2005)	{SAM} (EMOTIONS).	{INFORMAL} (GENDER, AGE, HEALTH, TECEXPRT).	<b>(T. POUCO OBSTRUTIVAS)</b> {HERBON} (PUPIL). <b>(T. OBSTRUTIVAS)</b> {Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).
<b>Partala et al.</b> (Partala et al., 2005)		{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {MODEL15} (EMG). <b>(OUTROS)</b> {LINK15}.
<b>Van Eck et al.</b> (van Eck et al., 2005)	{PSS} (STRESS), {LTE} (LIFEEVENTS), {LDI} (DIFFICULTIES), {PSC} (HEALTH), {SDS} (DEPRESSION), {STAI} (ANXIETY) e {STAS} (ANGER).	{INFORMAL} (MOOD, WELLBEING, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH, EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {I-CORTISOL, SALIVETTE} (CORT).
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)		{INFORMAL} (AGE, GENDER, ETHNICITY, EMOTIONS).	<b>(T. POUCO OBSTRUTIVAS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			{JAWBONE} (EDA, HR, ST).
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {MP100} (ECG(HR,HRV), PPG, ST, EDA).
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)		{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {ASL4000} (PUPIL). <b>(OUTROS)</b> {PSYSCOPE}.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	{BFS} (MOOD).	{INFORMAL} (EMOTIONS, ENERGY, ANXIETY).	<b>(T. OBSTRUTIVAS)</b> {MANUAL} (SEROT). <b>(OUTROS)</b> {INTERVIEW}.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)		{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {ORION, SALIVETTE} (CORT) e {Undefined(EMG)} (EMG).
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)		{INFORMAL} (STRESS).	<b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, PPG(BVP(HR))), EMG, RESP) e {Undefined(ECG)} (ECG(HR, HRV)).
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	{ERI} (STRESS) e {POMS} (MOOD).	{INFORMAL} (PERSON, AGE, WORKYEARS, ACADDG, PHYSI, BMI, HEIGHT, WEIGHT, WAIST, CAFFEI, ALCOH, SMOKING).	<b>(T. OBSTRUTIVAS)</b> {S90207} (BP(SBP, DBP)) e {VU-MAS} (ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC).
<b>Ritz et al.</b> (Ritz et al., 2000)	{SAM} (EMOTIONS), {AIM, TAS, MCSDS}.	{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {SIREGNOSTFD5} (ROS), {FH3803, GMCS5} (VT, RR), {FINAPRESS4} (HR, BP(SBP, DBP)) e {Undefined(EDA)} (EDA).
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	{MMPI, QMI, TAS, BDI, STAI} e {DES} (EMOTIONS).	{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG). <b>(OUTROS)</b> {INTERVIEW}.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	{QMI}.	{INFORMAL} (EMOTIONS).	<b>(T. OBSTRUTIVAS)</b> {S75-01} (ECG(HR)), {Undefined(EMG)} (EMG) e {S71-22} (EDA).
<b>R Rinha et al.</b> (R Sinha et al., 1992)	{QMI, TAS} e {DES} (EMOTIONS).		<b>(T. OBSTRUTIVAS)</b> {Undefined(BP)} (BP(SBP, DBP)),

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			{Undefined(ICG)} (ICG(SV, CO, PVR, PEP, LVET)), {Undefined(ECG)} (ECG(HR)) e {Undefined(PCG)} (PCG). <b>(OUTROS)</b> {INTERVIEW, OBSERVATION}.
--	--	--	--

() representa um sinal raw; e {} um instrumento.

### 3.3. OUTROS INSTRUMENTOS

Nesta secção são apresentados outros instrumentos referenciados pela literatura analisada, não incluídos nas secções já apresentadas. Apesar da sua importancia nos sistemas de deteção emocional, participam apenas indiretamente no processo de recolha de dados de contexto.

Na literatura analisada identificaram-se os seguintes instrumentos utilizados de forma secundária no processo de introspeção do contexto: o gravador Hitachi MS-DS400 **{DS400}** utilizado por Kawai et al. para guardar o vídeo recolhido em DVV (Kawai et al., 2013); o *Tobii Studio* **{TSTUDIO}** é uma aplicação utilizada nas investigações que utilizam dados de contexto ocular, apoia a investigação desde a gravação, análise e apresentação de resultados, e permite a apresentação de questionários (Tobii Technology AB, 2015) (Matlovic et al., 2016); a aplicação *LabChart* **{LABCHART}** da *ADInstruments* é usada como instrumento de aquisição de dados, e permite armazenar e monitorizar em tempo real e em simultâneo, os dados recolhidos por sensores de recolha (e.g. ML870, FE116, ML309, ML135, etc.) (ADInstruments, n.d.-e) (são vários os investigadores que utilizaram os sistemas da *ADInstruments* nomeadamente o LABCHART: Basu et al. (Basu et al., 2016); Mokhayeri et al. (Mokhayeri & Toosizadeh, 2011); Chang et al. (Chang et al., 2012); Ding et al. (Ding et al., 2013); etc.); a aplicação *AcqKnowledge* **{ACQK}** faz o tratamento da informação proveniente de instrumentos como o MP100, MP150 e MP160 (Biopac Systems Inc, 2017c) (Biopac Systems Inc, 2017e) (Toruzyme, 2001); o *Captiv* **{CAPTIV}** é uma ferramenta da TEA que facilita o processo de gravação, sincronização e análise de gravações de vídeo e outros sensores de recolha (TEA, 2016); o MATLAB (The Mathworks Inc., 2016) é uma plataforma de análise de dados que contém várias ferramentas, e é bastante utilizado pelos investigadores; Zenonos et al, utilizou a toolbox do MATLAB HRVAS **{HRVAS}** de Ramshur para extração do HRV (Ramshur, 2010) (Zenonos et al., 2016); algoritmos relacionados com *Human Activity Recognition* **{HAR}** (Bulling, Blanke, & Schiele, 2014) (Hammerla, Kirkham, Andras, & Ploetz, 2013); Yang et al. utilizou *Emotion Avatar Images* **{EAI}** na sua recolha de dados, para criar representações genéricas de faces recolhidas por vídeo com o objetivo de diminuir as características específicas das pessoas (S. Yang & Bhanu, 2011); o *BioExplorer* **{BIOEXPLORER}** é um software utilizado para *neurofeedback* e *biofeedback* (e.g. Bos utilizou-o em conjunto com o BQPET para recolher o EEG (Bos, 2010)) (Brainquiry, 2017); o *BioGraph* **{BIOGRAPH}** *Infiniti* da *Thought Technology* é utilizado em conjunto instrumentos de recolha de sinais fisiológicos e permite a visualização de dados de forma gráfica durante o processo de recolha e análise de dados raw (por e.g. Mandryk & Atkings utilizou o BIOGRAPH em conjunto com o PROCOMP no processo de recolha de sinais fisiológicos (Mandryk & Atkins, 2007)) (Thought Technology Ltd., n.d.) (Thought Technology Ltd., 2016b); e o *Grass Link15* **{LINK15}**, utilizado por (Partala et al., 2005), é um software que apoia na gravação de dados provenientes de dispositivos como o MODEL15.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Ainda no mesmo grupo de ferramentas incluem-se também os *Software Development Kits* (SDK) disponíveis para cada produto para permitir a integração com os dispositivos: MINDWAVE {MINDWAVE-SDK} (NeuroSky, 2017); KINECT {KINECT-SDK} (Microsoft, 2017a); e EPOC-SDK {EPOC-SDK} (Emotiv, 2017).

Existem também ferramentas de suporte ao processo experimental na fase de recolha de dados de contexto: o *PsyScope* {PSYSCOPE} é uma ferramenta utilizada no controlo experimental em laboratórios de psicologia, e permite desenhar e controlar processos experimentais sem necessidades de programação (J. Cohen, MacWhinney, Flatt, & Provost, 1993) (Bonatti, 2006) (a fase de administração de estímulos sonóros da experiência de Partala et al., foi controlada pelo PSYSCOPE, assim como o processo de recolha de dados das respostas dos participantes (Partala & Surakka, 2003)).

Identificaram-se ainda outros instrumentos utilizados de forma bastante residual: Rajita Sinha fez entrevista {INTERVIEW} aos sujeitos elegíveis a participar no seu processo experimental com o objetivo de administrar vários questionários para *screening* (Rajita Sinha, 1996); Hsu et al. utilizou INTERVIEW e observação {OBSERVATION} comportamental para identificar alterações emocionais na investigação em que apresentou o jogo *Emotion Labyrinth* (Hsu et al., 2012); e Z. Zhang et al. utilizou a INTERVIEW feita por um ator profissional para provocar emoções nos participantes através da conversa interpessoal (Z. Zhang et al., 2016). Soleymani et al. utilizou a OBSERVATION para que cinco anotadores atribuissem um valor de valence para servir de ground truth à investigação (Soleymani et al., 2013).

O quadro seguinte resume as investigações analisadas onde foram encontrados os instrumentos indicados nesta secção.

INVESTIGAÇÃO	INSTRUMENTOS & SENSORES DE RECOLHA	
	OUTROS	ANTERIORES
Matlovic et al. (Matlovic et al., 2016)	{TSTUDIO, CAPTIV}.	(T. NÃO OBSTRUTIVAS) {FACEREADER, SHORE}. (T. OBSTRUTIVAS) {EPOC} (EEG) e {TGSR} (EDA). (Q. INFORMAIS) {INFORMAL} (EMOTIONS).
Gogia et al. (Gogia et al., 2016)	{MINDWAVE-SDK, KINECT-SDK}.	(T. NÃO OBSTRUTIVAS) {KINECT, VIDEO} (HEAD). (T. POUCO OBSTRUTIVAS) {MINDWAVE} (EEG).
Zenonos et al. (Zenonos et al., 2016)	{HRVAS} (HRV)*** e {HAR} (ACC). *** HRV obtido através do HRVAS.	(T. POUCO OBSTRUTIVAS) {SILMEEW2X, SILMEEBTYPE} (ECG(HR{IBI(RMSSD, SDNN)), HRV***), PPG(PR, PTT), ST). (Q. FORMAIS) {HEALTHYOFFICE} (MOOD, EMOTIONS).
Basu et al. (Basu et al., 2016)	{LABCHART}.	(T. POUCO OBSTRUTIVAS) {BIOHARNESS} (ECG, HR, PR, RESP(RR)). (T. OBSTRUTIVAS) {ML870, FE116, ML135, ML309} (EDA, ST) e {Undefined(EMG)} (EMG).
Saha et al. (Saha et al., 2014)	{KINECT-SDK}.	(T. NÃO OBSTRUTIVAS) {KINECT} (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN, ACC).
Soleymani et al.	{OBSERVATION} (EMOTIONS).	(T. NÃO OBSTRUTIVAS)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Soleymani et al., 2013)		{VIDEO} (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH). <b>(T. OBSTRUTIVAS)</b> {ACTIVEII} (EEG).
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	{ACQK}.	<b>(T. OBSTRUTIVAS)</b> {MP150} (ECG(HRV), EMG, EDA, RESP). <b>(Q. FORMAIS)</b> {AFFECTGRID} (EMOTIONS).
<b>Kawai et al.</b> (Kawai et al., 2013)	{DS400}.	<b>(T. NÃO OBSTRUTIVAS)</b> {XCEI30} (PUPIL). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	{EAI}.	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (HEAD, FACE).
<b>N. Lane et al.</b> (N. Lane et al., 2011)	{HAR}.	<b>(T. NÃO OBSTRUTIVAS)</b> {BEWELL} (SLEEP, PHYSI, TALK, LOCAL, ACC). <b>(Q. INFORMAIS)</b> {INFORMAL} (DEPRESSION, SLEEP, WELLBEING).
<b>Bos</b> (Bos, 2010)	{BIOEXPLORER}.	<b>(T. POUCO OBSTRUTIVAS)</b> {BQPET} (EEG).
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	{EPOC-SDK}.	<b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG). <b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	{BIOGRAPH}.	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO, AUDIO}. <b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, ECG(HR), EMG). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	{OBSERVATION} (STRESS*).	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESP). <b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).
<b>Partala et al.</b> (Partala et al., 2005)	{LINK15}.	<b>(T. OBSTRUTIVAS)</b> {MODEL15} (EMG). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	{PSYSCOPE}.	<b>(T. OBSTRUTIVAS)</b> {ASL4000} (PUPIL). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	{INTERVIEW**}.	<b>(T. OBSTRUTIVAS)</b> {MANUAL} (SEROT). <b>(Q. FORMAIS)</b> {BFS} (MOOD). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS, ENERGY, ANXIETY).
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	{INTERVIEW}.	<b>(T. OBSTRUTIVAS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		{78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG). <b>(Q. FORMAIS)</b> {MMPI, QMI, TAS, BDI, STAI} e {DES} (EMOTIONS). <b>{Q. INFORMAIS}</b> {INFORMAL} (EMOTIONS).
<b>R Rinha et al.</b> (R Sinha et al., 1992)	{INTERVIEW, OBSERVATION}.	<b>(T. OBSTRUTIVAS)</b> {Undefined(BP)} (BP(SBP, DBP)), {Undefined(ICG)} (ICG(SV, CO, PVR, PEP, LVET)), {Undefined(ECG)} (ECG(HR)) e {Undefined(PCG)} (PCG). <b>(Q. FORMAIS)</b> {QMI, TAS} e {DES} (EMOTIONS).

() representa um sinal raw; {} um instrumento; \* provavelmente utilizado para recolha de ground truth; \*\*utilizado no processo de screening.

## 3.4. ANÁLISE

O quadro apresentado de seguida resume os instrumentos e sensores identificados nas investigações analisadas neste levantamento bibliográfico.

A necessidade de diversificar os dados de contexto a correlacionar, torna inevitável a utilização de um maior número de instrumentos e sensores na introspeção do contexto. Contudo, são várias as preocupações a ter em conta no momento da seleção dos dispositivos: obstrutividade sentida pelos utilizadores; qualidade dos dados recolhidos considerando que o ato de medir pode influenciar os próprios dados; preço dos dispositivos, sensores ou questionários; escolha de questionários aferidos para a população alvo; questões de ordem ética e de segurança; etc.

A seleção de instrumentos a utilizar na criação de um sistema de deteção automática de emoções pode ser um desafio. Apesar de ser recomendável a utilização de tecnologia de ponta com o objetivo de promover a precisão, desempenho e baixa obstrutividade, não se podem ignorar os constrangimentos orçamentais e *expertises* necessárias ao manuseamento de cada instrumento (Caballe, 2015). As técnicas não obstrutivas baseadas em VIDEO e AUDIO permitem a recolha de dados de contexto de qualidade por causa do alheamento do utilizador (Ouwkerk et al., 2008). No entanto, além dos problemas já atrás mencionados relacionados com a expressão e postura, questões de ordem ética e legal obrigam ao aviso prévio das pessoas para a captura de som e imagem retirando o efeito do alheamento das pessoas ao processo de recolha. Como os sinais fisiológicos são involuntários e tendem a representar pontos objetivos de dados de contexto (Rani & Sarkar, 2006) preferencialmente deveriam ser selecionados para a correlação nos sistemas. Contudo, a maioria dos instrumentos disponíveis para a recolha são obstrutivos e tendem a alterar os hábitos dos utilizadores podendo adulterar os dados que recolhem. O *smartphone* é um instrumento que, sem esforço adicional do utilizador e sem a necessidade de acrescentar sensores, fornece de forma natural dados de contexto social (e.g. CALL, SMS, EMAIL, etc.). Além disso recolhem informação resultante de comportamentos espontâneos (Rachuri et al., 2010). No entanto, além das questões de ordem ética relacionadas com a privacidade, não existe consenso acerca da melhor forma de avaliar o suporte social (J. L. Pais-Ribeiro, 1999), não sendo possível mapear os dados recolhidos diretamente em emoções. Os questionários são bastante utilizados na avaliação emocional (Fulton & Medlock, 2003) (Mandryk & Atkins, 2007) e recolhem informação direta do que se pretende medir. No entanto, apesar de serem aceites pela literatura como forma de medir emoções (Babiker et al., 2013),

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

representam uma técnica de recolha subjetiva cujas respostas podem conduzir a medições erradas (Caballe, 2015).

Perante a inexistência de formas ideais de medição objetiva resta gerir e mitigar os problemas dos dispositivos existentes. Como o principal objetivo dos instrumentos e sensores é a recolha de dados com qualidade de preferência relacionados com o comportamento espontâneo dos utilizadores, sugere-se a preferência pelas técnicas com baixa ou nula obstrutividade. Parecem imprescindível a utilização de uma aplicação para recolher dados de contexto social a partir do *smartphone* (e.g. FUNF). O SILMEEW2X, SILMEEBTYP, BQPET, JAWBONE, BIOHARNESS, MIBAND e EDAMOVE são instrumentos pouco obstrutivos e tecnologicamente atuais. Permitem recolher várias variáveis de contexto fisiológico potencialmente interessantes para um sistema de inferência emocional (cf. número de passos, distâncias percorridas, informação acerca do sono, ST, ECG, PPG, BP, EDA, RESP, etc.) (Linder, 2015) (Toshiba, 2015) (Brainquiry, n.d.) (Brainquiry, 2017) (Jawbone, 2017) (Medtronic, 2015) (Zephyr Technology, 2012) (XiaoMi, n.d.) (movisens GmbH, 2018b). Além destes podem ser utilizados outros dispositivos atuais não referenciados na literatura em análise: como o Zephyr HxM para medição do HRV e RR (Medtronic, 2015); o Wahoo TICKR (Wahoo Fitness, 2018) ou 4iiii Viiiiva (4iiii Innovations Inc., 2018) em conjunto com a aplicação CardioMood para medições do HR (Expert tools for Heart Rate analysis, 2016); a pulseira embrace da empatica (Empatica Inc., 2017); o EdaMove 3 da movisens (movisens GmbH, 2018a); ou o Oxímetro da MindMedia para medição da saturação do O<sub>2</sub> no sangue (Mind Media, n.d.). No caso de não existir solução com baixa obstrutividade para recolha de dados, sugere-se a utilização de sensores de tecnologia atual produzidos com objetivos de miniaturização para que apresentem o menor grau possível de obstrutividade (e.g. produtos da Shimmer (Shimmer Discovery in Motion, 2017), Neurosky (Neurosky, 2017), Plux (plux, n.d.), etc.). Além destes instrumentos, sugere-se também a reutilização de sistemas já existentes para recolher dados de contexto: o MoodScope pode contribuir com informação acerca da MOOD podendo evitar-se desta forma a utilização de um questionário para o efeito (permite integração através da sua API) (LiKamWa et al., 2013); podem utilizar-se os *Cognitive-Services* da Microsoft, o *Emotion as a Service* da Affectiva, ou o FACEREADER da Noldus para recolha de informação emocional (EMOTIONS) com base na análise da expressão facial, oral e postura corporal, a partir de VIDEO (Microsoft, 2017b) (Affectiva Inc., 2017) (Noldus, 2017); etc. Além destes instrumentos poderão também ser criados instrumentos específicos, seja através da assemblagem de sensores em plataformas como o Arduino ou Raspberry (Arduino, 2018) (Raspberry Pi Foundation, n.d.), ou desenvolvidas aplicações específicas para extração de comportamento dos utilizadores (e.g. registo de atividade em sistemas operativos, screen on&off, duração e tipo de interlocutores em CALL e SMS, etc.).

Apesar das reservas levantadas, os questionários podem ser ferramentas importantes para um sistema de reconhecimento emocional porque permitem mais facilmente recolher informação direta do que se pretende medir (Caballe, 2015) (Sano & Eng, 2016) (Johnston et al., 2009). Os questionários são muito utilizados pelos investigadores das ciências comportamentais (Kusserow et al., 2013) e são utilizados pelos profissionais de saúde na avaliação emocional (Fulton & Medlock, 2003) (Mandryk & Atkins, 2007), por serem instrumentos aceites para esse fim (Babiker et al., 2013). No entanto, são vários os autores que evitam a recolha de dados através de questionários. Por exemplo, alguns investigadores preferiram de utilizar questionários para recolha de *ground-truth*, em detrimento de recursos multimédia pré-etiquetados pelos autores com as emoções que provocam (e.g. IADS e IAPS). Contudo, a estratégia de induzir emoções com recursos pré-etiquetados com o conteúdo emocional

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

também não está isenta de problemas. As pessoas percebem as imagens e sons de forma distinta entre si, porque a percepção depende da experiência passada e da personalidade de cada um e, a forma de ponderar esta informação com os resultados da indução, é precisamente através da recolha de dados individuais com os questionários que se pretendiam evitar.

Como os questionários contribuem com informação importante para os sistemas de deteção emocional (Bos, 2010) (Babiker et al., 2013), torna-se incontornável a sua utilização. Contudo, os autores acreditam ser importante escolher questionários aferidos para a população alvo do experimento, com o objetivo de promover a qualidade dos dados recolhidos e diminuir dúvidas acerca da validade dos resultados obtidos. Além dos questionários utilizados nas investigações relatadas, existem outros que podem contribuir com dados de contexto interessantes para um sistema de deteção emocional: a escala *Social Readjustment Rating Scale* (SRRS) de Holmes and Rahe (Holmes & Rahe, 1967) criada para identificar os eventos mais stressantes da vida dos últimos 12 meses atribuindo a cada evento um peso traumático com base no sentimento do respondente (McLeod, 2010), poderá permitir uma avaliação do STRESS traumático; a Escala de Satisfação com o Suporte Social de Pais Ribeiro (ESSS) que avalia a satisfação com o suporte social recebido (e.g. com amigos, família, intimidade e atividades sociais) (J. L. Pais-Ribeiro, 1999), poderá contribuir com percepção individual acerca da sua satisfação com a rede social; o *Marlowe-Crowne Social Desirability Scale* (MCSDS) e o *Balanced Inventory of Desirable Responding* (BIDR) são instrumentos que avaliam a desejabilidade social e a necessidade de aprovação social (D P Crowne & Marlowe, 1960) (Douglas P. Crowne & Marlowe, 1960) (Leite, 2005) e podem fornecer dados de cariz social; a Escala de Ajustamento Conjugal (R-DAS) que avalia a satisfação, coesão e consenso entre conjugues (versão portuguesa (Pereira, 2003)) (Spanier, 1976), poderá contribuir com informação acerca do bem-estar marital; a escala de avaliação *Rosenberg Self-Esteem Scale* (RSES) que é uma das escalas mais antigas para avaliação global da autoestima em adolescentes, (i.e. o autoconceito positivo, aceitação social, autoeficácia e satisfação com a vida) (Santos et al. apresentaram uma versão preliminar para a população portuguesa (Santos & Maia, 2003) e Pechorro et al., fizeram uma validação para adolescentes portugueses em contexto forense (Pechorro, Marôco, Poiares, & Vieira, 2011)) (Baumeister et al., 2013) (Rosenberg, 1965), poderá contribuir com dados acerca da autoestima; o *World Health Organization Quality-Of-Life assessment* (WHOQOLBREF) é o questionário breve da OMS para medição da qualidade de vida (Group, 1998) (Rehabilitation Institute of Chicago, 2014) (Vaz Serra et al., 2006) (Universidade de Coimbra, n.d.), e poderá recolher informação acerca da qualidade de vida das pessoas; a Escala de Ansiedade, Depressão e Stress de 21 itens (EADS-21) (adaptação portuguesa) poderá medir de forma tripartida a ANXIETY, DEPRESSION e STRESS (J. Pais-Ribeiro et al., 2007); o *Oxford Happiness Questionnaire* (OHQ) é um questionário bastante utilizado pelos investigadores para medir a felicidade (HAPPY) e é utilizado na avaliação do bem-estar subjetivo (Hills & Argyle, 2002), poderá contribuir com dados relativos à felicidade; o *Patient Health Questionnaire* (PHQ-9) foi criado por Kroenke para avaliação da depressão, é um dos questionários mais utilizados para avaliação da saúde mental e é composto por nove itens de diagnóstico (cf. anedonia (i.e. falta de sentimento de prazer), disposição depressiva, dificuldade em dormir, sensação de cansaço, mudança de apetite, sentimento de culpa ou inutilidade, dificuldade na concentração, falta de ritmo ou inquietude, e pensamentos suicidas) (Kroenke, Spitzer, & Williams, 2001) (Sano & Eng, 2016), poderá contribuir com informação acerca da DEPRESSION; o *Goldberg Anxiety and Depression Scale* (GADS) é um questionário composto por dezoito itens para avaliar a depressão e ansiedade sentida no último mês (nove para a ansiedade e nove para a depressão), criado para ser aplicado por pessoal não médico (Goldberg, Bridges, Duncan-Jones, & Grayson, 1988), pode contribuir também para avaliação da

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

DEPRESSION e ANXIETY; o *Spiritual Well-Being Questionnaire* (SWBQ) que avalia o bem estar espiritual (Gouveia & Marques, 2009); *Échelle de Mesure des Manifestations du Bien-Être Psychologique* (EMMBEP) (versão portuguesa) (Monteiro, Tavares, Pereira, & Universidade de Aveiro, 2012); *Satisfaction With Life Scale* (SWLS) (Diener, Emmons, Larsen, & Griffin, 1985) validada para Português por Simões (ESV) (Simões, 1992); *Social Well-Being Questionnaire* que pretende medir o bem-estar das pessoas na perspetiva social (Radzyk, 2014); *Well-Being Questionnaire* (W-BQ12) (versão portuguesa) (P. C. Bradley & Holloway, n.d.) (Koch, 2012); e o *Product Emotion Measurement Instrument* (PrEmo) (PREMO) que é um questionário de resposta através de imagens e mede sete emoções positivas e sete negativas (EMOTIONS) (mais utilizado para avaliar o impacto emocional de produtos) (Wassink, 2013) (P. M. a Desmet, 2005) pode ser utilizado para medir EMOTIONS. Poderão ser também utilizados questionários informais específicos. No entanto serão aplicados apenas após os pré-testes necessários, e as questões serão preferencialmente inspiradas noutros questionários adaptados para a população portuguesa (e.g. recolha de informação sociocultural, recolha de dados laborais, recolha de qualidade de sono, cansaço, bem-estar, etc.).

INVESTIGAÇÃO	MEDIÇÃO OBJETIVA	MEDIÇÃO SUBJETIVA	OUTROS INST.
Perdiz et al. (Perdiz et al., 2017)	<b>(T. POUCO OBSTRUTIVAS)</b> {IMU} (HEAD). <b>(T. OBSTRUTIVAS)</b> {Undefined(EMG), Undefined(EOG)} (EMG, EOG).		
S. H. Lee et al. (S. H. Lee et al., 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, NOSE, LIPS, CHEEKS, JAW, MOUTH).		
Eckert et al. (Eckert et al., 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {APP, PICTURES} (FACS, CAU, EYES, EYEBROWS, NOSE, MOUTH).		
Matlovic et al. (Matlovic et al., 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {FACEREADER, SHORE}. <b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG) e {TGSR} (EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{TSTUDIO, CAPTIV}.
Gogia et al. (Gogia et al., 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {KINECT, VIDEO} (HEAD). <b>(T. POUCO OBSTRUTIVAS)</b> {MINDWAVE} (EEG).		{MINDWAVE-SDK, KINECT-SDK}.
Z. Zhang et al. (Z. Zhang et al., 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {DI3D, A655SC, VIDEO} (HEAD, FACS, ST). <b>(T. OBSTRUTIVAS)</b> {MP150, NIBP100D} (BP(SBP, DBP), HR, PR, RESP(RR)) e {Undefined(EDA)} (EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
Sano & Eng (Sano & Eng, 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {FUNF, APP} (LOCAL, CALL, SMS, SCREEN, APPS, EMAIL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC) e {MOTIONLOGGER} (ACC, LIGHT). <b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG), {Undefined(PSG)} (PSG), {Undefined(EOG)} (EOG),	<b>(Q. FORMAIS)</b> {SAME, PSQI} (SLEEP), {MBTI, BFIPT} (PERSON), {PSS} (STRESS), {SF-12} (HEALTH, CALM, ENERGY, MOOD) e {STAI} (ANXIETY). <b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, ACADDG, LIVING, ETHNICITY, RACE, SCHOOLY, SCHOOLA, HEALTH, SLEEP, NAP, PHYSI,	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	{Undefined(EMG)} (EMG) e {Undefined(MELAT)} (MELAT).	ACADCL, ACADGR, ACADEX, CAFFEI, ALCOH, DRUGS, SOCIAL, HAPPY, ALERT).	
<b>Zhao et al.</b> (Zhao et al., 2016)	<b>(T. NÃO OBSTRUTIVAS)</b> {EQ-RADIO} (HR(ABI(RMSSD, SDNN)), RESP) e {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {Undefined(ECG)} (ECG(HR)).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
<b>Zenonos et al.</b> (Zenonos et al., 2016)	<b>(T. POUCO OBSTRUTIVAS)</b> {SILMEEW2X, SILMEEBTYP} (ECG(HR(ABI(RMSSD, SDNN)), HRV), PPG(PR, PTT), ST).	<b>(Q. FORMAIS)</b> {HEALTHYOFFICE} (MOOD, EMOTIONS).	{HRVAS} (HRV) e {HAR} (ACC).
<b>Basu et al.</b> (Basu et al., 2016)	<b>(T. POUCO OBSTRUTIVAS)</b> {BIOHARNESS} (ECG, HR, PR, RESP(RR)). <b>(T. OBSTRUTIVAS)</b> {ML870, FE116, ML135, ML309} (EDA, ST) e {Undefined(EMG)} (EMG).		{LABCHART}.
<b>Aracena et al.</b> (Aracena et al., 2016)	<b>(T. OBSTRUTIVAS)</b> {EL1000} (PUPIL, GAZE).		
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	<b>(T. NÃO OBSTRUTIVAS)</b> {FACETRACKER} (FACS (HEAD, EYELIDS, EYEBROWS, CHEEKS, EYES, NOSE, WRINKLES, LIPS, CHIN, JAW), GAZE).		
<b>Turan et al.</b> (Turan et al., 2015)	<b>(T. NÃO OBSTRUTIVAS)</b> {PICTURES, VIDEO} (FACE, EYES).		
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	<b>(T. NÃO OBSTRUTIVAS)</b> {AUDIO} (SPEECH, VOLUME).		
<b>Lalitha et al.</b> (Lalitha et al., 2015)	<b>(T. NÃO OBSTRUTIVAS)</b> {AUDIO} (SPEECH, PITCH e VOLUME).		
<b>Singh et al.</b> (Singh et al., 2015)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (SHOULDERS, HANDS).		
<b>Murali et al.</b> (Murali et al., 2015)	<b>(T. OBSTRUTIVAS)</b> {MURALI} ((ECG, ICG)(PEP, PTT), NIBP, EDA, RESP(RR)).		
<b>Jaques et al.</b> (Jaques et al., 2015)	<b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, SCREEN, LOCAL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ST, ACC).	<b>(Q. INFORMAIS)</b> {INFORMAL} (HAPPY, ACADCL, ACADEX, ACADST, PHYSI, SOCIAL, CAFFEI, ALCOH, DRUGS, STRESS, HEALTH, ENERGY, ALERT, CALM, SLEEP, NAP).	
<b>Cruz et al.</b> (Cruz et al., 2015)	<b>(T. OBSTRUTIVAS)</b> {MOBILAB} (EOG).		
<b>Saha et al.</b> (Saha et al., 2014)	<b>(T. NÃO OBSTRUTIVAS)</b> {KINECT} (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN, ACC).		{KINECT-SDK}.
<b>Matiko et al.</b>	<b>(T. OBSTRUTIVAS)</b> {Undefined(EEG)} (EEG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Matiko et al., 2014)			
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	<b>(T. NÃO OBSTRUTIVAS)</b> {APP} (CALL, SMS, PROXIMITY) e {EXISTINGDATA} (WEATHER).	<b>(Q. FORMAIS)</b> {BFIPT} (PERSON). <b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).	
<b>Agrawal et al.</b> (Agrawal et al., 2013)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (EYES, MOUTH, LIPS, SKIN).		
<b>Soleymani et al.</b> (Soleymani et al., 2013)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH). <b>(T. OBSTRUTIVAS)</b> {ACTIVEII} (EEG).		{OBSERVATION} (EMOTIONS).
<b>Vermun et al.</b> (Vermun et al., 2013)	<b>(T. NÃO OBSTRUTIVAS)</b> {KINECT} (HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP, KNEES).		
<b>Kusserow et al.</b> (Kusserow et al., 2013)	<b>(T. POUCO OBSTRUTIVAS)</b> {TALKASSIST} (HR(HRV), EDA, ACC, ST), {KUSSEROW2} (ECG(HR), ACC), {KUSSEROW3} (ECG(HR), ACC) e {KUSSEROW4} (HR, ACC).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS, MOOD).	
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	<b>(T. OBSTRUTIVAS)</b> {MP150} (ECG(HRV), EMG, EDA, RESP).	<b>(Q. FORMAIS)</b> {AFFECTGRID} (EMOTIONS).	{ACQK}.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	<b>(T. OBSTRUTIVAS)</b> {Undefined(NIBP), Undefined(RESPI)} (NIBP, RESP(RR)).		
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	<b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA, ACC) e {FUNF} (CALL, SMS, LOCAL, SCREEN).	<b>(Q. FORMAIS)</b> {PSS} (STRESS), {PSQI} (SLEEP) e {BFIPT} (PERSON). <b>(Q. INFORMAIS)</b> {INFORMAL} (SLEEP, ELECTR, HEALTH, MOOD, ALERT, TIRED, STRESS, NAP, CAFFEI, ALCOH).	
<b>Raudonis</b> (Raudonis, 2013)	<b>(T. POUCO OBSTRUTIVAS)</b> {RAUDONIS1} (GAZE, EYES, PUPIL).		
<b>Kawai et al.</b> (Kawai et al., 2013)	<b>(T. NÃO OBSTRUTIVAS)</b> {XCEI30} (PUPIL).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{DS400}.
<b>Babiker et al.</b> (Babiker et al., 2013)	<b>(T. NÃO OBSTRUTIVAS)</b> {TX300} (EYES, GAZE, PUPIL).	<b>(Q. FORMAIS)</b> {PANAS-X} (EMOTIONS).	
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	<b>(T. NÃO OBSTRUTIVAS)</b> {MOODSCOPE} (SMS, EMAIL, CALL, APPS, BROWSER, LOCAL).	<b>(Q. FORMAIS)</b> {CIRCUMPLEX} (MOOD).	
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	<b>(T. OBSTRUTIVAS)</b> {Undefined(EEG), Undefined(HR), Undefined(HRV), Undefined(PEP), Undefined(SV), Undefined(BP), Undefined(RESPI), Undefined(EDA), Undefined(nSRR), Undefined(ST)} (EEG, HR, HRV, PEP, SV, BP(SBP, DBP), RESP(VT, ROS, RR), EDA, nSRR, ST).		

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>C. Y. Chang et al.</b> (Chang et al., 2012)	<b>(T. OBSTRUTIVAS)</b> {ML870} (ECG, BVP, PR, EDA).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS).	
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)	<b>(T. NÃO OBSTRUTIVAS)</b> {APP} (LOCAL, PROXIMITY, CALL, SMS).		
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (HEAD, FACE).		{EAI}.
<b>Dhall et al.</b> (Dhall et al., 2011)	<b>(T. NÃO OBSTRUTIVAS)</b> {PICTURES, VIDEO} (FACE).		
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (PUPIL). <b>(T. OBSTRUTIVAS)</b> {ML870} (ECG(HRV), PPG).		
<b>Hernandez et al.</b> (Hernandez et al., 2011)	<b>(T. NÃO OBSTRUTIVAS)</b> {EXISTINGDATA} (CALL). <b>(T. POUCO OBSTRUTIVAS)</b> {AFFECTIVAQ} (EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).	{OBSERVATION} (STRESS).
<b>N. Lane et al.</b> (N. Lane et al., 2011)	<b>(T. NÃO OBSTRUTIVAS)</b> {BEWELL} (SLEEP, PHYSI, TALK, LOCAL, ACC).	<b>(Q. INFORMAIS)</b> {INFORMAL} (DEPRESSION, SLEEP, WELLBEING).	{HAR}.
<b>H. Wang et al.</b> (H. Wang et al., 2010)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (EYES).		
<b>Bos</b> (Bos, 2010)	<b>(T. POUCO OBSTRUTIVAS)</b> {BQPET} (EEG).		{BIOEXPLORER}.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	<b>(T. OBSTRUTIVAS)</b> {EPOC} (EEG).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{EPOC-SDK}.
<b>Setz et al.</b> (Setz et al., 2010)	<b>(T. POUCO OBSTRUTIVAS)</b> {EMOTIONBOARD} (EDA).		
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	<b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EMG, EDA, ECG(HR, HRV), RESP(RR, BRV)).		
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	<b>(T. OBSTRUTIVAS)</b> {HEALTHLAB} (RESP(RR, RDEP), EDA, ECG(HR, HRV, IBI), EMG, ST).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	<b>(T. OBSTRUTIVAS)</b> {ASL504} (PUPIL), {S71-22} (EDA) e {S75-01} (ECG(HR, IBI)).		
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, CHEEKS, FOREHEAD, JAW, NOSE, HANDS, FINGERS, FISTS, PALMS, SHOULDERS, NECK).		
<b>Castellano et al.</b> (Castellano et al., 2007)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (ARMS).		

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO, AUDIO}. <b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, ECG(HR), EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{BIOGRAPH}.
<b>Sebe et al.</b> (Sebe et al., 2006)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (HEAD, EYEBROWS, EYELIDS, MOUTH) e {AUDIO} (VOLUME, SPEECH, PITCH).		
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	<b>(T. OBSTRUTIVAS)</b> {Undefined(EDA), Undefined(BVP), Undefined(PUPIL), Undefined(ST), Undefined(LIGHT), Undefined(TEMP)} (EDA, BVP(IBE), PUPIL, ST, LIGHT, TEMP).		
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO}. <b>(T. OBSTRUTIVAS)</b> {FLEXCOMP} (ECG(HR, HRV), EMG, EDA, RESP).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).	{OBSERVATION} (STRESS).
<b>Herbon et al.</b> (Herbon et al., 2005)	<b>(T. POUCO OBSTRUTIVAS)</b> {HERBON} (PUPIL). <b>(T. OBSTRUTIVAS)</b> {Undefined(EDA), Undefined(ST), Undefined(HR)} (EDA, ST, HR).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (GENDER, AGE, HEALTH, TECHEXPERT).	
<b>Partala et al.</b> (Partala et al., 2005)	<b>(T. OBSTRUTIVAS)</b> {MODEL15} (EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{LINK15}.
<b>Van Eck et al.</b> (van Eck et al., 2005)	<b>(T. OBSTRUTIVAS)</b> {I-CORTISOL, SALIVETTE} (CORT).	<b>(Q. FORMAIS)</b> {PSS} (STRESS), {LTE} (LIFEEVENTS), {LDI} (DIFFICULTIES), {PSC} (HEALTH), {SDS} (DEPRESSION), {STAI} (ANXIETY) e {STAS} (ANGER).  <b>(Q. INFORMAIS)</b> {INFORMAL} (MOOD, WELLBEING, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH, EMOTIONS).	
<b>Busso et al.</b> (Busso et al., 2004)	<b>(T. NÃO OBSTRUTIVAS)</b> {VIDEO} (FOREHEAD, EYEBROWS, EYES, CHEEKS) e {AUDIO} (PITCH, VOLUME).		
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	<b>(T. POUCO OBSTRUTIVAS)</b> {JAWBONE} (EDA, HR, ST).	<b>(Q. INFORMAIS)</b> {INFORMAL} (AGE, GENDER, ETHNICITY, EMOTIONS).	
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	<b>(T. OBSTRUTIVAS)</b> {MP100} (ECG(HR,HRV), PPG, ST, EDA).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
<b>Haag et al.</b> (Haag et al., 2004)	<b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EMG, EDA, ST, PPG(BVP(HR)), ECG(HR), RESP).		
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	<b>(T. OBSTRUTIVAS)</b> {ASL4000} (PUPIL).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{PSYSCOPE}.
<b>C J Harmer et al.</b>	<b>(T. OBSTRUTIVAS)</b> {MANUAL} (SEROT).	<b>(Q. FORMAIS)</b> {BFS} (MOOD).	{INTERVIEW}.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(C J Harmer et al., 2003)		<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS, ENERGY, ANXIETY).	
<b>Nwe et al.</b> (Nwe et al., 2001)	<b>(T. NÃO OBSTRUTIVAS)</b> {AUDIO} (SPEECH).		
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)	<b>(T. OBSTRUTIVAS)</b> {ORION, SALIVETTE} (CORT) e {Undefined(EMG)} (EMG).	<b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
<b>Jennifer a Healey</b> (Jennifer a Healey et al., 2000)	<b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, PPG(BVP(HR))), EMG, RESP) e {Undefined(ECG)} (ECG(HR, HRV)).	<b>(Q. INFORMAIS)</b> {INFORMAL} (STRESS).	
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	<b>(T. OBSTRUTIVAS)</b> {S90207} (BP(SBP, DBP)) e {VU-MAS} (ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC).	<b>(Q. FORMAIS)</b> {ERI} (STRESS) e {POMS} (MOOD). <b>(Q. INFORMAIS)</b> {INFORMAL} (PERSON, AGE, WORKYEARS, ACADDG, PHYSI, BMI, HEIGHT, WEIGHT, WAIST, CAFFEI, ALCOH, SMOKING).	
<b>Ritz et al.</b> (Ritz et al., 2000)	<b>(T. OBSTRUTIVAS)</b> {SIREGNOSTFD5} (ROS), {FH3803, GMCS5} (VT, RR), {FINAPRESS4} (HR, BP(SBP, DBP)) e {Undefined(EDA)} (EDA).	<b>(Q. FORMAIS)</b> {SAM} (EMOTIONS), {AIM, TAS, MCSDS}. <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	<b>(T. NÃO OBSTRUTIVAS)</b> {AUDIO} (SPEECH, PITCH) e {VIDEO} (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN).		
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	<b>(T. OBSTRUTIVAS)</b> {PROCOMP} (EDA, PPG(BVP(HR))), RESP, EMG).		
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	<b>(T. OBSTRUTIVAS)</b> {78B} (BP(SBP, DBP)) e {Undefined(ECG), Undefined(EDA), Undefined(ST), Undefined(EOG), Undefined(EMG)} (ECG(HR), EDA, ST, EOG, EMG).	<b>(Q. FORMAIS)</b> {MMPI, QMI, TAS, BDI, STAI} e {DES} (EMOTIONS). <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	{INTERVIEW}.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	<b>(T. OBSTRUTIVAS)</b> {S75-01} (ECG(HR)), {Undefined(EMG)} (EMG) e {S71-22} (EDA).	<b>(Q. FORMAIS)</b> {QMI}. <b>(Q. INFORMAIS)</b> {INFORMAL} (EMOTIONS).	
<b>R Rinha et al.</b> (R Sinha et al., 1992)	<b>(T. OBSTRUTIVAS)</b> {Undefined(BP)} (BP(SBP, DBP)), {Undefined(ICG)} (ICG(SV, CO, PVR, PEP, LVET)), {Undefined(ECG)} (ECG(HR)) e {Undefined(PCG)} (PCG).	<b>(Q. FORMAIS)</b> {QMI, TAS} e {DES} (EMOTIONS).	{INTERVIEW, OBSERVATION}.

() representa um sinal raw; e {} um instrumento.

## 4. PRÉ-PROCESSAMENTO

A precisão dos sistemas de detecção emocional tem vindo a aumentar fruto da diversificação de dados de contexto recolhidos, da evolução das técnicas aplicadas (e.g. processamento de imagem, reconhecimento de voz, processamento de linguagem natural, dinâmica no uso de dispositivos de *input* (cf. teclado, rato e *touch-screen*)), evolução tecnológica ao nível de sensores (Bakhtiyari & Husain, 2014), e evolução dos algoritmos de Inteligência Artificial nomeadamente os que têm sido utilizados para apoio à resolução de problemas reais do ser humano (Gama, Carvalho, Faceli, Lorena, & Oliveira, 2012).

Um dos requisitos mais importantes para os algoritmos de aprendizagem automática é a capacidade de lidar com *datasets* imperfeitos (Gama et al., 2012). Um *dataset* pode ser definido como um conjunto de dados composto por objetos (instâncias, registos ou observações) e atributos (campos ou características de cada objeto). Um objeto representa um conceito físico ou abstrato e é descrito por um conjunto de atributos (tuplos chave-valor) que resume as suas características. Cada objeto representa uma ocorrência de dados e cada atributo uma propriedade que caracteriza ou identifica o objeto (Gama et al., 2012). Existem *datasets* de vários tipos: series temporais que registam ocorrências de dados cronologicamente (e.g. registos de ST ao longo de vários dias), grafos (e.g. trajetos percorridos), transações (e.g. registos de compras), etc. (Gama et al., 2012). Os atributos também podem ser de vários tipos (quantitativo ou qualitativo) e escalas (operações possíveis de realizar sobre os valores). Os atributos quantitativos são numéricos, e podem ser discretos permitindo um número contável de valores (e.g. número de CALL, idades), ou contínuos podendo assumir um número infinito de valores reais (e.g. distâncias, pesos, etc.). Os atributos numéricos são habitualmente acompanhados de uma unidade para contextualizar a medida (e.g. metro, quilograma, etc.). Os atributos qualitativos são representados por um número finito de símbolos ou nomes. Quanto à escala, os atributos podem ser classificados como: nominais (i.e. etiquetas sem relação de ordenação entre si (e.g. {Portugal, Espanha, França})); ordinais (i.e. em que as categorias assumem uma ordem (e.g. {poucos, alguns, muitos})); intervalares (i.e. os valores são representados por intervalos (e.g. [20; 38[, [38; 44])) e racionais (i.e. valores absolutos que representam uma medida em conjunto com uma unidade (e.g. 30.5°C, 10.5m, etc.)) (Gama et al., 2012).

Normalmente o desempenho dos algoritmos melhora com o aumento do número de objetos e diminui com o aumento da quantidade de atributos (Gama et al., 2012). No entanto, existem outros factores que podem afetar o desempenho dos algoritmos e prejudicar os processos de indução: diversidade de dimensões ou formatos; ruído ou imperfeições do sinal; valores incorretos ou inconsistentes; dados em falta ou redundantes; etc. (Gama et al., 2012) (S. Zhang, Zhang, & Yang, 2010). As técnicas de pré-processamento permitem identificar e reduzir a ocorrência de problemas nos *datasets* (Gama et al., 2012). O objetivo principal destas técnicas é aumentar a eficiência dos dados para otimizar o processamento dos algoritmos (e.g. normalizar a intensidade luminosa e tamanho de imagens, reduzir a dimensionalidade dos *datasets*, etc.) (Mokhayeri & Toosizadeh, 2011), e criar modelos mais fiéis à realidade (Gama et al., 2012). No entanto, as técnicas de pré-processamento também podem ser utilizadas para adequar os dados à aplicação de um determinado tipo de algoritmo (Gama et al., 2012). Não existe uma ordem definida para a aplicação das técnicas de pré-processamento (Gama et al., 2012). Assim, o *input* de uma técnica pode ser o *dataset* recolhido do contexto (i.e. dados *raw*),

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

ou o *output* resultante da aplicação de qualquer outra técnica. O *output* pode ser definido como o resultado da aplicação do algoritmo da técnica aplicada, ao *input* do algoritmo.

Gama et al. (Gama et al., 2012) categorizou as tarefas de pré-processamento em vários grupos: i) integração de dados de várias fontes; ii) técnicas de amostragem para otimização do conteúdo do *dataset* (objetos e atributos); iii) balanceamento de número de objetos entre classes por causa da sensibilidade de alguns algoritmos ao processamento de conjuntos de dados com classes desbalanceadas; iv) limpeza de dados (e.g. remoção de ruído, reconstrução de dados em falta, incompletos ou inconsistentes); v) redução dimensional para promover a eficiência dos algoritmos (e.g. redução de atributos redundantes, irrelevantes ou inconsistentes); e vi) transformação de dados (e.g. normalização de sinal, conversão de tipos, etc.) (Gama et al., 2012).

Tendo por base a categorização de Gama et al. (Gama et al., 2012) e a realidade das investigações consideradas neste levantamento bibliográfico, decidimos dividir as técnicas de pré-processamento nos seguintes grupos: i) manutenção do *dataset* que inclui as técnicas relacionadas com a qualidade dos dados; ii) manutenção de sinal que engloba técnicas como a normalização, segmentação e geração de novo sinal; e iii) amostragem e meta-informação onde constam as técnicas de amostragem, balanceamento e etiquetagem de dados.

O quadro seguinte resume as técnicas de pré-processamento identificadas neste levantamento bibliográfico.

ID	DESCRIÇÃO	GRUPO	CATEGORIA
<b>MANUTENÇÃO DO DATASET</b>			
<b>ADABOOST</b>	<i>Adaboost Algorithm.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>AGGREGATION</b>	Combinação de vários atributos dependentes num único.	Redução dimensional e redundância de objetos	Redução dimensional
<b>BESTFIRST</b>	<i>Best-First Search.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>BOGOMOLOV</b>	Algoritmo adaptado por Bogomolov et al. (Bogomolov et al., 2014).	Redução dimensional e redundância de objetos	Redução dimensional
<b>CONSISTENCY</b>	Avaliação do nível de consistência de dados.	Ruído, dados incompletos e inconsistentes	Dados inconsistentes
<b>CORRELATION</b>	Permite medir a força da relação entre variáveis.	Redução dimensional e redundância de objetos	Redução dimensional
<b>DCC</b>	<i>Discriminant - Analysis of Canonical Correlations.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>DISCARDDATA</b>	Remoção de objetos por conterem falta de dados.	Ruído, dados incompletos e inconsistentes	Dados incompletos
<b>DISTINCTOBJ</b>	Assunção de apenas objetos distintos.	Redução dimensional e redundância de objetos	Redundância de objetos
<b>-DUPLICATE</b>	Remoção de objetos redundantes (e.g. recolhidos em duplicado).	Redução dimensional e redundância de objetos	Redundância de objetos
<b>-EYEBLINK</b>	Remoção do piscar de olhos.	Ruído, dados incompletos e inconsistentes	Ruído

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>FAKEDATA</b>	Geração de dados artificiais para colmatar o preenchimento de dados em falta.	Ruído, dados incompletos e inconsistentes	Dados incompletos
<b>FDA</b>	<i>Fisher's Discriminant Analysis.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>-FRAMES</b>	Remoção de <i>frames</i> de VIDEO redundantes.	Redução dimensional e redundância de objetos	Redundância de objetos
<b>GA</b>	<i>Genetic Algorithm.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>LDA</b>	<i>Linear Discriminant Analysis (LDA).</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>MANADJUST</b>	Edição manual de dados.	Ruído, dados incompletos e inconsistentes	Outras
<b>MANINSERT</b>	Inserção manual de dados.	Ruído, dados incompletos e inconsistentes	Outras
<b>MANSELECT</b>	Seleção manual de atributos irrelevantes ou relevantes.	Redução dimensional e redundância de objetos	Redução dimensional
<b>MITIGATION</b>	Atenuação de efeitos externos (i.e. interferências) ao sinal.	Ruído, dados incompletos e inconsistentes	Outras
<b>MURALI</b>	Algoritmo específico criado por Murali et al. (Murali et al., 2015).	Redução dimensional e redundância de objetos	Redução dimensional
<b>-NOISE</b>	Diminuição ou remoção de ruído.	Ruído, dados incompletos e inconsistentes	Ruído
<b>NULL</b>	Assunção da falta de dados.	Ruído, dados incompletos e inconsistentes	Dados incompletos
<b>-OUTLIERS</b>	Remoção de valores discrepantes na distribuição.	Ruído, dados incompletos e inconsistentes	Dados inconsistentes
<b>PCA</b>	<i>Principal Component Analysis (PCA).</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>-PEAK</b>	Identificação remoção de picos identificados como possíveis artefactos de ruído.	Ruído, dados incompletos e inconsistentes	Ruído
<b>RELIABILITY</b>	Avaliação do nível de confiabilidade dos dados.	Ruído, dados incompletos e inconsistentes	Dados incompletos
<b>-SACCADE</b>	Remoção dos movimentos rápidos do olho.	Ruído, dados incompletos e inconsistentes	Ruído
<b>SBS</b>	<i>Sequential Backward Selection (SFS).</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>SCATTER</b>	Diagrama que permite analisar visualmente no espaço cartesiano a redundância entre atributos.	Redução dimensional e redundância de objetos	Redução dimensional
<b>SFFS</b>	<i>Sequential Floating Forward Selection.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>SFS</b>	<i>Sequential Forward Selection (SFS).</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>SLPP</b>	<i>Supervised Locality Preserving Projection.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>TOLERANCE</b>	Assunção de tolerâncias de dados ou momentos de inserção de dados.	Ruído, dados incompletos e inconsistentes	Dados incompletos

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>WFS</b>	<i>Wrapper Feature Selection.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b><math>\chi^2</math></b>	<i>Chi-square.</i>	Redução dimensional e redundância de objetos	Redução dimensional
<b>MANUTENÇÃO DO SINAL</b>			
<b>2D-DISCRETE</b>	Conversão de espaço bidimensional para discreto.	Conversão de sinal e de tipos de dados	Conversão de tipos de dados
<b>3D2D</b>	Conversão de três para duas dimensões e vice-versa.	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>ABPF</b>	Filtro passa-banda adaptativo.	Normalização, amplificação e filtros	Filtros
<b>ADL</b>	Identificação de tarefas do dia-a-dia (e.g. dormir, sentar, caminhar, etc.).	Segmentação e geração de novo sinal	Geração de novo sinal
<b>BANDS</b>	Segmentação de sinal em bandas.	Segmentação e geração de novo sinal	Segmentação de sinal
<b>BINARY</b>	Binarização de imagens.	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>BPF</b>	Filtro passa-banda.	Normalização, amplificação e filtros	Filtros
<b>COLORSEG</b>	Segmentação de cor.	Segmentação e geração de novo sinal	Segmentação de sinal
<b><math>D^2Y/DX^2</math></b>	Diferenciação de sinal na segunda derivada.	Segmentação e geração de novo sinal	Geração de novo sinal
<b>DWT</b>	<i>Discrete Wavelet Transform.</i>	Segmentação e geração de novo sinal	Segmentação de sinal
<b>DY/DX</b>	Diferenciação de sinal na primeira derivada.	Segmentação e geração de novo sinal	Geração de novo sinal
<b>FD</b>	<i>Fractal Dimension.</i>	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>FOURIER</b>	Conversão de sinal do domínio do tempo para frequências.	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>GREYSCALE</b>	Conversão de PICTURES em escalas cinza.	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>HHT</b>	<i>Hilbert-Huang Transform.</i>	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>HPF</b>	Filtro passa-alta.	Normalização, amplificação e filtros	Filtros
<b>IMGALIGN</b>	Normalização do alinhamento de imagens (e.g. posição dos olhos).	Normalização, amplificação e filtros	Normalização
<b>-IMGBKG</b>	Remoção do <i>background</i> de PICTURES após reconhecimento de formas ou pontos de relevo.	Segmentação e geração de novo sinal	Segmentação de sinal
<b>IMGCONTRAST</b>	Normalização do contraste em imagens.	Normalização, amplificação e filtros	Normalização
<b>IMGINTENSITY</b>	Normalização da intensidade luminosa em imagens.	Normalização, amplificação e filtros	Normalização

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>IMGSIZE</b>	Normalização de tamanho de imagens.	Normalização, amplificação e filtros	Normalização
<b>INTEGRATION</b>	Integração ou fusão de dados de várias fontes.	Segmentação e geração de novo sinal	Outras
<b>INTERVALSPLIT</b>	Divisão do sinal em intervalos temporais.	Segmentação e geração de novo sinal	Segmentação de sinal
<b>KAWAI2</b>	Técnica adaptada por Kawai et al. (Kawai et al., 2013).	Normalização, amplificação e filtros	Normalização
<b>LPF</b>	Filtro passa-baixa.	Normalização, amplificação e filtros	Filtros
<b>N-N</b>	Segmentação de sinais fisiológicos em intervalos N-N.	Segmentação e geração de novo sinal	Segmentação de sinal
<b>NORM</b>	Normalização de dados (e.g. amplitudes de atributos numéricos).	Normalização, amplificação e filtros	Normalização
<b>PATHSTAKEN</b>	Criação de dados acerca de trajetos percorridos.	Segmentação e geração de novo sinal	Geração de novo sinal
<b>QUALI-QUANTI</b>	Conversão de valores qualitativos para quantitativos.	Conversão de sinal e de tipos de dados	Conversão de tipos de dados
<b>R-R</b>	Segmentação de sinais fisiológicos em intervalos R-R.	Segmentação e geração de novo sinal	Segmentação de sinal
<b>SIGAMP</b>	Amplificação de sinal	Normalização, amplificação e filtros	Amplificação
<b>SIGSMOOTH</b>	Alisamento de sinal.	Normalização, amplificação e filtros	Outras
<b>SIGSPLIT</b>	Separação de sinais (e.g. ECG e ICG).	Segmentação e geração de novo sinal	Segmentação de sinal
<b>TASKSPLIT</b>	Identificação de tarefas (e.g. saltos de <i>ski jumpers</i> ).	Segmentação e geração de novo sinal	Geração de novo sinal
<b>USUALPLACES</b>	Criação de dados acerca de locais frequentados.	Segmentação e geração de novo sinal	Geração de novo sinal
<b>VIDEO-PICS</b>	Conversão de VIDEO em PICTURES.	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>ZHAO1</b>	Técnica específica do autor Zhao et al. para enfatizar o sinal a extrair (Zhao et al., 2016).	Normalização, amplificação e filtros	Outras
<b>ZHAO2</b>	Técnica de segmentação adaptada por Zhato et al. (Zhao et al., 2016).	Segmentação e geração de novo sinal	Segmentação de sinal
<b>ZTRANSFORM</b>	Conversão de sinal do domínio do tempo para frequências.	Conversão de sinal e de tipos de dados	Conversão de sinal
<b>AMOSTRAGEM E META-INFORMAÇÃO</b>			
<b>+ARTIFICIALDATA</b>	Geração sintética de dados.	Balanceamento e etiquetagem	Balanceamento
<b>DECIMATION</b>	Diminuição da taxa de amostragem ( <i>downsampling</i> ).	Técnicas de amostragem	N/A
<b>INTENTIONAL</b>	O critério de amostragem é intencionalmente definido pelo investigador.	Técnicas de amostragem	N/A

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>LABELING</b>	Enriquecimento de dados através da colocação de etiquetas com meta-informação.	Balanceamento e etiquetagem	Etiquetagem
<b>RANDOM</b>	A seleção de objetos é feita de forma aleatória (e.g. sorteio).	Técnicas de amostragem	N/A
<b>SPREADSUBSAMPLE</b>	Balanceamento entre classes é feita através da aplicação de uma técnica de <i>downsampling</i> do WEKA.	Balanceamento e etiquetagem	Balanceamento
<b>STRATIFIED</b>	A seleção de objetos é feita com base estratos previamente definidos.	Técnicas de amostragem	N/A
<b>SYSTEMATIC</b>	A seleção é feita a cada $r$ ocorrências de objetos.	Técnicas de amostragem	N/A
<b>OUTRAS TÉCNICAS E INSTRUMENTOS</b>			
<b>ANOVA</b>	Análise de variância para encontrar diferenças entre grupos ou experiências.	N/A	Representação de dados
<b>AUBT</b>	<i>Augsburg Biosignal Toolbox</i> .	N/A	Instrumentos
<b>BLINKDETECT</b>	Deteção do piscar de olhos em VIDEO.	N/A	Técnicas de suporte
<b>CLUSTERING</b>	Definição de <i>clusters</i> em PICTURES com o objetivo de identificar objetos ou zonas de imagem.	N/A	Técnicas de suporte
<b>COLORCORR</b>	<i>Color Correlogram</i> .	N/A	Representação de dados
<b>CROP</b>	Recortar PICTURES.	N/A	Técnicas de suporte
<b>EEGLAB</b>	Instrumento para manutenção de sinal EEG.	N/A	Instrumentos
<b>EYESWEB</b>	Instrumento para monitorização de movimento corporal em tempo real.	N/A	Instrumentos
<b>FEELTRACE</b>	Instrumento para rastrear e provocar emoções em simultâneo.	N/A	Instrumentos
<b>FINDREGION</b>	Deteção de regiões ou bordas em imagens.	N/A	Técnicas de suporte
<b>GLM</b>	Instrumento para analisar a relação entre variáveis.	N/A	Instrumentos
<b>HAC</b>	<i>Hierarchical Agglomerative Clustering</i> .	N/A	Instrumentos
<b>HISTOGRAM</b>	Histograma.	N/A	Representação de dados
<b>KAWAI1</b>	Técnica específica de Kawai et al. (Kawai et al., 2013) para atenuar as diferenças de brilho em imagens.	N/A	Técnicas de suporte
<b>KHRV</b>	KUBIOS HRV (ferramenta para análise do HRV).	N/A	Instrumentos
<b>LANE1</b>	Técnica específica de Lane et al. (N. Lane et al., 2011) para estimar o tempo de sono com base nos	N/A	Outras

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	momentos de recarga da bateria do <i>smartphone</i> .		
<b>MATLAB</b>	Plataforma da <i>Mathworks Matlab</i> .	N/A	Instrumentos
<b>MORPHOPS</b>	Operações morfológicas sobre PICTURES.	N/A	Técnicas de suporte
<b>MOTIONDETECT</b>	Deteção de movimento de objetos ou pessoas.	N/A	Técnicas de suporte
<b>ORIGIN</b>	Plataforma da <i>OriginLab</i> .	N/A	Instrumentos
<b>PEAKDETECT</b>	Deteção de picos de sinal (e.g. ciclos de respiração).	N/A	Outras
<b>RAUDONIS2</b>	Técnica específica de Raudonis (Raudonis, 2013) para considerar a variação da luminosidade na PUPIL.	N/A	Técnicas de suporte
<b>SI-SSM</b>	<i>Index-based Shape Index-based Statistical shape model</i> .	N/A	Técnicas de suporte
<b>SPARSEREP</b>	<i>Sparse Representation</i> .	N/A	Representação de dados
<b>TTEST</b>	Análise estatística das médias de dois conjuntos.	N/A	Representação de dados
<b>WEKA</b>	<i>Waikato Environment for Knowledge Analysis</i> .	N/A	Instrumentos
<b>YANG1</b>	Técnica específica de Yant et al. (S. Yang & Bhanu, 2011) para representar faces em avatares.	N/A	Representação de dados
<b>ZFACE</b>	Instrumento para rastrear expressões faciais.	N/A	Instrumentos

Para mais fácil entendimento, neste documento será utilizado o termo RAW para identificar o sinal original recolhido do contexto, e o nome da técnica aplicada para especificar o sinal *output* dessa mesma técnica. Além disso, nos casos em que seja possível identificar o encadeamento das técnicas aplicadas, será utilizada a notação [sinal original [sinal resultante]] para indicar a percepção dos autores do encadeamento dos sinais utilizados. Assim (EDA) [RAW] indica os dados *raw* do EDA, (EDA) [RAW, LPF], especifica o sinal RAW e o sinal LPF do sinal EDA, e EDA [RAW [LPF [DY/DX]]] refere-se ao sinal resultante da aplicação do DY/DX ao sinal LPF, cujo *input* foram os dados EDA recolhidos do contexto. Para simplificação da notação e quando subentendido, o termo RAW poderá ser omitido, significando o próprio parêntesis curvo a indicação da versão RAW do sinal. Assim (EDA) [RAW[LPF[DY/DX]]] é equivalente a (EDA) [LPF[DY/DX]].

Da mesma forma que não existe uma ordem pré-definida para a utilização das técnicas de pré-processamento (Gama et al., 2012), também podem ser aplicadas técnicas sobre o *dataset* já complementado com propriedades adicionais. As propriedades extraídas serão abordadas na secção 5. No entanto, por ser necessário especificar a aplicação de técnicas de pré-processamento sobre propriedades extraídas e *datasets* complementados com propriedades extraídas, introduzimos antecipadamente a notação a utilizar para a sua representação. Assim, (ACC)<MAG>[NORM] representa a aplicação da técnica de pré-processamento NORM à propriedade magnitude (MAG) extraída do sinal RAW do ACC. A notação <ACC> representa de forma simplificada o conjunto final de atributos (i.e. originais e propriedades extraídas) do sinal ACC (e.g. <ACC, EDA> [CORRELATION] indica a aplicação da técnica CORRELATION aos atributos

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

base e propriedades extraídas dos sinais ACC e EDA). Como são várias as investigações que incidem a aplicação de técnicas de pré-processamento sobre propriedades extraídas, para evitar a mistura constante da explicação de termos que são apresentados formalmente na introdução da secção 5, remete-se para essa secção quando os *tokens* utilizados dentro de <> não forem autoindicáveis apenas através do seu nome.

## 4.1. MANUTENÇÃO DO DATASET

Nesta secção abordam-se as técnicas relacionadas com a qualidade e redundância dos dados do *dataset*. As técnicas de manutenção de dados têm por objetivo detetar e corrigir (ou minimizar), os problemas existentes nos conjuntos de dados. Os dados podem apresentar vários tipos de problemas: i) valores inesperados (e.g. idade de uma pessoa superior ao possível); ii) valores inconsistentes (i.e. atributos com valores contraditórios para mesmo objeto); iii) valores redundantes (e.g. valores de um atributo iguais em todos os objetos ou existência de atributos cujo valor pode ser retirado de outro); iv) dados incompletos (e.g. alguns atributos com dados por preencher); etc. (Gama et al., 2012).

Tendo por base a literatura em análise, dividiram-se as técnicas de pré-processamento relacionadas com a manutenção do *dataset* nas seguintes categorias: i) ruído, dados incompletos e inconsistentes; e ii) redução dimensional e redundância de objetos.

### 4.1.1. Ruído, dados incompletos e inconsistentes

Os dados de contexto recolhidos pelos sensores podem conter ruído criado por interferências externas como a eletrostática, movimentos musculares, etc. Estes ruídos devem ser removidos ou mitigados do sinal de entrada antes que este seja usado como base de processamento (Jerritta et al., 2011).

Nesta secção incluem-se as técnicas de pré-processamento que tem por objetivo aumentar qualidade do conjunto de dados. Os processos de recolha de dados de contexto podem originar a presença de dados no *dataset* que não pertencem à distribuição que os gerou. Este ruído pode resultar do mau preenchimento de dados pelo utilizador ou por interferências ocorridas durante o processo de introspeção do contexto. São várias as técnicas utilizadas a este nível: a redução de ruído [-NOISE] é utilizada em vários tipos de sinal (e.g. Mokhayeri et al. (Mokhayeri & Toosizadeh, 2011) e Aracena et al. (Aracena et al., 2016) utilizaram técnicas para remover o ruído de imagens da PUPIL, Sano & Eng. utilizaram um algoritmo desenvolvido pelo seu grupo de pesquisa para deteção de artefactos no sinal EDA (Sano & Eng, 2016), Bos utilizou LPF e HPF para remover ruído e artefactos do sinal EEG (e.g. movimento ocular) (Bos, 2010), e Kim et al. utilizaram o ABPF para remover artefactos e LPF para remover ruído (J. Kim & André, 2008)); a remoção de picos de sinal [-PEAK] identificados como possíveis artefactos de ruído (e.g. Jaques et al. (Jaques et al., 2015)); a remoção do piscar de olhos em VIDEO [-EYEBLINK] (e.g. Mokhayeri et al. (Mokhayeri & Toosizadeh, 2011) e Aracena et al. (Aracena et al., 2016)); e os movimentos rápidos dos olhos (i.e. *saccades*) são estudados por uns investigadores (e.g. Perdiz et al. (Perdiz et al., 2017)) e tratados como ruído por outros porque causam interferência nos sinais estudados [-SACCADE] (e.g. Aracena et al. (Aracena et al., 2016)).

O *dataset* pode também conter dados incompletos. Os atributos com falta de valor podem resultar do esquecimento ou decisão pelo não preenchimento por parte do utilizador, ou por

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

causa de problemas nos processos de recolha do contexto. Para resolver os problemas dos dados incompletos, os investigadores utilizam várias técnicas de pré-processamento: Jaques et al. removeram manualmente **[DISCARDATA]** os eventos SCREEN com menos de cinco utilizações diárias (Jaques et al., 2015)) e Soleymani et al. descartaram alguns videos de respostas faciais porque os anotadores não conseguiram ter a percepção do *valence* sentido pelos participantes com base nas expressões (Soleymani et al., 2013); Lee et al. geraram dados para resolver o problema das transições parciais de expressões faciais **[FAKEDATA]** (S. H. Lee et al., 2016), e Jaques et al. também geraram dados (i.e. FAKEDATA) através da interpolação para preencher dados em falta do LOCAL (Jaques et al., 2015); Jaques et al. utilizaram também a assunção de inexistência de dados, dando um valor representativo da lacuna aos atributos em causa **[NULL]**; Zenonos et al. decidiram tolerar **[TOLERANCE]** atrasos nas anotações dos seus participantes dentro de uma determinada janela temporal (Zenonos et al., 2016); e LikamWa et al. avaliaram as taxas de resposta para determinar o nível de confiabilidade dos dados recolhidos **[RELIABILITY]** (LiKamWa et al., 2013) e Healey et al. testaram o nível de RELIABILITY das anotações dos *coders* da sua investigação utilizando o *alpha Cronbach* (L. J. Cronbach, 1951) (L. Cronbach, 1951) (J. A. Healey & Picard, 2005).

Por vezes o *dataset* também pode conter dados inconsistentes (i.e. valores contraditórios ou discrepantes) (e.g. uma pessoa pesar 130kg com 3 anos de idade) (Gama et al., 2012). A este nível, os autores utilizam as seguintes técnicas: Babiker et al. utilizaram uma *moving average* para remover *outliers* **[-OUTLIERS]** (Babiker et al., 2013); e LikamWa et al. avaliaram a consistência **[CONSISTENCY]** dos dados recolhidos acerca da MOOD, para despistar variações anormais no tempo (LiKamWa et al., 2013) (Batson, Shaw, & Oleson, 1992) (Beedie, Terry, & Lane, 2005).

Incluem-se nesta secção ainda outras técnicas relacionadas com a atenuação **[MITIGATION]** de efeitos externos ao sinal (e.g. Jaques et al. utilizaram o ACC e ST para diminuir o efeito da atividade física no sinal EDA recolhido (Jaques et al., 2015), Kawai et al. utilizaram o *signal averaging* do diametro da PUPIL para diminuir *Signal-to-Noise* RATIO causado pela apresentação de várias imagens (Kawai et al., 2013), e Babiker et al. preferiram utilizar estímulos sonóros para evitar as interferências da luminância das imagens (Babiker et al., 2013)). Por fim, consideram-se também nesta secção as técnicas utilizadas para inserção ou edição direta de dados pelos utilizadores ou investigadores: Kawai et al. corrigiram manualmente o DIAMETER da PUPIL quando o sistema o mediu incorretamente **[MANADJUST]** (Kawai et al., 2013); Lane et al. permitiram que os participantes da sua experiência, além de puderem corrigir erros de inferência da aplicação que criou (i.e. MANADJUST), pudessem também inserir manualmente atividades não inferidas pelo BEWELL **[MANINSERT]** (N. Lane et al., 2011); Chen et al. inseriram manualmente informação acerca do movimento dos olhos e boca (L. S. Chen et al., 1998) e assistentes treinados de Sinha et al. inseriram manualmente os valores cedidos pelo ICG (R Sinha et al., 1992) (i.e. MANINSERT).

INVESTIGAÇÃO	MANUTENÇÃO DO DATASET	
	RUIDO, D. INC. E INC.	OUTRAS
S. H. Lee et al. (S. H. Lee et al., 2016)	(FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)) [FAKEDATA].	<b>(NORM., AMP E FILTR.)</b> (EYEBROWS, EYELIDS) [NORM]. <b>(OUTRAS)</b> (FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH) [CLUSTERING, SPARSEREP] e (EYEBROWS, EYELIDS) [FINDREGION, CROP]. {HAC}.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Gogia et al.</b> (Gogia et al., 2016)	(EEG) [-EYEBLINK].	<b>Red. dim. e red. objs:</b> (EEG) [-DUPLICATE].  <b>(BALANC. E ETIQ.)</b> (EEG) [[[-EYEBLINK, -DUPLICATE] [LABELING]] [+ARTIFICIALDATA]].
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	(EDA) [-NOISE].	<b>Red. dim. e red. objs:</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]].  <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]]. <b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
<b>Zhao et al.</b> (Zhao et al., 2016)	(RESP, HR) [-NOISE].	<b>(NORM., AMP E FILTR.)</b> (RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF]. <b>(SEG. E GER. SINAL)</b> (RESP, HR) [D2Y/DX2, ZHAO2]. <b>(OUTRAS)</b> (RESP) [LPF [PEAKDETECT]].
<b>Zenonos et al.</b> (Zenonos et al., 2016)	(MOOD, EMOTIONS) [TOLERANCE].	<b>(NORM., AMP E FILTR.)</b> (IBI) [NORM]. <b>(SEG. E GER. SINAL)</b> (IBI) [BANDS]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].
<b>Aracena et al.</b> (Aracena et al., 2016)	(PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE].	<b>(NORM., AMP E FILTR.)</b> (PUPIL) [LPF, NORM]. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan, Murali, Rincon, & Atienza, 2015)	(ECG, ICG) [-NOISE].	<b>Red. dim. e red. objs:</b> (((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI].  <b>(NORM., AMP E FILTR.)</b> (ECG, EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (ECG, ICG) [SIGSPILT]. <b>(OUTRAS)</b> (ECG) [PEAKDETECT].
<b>Jaques et al.</b> (Jaques et al., 2015)	(EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]].	<b>Red. dim. e red. objs:</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADDEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT].  <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]] e <ACC> [NORM]. <b>(SEG. E GER. SINAL)</b> (LOCAL) [[INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]]] e (EDA) [DY/DX]. <b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].
<b>Soleymani et al.</b>	(EMOTIONS) [DISCARDATA] e	<b>(CONV. SINAL)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p>(Soleymani et al., 2013)</p>	<p>(EEG) [-NOISE].</p>	<p>(EEG) [FOURIER].  <b>(NORM., AMP E FILTR.)</b>          (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM].  <b>(SEG. E GER. SINAL)</b>          (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] &lt;DISTANCE&gt; [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION].  <b>(TEC. AMOSTRAGEM)</b>          [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC].  <b>(BALANC. E ETIQ.)</b>          (EMOTIONS) [LABELING].  <b>(OUTRAS)</b>          {FEELTRACE}</p>
<p><b>Kawai et al.</b> (Kawai et al., 2013)</p>	<p>(PUPIL) &lt;DIAMETER&gt; [MANADJUST, -NOISE, MITIGATION].</p>	<p><b>(CONV. SINAL)</b>          (PUPIL) [BINARY].  <b>(NORM., AMP E FILTR.)</b>          (PUPIL) &lt;DIAMETER&gt; [KAWAI2 [NORM]].  <b>(OUTRAS)</b>          (PUPIL) [FINDREGION, CLUSTERING, KAWAI1].</p>
<p><b>Babiker et al.</b> (Babiker et al., 2013)</p>	<p>(PUPIL) [MITIGATION], &lt;PUPIL&gt; [NORM] [[-NOISE, -OUTLIERS] [FAKEDATA, DISCARDDATA]].</p>	<p><b>(NORM., AMP E FILTR.)</b>          &lt;PUPIL&gt; [NORM].  <b>(SEG. E GER. SINAL)</b>          (PUPIL) &lt;INTERVALSPLIT&gt;.  <b>(TEC. AMOSTRAGEM)</b>          (PUPIL) [SYSTEMATIC].  <b>(OUTRAS)</b>          (PUPIL) [FINDREGION].</p>
<p><b>LikamWa et al.</b> (LiKamWa et al., 2013)</p>	<p>(MOOD) [RELIABILITY, CONSISTENCY].</p>	<p><b>Red. dim. e red. objs:</b>          &lt;MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL&gt; [SFS, CORRELATION].   <b>(NORM., AMP E FILTR.)</b>          (CALL, SMS, EMAIL) &lt;COUNT&gt; [NORM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM [NORM]] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [NORM].  <b>(SEG. E GER. SINAL)</b>          (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].  <b>(BALANC. E ETIQ.)</b>          (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] &lt;PERIODS &lt;COUNT, STD &lt;MEAN, MAX&gt;&gt;&gt; [LABELING] e (APPS) [LABELING].  <b>(OUTRAS)</b>          (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM], (APPS) &lt;DURATION&gt; [HISTOGRAM] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [HISTOGRAM].</p>
<p><b>C. Y. Chang et al.</b> (Chang et al., 2012)</p>	<p>(ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]].</p>	<p><b>Red. dim. e red. objs:</b>          (ECG, PR, BVP, EDA) [MANSELECT].   <b>(NORM., AMP E FILTR.)</b>          (ECG, PR, BVP, EDA) [LPF, HPF, NORM].  <b>(SEG. E GER. SINAL)</b>          (ECG, PR, BVP, EDA) [R-R].  <b>(TEC. AMOSTRAGEM)</b>          (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].  <b>(OUTRAS)</b>          (ECG, BVP, PR) [PEAKDETECT].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri &amp; Toosizadeh, 2011)</p>	<p>(PUPIL) [-NOISE, -EYEBLINK].</p>	<p><b>Red. dim. e red. objs:</b> &lt;ECG(HRV), PPG, PUPIL&gt; [GA].</p> <p><b>(CONV. SINAL)</b> (PUPIL) [VIDEO-PICS].</p> <p><b>(NORM., AMP E FILTR.)</b> (PUPIL) [IMGSIZE, IMGINTENSITY].</p> <p><b>(SEG. E GER. SINAL)</b> (ECG(HRV)) [BANDS].</p> <p><b>(OUTRAS)</b> (PUPIL) [FINDREGION, BLINKDETECT].</p>
<p><b>Hernandez et al.</b> (Hernandez et al., 2011)</p>	<p>(EDA) [-NOISE].</p>	<p><b>(NORM., AMP E FILTR.)</b> (EDA, STRESS) [NORM] e &lt;EDA, STRESS&gt; [NORM].</p> <p><b>(BALANC. E ETIQ.)</b> (CALL) [LABELING].</p> <p><b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>N. Lane et al.</b> (N. Lane et al., 2011)</p>	<p>(SLEEP, PHYSI) [MANINSERT].</p>	<p><b>(SEG. E GER. SINAL)</b> (ACC) [ADL].</p> <p><b>(OUTRAS)</b> (SLEEP) [LANE1] e (SLEEP, PHYSI) [MANADJUST].</p>
<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>	<p>(EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]].</p>	<p><b>Red. dim. e red. objs:</b> &lt;EYES&gt; [ADABOOST].</p> <p><b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]].</p> <p><b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG].</p> <p><b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING].</p> <p><b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].</p>
<p><b>Bos</b> (Bos, 2010)</p>	<p>(EEG) [-NOISE].</p>	<p><b>Red. dim. e red. objs:</b> &lt;EEG&gt; [PCA].</p> <p><b>(CONV. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER]]].</p> <p><b>(NORM., AMP E FILTR.)</b> (EEG) [-NOISE [BPF].</p> <p><b>(SEG. E GER. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]].</p> <p><b>(OUTRAS)</b> {EEGLAB}.</p>
<p><b>Setz et al.</b> (Setz et al., 2010)</p>	<p>(EDA) [DISCARDATA, MANADJUST [-NOISE]].</p>	<p><b>Red. dim. e red. objs:</b> &lt;EDA&gt; [WFA].</p> <p><b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, LPF [HPF [LPF]]].</p> <p><b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>J. Kim &amp; André</b> (J. Kim &amp; André, 2008)</p>	<p>(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE].</p>	<p><b>Red. dim. e red. objs:</b> &lt;ECG(HR, HRV), RESP(RR, BRV), EDA, EMG&gt; [SBS].</p> <p><b>(CONV. SINAL)</b> (ECG(HR, HRV)) [FOURIER].</p> <p><b>(NORM., AMP E FILTR.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM].</p> <p><b>(SEG. E GER. SINAL)</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	(RESP) [-PEAK].	<b>Red. dim. e red. objs:</b> <ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG> e (EMOTIONS) [CORRELATION, MANSELECT].  <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(BALANC. E ETIQ.)</b> (RESP(RR)) <AMP> [LABELING].
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	(PUPIL) [FAKEDATA].	<b>(NORM., AMP E FILTR.)</b> (PUPIL, EDA) [NORM].
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	(ECG(HR)) [MANADJUST, FAKEDATA].	<b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED]. <b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	(PUPIL) <DIAMETER> [-NOISE [FAKEDATA]].	<b>(NORM., AMP E FILTR.)</b> (ST) [SIGAMP [LPF [NORM]]] e (BVP(IBE), EDA) [NORM].
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard, Vyzas, & Healey, 2001)	(EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY].	<b>Red. dim. e red. objs:</b> <EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT].  <b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS]. <b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
<b>Herbon et al.</b> (Herbon et al., 2005)	(HR, EDA, PUPIL, EMOTIONS) [DISCARDATA] e (HR, EDA, PUPIL) <STD <THRESHOLD>> [DISCARDATA].	<b>(CONV. SINAL)</b> (HR, EDA, ST, PUPIL) [ZTRANSFORM].
<b>Partala et al.</b> (Partala et al., 2005)	(EMG) [-EYEBLINK].	<b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP [HPF, LPF]]. <b>(SEG. E GER. SINAL)</b> (EMG) e (EMOTIONS) [LABELING]. <b>(OUTRAS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(EMG) [TTEST].
<b>Van Eck et al.</b> (van Eck et al., 2005)	(HEALTH) [DISCARDATA] e (CORT) [-OUTLIERS].	<b>Red. dim. e red. obj:</b> (LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH) [PCA [AGGREGATION]].  <b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]].	<b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	(PUPIL) [DISCARDATA, - EYEBLINK].	<b>(BALANC. E ETIQ.)</b> (PUPIL) [LABELING]. <b>(OUTRAS)</b> (PUPIL) [PEAKDETECT, TTEST].
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	(BP(SBP, DBP)) [-NOISE, - OUTLIERS].	<b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]]. <b>(TEC. AMOSTRAGEM)</b> (STRESS) [INTENTIONAL, STRATIFIED]. <b>(BALANC. E ETIQ.)</b> BP(SBP, DBP) [LABELING]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	(EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].	<b>(CONV. SINAL)</b> (EYES, MOUTH) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PITCH) [NORM]. <b>(SEG. E GER. SINAL)</b> (SPEECH) [INTERVALSPLIT] e (PITCH) <CONTOUR> [DY/DX].
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(BP(DBP)) [DISCARDATA] e (EMG) [-NOISE].	<b>Red. dim. e red. obj:</b> (EMG) [MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM]. <b>(TEC. AMOSTRAGEM)</b> (EMG, ST) [SYSTEMATIC].
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	(ECG(HR)) [DISCARDATA].	<b>(CONV. SINAL)</b> (EMOTIONS) [QUALI-QUANTI]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, LPF, HPF].
<b>R Sinha et al.</b> (R Sinha et al., 1992)	(ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDATA].	<b>Red. dim. e red. obj:</b> (BP(SBP, DBP), ECG(HR)) [MANSELECT].  <b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [SIGAMP].

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(SEG. E GER. SINAL) (ECG) [R-R].
--	--	-------------------------------------

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

### 4.1.2. Redução dimensional e redundância de objetos

Nesta secção aborda-se o problema da redundância de atributos e de objetos. Inicialmente apresentam-se as técnicas relacionadas com a redução dimensional que trata o problema do número elevado de atributos e da sua redundância, seguindo-se as técnicas relacionadas com a redundância de objetos.

Até os algoritmos de classificação mais conhecidos são sensíveis à presença de atributos pouco relevantes e redundantes num *dataset* (Gilad-bachrach, 2004). O elevado número de atributos é conhecido como a maldição da dimensionalidade (Bellman, 1961) e descreve o problema causado pelo grande crescimento do *dataset* resultante da introdução de novos atributos (Gilad-bachrach, 2004) (Gama et al., 2012) (J. Kim & André, 2008). Como o aumento do número de atributos aumenta exponencialmente o número de combinações possíveis de dados, os algoritmos de classificação podem tornar-se ineficientes. As técnicas de redução dimensional pretendem encontrar os atributos que contribuem de forma efetiva para as taxas de sucesso dos classificadores, avaliando a qualidade da correlação entre si (Jerritta et al., 2011). A redução dimensional contribui para a diminuição do esforço de processamento, para aumento do desempenho dos sistemas e das taxas de acerto dos algoritmos (Raschka, 2014) (J. Kim & André, 2008) (Guyon & Elisseeff, 2003) (Mokhayeri & Toosizadeh, 2011).

Para descobrir quais os atributos redundantes existentes num *dataset* os investigadores utilizam técnicas de pré-processamento. Além das automáticas abordadas de seguida, os investigadores utilizam instrumentos manuais para analisar a redundância e relação entre atributos: o *scatter plot* [**SCATTER**] é um diagrama matemático que permite analisar visualmente os padrões formados no espaço bidimensional cartesiano entre duas variáveis com o objetivo de avaliar a sua interdependência (i.e. relacionamento ou redundância) (e.g. Perdiz et al. (Perdiz et al., 2017)) (Phinyomark, Phukpattaranont, & Limsakul, 2012) (Guyon & Elisseeff, 2003); Bogolomov et al., Sano et al. e LikamWa et al., utilizaram técnicas de correlação [**CORRELATION**] para medir a força da relação entre variáveis (e.g. *Person Product-Moment Correlation*) (Sigma, 2016) (Andale, 2012) (Crossman, 2017) (W. H. Press, B. P. Flannery, n.d.) (Laerd, 2013) (Bogomolov et al., 2014) (Sano & Picard, 2013b) (LikamWa et al., 2013); e o Chi-square [**X<sup>2</sup>**] é um teste estatístico que avalia a dependência entre duas variáveis (Cambridge University, 2008) (Adhikari, 2016) (o valor do X<sup>2</sup> representa o grau de relevância de uma propriedade na classe a que pertence (Alzoubi et al., 2013)).

No entanto, os investigadores recorrem essencialmente a técnicas automáticas para apoiar o processo da redução dimensional. São vários os algoritmos utilizados pelos investigadores incluídos nesta revisão bibliográfica para este fim: o *Principal Component Analysis* [**PCA**] é um algoritmo não supervisionado (i.e. ignora as *class labels*) que converte um conjunto de objetos possivelmente correlacionáveis num novo *dataset* de dados não correlacionados (Raschka, 2014) (Gama et al., 2012) (Pearson, 1901), e o objetivo principal é encontrar os *principal components* responsáveis pela variância dos dados (Raschka, 2014); o *Linear Discriminant Analysis* [**LDA**] é um algoritmo supervisionado que tem por objetivo projetar um *dataset* com menos dimensões fazendo uma separação otimizada por classes para evitar o *overfitting* e diminuir o esforço de processamento (Raschka, 2014) (Fisher, 1936b) (além de encontrar os

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

responsáveis pela variância como faz o PCA, o LDA maximiza a separação entre as diferentes classes (Raschka, 2014)) (e.g. Phinyomark et al. utilizaram o LDA para encontrar as propriedades redundantes e as mais representativas do seu *dataset* (Phinyomark et al., 2012)); *Sequential Forward Selection* [SFS] que realiza um procura heurística em profundidade nas propriedades disponíveis (J. Kim & André, 2008); *Sequential Backward Selection* [SBS] é similar ao SFS mas faz uma procura *top-down* (remove uma propriedade a cada iteração) (J. Kim & André, 2008); *Sequential Floating Forward Selection* [SFFS] (J. Kim & André, 2008); *Genetic Algorithm* [GA] (J. Kim & André, 2008); *Supervised Locality Preserving Projection* [SLPP] (Turan et al., 2015) (Zheng, Yang, Tan, Jia, & Yang, 2007) (Lu, Lu, Qi, & Wang, 2010); *Discriminant-Analysis of Canonical Correlations* [DCC] (Turan et al., 2015) (T. K. Kim, Kittler, & Cipolla, 2007); *Adaboost Algorithm* [ADABOOST] (Csail, n.d.) (Schapire, 2013) (H. Wang et al., 2010); *Best-First Search* [BESTFIRST] (Mackworth & Goebel, 1998) (Korf, 1993) (Gunes & Piccardi, 2007); Murali et al. criaram o seu próprio algoritmo de *feature selection* [MURALI] (Murali et al., 2015) (Padmanabhan et al., 2015); *Wrapper Feature Selection* [WFS] (Jaques et al. utilizaram o WFS para avaliar a relevância de cada propriedade no seu *dataset* (Jaques et al., 2015)) (Guyon & Elisseeff, 2003) (Panthong & Srivihok, 2015) (Kohavi & John, 1997); e *Fisher's Discriminant Analysis* [FDA] (Fisher, 1936a) (Fukunaga, 1990) (e.g. Matiko et al. utilizaram este algoritmo porque o consideram robusto na redução dimensional (Matiko et al., 2014)). Alguns autores recorrem ainda a técnicas mais específicas de apoio na redução dimensional (e.g. Bogomolov et al. selecionaram propriedades utilizando um sistema de pontuação [BOGOMOLOV] adaptando o *Gini Coefficient of Inequality* como métrica (Bogomolov et al., 2014)).

Depois de descobertos os atributos irrelevantes ou redundantes, os investigadores utilizam várias estratégias para reduzir a dimensionalidade: seleção manual [MANSELECT] de atributos irrelevantes a eliminar (e.g. valor de um atributo igual em todos os objetos, ou informação pessoal dos participantes), ou relevantes a considerar (processo é normalmente supervisionado por especialistas de domínio e pode ser auxiliado por instrumentos visuais (e.g. SCATTER)) (e.g. Jaques et al. adicionaram e removeram propriedades até conseguirem um conjunto que permitisse atingir uma maior precisão na classificação (Jaques et al., 2015)) (incluem-se neste grupo as técnicas de redução dimensional não identificadas pelos autores (e.g. Basu et al. (Basu et al., 2016), Sinha (Rajita Sinha, 1996) e Sinha et al. (R Sinha et al., 1992))) (Gama et al., 2012); e agregação [AGGREGATION], i.e. combinação de vários atributos dependentes num único (Gama et al., 2012) (e.g. Phinyomark et al. aglomeraram atributos (EMG) [RAW, NORM] para reduzir a redundância de dados (Phinyomark et al., 2012), van Eck et al. juntaram vários itens para formar apenas o "Positive Affect" e o "Negative Affect" (van Eck et al., 2005)).

Alguns investigadores tratam também o problema da redundância de objetos: Gogia et al. removeram do seu *dataset* valores EEG recolhidos em duplicado [-DUPLICATE] (Gogia et al., 2016); Sano & Eng. considerou apenas um objeto pico de sinal EDA a cada intervalo de tempo [DISTINCTOBJ] (i.e. no mesmo segundo apenas um pico EDA foi considerado) (Sano & Eng, 2016); e Dhall et al. removeram *frames* redundantes de VIDEO [-FRAMES] (Dhall et al., 2011) e Gunes et al. omitiram *frames* com movimentos intermédios (Gunes & Piccardi, 2007).

INVESTIGAÇÃO	MANUTENÇÃO DO DATASET	
	RED. DIM. E RED. OBJS	OUTRAS
Perdiz et al. (Perdiz et al., 2017) e (Phinyomark et al., 2012)	(EMG) [SCATTER, LDA [AGGREGATION]].	(NORM., AMP E FILTR.) (EMG) [BPF, SIGAMP, NORM].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Gogia et al.</b> (Gogia et al., 2016)	(EEG) [-DUPLICATE].	<b>Ruído, d. inc. e inc.:</b> (EEG) [-EYEBLINK].  <b>(BALANC. E ETIQ.)</b> (EEG) [[[-EYEBLINK, -DUPLICATE] [LABELING]] [+ARTIFICIALDATA]].
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	(HEAD, FACS) [PCA].	<b>(TEC. AMOSTRAGEM)</b> (HEAD, FACS) [RANDOM]. <b>(BALANC. E ETIQ.)</b> (FACS) [LABELING]. <b>(OUTRAS)</b> (FACS) [FINDREGION, SI-SSM]. {ZFACE}.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	(EDA) [LPF [DY/DX [DISTINCTOBJ]]].	<b>Ruído, d. inc. e inc.:</b> (EDA) [-NOISE].  <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]]. <b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
<b>Basu et al.</b> (Basu et al., 2016)	(ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM [MANSELECT]].	<b>(NORM., AMP E FILTR.)</b> (ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM]. <b>(OUTRAS)</b> {KHRV, WEKA, LABCHART, MATLAB, ORIGIN}.
<b>Turan et al.</b> (Turan et al., 2015)	(FACE, EYES) [SLPP, DCC].	<b>(BALANC. E ETIQ.)</b> (FACE, EYES) [LABELING]. <b>(OUTRAS)</b> (EYES) [FINDREGION].
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)	((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI].	<b>Ruído, d. inc. e inc.:</b> (ECG, ICG) [-NOISE].  <b>(NORM., AMP E FILTR.)</b> (ECG, EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (ECG, ICG) [SIGSPPLIT]. <b>(OUTRAS)</b> (ECG) [PEAKDETECT].
<b>Jaques et al.</b> (Jaques et al., 2015)	(EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT].	<b>Ruído, d. inc. e inc.:</b> (EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]].  <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]] e <ACC> [NORM]. <b>(SEG. E GER. SINAL)</b> (LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX]. <b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].
<b>Matiko et al.</b> (Matiko et al., 2014)	(EEG) [SCATTER, FDA].	<b>(NORM., AMP E FILTR.)</b> (EDA) [FDA [NORM]]. <b>(BALANC. E ETIQ.)</b> (EDA) [LABELING].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	(PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [CORELATION, BOGOMOLOV [MANSELECT]].	<b>(NORM., AMP E FILTR.)</b> (PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [NORM].
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	(ECG(HRV), RESP, EDA, EMG) [X <sup>2</sup> ].	<b>(BALANC. E ETIQ.)</b> (ECG(HRV), RESP, EDA, EMG) [SPREADSUBSAMPLE]. <b>(OUTRAS)</b> {AUBT}.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	<EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS> [CORRELATION, PCA, SFFS].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [DY/DX]] e (ACC) [ADL]. <b>(OUTRAS)</b> (EDA) [[LPF [DY/DX [PEAKDETECT]]]].
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	<MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL> [SFS, CORRELATION].	<b>Ruído, d. inc. e inc.:</b> (MOOD) [RELIABILITY, CONSISTENCY].  <b>(NORM., AMP E FILTR.)</b> (CALL, SMS, EMAIL) <COUNT> [NORM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM [NORM]] e (APPS) [LABELING] <COUNT, DURATION> [NORM]. <b>(SEG. E GER. SINAL)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]]. <b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] <PERIODS <COUNT, STD <MEAN, MAX>>> [LABELING] e (APPS) [LABELING]. <b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM], (APPS) <DURATION> [HISTOGRAM] e (APPS) [LABELING] <COUNT, DURATION> [HISTOGRAM].
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	(ECG, PR, BVP, EDA) [MANSELECT].	<b>Ruído, d. inc. e inc.:</b> (ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]].  <b>(NORM., AMP E FILTR.)</b> (ECG, PR, BVP, EDA) [LPF, HPF, NORM]. <b>(SEG. E GER. SINAL)</b> (ECG, PR, BVP, EDA) [R-R]. <b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]]. <b>(OUTRAS)</b> (ECG, BVP, PR) [PEAKDETECT].
<b>Dhall et al.</b> (Dhall et al., 2011)	(FACE) [VIDEO-PICS [-FRAMES [PCA]].	<b>(CONV. SINAL)</b> (FACE) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (FACE) [VIDEO-PICS [NORM]]. <b>(OUTRAS)</b> (FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	<ECG(HRV), PPG, PUPIL> [GA].	<b>Ruído, d. inc. e inc.:</b> (PUPIL) [-NOISE, -EYEBLINK].  <b>(CONV. SINAL)</b> (PUPIL) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) [IMGSIZE, IMGINTENSITY]. <b>(SEG. E GER. SINAL)</b> (ECG(HRV)) [BANDS].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(OUTRAS) (PUPIL) [FINDREGION, BLINKDETECT].
H. Wang et al. (H. Wang et al., 2010)	<EYES> [ADABOOST].	<b>Ruído, d. inc. e inc.:</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]].  <b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]]. <b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG]. <b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING]. <b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].
Bos (Bos, 2010)	<EEG> [PCA].	<b>Ruído, d. inc. e inc.:</b> (EEG) [-NOISE].  <b>(CONV. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER]]]. <b>(NORM., AMP E FILTR.)</b> (EEG) [-NOISE [BPF]. <b>(SEG. E GER. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]]. <b>(OUTRAS)</b> {EEGLAB}.
Setz et al. (Setz et al., 2010)	<EDA> [WFA].	<b>Ruído, d. inc. e inc.:</b> (EDA) [DISCARDATA, MANADJUST [-NOISE]].  <b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, LPF [HPF [LPF]]]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
J. Kim & André (J. Kim & André, 2008)	<ECG(HR, HRV), RESP(RR, BRV), EDA, EMG> [SBS].	<b>Ruído, d. inc. e inc.:</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE].  <b>(CONV. SINAL)</b> (ECG(HR, HRV)) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
Lichtenstein et al. (Lichtenstein, Antje; Oehme, 2008)	<ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG> e (EMOTIONS) [CORRELATION, MANSELECT].	<b>Ruído, d. inc. e inc.:</b> (RESP) [-PEAK].  <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(BALANC. E ETIQ.)</b> (RESP(RR)) <AMP> [LABELING].
Gunes & Piccardi (Gunes & Piccardi, 2007)	(SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS,	<b>(CONV. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST].	<p><b>(NORM., AMP E FILTR.)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST].</p> <p><b>(SEG. E GER. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].</p> <p><b>(OUTRAS)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.</p>
<b>Castellano et al.</b> (Castellano et al., 2007)	(ARMS) [DISCARDATA].	<p><b>(NORM., AMP E FILTR.)</b> (ARMS) &lt;MOTION &lt;MAX, MIN&gt;&gt; [NORM].</p> <p><b>(SEG. E GER. SINAL)</b> (ARMS) [-IMGBKG].</p> <p><b>(OUTRAS)</b> {EYESWEB}.</p>
<b>Sebe et al.</b> (Sebe et al., 2006)	(PITCH) [CORRELATION].	<p><b>(CONV. SINAL)</b> (HEAD, EYEBROWS, EYELIDS, MOUTH) [3D2D].</p> <p><b>(SEG. E GER. SINAL)</b> (HEAD, EYEBROWS, EYELIDS, MOUTH, VOLUME, SPEECH, PITCH) [INTEGRATION].</p>
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	<EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT].	<p><b>Ruído, d. inc. e inc.:</b> (EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY].</p> <p><b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH].</p> <p><b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS].</p> <p><b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].</p> <p><b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<b>Van Eck et al.</b> (van Eck et al., 2005)	(LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH) [PCA [AGGREGATION]].	<p><b>Ruído, d. inc. e inc.:</b> (HEALTH) [DISCARDATA] e (CORT) [-OUTLIERS].</p> <p><b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].</p>
<b>Busso et al.</b> (Busso et al., 2004)	<PITCH, VOLUME> [SBS], <FOREHEAD, EYEBROWS, EYES, CHEEKS> [PCA] e <PITCH, VOLUME, FOREHEAD, EYEBROWS, EYES, CHEEKS> [SBS [AGGREGATION], MANSELECT].	<p><b>(OUTRAS)</b> (FOREHEAD, EYEBROWS, EYES, CHEEKS) [FINDREGION, CLUSTERING].</p>
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	(MOOD, ENERGY) [PCA].	
<b>Ritz et al.</b> (Ritz et al., 2000)	(BP(SBP)) [CORRELATION].	<p><b>(SEG. E GER. SINAL)</b> (BP(SBP)) [INTERVALSPLIT].</p> <p><b>(OUTRAS)</b></p>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(HR, BP(SBP, DBP), ROS, RR, VT, EDA, EMOTIONS) [ANOVA].
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(EMG) [MANSELECT].	<b>Ruído, d. inc. e inc.:</b> (BP(DBP)) [DISCARDATA] e (EMG) [-NOISE].  <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM]. <b>(TEC. AMOSTRAGEM)</b> (EMG, ST) [SYSTEMATIC].
<b>R Sinha et al.</b> (R Sinha et al., 1992)	(BP(SBP, DBP), ECG(HR)) [MANSELECT].	<b>Ruído, d. inc. e inc.:</b> (ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDATA].  <b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [SIGAMP]. <b>(SEG. E GER. SINAL)</b> (ECG) [R-R].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

### 4.1.3. Análise

O desempenho dos algoritmos pode ser afetado pelo estado dos dados (Gama et al., 2012). Os dados *input* das técnicas de pré-processamento dos sistemas de detecção emocional são imperfeitos, porque são recolhidos do ambiente natural (i.e. mundo analógico) (e.g. corpo humano) através de sensores que são dispositivos discretizadores sinal. Dessa digitalização de dados podem resultar vários problemas: ruído (e.g. valores inesperados); dados incompletos (i.e. valores em falta); dados inconsistentes (i.e. valores contraditórios); e dados redundantes (i.e. valores que podem ser deduzidos a partir de outros) (Jerritta et al., 2011) (Gama et al., 2012). Além disso, o paradoxo entre a tentação de aumentar o número de atributos na tentativa de melhorar taxas de acerto, e os problemas causados nos algoritmos por causa da elevada dimensionalidade (Raschka, 2014) (Gama et al., 2012) (J. Kim & André, 2008), representa para os investigadores uma preocupação acrescida por causa da ponderação entre prós e contras no acréscimo de dados ou propriedades. As técnicas de manutenção do *dataset* permitem torná-lo menos imperfeito, através da detecção, correção e atenuação de problemas. O aumento da qualidade dos dados faz com que o *dataset* se torne um melhor *input* aos algoritmos de aprendizagem automática, promovendo a precisão dos resultados (K. H. Kim et al., 2004) (Mokhayeri & Toosizadeh, 2011) (Gama et al., 2012).

Transversalmente, os investigadores preocupam-se com o ruído dos dados recolhidos do contexto. A importância da qualidade do *input* dos sistemas estará por detrás desta preocupação. As técnicas mais utilizadas pelos autores para resolver o problema dos dados incompletos é o DISCARDATA e a geração sintética de dados em falta (i.e. FAKEDATA). São de realçar, no entanto, as técnicas TOLERANCE e RELIABILITY que admitem a margem para as falhas humanas e a necessidade de avaliação do impacto dessas falhas no *dataset*.

A preocupação da qualidade dos dados também é evidente na avaliação da CONSISTENCY dos dados e na MITIGATION feita das possíveis interferências de sinal. De realçar também a grande quantidade de investigadores que recorrem à edição manual dos dados (i.e. MANADJUST e

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

MANINSERT), não ficando claro o impacto destas ações nos dados e na validade dos resultados obtidos com base nos mesmos.

Os autores recorrem também a técnicas de redução dimensional, com o objetivo de encontrar os atributos que realmente contribuem para as taxas de acerto dos classificadores (Jerritta et al., 2011) (Guyon & Elisseeff, 2003) (Gama et al., 2012). De entre eles, são mais os que utilizam algoritmos próprios para o efeito, do que os que recorrem a métodos mais visuais (i.e. menos automáticos) como o SCATTER e o CORRELATION. A redundância de objetos é analisada de forma bem mais residual até porque será difícil definir quando dois objetos são realmente redundantes. Se os objetos presentes no *dataset* resultam da discretização de um sinal analógico, simbolizam pontos de dados diferentes que existiram no mundo natural, podendo gerar controvérsia a alegação de que se repetiram.

INVESTIGAÇÃO	RÚIDO, D. INC. E INC.	RED. DIM. E RED. OBJS	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017) e (Phinyomark et al., 2012)		(EMG) [SCATTER, LDA [AGGREGATION]].	<b>(NORM., AMP E FILTR.)</b> (EMG) [BPF, SIGAMP, NORM].
<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	(FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)) [FAKEDATA].		<b>(NORM., AMP E FILTR.)</b> (EYEBROWS, EYELIDS) [NORM]. <b>(OUTRAS)</b> (FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH) [CLUSTERING, SPARSEREPE] e (EYEBROWS, EYELIDS) [FINDREGION, CROP]. {HAC}.
<b>Gogia et al.</b> (Gogia et al., 2016)	(EEG) [-EYEBLINK].	(EEG) [-DUPLICATE].	<b>(BALANC. E ETIQ.)</b> (EEG) [[[-EYEBLINK, -DUPLICATE] [LABELING]] [+ARTIFICIALDATA]].
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)		(HEAD, FACS) [PCA].	<b>(TEC. AMOSTRAGEM)</b> (HEAD, FACS) [RANDOM]. <b>(BALANC. E ETIQ.)</b> (FACS) [LABELING]. <b>(OUTRAS)</b> (FACS) [FINDREGION, SI-SSM]. {ZFACE}.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	(EDA) [-NOISE].	(EDA) [LPF [DY/DX [DISTINCTOBJ]]].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]]. <b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
<b>Zhao et al.</b> (Zhao et al., 2016)	(RESP, HR) [-NOISE].		<b>(NORM., AMP E FILTR.)</b> (RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF]. <b>(SEG. E GER. SINAL)</b> (RESP, HR) [D2Y/DX2, ZHAO2]. <b>(OUTRAS)</b> (RESP) [LPF [PEAKDETECT]].
<b>Zenonos et al.</b>	(MOOD, EMOTIONS) [TOLERANCE].		<b>(NORM., AMP E FILTR.)</b> (IBI) [NORM].

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Zenonos et al., 2016)			<b>(SEG. E GER. SINAL)</b> (IBI) [BANDS]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].
<b>Basu et al.</b> (Basu et al., 2016)		(ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM [MANSELECT]].	<b>(NORM., AMP E FILTR.)</b> (ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM]. <b>(OUTRAS)</b> {KHRV, WEKA, LABCHART, MATLAB, ORIGIN}.
<b>Aracena et al.</b> (Aracena et al., 2016)	(PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE].		<b>(NORM., AMP E FILTR.)</b> (PUPIL) [LPF, NORM]. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].
<b>Turan et al.</b> (Turan et al., 2015)		(FACE, EYES) [SLPP, DCC].	<b>(BALANC. E ETIQ.)</b> (FACE, EYES) [LABELING]. <b>(OUTRAS)</b> (EYES) [FINDREGION].
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)	(ECG, ICG) [-NOISE].	((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI].	<b>(NORM., AMP E FILTR.)</b> (ECG, EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (ECG, ICG) [SIGSPLOT]. <b>(OUTRAS)</b> (ECG) [PEAKDETECT].
<b>Jaques et al.</b> (Jaques et al., 2015)	(EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]].	(EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]] e <ACC> [NORM]. <b>(SEG. E GER. SINAL)</b> (LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX]. <b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].
<b>Matiko et al.</b> (Matiko et al., 2014)		(EEG) [SCATTER, FDA].	<b>(NORM., AMP E FILTR.)</b> (EDA) [FDA [NORM]]. <b>(BALANC. E ETIQ.)</b> (EDA) [LABELING].
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)		(PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [CORELATION, BOGOMOLOV [MANSELECT]].	<b>(NORM., AMP E FILTR.)</b> (PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [NORM].
<b>Soleymani et al.</b> (Soleymani et al., 2013)	(EMOTIONS) [DISCARDATA] e (EEG) [-NOISE].		<b>(CONV. SINAL)</b> (EEG) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>(SEG. E GER. SINAL)</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] <DISTANCE> [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION]. <b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			<b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING]. <b>(OUTRAS)</b> {FEELTRACE}.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)		(ECG(HRV), RESP, EDA, EMG) [X <sup>2</sup> ].	<b>(BALANC. E ETIQ.)</b> (ECG(HRV), RESP, EDA, EMG) [SPREADSUBSAMPLE]. <b>(OUTRAS)</b> {AUBT}.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		<EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS> [CORRELATION, PCA, SFFS].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [DY/DX]] e (ACC) [ADL]. <b>(OUTRAS)</b> (EDA) [[LPF [DY/DX [PEAKDETECT]]]].
<b>Kawai et al.</b> (Kawai et al., 2013)	(PUPIL) <DIAMETER> [MANADJUST, -NOISE, MITIGATION].		<b>(CONV. SINAL)</b> (PUPIL) [BINARY]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) <DIAMETER> [KAWAI2 [NORM]]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION, CLUSTERING, KAWAI1].
<b>Babiker et al.</b> (Babiker et al., 2013)	(PUPIL) [MITIGATION], <PUPIL> [NORM [-NOISE, -OUTLIERS][FAKEDATA, DISCARDATA]].		<b>(NORM., AMP E FILTR.)</b> <PUPIL> [NORM]. <b>(SEG. E GER. SINAL)</b> (PUPIL) <INTERVALSPLIT>. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION].
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	(MOOD) [RELIABILITY, CONSISTENCY].	<MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL> [SFS, CORRELATION].	<b>(NORM., AMP E FILTR.)</b> (CALL, SMS, EMAIL) <COUNT> [NORM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM [NORM]] e (APPS) [LABELING] <COUNT, DURATION> [NORM]. <b>(SEG. E GER. SINAL)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]]. <b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] <PERIODS <COUNT, STD <MEAN, MAX>>> [LABELING] e (APPS) [LABELING]. <b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM], (APPS) <DURATION> [HISTOGRAM] e (APPS) [LABELING] <COUNT, DURATION> [HISTOGRAM].
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	(ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]].	(ECG, PR, BVP, EDA) [MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (ECG, PR, BVP, EDA) [LPF, HPF, NORM]. <b>(SEG. E GER. SINAL)</b> (ECG, PR, BVP, EDA) [R-R].

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			<p><b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].</p> <p><b>(OUTRAS)</b> (ECG, BVP, PR) [PEAKDETECT].</p>
<p><b>Dhall et al.</b> (Dhall et al., 2011)</p>		(FACE) [VIDEO-PICS [-FRAMES [PCA]].	<p><b>(CONV. SINAL)</b> (FACE) [VIDEO-PICS].</p> <p><b>(NORM., AMP E FILTR.)</b> (FACE) [VIDEO-PICS [NORM]].</p> <p><b>(OUTRAS)</b> (FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].</p>
<p><b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri &amp; Toosizadeh, 2011)</p>	(PUPIL) [-NOISE, -EYEBLINK].	<ECG(HRV), PPG, PUPIL> [GA].	<p><b>(CONV. SINAL)</b> (PUPIL) [VIDEO-PICS].</p> <p><b>(NORM., AMP E FILTR.)</b> (PUPIL) [IMGSIZE, IMGINTENSITY].</p> <p><b>(SEG. E GER. SINAL)</b> (ECG(HRV)) [BANDS].</p> <p><b>(OUTRAS)</b> (PUPIL) [FINDREGION, BLINKDETECT].</p>
<p><b>Hernandez et al.</b> (Hernandez et al., 2011)</p>	(EDA) [-NOISE].	<p><b>(NORM., AMP E FILTR.)</b> (EDA, STRESS) [NORM] e &lt;EDA, STRESS&gt; [NORM].</p> <p><b>(BALANC. E ETIQ.)</b> (CALL) [LABELING].</p> <p><b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>	
<p><b>N. Lane et al.</b> (N. Lane et al., 2011)</p>	(SLEEP, PHYSI) [MANINSERT].		<p><b>(SEG. E GER. SINAL)</b> (ACC) [ADL].</p> <p><b>(OUTRAS)</b> (SLEEP) [LANE1] e (SLEEP, PHYSI) [MANADJUST].</p>
<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>	(EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]].	<EYES> [ADABOOST].	<p><b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]].</p> <p><b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG].</p> <p><b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING].</p> <p><b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].</p>
<p><b>Bos</b> (Bos, 2010)</p>	(EEG) [-NOISE].	<EEG> [PCA].	<p><b>(CONV. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER]]].</p> <p><b>(NORM., AMP E FILTR.)</b> (EEG) [-NOISE [BPF].</p> <p><b>(SEG. E GER. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]].</p> <p><b>(OUTRAS)</b> {EEGLAB}.</p>
<p><b>Setz et al.</b> (Setz et al., 2010)</p>	(EDA) [DISCARDATA, MANADJUST [-NOISE]].	<EDA> [WFA].	<p><b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, LPF [HPF [LPF]]].</p> <p><b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>J. Kim &amp; André</b> (J. Kim &amp; André, 2008)</p>	<p>(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE].</p>	<p>&lt;ECG(HR, HRV), RESP(RR, BRV), EDA, EMG&gt; [SBS].</p>	<p><b>(CONV. SINAL)</b> (ECG(HR, HRV)) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].</p>
<p><b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)</p>	<p>(RESP) [-PEAK].</p>	<p>&lt;ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG&gt; e (EMOTIONS) [CORRELATION, MANSELECT].</p>	<p><b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(BALANC. E ETIQ.)</b> (RESP(RR)) &lt;AMP&gt; [LABELING].</p>
<p><b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)</p>	<p>(PUPIL) [FAKEDATA].</p>		<p><b>(NORM., AMP E FILTR.)</b> (PUPIL, EDA) [NORM].</p>
<p><b>Gunes &amp; Piccardi</b> (Gunes &amp; Piccardi, 2007)</p>		<p>(SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST].</p>	<p><b>(CONV. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY]. <b>(NORM., AMP E FILTR.)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST]. <b>(SEG. E GER. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG]. <b>(OUTRAS)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.</p>
<p><b>Castellano et al.</b> (Castellano et al., 2007)</p>		<p>(ARMS) [DISCARDATA].</p>	<p><b>(NORM., AMP E FILTR.)</b> (ARMS) &lt;MOTION &lt;MAX, MIN&gt;&gt; [NORM]. <b>(SEG. E GER. SINAL)</b> (ARMS) [-IMGBKG]. <b>(OUTRAS)</b> {EYESWEB}.</p>
<p><b>Mandryk &amp; Atkins</b></p>	<p>(ECG(HR)) [MANADJUST, FAKEDATA].</p>		<p><b>(NORM., AMP E FILTR.)</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Mandryk & Atkins, 2007)			(ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED]. <b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) HISTOGRAM].
<b>Sebe et al.</b> (Sebe et al., 2006)		(PITCH) [CORRELATION].	<b>(CONV. SINAL)</b> (HEAD, EYEBROWS, EYELIDS, MOUTH) [3D2D]. <b>(SEG. E GER. SINAL)</b> (HEAD, EYEBROWS, EYELIDS, MOUTH, VOLUME, SPEECH, PITCH) [INTEGRATION].
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	(PUPIL) <DIAMETER>[-NOISE [FAKEDATA]].		<b>(NORM., AMP E FILTR.)</b> (ST) [SIGAMP [LPF [NORM]]] e (BVP[IBI], EDA) [NORM].
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	(EDA, ECG(HR, HRV)) [DISCARDDATA] e (STRESS) [RELIABILITY].	<EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS]. <b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
<b>Herbon et al.</b> (Herbon et al., 2005)	(HR, EDA, PUPIL, EMOTIONS) [DISCARDDATA] e (HR, EDA, PUPIL) <STD <THRESHOLD>> [DISCARDDATA].		<b>(CONV. SINAL)</b> (HR, EDA, ST, PUPIL) [ZTRANSFORM].
<b>Partala et al.</b> (Partala et al., 2005)	(EMG) [-EYEBLINK].		<b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP [HPF, LPF]]. <b>(SEG. E GER. SINAL)</b> (EMG) e (EMOTIONS) [LABELING]. <b>(OUTRAS)</b> (EMG) [TTEST].
<b>Van Eck et al.</b> (van Eck et al., 2005)	(HEALTH) [DISCARDDATA] E (CORT) [-OUTLIERS].	(LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS, PHYSI, SMOKING, FOOD, CAFFEI,	<b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		ALCOH) [PCA [AGGREGATION]].	
<b>Busso et al.</b> (Busso et al., 2004)		<PITCH, VOLUME> [SBS], <FOREHEAD, EYEBROWS, EYES, CHEEKS> [PCA] e <PITCH, VOLUME, FOREHEAD, EYEBROWS, EYES, CHEEKS> [SBS [AGGREGATION], MANSELECT].	<b>(OUTRAS)</b> (FOREHEAD, EYEBROWS, EYES, CHEEKS) [FINDREGION, CLUSTERING].
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [- OUTLIERS]].		<b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV)) [PEAKDETECT [R- R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	(PUPIL) [DISCARDATA, - EYEBLINK].		<b>(BALANC. E ETIQ.)</b> (PUPIL) [LABELING]. <b>(OUTRAS)</b> (PUPIL) [PEAKDETECT, TTEST].
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)		(MOOD, ENERGY) [PCA].	
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	(BP(SBP, DBP)) [-NOISE, - OUTLIERS].		<b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI (RMSSD (VAGAL))), ACC) [INTEGRATION [ADL]]. <b>(TEC. AMOSTRAGEM)</b> (STRESS) [INTENTIONAL, STRATIFIED]. <b>(BALANC. E ETIQ.)</b> BP(SBP, DBP) [LABELING]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>Ritz et al.</b> (Ritz et al., 2000)		(BP(SBP)) [CORRELATION].	<b>(SEG. E GER. SINAL)</b> (BP(SBP)) [INTERVALSPLIT]. <b>(OUTRAS)</b> (HR, BP(SBP, DBP), ROS, RR, VT, EDA, EMOTIONS) [ANOVA].
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	(EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].		<b>(CONV. SINAL)</b> (EYES, MOUTH) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PITCH) [NORM]. <b>(SEG. E GER. SINAL)</b> (SPEECH) [INTERVALSPLIT] e (PITCH) <CONTOUR> [DY/DX].
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(BP(DBP)) [DISCARDATA]	(EMG) [MANSELECT].	<b>(NORM., AMP E FILTR.)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	e (EMG) [-NOISE].		(EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM]. <b>(TEC. AMOSTRAGEM)</b> (EMG, ST) [SYSTEMATIC].
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	(ECG(HR)) [DISCARDDATA].		<b>(CONV. SINAL)</b> (EMOTIONS) [QUALI-QUANTI]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, LPF, HPF].
<b>R Sinha et al.</b> (R Sinha et al., 1992)	(ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDDATA].	(BP(SBP, DBP), ECG(HR)) [MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [SIGAMP]. <b>(SEG. E GER. SINAL)</b> (ECG) [R-R].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

## 4.2. MANUTENÇÃO DE SINAL

Nesta secção são apresentadas técnicas de pré-processamento responsáveis por adequar os sinais ao processamento de algoritmos.

Tendo por base a literatura em análise, resolveu-se por efetuar um agrupamento das técnicas identificadas em três categorias: i) conversão de sinal e de tipos de dados; ii) normalização, amplificação e filtros; e iii) segmentação e geração de novo sinal.

### 4.2.1. Conversão de sinal

A conversão de sinal é um dos tipos de técnicas utilizadas pelos investigadores na manutenção de sinal. Na literatura analisada foram identificadas várias técnicas de conversão de sinal: VIDEO em PICTURES [**VIDEO-PICS**] (e.g. Mokhayeri et al. (Mokhayeri & Toosizadeh, 2011), Singh et al. converteram video em *frames* para analisar posturas corporais (Singh et al., 2015)); conversão de PICTURES para escala de cinzentos [**GREYSCALE**] e binarização de imagens [**BINARY**] (e.g. Eckert et al. utilizaram a GREYSCALE e BINARY para aplicar MORPHOPS nos EYES, EYEBROWS e MOUTH (Eckert et al., 2016); e conversão ou modelação de duas para três dimensões e vice-versa [**3D2D**] (Sebe et al., 2006).

São também vários os autores que utilizam as transformadas de *Fourier* [**FOURIER**] para converter o sinal do domínio do tempo para o domínios das frequências (Bracewell, 2014) (S. W. Smith, 2003): Korkmaz et al. utilizaram o *Fast Fourier Transform* para converter o sinal SPEECH (Korkmaz & Atasoy, 2015); e Soleymani et al. utilizaram o *Short Time Fourier Transform* para diminuir a resolução temporal do sinal EEG (Soleymani et al., 2013). Os autores utilizam também outras técnicas para transformação de domínios e análise de sinal: Herbon et al. utilizaram a transformada Z [**ZTRANSFORM**] na redução de diferenças entre sujeitos da sua experiência (Wickert, n.d.) (S. W. Smith, 1997) (Herbon et al., 2005); Nawasalkar et al. utilizaram o *Hilbert-Huang Transform* [**HHT**] para decompor o sinal com o objetivo de facilitar a análise nos domínios *time-frequency-transform* (N. E. Huang & Wu, 2008) (Tan, 2016); e Liu et al. utilizaram o algoritmo *Fractal Dimension* [**FD**] para extrair propriedades do sinal EEG (Maragos & Sun, 1993) (Theiler, 1990) (Y. Liu et al., 2010).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Incluem-se também nesta secção as técnicas relacionadas com a conversão de tipos de dados (e.g. Liu et al. converteram os LEVEL do espaço bidimensional *valence/arousal* em emoções discretas definindo um THRESHOLD para cada uma [**2D-DISCRETE**] (Y. Liu et al., 2010)). A transformação de tipos de dados de um atributo pode ser necessária por vários motivos, nomeadamente pelo facto do novo tipo ser mais adequado à utilização num determinado algoritmo (Gama et al., 2012). Alguns algoritmos apenas processam com atributos de valor numérico (e.g. *Artificial Neural Networks* (ANN), *Support Vector Machine* (SVM), etc.), e outros são mais adequados para trabalhar com valores qualitativos como nos modelos Bayesianos (Gama et al., 2012) (e.g. Vrana converteu valores qualitativos para quantitativos [**QUALI-QUANTI**] para uma escala de [0;20] (Scott R. Vrana, 1993)).

INVESTIGAÇÃO	MANUTENÇÃO DE SINAL	
	CONV. SINAL	OUTRAS
<b>Eckert et al.</b> (Eckert et al., 2016)	(EYES, EYEBROWS, NOSE, MOUTH) [GREYSCALE [BINARY]].	<b>Norm., amp e filtr.:</b> (EYES, EYEBROWS, NOSE, MOUTH) [IMGCONTRAST].  <b>(OUTRAS)</b> EYES, EYEBROWS, NOSE, MOUTH) [FINDREGION, [GREYSCALE [BINARY [MORPHOPS]]] e (FACS, CAU) [MOTIONDETECT].
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	(SPPECH) [FOURIER].	<b>Norm., amp e filtr.:</b> (SPPECH) [SIGAMP]. <b>Seg. e ger. sinal:</b> (SPEECH) [[FOURIER, SIGAMP] [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]].
<b>Singh et al.</b> (Singh et al., 2015)	(SHOULDERS, HANDS) [VIDEO-PICS].	<b>Seg. e ger. sinal:</b> (SHOULDERS, HANDS) [VIDEO-PICS [-IMGBKG]].
<b>Saha et al.</b> (Saha et al., 2014)	(HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [VIDEO-PICS].	<b>Seg. e ger. sinal:</b> (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [-IMGBKG].
<b>Agrawal et al.</b> (Agrawal et al., 2013)	(EYES, MOUTH, LIPS, SKIN) [VIDEO-PICS].	<b>(OUTRAS)</b> (SKIN, EYES, MOUTH) [FINDREGION]. {MATLAB}.
<b>Soleymani et al.</b> (Soleymani et al., 2013)	(EEG) [FOURIER].	<b>Norm., amp e filtr.:</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>Seg. e ger. sinal:</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] <DISTANCE> [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION].  <b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDATA] e (EEG) [-NOISE]. <b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING]. <b>(OUTRAS)</b> {FEELTRACE}.
<b>Vermun et al.</b> (Vermun et al., 2013)	(HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP e KNEES) [VIDEO-PICS].	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	(NIBP, RESP(RR)) [HHT].	
<b>Raudonis</b> (Raudonis, 2013)	(PUPIL) [GREYSCALE].	<b>(OUTRAS)</b> (PUPIL) [FINDREGION, RAUDONIS2].
<b>Kawai et al.</b> (Kawai et al., 2013)	(PUPIL) [BINARY].	<b>Norm., amp e filtr.:</b> (PUPIL) <DIAMETER> [KAWAI2 [NORM]].  <b>(RUIDO, D. INC. E INC.)</b> (PUPIL) <DIAMETER> [MANADJUST, -NOISE, MITIGATION]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION, CLUSTERING, KAWAI1].
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	(HEAD, FACE) [VIDEO-PICS].	<b>Norm., amp e filtr.:</b> (HEAD, FACE) [VIDEO-PICS [IMGALIGN]].  <b>(OUTRAS)</b> (HEAD, FACE) [FINDREGION, YANG1].
<b>Dhall et al.</b> (Dhall et al., 2011)	(FACE) [VIDEO-PICS].	<b>Norm., amp e filtr.:</b> (FACE) [VIDEO-PICS [NORM]].  <b>(RED. DIM. E RED. OBJS)</b> (FACE) [VIDEO-PICS [-FRAMES [PCA]]. <b>(OUTRAS)</b> (FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	(PUPIL) [VIDEO-PICS].	<b>Norm., amp e filtr.:</b> (PUPIL) [IMGSIZE, IMGINTENSITY]. <b>Seg. e ger. sinal:</b> (ECG(HRV)) [BANDS].  <b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [-NOISE, -EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HRV), PPG, PUPIL> [GA]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION, BLINKDETECT].
<b>Bos</b> (Bos, 2010)	(EEG) [-NOISE [BPF [FOURIER]]].	<b>Norm., amp e filtr.:</b> (EEG) [-NOISE [BPF]. <b>Seg. e ger. sinal:</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]].  <b>(RUIDO, D. INC. E INC.)</b> (EEG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> <EEG> [PCA]. <b>(OUTRAS)</b> {EEGLAB}.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	(EEG) [FD] e [EMOTIONS] [2D-DISCRETE].	<b>Norm., amp e filtr.:</b> <EEG> [BPF]. <b>Seg. e ger. sinal:</b> <EEG> [INTERVALSPLIT].
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	(ECG(HR, HRV)) [FOURIER].	<b>Norm., amp e filtr.:</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM]. <b>Seg. e ger. sinal:</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<p>(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HR, HRV), RESP(RR, BRV), EDA, EMG&gt; [SBS].</p> <p><b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].</p>
<p><b>Gunes &amp; Piccardi</b> (Gunes &amp; Piccardi, 2007)</p>	<p>(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY].</p>	<p><b>Norm., amp e filtr.:</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST].</p> <p><b>Seg. e ger. sinal:</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST].</p> <p><b>(OUTRAS)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.</p>
<p><b>Sebe et al.</b> (Sebe et al., 2006)</p>	<p>(HEAD, EYEBROWS, EYELIDS, MOUTH) [3D2D].</p>	<p><b>Seg. e ger. sinal:</b> (HEAD, EYEBROWS, EYELIDS, MOUTH, VOLUME, SPEECH, PITCH) [INTEGRATION].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (PITCH) [CORRELATION].</p>
<p><b>Herbon et al.</b> (Herbon et al., 2005)</p>	<p>(HR, EDA, ST, PUPIL) [ZTRANSFORM].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (HR, EDA, PUPIL, EMOTIONS) [DISCARDATA] e (HR, EDA, PUPIL) &lt;STD &lt;THRESHOLD&gt;&gt; [DISCARDATA].</p>
<p><b>Nwe et al.</b> (Nwe et al., 2001)</p>	<p>(SPEECH) [FOURIER].</p>	<p><b>Norm., amp e filtr.:</b> (SPEECH) [SIGSMOOTH].</p> <p><b>Seg. e ger. sinal:</b> (SPEECH) [INTERVALSPLIT].</p>
<p><b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)</p>	<p>(RESP) [FOURIER].</p>	<p><b>Norm., amp e filtr.:</b> (PPG(BVP(HR)), ECG(HR, HRV), RESP, EDA) [SIGSMOOTH, NORM].</p> <p><b>(BALANC. E ETIQ.)</b> (EMG) [LABELING].</p> <p><b>(OUTRAS)</b> {MATLAB}.</p>
<p><b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)</p>	<p>(EYES, MOUTH) [FOURIER].</p>	<p><b>Norm., amp e filtr.:</b> (PITCH) [NORM].</p> <p><b>Seg. e ger. sinal:</b> (SPEECH) [INTERVALSPLIT] e (PITCH) &lt;CONTOUR&gt; [DY/DX].</p> <p><b>(RUIDO, D. INC. E INC.)</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	(EMOTIONS) [QUALI-QUANTI].	<b>Norm., amp e filtr.:</b> (EMG) [SIGAMP, LPF, HPF].  <b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [DISCARDATA].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

#### 4.2.2. Normalização, amplificação e filtros

A normalização [**NORM**] é utilizada em vários contextos: redimensionar amplitudes de atributos numéricos (e.g. Basu et al. (Basu et al., 2016)); preparar os dados para a execução de um algoritmo ou tipo de algoritmo; uniformizar unidades de medida; padronizar limites entre atributos (e.g. para evitar que os algoritmos considerem mais importantes os que apresentam valores superiores) (Gama et al., 2012); etc. No entanto, a normalização também pode acontecer ao nível do VIDEO, AUDIO e PICTURES: tamanho [**IMGSIZE**] (e.g. Mokhayeri et al. utilizaram IMGSIZE para normalizar a dimensão de imagens da PUPIL); contraste [**IMGCONTRAST**] (e.g. Eckert et al. melhoraram o contraste de imagens recolhidas em ambientes difíceis de luz através de uma equalização de histograma (Eckert et al., 2016)); intensidade luminosa [**IMGINTENSITY**] (e.g. Mokhayeri et al. normalizaram a intensidade luminosa das imagens da PUPIL (Mokhayeri & Toosizadeh, 2011)); Yang et al. utilizaram o *Sift Flow Algorithm* (SIFT) (C. Liu, Yuen, & Torralba, 2015) para normalizar o alinhamento [**IMGALIGN**] de faces em imagens para facilitar a generalização de rostos em *Emotion Avatar Image* (EAI) (S. Yang & Bhanu, 2011); e Kawai et al. utilizaram a média progressiva em janela (*moving average*) para alisar o diâmetro da PUPIL no tempo [**KAWAI2**] (Kawai et al., 2013).

Nesta revisão bibliográfica identificaram-se também técnicas relacionadas com a amplificação [**SIGAMP**] e filtros de sinal: *Low-Pass Filter* [**LPF**] (e.g. Jaques et al. (Jaques et al., 2015)); *High-Pass Filter* [**HPF**]; *Band-Pass Filter* [**BPF**] (e.g. Perdiz et al. (Perdiz et al., 2017), Chang et al. (Chang et al., 2012)); e *Adaptative Band-pass Filter* [**ABPF**] (e.g. Kim et al. (J. Kim & André, 2008)).

Incluem-se ainda nesta secção outras técnicas para manipulação de sinal: Zhao et al. atenuaram o efeito da movimentação torácica da respiração no sinal RF refletido, com o objetivo de enfatizar o sinal e extrair os batimentos cardíacos [**ZHAO1**] (Zhao et al., 2016); e Mandryk et al. utilizaram o alisamento de sinal [**SIGSMOOTH**] do HR após a geração de FAKEDATA (i.e. geração de dados adicionais através da interpolação para compatibilizar a frequência com o EMG e EDA) (Mandryk & Atkins, 2007).

INVESTIGAÇÃO	MANUTENÇÃO DE SINAL	
	NORM., AMP E FILTR.	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017) e (Phinyomark et al., 2012)	(EMG) [BPF, SIGAMP, NORM].	<b>(RED. DIM. E RED. OBJS)</b> (EMG) [SCATTER, LDA [AGGREGATION]].
<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	(EYEBROWS, EYELIDS) [NORM].	<b>(RUIDO, D. INC. E INC.)</b> (FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)) [FAKEDATA]. <b>(OUTRAS)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH) [CLUSTERING, SPARSEREP] e (EYEBROWS, EYELIDS) [FINDREGION, CROP]. {HAC}.
<b>Eckert et al.</b> (Eckert et al., 2016)	(EYES, EYEBROWS, NOSE, MOUTH) [IMGCONTRAST].	<b>Conv. sinal:</b> (EYES, EYEBROWS, NOSE, MOUTH) [GREYSCALE [BINARY]].  <b>(OUTRAS)</b> EYES, EYEBROWS, NOSE, MOUTH) [FINDREGION, [GREYSCALE [BINARY [MORPHOPS]]] e (FACS, CAU) [MOTIONDETECT].
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	(EDA) [LPF [NORM]].	<b>Seg. e ger. sinal:</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]].  <b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]]. <b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
<b>Zhao et al.</b> (Zhao et al., 2016)	(RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF].	<b>Seg. e ger. sinal:</b> (RESP, HR) [D2Y/DX2, ZHAO2].  <b>(RUIDO, D. INC. E INC.)</b> (RESP, HR) [-NOISE]. <b>(OUTRAS)</b> (RESP) [LPF [PEAKDETECT]].
<b>Zenonos et al.</b> (Zenonos et al., 2016)	(IBI) [NORM].	<b>Seg. e ger. sinal:</b> (IBI) [BANDS].  <b>(RUIDO, D. INC. E INC.)</b> (MOOD, EMOTIONS) [TOLERANCE]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].
<b>Basu et al.</b> (Basu et al., 2016)	(ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM].	<b>(RED. DIM. E RED. OBJS)</b> (ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM [MANSELECT]]. <b>(OUTRAS)</b> {KHRV, WEKA, LABCHART, MATLAB, ORIGIN}.
<b>Aracena et al.</b> (Aracena et al., 2016)	(PUPIL) [LPF, NORM].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE]. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	(FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)) [NORM].	<b>(OUTRAS)</b> (GAZE) [FINDREGION].
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	(SPPECH) [SIGAMP].	<b>Conv. sinal:</b> (SPPECH) [FOURIER]. <b>Seg. e ger. sinal:</b> (SPEECH) [[FOURIER, SIGAMP] [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]].
<b>Murali et al.</b>	(ECG, EDA) [LPF].	<b>Seg. e ger. sinal:</b> (ECG, ICG) [SIGSPILT].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Murali et al., 2015) e (Padmanabhan et al., 2015)		<p><b>(RUIDO, D. INC. E INC.)</b> (ECG, ICG) [-NOISE].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI].</p> <p><b>(OUTRAS)</b> (ECG) [PEAKDETECT].</p>
Jaques et al. (Jaques et al., 2015)	(EDA) [LPF [NORM]] e <ACC> [NORM].	<p><b>Seg. e ger. sinal:</b> (LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT].</p> <p><b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].</p>
Cruz et al. (Cruz et al., 2015)	(EOG) [BPF].	<p><b>Seg. e ger. sinal:</b> (EOG) [INTERVALSPLIT].</p>
Matiko et al. (Matiko et al., 2014)	(EDA) [FDA [NORM]].	<p><b>(RED. DIM. E RED. OBJS)</b> (EEG) [SCATTER, FDA].</p> <p><b>(BALANC. E ETIQ.)</b> (EDA) [LABELING].</p>
Bogomolov et al. (Bogomolov et al., 2014)	(PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [NORM].	<p><b>(RED. DIM. E RED. OBJS)</b> (PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [CORRELATION, BOGOMOLOV [MANSELECT]].</p>
Soleymani et al. (Soleymani et al., 2013)	(HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM].	<p><b>Conv. sinal:</b> (EEG) [FOURIER].</p> <p><b>Seg. e ger. sinal:</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] &lt;DISTANCE&gt; [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDDATA] e (EEG) [-NOISE].</p> <p><b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC].</p> <p><b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].</p> <p><b>(OUTRAS)</b> {FEELTRACE}.</p>
Sano & Picard (Sano & Picard, 2013b)	(EDA) [LPF].	<p><b>Seg. e ger. sinal:</b> (EDA) [LPF [DY/DX]] e (ACC) [ADL].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS&gt; [CORRELATION, PCA, SFFS].</p> <p><b>(OUTRAS)</b> (EDA) [[LPF [DY/DX [PEAKDETECT]]]].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Kawai et al.</b> (Kawai et al., 2013)</p>	<p>(PUPIL) &lt;DIAMETER&gt; [KAWAI2 [NORM]].</p>	<p><b>Conv. sinal:</b> (PUPIL) [BINARY].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) &lt;DIAMETER&gt; [MANADJUST, -NOISE, MITIGATION].</p> <p><b>(OUTRAS)</b> (PUPIL) [FINDREGION, CLUSTERING, KAWAI1].</p>
<p><b>Babiker et al.</b> (Babiker et al., 2013)</p>	<p>&lt;PUPIL&gt; [NORM].</p>	<p><b>Seg. e ger. sinal:</b> (PUPIL) &lt;INTERVALSPLIT&gt;.</p> <p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], &lt;PUPIL&gt; [NORM [[-NOISE, -OUTLIERS][FAKEDATA, DISCARDATA]]].</p> <p><b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].</p> <p><b>(OUTRAS)</b> (PUPIL) [FINDREGION].</p>
<p><b>LikamWa et al.</b> (LiKamWa et al., 2013)</p>	<p>(CALL, SMS, EMAIL) &lt;COUNT&gt; [NORM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM [NORM]] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [NORM].</p>	<p><b>Seg. e ger. sinal:</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL&gt; [SFS, CORRELATION].</p> <p><b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] &lt;PERIODS &lt;COUNT, STD &lt;MEAN, MAX&gt;&gt;&gt; [LABELING] e (APPS) [LABELING].</p> <p><b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM], (APPS) &lt;DURATION&gt; [HISTOGRAM] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [HISTOGRAM].</p>
<p><b>C. Y. Chang et al.</b> (Chang et al., 2012)</p>	<p>(ECG, PR, BVP, EDA) [LPF, HPF, NORM].</p>	<p><b>Seg. e ger. sinal:</b> (ECG, PR, BVP, EDA) [R-R].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT].</p> <p><b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].</p> <p><b>(OUTRAS)</b> (ECG, BVP, PR) [PEAKDETECT].</p>
<p><b>Yang &amp; Bhanu</b> (S. Yang &amp; Bhanu, 2011)</p>	<p>(HEAD, FACE) [VIDEO-PICS [IMGALIGN]].</p>	<p><b>Conv. sinal:</b> (HEAD, FACE) [VIDEO-PICS].</p> <p><b>(OUTRAS)</b> (HEAD, FACE) [FINDREGION, YANG1].</p>
<p><b>Dhall et al.</b> (Dhall et al., 2011)</p>	<p>(FACE) [VIDEO-PICS [NORM]].</p>	<p><b>Conv. sinal:</b> (FACE) [VIDEO-PICS].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (FACE) [VIDEO-PICS [-FRAMES [PCA]].</p> <p><b>(OUTRAS)</b> (FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].</p>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri &amp; Toosizadeh, 2011)</p>	<p>(PUPIL) [IMGSIZE, IMGINTENSITY].</p>	<p><b>Conv. sinal:</b> (PUPIL) [VIDEO-PICS]. <b>Seg. e ger. sinal:</b> (ECG(HRV)) [BANDS].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [-NOISE, -EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HRV), PPG, PUPIL&gt; [GA]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION, BLINKDETECT].</p>
<p><b>Hernandez et al.</b> (Hernandez et al., 2011)</p>	<p>(EDA, STRESS) [NORM] e &lt;EDA, STRESS&gt; [NORM].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(BALANC. E ETIQ.)</b> (CALL) [LABELING]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>	<p>(EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]].</p>	<p><b>Seg. e ger. sinal:</b> (EYES) [-IMGBKG].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EYES&gt; [ADABOOST]. <b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING]. <b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].</p>
<p><b>Bos</b> (Bos, 2010)</p>	<p>(EEG) [-NOISE [BPF].</p>	<p><b>Conv. sinal:</b> (EEG) [-NOISE [BPF [FOURIER]]]. <b>Seg. e ger. sinal:</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EEG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EEG&gt; [PCA]. <b>(OUTRAS)</b> {EEGLAB}.</p>
<p><b>Y. Liu et al.</b> (Y. Liu et al., 2010)</p>	<p>&lt;EEG&gt; [BPF].</p>	<p><b>Conv. sinal:</b> (EEG) [FD] e [EMOTIONS] [2D-DISCRETE]. <b>Seg. e ger. sinal:</b> &lt;EEG&gt; [INTERVALSPLIT].</p>
<p><b>Setz et al.</b> (Setz et al., 2010)</p>	<p>(EDA) [SIGAMP, LPF [HPF [LPF]]].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [DISCARDATA, MANADJUST [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EDA&gt; [WFA]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>J. Kim &amp; André</b> (J. Kim &amp; André, 2008)</p>	<p>(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM].</p>	<p><b>Conv. sinal:</b> (ECG(HR, HRV)) [FOURIER]. <b>Seg. e ger. sinal:</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]].</p> <p><b>(RUIDO, D. INC. E INC.)</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HR, HRV), RESP(RR, BRV), EDA, EMG> [SBS]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	(EDA) [LPF].	<b>(RUIDO, D. INC. E INC.)</b> (RESP) [-PEAK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG> e (EMOTIONS) [CORRELATION, MANSELECT]. <b>(BALANC. E ETIQ.)</b> (RESP(RR)) <AMP> [LABELING].
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	(PUPIL, EDA) [NORM].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [FAKEDATA].
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST].	<b>Conv. sinal:</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY]. <b>Seg. e ger. sinal:</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].  <b>(RED. DIM. E RED. OBJS)</b> (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST]. <b>(OUTRAS)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.
<b>Castellano et al.</b> (Castellano et al., 2007)	(ARMS) <MOTION <MAX, MIN>> [NORM].	<b>Seg. e ger. sinal:</b> (ARMS) [-IMGBKG].  <b>(RED. DIM. E RED. OBJS)</b> (ARMS) [DISCARDATA]. <b>(OUTRAS)</b> {EYESWEB}.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	(ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]].	<b>Seg. e ger. sinal:</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION].  <b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED]. <b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	(ST) [SIGAMP [LPF [NORM]]] e (BVP(IBE), EDA) [NORM].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) <DIAMETER>[-NOISE [FAKEDATA]].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>J. A. Healey &amp; Picard</b> (J. A. Healey &amp; Picard, 2005) e (Rosalind W. Picard et al., 2001)</p>	<p>(STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH].</p>	<p><b>Seg. e ger. sinal:</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;EDA, EMG, RESP, ECG(HR, HRV)&gt; [SCATTER, MANSELECT].</p> <p><b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].</p> <p><b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>Partala et al.</b> (Partala et al., 2005)</p>	<p>(EMG) [SIGAMP [HPF, LPF]].</p>	<p><b>Seg. e ger. sinal:</b> (EMG) e (EMOTIONS) [LABELING].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EMG) [-EYEBLINK].</p> <p><b>(OUTRAS)</b> (EMG) [TTEST].</p>
<p><b>Lisetti &amp; Nasoz</b> (Lisetti &amp; Nasoz, 2004)</p>	<p>(HR, EDA, ST) [NORM].</p>	
<p><b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)</p>	<p>(EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH].</p>	<p><b>Seg. e ger. sinal:</b> (ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] E (EDA) [INTERVALSPLIT].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]].</p> <p><b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION].</p> <p><b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].</p>
<p><b>Haag et al.</b> (Haag et al., 2004)</p>	<p>(ECG(HR)) [LPF [HPF]], (ECG(HR)) [[DY/DX, D2Y/DX2] [SIGSMOOTH]], (EDA) [NORM [LPF]], (EMG) [SIGSMOOTH] e &lt;PPG(BVP(HR)), ECG, RESP, EDA, ST, EMG&gt; [NORM].</p>	<p><b>Seg. e ger. sinal:</b> (ECG(HR)) [DY/DX, D2Y/DX2] e (PPG(BVP(HR)), RESP) [INTERVALSPLIT].</p> <p><b>(OUTRAS)</b> (PPG(BVP(HR))) [HISTOGRAM].</p>
<p><b>Nwe et al.</b> (Nwe et al., 2001)</p>	<p>(SPEECH) [SIGSMOOTH].</p>	<p><b>Conv. sinal:</b> (SPEECH) [FOURIER].</p> <p><b>Seg. e ger. sinal:</b> (SPEECH) [INTERVALSPLIT].</p>
<p><b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)</p>	<p>(PPG(BVP(HR)), ECG(HR, HRV), RESP, EDA) [SIGSMOOTH, NORM].</p>	<p><b>Conv. sinal:</b> (RESP) [FOURIER].</p> <p><b>(BALANC. E ETIQ.)</b> (EMG) [LABELING].</p> <p><b>(OUTRAS)</b> {MATLAB}.</p>
<p><b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)</p>	<p>(PITCH) [NORM].</p>	<p><b>Conv. sinal:</b> (EYES, MOUTH) [FOURIER].</p> <p><b>Seg. e ger. sinal:</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(SPEECH) [INTERVALSPLIT] e (PITCH) <CONTOUR> [DY/DX].  <b>(RUIDO, D. INC. E INC.)</b> (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	(RESP) [NORM], <RESP> [NORM] e (EDA) [SIGSMOOTH, NORM].	<b>(BALANC. E ETIQ.)</b> (EMG, EDA, PPG(BVP(HR))), RESP [LABELING].
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM].	<b>(RUIDO, D. INC. E INC.)</b> (BP(DBP)) [DISCARDATA] e (EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EMG) [MANSELECT]. <b>(TEC. AMOSTRAGEM)</b> (EMG, ST) [SYSTEMATIC].
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	(EMG) [SIGAMP, LPF, HPF].	<b>Conv. sinal:</b> (EMOTIONS) [QUALI-QUANTI].  <b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [DISCARDATA].
<b>R Sinha et al.</b> (R Sinha et al., 1992)	(ECG(HR)) [SIGAMP].	<b>Seg. e ger. sinal:</b> (ECG) [R-R].  <b>(RUIDO, D. INC. E INC.)</b> (ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDATA]. <b>(RED. DIM. E RED. OBJS)</b> (BP(SBP, DBP), ECG(HR)) [MANSELECT].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

### 4.2.3. Segmentação e geração de novo sinal

Nesta secção incluem-se as técnicas de segmentação e geração de sinal. As técnicas de segmentação podem ser vistas como geradoras de novo sinal. No entanto, decidimos separar deste grupo as técnicas cujo único propósito é apenas a geração de sinal. Assim, na categoria de segmentação de sinal incluem-se as técnicas cuja principal função é segmentar o sinal, e na categoria de geração de novo sinal incluímos as técnicas que apenas geram novo sinal.

Foram identificados vários autores que recorrem a técnicas de segmentação de sinal: Matlovic et al. utilizaram o *Discrete Wavelet Transform* [DWT] para extrair as ondas ALPHA e BETA do EEG [RAW] (Matlovic et al., 2016)); Zhao et al. segmentou o sinal da aceleração para extrair os batimentos cardíacos a partir do sinal WiFi, utilizando uma técnica de segmentação baseada na análise da variância (VAR) entre segmentos de sinal [ZHAO2] (Zhao et al., 2016); Singh et al. removeram o *background* de imagens deixando apenas as retas representativas do declive dos ombros das pessoas [-IMGBKG] (Singh et al., 2015); Gunes et al. segmentaram a cor da pele com base no espaço de cor HSV (*hue, saturation, and value*) [COLORSEG] (Gunes & Piccardi, 2007); Zenonos et al. segmentaram o *power spectral density* (PSD) do IBI em bandas em função da intensidade (cf. VLF, LF e HF) [BANDS], Murad & Malkawi também separou vários sinais (e.g. SV, SBP, DBP, HRV, PEP, etc.) (Murad & Malkawi, 2012), e Soleymani et al. também segmentaram o sinal EEG em várias bandas (cf. THETA, ALPHA, BETA e GAMMA) (Soleymani et al., 2013); Korkmaz et al. e Chen et al. dividiram o SPEECH em vários intervalos pequenos [INTERVALSPLIT]

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

por serem mais adequados à extração do MFCC (Korkmaz & Atasoy, 2015) (L. S. Chen et al., 1998), Liu et al. dividiram o sinal EEG recolhido em vários intervalos de tempo para utilização em experimentos paralelos (Y. Liu et al., 2010), e Kim et al. segmentaram os vários sinais recolhidos em vários intervalos de tempo (J. Kim & André, 2008); Murali et al. separou o sinal ECG do ICG com o objetivo de remover o ruído da atividade muscular [**SIGSPLIT**] (Murali et al., 2015). Incluem-se ainda nesta secção técnicas específicas de segmentação de sinal: Chang et al. utilizaram segmentaram os sinais fisiológicos em intervalos R-R [**R-R**] (Chang et al., 2012); e Kim et al. segmentaram o ECG em intervalos (*Normal-to-Normal*) [**N-N**] na obtenção do HRV (J. Kim & André, 2008).

Outra estratégia seguida pelos investigadores passa pela geração de novo sinal com base no *dataset* original: diferenciação de sinal na primeira e segunda derivada [**DY/DX**] [**D<sup>2</sup>Y/DX<sup>2</sup>**] (e.g. Jaques et al. calcularam a DY/DX do EDA (Jaques et al., 2015)); criação de dados representativos de percursos percorridos [**PATHSTAKEN**] (e.g. Jaques et al. utilizaram o *Gaussian Mixture Model* (GMM) para calcular trajetos regularmente percorridos com base nos dados de LOCAL (Jaques et al., 2015)); Kusserow et al. utilizaram a segmentação do ACC para detetar saltos e fases de salto de *ski jumpers* [**TASKSPLIT**] (Kusserow et al., 2013); Bauer et al. utilizaram o algoritmo de classificação de padrões *k-means* (Duda, Hart, & Stork, 2001) para detetar os padrões de movimentação e paragem dos participantes, com o objetivo de caracterizar os locais geográficos habitualmente frequentados pelas pessoas [**USUALPLACES**] (Bauer & Lukowicz, 2012); e geração de dados acerca das atividades diárias [**ADL**] (e.g. Sano & Eng. utilizaram algoritmos como *standard zero-crossing detection* (Ismailoglu & Yalcin, 1999) (Kosaka, Tanahashi, Matsui, & Fujitsuna, 2002) e *função de Cole* (Cole, Kripke, Gruen, Mullaney, & Gillin, 1992) para detetar o estado dormir e acordado, e atividades diárias como o sentar, correr ou caminhar (Sano & Eng, 2016), Vrijkotte et al. integrou dados fisiológicos com PHYSI com o objetivo de discriminar os estados do corpo: deitado, sentado, andar, trabalhos domésticos, trabalho de secretária, almoço ou jantar, etc.(Vrijkotte et al., 2000)).

Incluem-se também nesta secção outras técnicas de integração ou fusão [**INTEGRATION**] que geram também novos dados através da combinação de informação proveniente de várias fontes ou sistemas (Gama et al., 2012): Jaques et al. integraram as coordenadas do GPS, com os dados do WiFi e do telemóvel (antenas do operador) para criar um registo único de localização dos utilizadores (Jaques et al., 2015); Soleymani et al. fundiram dados provenientes de várias modalidades num único *dataset* (Soleymani et al., 2013); e Mandryk et al. fundiram VIDEO, dados de contexto fisiológico, som do jogo e som ambiente, num único VIDEO, com o objetivo objetivo de estudar a componente emocional em ambiente de jogos (Mandryk & Atkins, 2007).

INVESTIGAÇÃO	MANUTENÇÃO DE SINAL	
	SEG. E GER. SINAL	OUTRAS
Matlovic et al. (Matlovic et al., 2016)	(EEG) [DWT].	
Sano & Eng (Sano & Eng, 2016)	(EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]].	<b>Norm., amp e filtr.:</b> (EDA) [LPF [NORM]].  <b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]]. <b>(BALANC. E ETIQ.)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(SLEEP, EDA) [LABELING]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
<b>Zhao et al.</b> (Zhao et al., 2016)	(RESP, HR) [D2Y/DX2, ZHAO2].	<b>Norm., amp e filtr.:</b> (RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF].  <b>(RUIDO, D. INC. E INC.)</b> (RESP, HR) [-NOISE]. <b>(OUTRAS)</b> (RESP) [LPF [PEAKDETECT]].
<b>Zenonos et al.</b> (Zenonos et al., 2016)	(IBI) [BANDS].	<b>Norm., amp e filtr.:</b> (IBI) [NORM].  <b>(RUIDO, D. INC. E INC.)</b> (MOOD, EMOTIONS) [TOLERANCE]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	(SPEECH) [[FOURIER, SIGAMP] [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]].	<b>Conv. sinal:</b> (SPEECH) [FOURIER]. <b>Norm., amp e filtr.:</b> (SPEECH) [SIGAMP].
<b>Lalitha et al.</b> (Lalitha et al., 2015)	(SPEECH) [DWT].	
<b>Singh et al.</b> (Singh et al., 2015)	(SHOULDERS, HANDS) [VIDEO-PICS [-IMGBKG]].	<b>Conv. sinal:</b> (SHOULDERS, HANDS) [VIDEO-PICS].
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)	(ECG, ICG) [SIGSPLIT].	<b>Norm., amp e filtr.:</b> (ECG, EDA) [LPF].  <b>(RUIDO, D. INC. E INC.)</b> (ECG, ICG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI]. <b>(OUTRAS)</b> (ECG) [PEAKDETECT].
<b>Jaques et al.</b> (Jaques et al., 2015)	(LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX].	<b>Norm., amp e filtr.:</b> (EDA) [LPF [NORM]] e <ACC> [NORM].  <b>(RUIDO, D. INC. E INC.)</b> (EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]]. <b>(RED. DIM. E RED. OBJS)</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT]. <b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].
<b>Cruz et al.</b> (Cruz et al., 2015)	(EOG) [INTERVALSPLIT].	<b>Norm., amp e filtr.:</b> (EOG) [BPF].
<b>Saha et al.</b> (Saha et al., 2014)	(HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [- IMGBKG].	<b>Conv. sinal:</b> (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [VIDEO-PICS].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Soleymani et al.</b> (Soleymani et al., 2013)</p>	<p>(EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] &lt;DISTANCE&gt; [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION].</p>	<p><b>Conv. sinal:</b> (EEG) [FOURIER]. <b>Norm., amp e filtr.:</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDATA] e (EEG) [-NOISE]. <b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING]. <b>(OUTRAS)</b> {FEELTRACE}.</p>
<p><b>Kusserow et al.</b> (Kusserow et al., 2013)</p>	<p>(ACC) [TASKSPLIT] e (HR, ACC) [INTEGRATION].</p>	
<p><b>Sano &amp; Picard</b> (Sano &amp; Picard, 2013b)</p>	<p>(EDA) [LPF [DY/DX]] e (ACC) [ADL].</p>	<p><b>Norm., amp e filtr.:</b> (EDA) [LPF].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS&gt; [CORRELATION, PCA, SFFS]. <b>(OUTRAS)</b> (EDA) [[LPF [DY/DX [PEAKDETECT]]]].</p>
<p><b>Babiker et al.</b> (Babiker et al., 2013)</p>	<p>(PUPIL) &lt;INTERVALSPLIT&gt;.</p>	<p><b>Norm., amp e filtr.:</b> &lt;PUPIL&gt; [NORM].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], &lt;PUPIL&gt; [NORM [[-NOISE, -OUTLIERS][FAKEDATA, DISCARDATA]]]. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION].</p>
<p><b>LikamWa et al.</b> (LiKamWa et al., 2013)</p>	<p>(MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].</p>	<p><b>Norm., amp e filtr.:</b> (CALL, SMS, EMAIL) &lt;COUNT&gt; [NORM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM [NORM]] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [NORM].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY]. <b>(RED. DIM. E RED. OBJS)</b> &lt;MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL&gt; [SFS, CORRELATION]. <b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] &lt;PERIODS &lt;COUNT, STD &lt;MEAN, MAX&gt;&gt;&gt; [LABELING] e (APPS) [LABELING]. <b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM], (APPS) &lt;DURATION&gt; [HISTOGRAM] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [HISTOGRAM].</p>
<p><b>Murad &amp; Malkawi</b> (Murad &amp; Malkawi, 2012)</p>	<p>(EEG, HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS].</p>	<p><b>(BALANC. E ETIQ.)</b> (HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS [LABELING]].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>C. Y. Chang et al.</b> (Chang et al., 2012)</p>	<p>(ECG, PR, BVP, EDA) [R-R].</p>	<p><b>Norm., amp e filtr.:</b> (ECG, PR, BVP, EDA) [LPF, HPF, NORM].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT].</p> <p><b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].</p> <p><b>(OUTRAS)</b> (ECG, BVP, PR) [PEAKDETECT].</p>
<p><b>Bauer &amp; Lukowicz</b> (Bauer &amp; Lukowicz, 2012)</p>	<p>(LOCAL) [INTEGRATION, USUALPLACES].</p>	
<p><b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri &amp; Toosizadeh, 2011)</p>	<p>(ECG(HRV)) [BANDS].</p>	<p><b>Conv. sinal:</b> (PUPIL) [VIDEO-PICS].</p> <p><b>Norm., amp e filtr.:</b> (PUPIL) [IMGSIZE, IMGINTENSITY].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [-NOISE, -EYEBLINK].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HRV), PPG, PUPIL&gt; [GA].</p> <p><b>(OUTRAS)</b> (PUPIL) [FINDREGION, BLINKDETECT].</p>
<p><b>N. Lane et al.</b> (N. Lane et al., 2011)</p>	<p>(ACC) [ADL].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (SLEEP, PHYSI) [MANINSERT].</p> <p><b>(OUTRAS)</b> (SLEEP) [LANE1] e (SLEEP, PHYSI) [MANADJUST].</p>
<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>	<p>(EYES) [-IMGBKG].</p>	<p><b>Norm., amp e filtr.:</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY] [-NOISE]]]].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;EYES&gt; [ADABOOST].</p> <p><b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING].</p> <p><b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].</p>
<p><b>Bos</b> (Bos, 2010)</p>	<p>(EEG) [-NOISE [BPF [FOURIER [BANDS]]]].</p>	<p><b>Conv. sinal:</b> (EEG) [-NOISE [BPF [FOURIER]]].</p> <p><b>Norm., amp e filtr.:</b> (EEG) [-NOISE [BPF].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (EEG) [-NOISE].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;EEG&gt; [PCA].</p> <p><b>(OUTRAS)</b> {EEGLAB}.</p>
<p><b>Y. Liu et al.</b> (Y. Liu et al., 2010)</p>	<p>&lt;EEG&gt; [INTERVALSPLIT].</p>	<p><b>Conv. sinal:</b> (EEG) [FD] e [EMOTIONS] [2D-DISCRETE].</p> <p><b>Norm., amp e filtr.:</b> &lt;EEG&gt; [BPF].</p>
<p><b>J. Kim &amp; André</b></p>	<p>(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT],</p>	<p><b>Conv. sinal:</b> (ECG(HR, HRV)) [FOURIER].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p>(J. Kim &amp; André, 2008)</p>	<p>(ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]].</p>	<p><b>Norm., amp e filtr.:</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HR, HRV), RESP(RR, BRV), EDA, EMG&gt; [SBS].</p> <p><b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].</p>
<p><b>Gunes &amp; Piccardi</b> (Gunes &amp; Piccardi, 2007)</p>	<p>(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].</p>	<p><b>Conv. sinal:</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY].</p> <p><b>Norm., amp e filtr.:</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST].</p> <p><b>(OUTRAS)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.</p>
<p><b>Castellano et al.</b> (Castellano et al., 2007)</p>	<p>(ARMS) [-IMGBKG].</p>	<p><b>Norm., amp e filtr.:</b> (ARMS) &lt;MOTION &lt;MAX, MIN&gt;&gt; [NORM].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (ARMS) [DISCARDATA].</p> <p><b>(OUTRAS)</b> {EYESWEB}.</p>
<p><b>Mandryk &amp; Atkins</b> (Mandryk &amp; Atkins, 2007)</p>	<p>(ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION].</p>	<p><b>Norm., amp e filtr.:</b> (ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA].</p> <p><b>(TEC. AMOSTRAGEM)</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED].</p> <p><b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING].</p> <p><b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].</p>
<p><b>Sebe et al.</b> (Sebe et al., 2006)</p>	<p>(HEAD, EYEBROWS, EYELIDS, MOUTH, VOLUME, SPEECH, PITCH) [INTEGRATION].</p>	<p><b>Conv. sinal:</b> (HEAD, EYEBROWS, EYELIDS, MOUTH) [3D2D].</p> <p><b>(RED. DIM. E RED. OBJS)</b> (PITCH) [CORRELATION].</p>
<p><b>J. A. Healey &amp; Picard</b></p>	<p>(ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR,</p>	<p><b>Norm., amp e filtr.:</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS].	<b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY]. <b>(RED. DIM. E RED. OBJS)</b> <EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT]. <b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
<b>Partala et al.</b> (Partala et al., 2005)	(EMG) e (EMOTIONS) [LABELING].	<b>Norm., amp e filtr.:</b> (EMG) [SIGAMP [HPF, LPF]].  <b>(RUIDO, D. INC. E INC.)</b> (EMG) [-EYEBLINK]. <b>(OUTRAS)</b> (EMG) [TTEST].
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT].	<b>Norm., amp e filtr.:</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH].  <b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Haag et al.</b> (Haag et al., 2004)	(ECG(HR)) [DY/DX, D2Y/DX2] e (PPF(BVP(HR)), RESP) [INTERVALSPLIT].	<b>Norm., amp e filtr.:</b> (ECG(HR)) [LPF [HPF]], (ECG(HR)) [[DY/DX, D2Y/DX2] [SIGSMOOTH]], (EDA) [NORM [LPF]], (EMG) [SIGSMOOTH] e <PPG(BVP(HR)), ECG, RESP, EDA, ST, EMG> [NORM].  <b>OUTRAS</b> (PPG(BVP(HR))) [HISTOGRAM].
<b>Nwe et al.</b> (Nwe et al., 2001)	(SPEECH) [INTERVALSPLIT].	<b>Conv. sinal:</b> (SPEECH) [FOURIER]. <b>Norm., amp e filtr.:</b> (SPEECH) [SIGSMOOTH].
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	(PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]].	<b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS]. <b>(TEC. AMOSTRAGEM)</b> (STRESS) [INTENTIONAL, STRATIFIED]. <b>(BALANC. E ETIQ.)</b> BP(SBP, DBP) [LABELING]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>Ritz et al.</b> (Ritz et al., 2000)	(BP(SBP)) [INTERVALSPLIT].	<b>(RED. DIM. E RED. OBJS)</b> (BP(SBP)) [CORRELATION]. <b>(OUTRAS)</b> (HR, BP(SBP, DBP), ROS, RR, VT, EDA, EMOTIONS) [ANOVA].
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	(SPEECH) [INTERVALSPLIT] e (PITCH) <CONTOUR> [DY/DX].	<b>Conv. sinal:</b> (EYES, MOUTH) [FOURIER]. <b>Norm., amp e filtr.:</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(PITCH] [NORM].  <b>(RUIDO, D. INC. E INC.)</b> (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].
<b>R Sinha et al.</b> (R Sinha et al., 1992)	(ECG) [R-R].	<b>Norm., amp e filtr.:</b> (ECG(HR)) [SIGAMP].  <b>(RUIDO, D. INC. E INC.)</b> (ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDATA]. <b>(RED. DIM. E RED. OBJ)</b> (BP(SBP, DBP), ECG(HR)) [MANSELECT].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

#### 4.2.4. Análise

Os algoritmos de classificação podem não conseguir utilizar os dados no seu formato RAW por causa da sua sensibilidade a determinados tipos de dados ou à existência de intervalos numéricos diferentes entre atributos (Gama et al., 2012). Os algoritmos não interpretam a natureza de valores nem unidades de medida, vendo-os apenas como dados possivelmente correlacionáveis (Gama et al., 2012).

A grande diversidade de sensores utilizados nas investigações (i.e. marcas, características, finalidades), faz com que os dados recolhidos possam conter discrepâncias que necessitam de pré-processamento: i) podem ser recolhidos formatos incompatíveis com necessidades de conversão (e.g. Singh et al. e Agrawal et al. recorreram à conversão de vídeo em imagens (i.e. VIDEO-PICS) nas suas investigações (Singh et al., 2015) (Agrawal et al., 2013)) (Gama et al., 2012); podem existir diferentes unidades de medida ou conter amplitudes diferentes tornando-se necessário uniformizá-los (e.g. Mandryk & Atkins normalizaram três sinais fisiológicos (cf. ECG, EMG e EDA) para um valor percentual (Mandryk & Atkins, 2007)) (Basu et al., 2016) (Gama et al., 2012); e iii) pode haver necessidade de gerar novos sinais que espelhem de forma mais clara, explícita ou propícia, a informação presente num sinal original (e.g. Zhao et al. calcularam a  $D^2Y/DX^2$  da sinal RESP e HR (Zhao et al., 2016) e Jaques et al. integraram dados acerca do LOCAL com o objetivo de gerar dados acerca dos caminhos percorridos pelos participantes na sua experiência (i.e. PATHSTAKEN) (Jaques et al., 2015)).

Na literatura em revisão, são muitos os investigadores que trabalham sobre VIDEO e PICTURES que recorrem à conversão de sinal. No entanto, são também bastantes as investigações que fazem conversão de sinal entre domínios (e.g. tempo para frequências), utilizando técnicas como FOURIER, ZTRANSFORM, HHT ou FD. A utilização de técnicas de conversão de sinal é natural atendendo à necessidade de processamento de sinal a que os dados são sujeitos. Apesar de serem poucos os autores que relatam a utilização de conversão de tipos de dados, acreditamos que sejam técnicas utilizadas frequentemente, e que apenas não são totalmente relatadas devido ao carácter implícito que pode ser assumido nos processos de tratamento e transformação de dados.

A utilização da normalização é ampla e transversal aos diferentes tipos de sinais tratados pelas investigações analisadas. A grande utilização de técnicas relacionadas com a normalização, amplificação e filtros sobre o sinal, revela a preocupação dos autores em garantir a eficiência

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

dos algoritmos melhorando a qualidade do seu *input* (e.g. Zhai & Barreto amplificaram o ST recolhido na ponta dos dedos, aplicaram um LPF para remover possível ruído e, no final, normalizaram os valores resultantes (i.e. (ST) [SIGAMP [LPF [NORM]]]) (Zhai & Barreto, 2006)).

A segmentação e geração de novo sinal são técnicas importantes por causa da capacidade que têm de transformar o sinal original em informação mais rica e pertinente para os algoritmos, deduzindo novo sinal a partir de outro. A utilização adicional de sinais derivados do original, pode permitir que os algoritmos trabalhem com informação num nível de abstração superior ao dos dados originais. Das investigações em análise, destaca-se a utilização de técnicas relacionadas com a separação do sinal em bandas e intervalos (i.e. BANDS e INTERVALSPLIT), e a utilização de novos sinais como DY/DX e D<sup>2</sup>Y/DX<sup>2</sup>. Salientar a fraca utilização de dados relacionados com atividades diárias das pessoas, espaços usualmente frequentados e caminhos percorridos (i.e. ADL, USUALPLACES, PATHSTAKEN) que, consideramos, podem contribuir para um reconhecimento emocional mais eficiente.

Acreditamos também que sejam utilizadas mais frequentemente técnicas relacionadas com INTEGRATION. Talvez não sejam sempre relatadas pelos autores, pelo facto de as considerarem implícitas no próprio processo de preparação inicial do *dataset*.

INVESTIGAÇÃO	CONV. SINAL	NORM., AMP E FILTR.	SEG. E GER. SINAL	OUTRAS
Perdiz et al. (Perdiz et al., 2017) e (Phinyomark et al., 2012)		(EMG) [BPF, SIGAMP, NORM].		<b>(RED. DIM. E RED. OBJS)</b> (EMG) [SCATTER, LDA [AGGREGATION]].
S. H. Lee et al. (S. H. Lee et al., 2016)		(EYEBROWS, EYELIDS) [NORM].		<b>(RUIDO, D. INC. E INC.)</b> (FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)) [FAKEDATA]. <b>(OUTRAS)</b> (FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH) [CLUSTERING, SPARSEREP] e (EYEBROWS, EYELIDS) [FINDREGION, CROP]. {HAC}.
Eckert et al. (Eckert et al., 2016)	(EYES, EYEBROWS, NOSE, MOUTH) [GREYSCALE [BINARY]].	(EYES, EYEBROWS, NOSE, MOUTH) [IMGCONTRAST].		<b>(OUTRAS)</b> (EYES, EYEBROWS, NOSE, MOUTH) [FINDREGION, [GREYSCALE [BINARY [MORPHOPS]]] e (FACS, CAU) [MOTIONDETECT].
Matlovic et al. (Matlovic et al., 2016)			(EEG) [DWT].	
Sano & Eng (Sano & Eng, 2016)		(EDA) [LPF [NORM]].	(EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]]. <b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Zhao et al.</b> (Zhao et al., 2016)		(RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF].	(RESP, HR) [D2Y/DX2, ZHAO2].	<b>(RUIDO, D. INC. E INC.)</b> (RESP, HR) [-NOISE]. <b>(OUTRAS)</b> (RESP) [LPF [PEAKDETECT]].
<b>Zenonos et al.</b> (Zenonos et al., 2016)		(IBI) [NORM].	(IBI) [BANDS].	<b>(RUIDO, D. INC. E INC.)</b> (MOOD, EMOTIONS) [TOLERANCE]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].
<b>Basu et al.</b> (Basu et al., 2016)		(ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM].		<b>(RED. DIM. E RED. OBJS)</b> (ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM [MANSELECT]]. <b>(OUTRAS)</b> {KHRV, WEKA, LABCHART, MATLAB, ORIGIN}.
<b>Aracena et al.</b> (Aracena et al., 2016)		(PUPIL) [LPF, NORM].		<b>(RUIDO, D. INC. E INC.)</b> (PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE]. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)		(FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)) [NORM].		<b>(OUTRAS)</b> (GAZE) [FINDREGION].
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	(SPPECH) [FOURIER].	(SPPECH) [SIGAMP].	(SPEECH) [[FOURIER, SIGAMP] [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]].	
<b>Lalitha et al.</b> (Lalitha et al., 2015)			(SPEECH) [DWT].	
<b>Singh et al.</b> (Singh et al., 2015)	(SHOULDERS, HANDS) [VIDEO-PICS].		(SHOULDERS, HANDS) [VIDEO-PICS [-IMGBKG]].	
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)		(ECG, EDA) [LPF].	(ECG, ICG) [SIGSPLIT].	<b>(RUIDO, D. INC. E INC.)</b> (ECG, ICG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI]. <b>(OUTRAS)</b> (ECG) [PEAKDETECT].
<b>Jaques et al.</b> (Jaques et al., 2015)		(EDA) [LPF [NORM]] e <ACC> [NORM].	(LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]]. <b>(RED. DIM. E RED. OBJS)</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI,

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT]. <b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].
<b>Cruz et al.</b> (Cruz et al., 2015)		(EOG) [BPF].	(EOG) [INTERVALSPLIT].	
<b>Saha et al.</b> (Saha et al., 2014)	(HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [VIDEO-PICS].		(HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [-IMGBKG].	
<b>Matiko et al.</b> (Matiko et al., 2014)		(EDA) [FDA [NORM]].		<b>(RED. DIM. E RED. OBJS)</b> (EEG) [SCATTER, FDA]. <b>(BALANC. E ETIQ.)</b> (EDA) [LABELING].
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)		(PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [NORM].		<b>(RED. DIM. E RED. OBJS)</b> (PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [CORELATION, BOGOMOLOV [MANSELECT]].
<b>Agrawal et al.</b> (Agrawal et al., 2013)	(EYES, MOUTH, LIPS, SKIN) [VIDEO-PICS].			<b>(OUTRAS)</b> (SKIN, EYES, MOUTH) [FINDREGION]. {MATLAB}.
<b>Soleymani et al.</b> (Soleymani et al., 2013)	(EEG) [FOURIER].	(HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM].	(EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] <DISTANCE> [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION].	<b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDDATA] e (EEG) [-NOISE]. <b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING]. <b>(OUTRAS)</b> {FEELTRACE}.
<b>Vermun et al.</b> (Vermun et al., 2013)	(HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP e KNEES) [VIDEO-PICS].			
<b>Kusserow et al.</b> (Kusserow et al., 2013)			(ACC) [TASKSPLIT] e (HR, ACC) [INTEGRATION].	
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	(NIBP, RESP(RR)) [HHT].			
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		(EDA) [LPF].	(EDA) [LPF [DY/DX]] e (ACC) [ADL].	<b>(RED. DIM. E RED. OBJS)</b> <EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS> [CORRELATION, PCA, SFFS].

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				<b>(OUTRAS)</b> (EDA) [[LPF [DY/DX [PEAKDETECT]]]].
<b>Raudonis</b> (Raudonis, 2013)	(PUPIL) [GREYSCALE].			<b>(OUTRAS)</b> (PUPIL) [FINDREGION, RAUDONIS2].
<b>Kawai et al.</b> (Kawai et al., 2013)	(PUPIL) [BINARY].	(PUPIL) <DIAMETER> [KAWAI2 [NORM]].		<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) <DIAMETER> [MANADJUST, -NOISE, MITIGATION]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION, CLUSTERING, KAWAI1].
<b>Babiker et al.</b> (Babiker et al., 2013)		<PUPIL> [NORM].	(PUPIL) <INTERVALSPLIT>.	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], <PUPIL> [NORM [[-NOISE, - OUTLIERS][FAKEDATA, DISCARDDATA]]]. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION].
<b>LikamWa et al.</b> (LiKamWa et al., 2013)		(CALL, SMS, EMAIL) <COUNT> [NORM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM [NORM]] e (APPS) [LABELING] <COUNT, DURATION> [NORM].	(MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].	<b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY]. <b>(RED. DIM. E RED. OBJS)</b> <MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL> [SFS, CORRELATION]. <b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] <PERIODS <COUNT, STD <MEAN, MAX>>> [LABELING] e (APPS) [LABELING]. <b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM], (APPS) <DURATION> [HISTOGRAM] e (APPS) [LABELING] <COUNT, DURATION> [HISTOGRAM].
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)			(EEG, HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS].	<b>(BALANC. E ETIQ.)</b> (HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS [LABELING]].
<b>C. Y. Chang et al.</b> (Chang et al., 2012)		(ECG, PR, BVP, EDA) [LPF, HPF, NORM].	(ECG, PR, BVP, EDA) [R-R].	<b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT]. <b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]]. <b>(OUTRAS)</b>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				(ECG, BVP, PR) [PEAKDETECT].
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)			(LOCAL) [INTEGRATION, USUALPLACES].	
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	(HEAD, FACE) [VIDEO-PICS].	(HEAD, FACE) [VIDEO-PICS [IMGALIGN]].		<b>(OUTRAS)</b> (HEAD, FACE) [FINDREGION, YANG1].
<b>Dhall et al.</b> (Dhall et al., 2011)	(FACE) [VIDEO-PICS].	(FACE) [VIDEO-PICS [NORM]].		<b>(RED. DIM. E RED. OBJS)</b> (FACE) [VIDEO-PICS [- FRAMES [PCA]]. <b>(OUTRAS)</b> (FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	(PUPIL) [VIDEO-PICS].	(PUPIL) [IMGSIZE, IMGINTENSITY].	(ECG(HRV)) [BANDS].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [-NOISE, -EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HRV), PPG, PUPIL> [GA]. <b>(OUTRAS)</b> (PUPIL) [FINDREGION, BLINKDETECT].
<b>Hernandez et al.</b> (Hernandez et al., 2011)		(EDA, STRESS) [NORM] e <EDA, STRESS> [NORM].		<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(BALANC. E ETIQ.)</b> (CALL) [LABELING]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
<b>N. Lane et al.</b> (N. Lane et al., 2011)			(ACC) [ADL].	<b>(RUIDO, D. INC. E INC.)</b> (SLEEP, PHYSI) [MANINSERT]. <b>(OUTRAS)</b> (SLEEP) [LANE1] e (SLEEP, PHYSI) [MANADJUST].
<b>H. Wang et al.</b> (H. Wang et al., 2010)		(EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]].	(EYES) [-IMGBKG].	<b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [- NOISE]]]]. <b>(RED. DIM. E RED. OBJS)</b> <EYES> [ADABOOST]. <b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING]. <b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].
<b>Bos</b> (Bos, 2010)	(EEG) [-NOISE [BPF [FOURIER]]].	(EEG) [-NOISE [BPF].	(EEG) [-NOISE [BPF [FOURIER [BANDS]]]].	<b>(RUIDO, D. INC. E INC.)</b> (EEG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> <EEG> [PCA]. <b>(OUTRAS)</b> {EEGLAB}.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	(EEG) [FD] e [EMOTIONS] [2D- DISCRETE].	<EEG> [BPF].	<EEG> [INTERVALSPLIT].	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Setz et al.</b> (Setz et al., 2010)		(EDA) [SIGAMP, LPF [HPF [LPF]]].		<b>(RUIDO, D. INC. E INC.)</b> (EDA) [DISCARDATA, MANADJUST [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> <EDA> [WFA]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	(ECG(HR, HRV)) [FOURIER].	(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM].	(ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP(RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]].	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HR, HRV), RESP(RR, BRV), EDA, EMG> [SBS]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)		(EDA) [LPF].		<b>(RUIDO, D. INC. E INC.)</b> (RESP) [-PEAK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG> e (EMOTIONS) [CORRELATION, MANSELECT]. <b>(BALANC. E ETIQ.)</b> (RESP(RR)) <AMP> [LABELING].
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)		(PUPIL, EDA) [NORM].		<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [FAKEDATA].
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY].	(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST].	(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].	<b>(RED. DIM. E RED. OBJS)</b> (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST]. <b>(OUTRAS)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.
<b>Castellano et al.</b> (Castellano et al., 2007)		(ARMS) <MOTION <MAX, MIN>> [NORM].	(ARMS) [-IMGBKG].	<b>(RED. DIM. E RED. OBJS)</b> (ARMS) [DISCARDATA]. <b>(OUTRAS)</b> {EYESWEB}.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)		(ECG(HR)) [FAKEDATA [SIGSMOOTH[NORM]]], (EMG)	(ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION].	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA]. <b>(TEC. AMOSTRAGEM)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		[SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]].		(ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED]. <b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].
<b>Sebe et al.</b> (Sebe et al., 2006)	(HEAD, EYEBROWS, EYELIDS, MOUTH) [3D2D].		(HEAD, EYEBROWS, EYELIDS, MOUTH, VOLUME, SPEECH, PITCH) [INTEGRATION].	<b>(RED. DIM. E RED. OBJS)</b> (PITCH) [CORRELATION].
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)		(ST) [SIGAMP [LPF [NORM]]] e (BVP[IBI], EDA) [NORM].		<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) <DIAMETER>[-NOISE [FAKEDATA]].
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)		(STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH].	(ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS].	<b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY]. <b>(RED. DIM. E RED. OBJS)</b> <EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT]. <b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].
<b>Herbon et al.</b> (Herbon et al., 2005)	(HR, EDA, ST, PUPIL) [ZTRANSFORM].			<b>(RUIDO, D. INC. E INC.)</b> (HR, EDA, PUPIL, EMOTIONS) [DISCARDATA] e (HR, EDA, PUPIL) <STD <THRESHOLD>> [DISCARDATA].
<b>Partala et al.</b> (Partala et al., 2005)		(EMG) [SIGAMP [HPF, LPF]].	(EMG) e (EMOTIONS) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (EMG) [-EYEBLINK]. <b>(OUTRAS)</b> (EMG) [TTEST].
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)		(HR, EDA, ST) [NORM].		
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		(EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH].	(ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT].	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Haag et al.</b> (Haag et al., 2004)		(ECG(HR)) [LPF [HPF]], (ECG(HR)) [[DY/DX, D2Y/DX2] [SIGSMOOTH]], (EDA)	(ECG(HR)) [DY/DX, D2Y/DX2] e (PPF(BVP(HR)), RESP) [INTERVALSPLIT].	<b>(OUTRAS)</b> (PPG(BVP(HR))) [HISTOGRAM].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		[NORM [LPF]], (EMG) [SIGSMOOTH] e <PPG(BVP(HR)), ECG, RESP, EDA, ST, EMG> [NORM].		
<b>Nwe et al.</b> (Nwe et al., 2001)	(SPEECH) [FOURIER].	(SPEECH) [SIGSMOOTH].	(SPEECH) [INTERVALSPLIT].	
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)	(RESP) [FOURIER].	(PPG(BVP(HR)), ECG(HR, HRV), RESP, EDA) [SIGSMOOTH, NORM].		<b>(BALANC. E ETIQ.)</b> (EMG) [LABELING]. <b>(OUTRAS)</b> {MATLAB}.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)			(PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]].	<b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS]. <b>(TEC. AMOSTRAGEM)</b> (STRESS) [INTENTIONAL, STRATIFIED]. <b>(BALANC. E ETIQ.)</b> BP(SBP, DBP) [LABELING]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>Ritz et al.</b> (Ritz et al., 2000)			(BP(SBP)) [INTERVALSPLIT].	<b>(RED. DIM. E RED. OBJS)</b> (BP(SBP)) [CORRELATION]. <b>(OUTRAS)</b> (HR, BP(SBP, DBP), ROS, RR, VT, EDA, EMOTIONS) [ANOVA].
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	(EYES, MOUTH) [FOURIER].	(PITCH) [NORM].	(SPEECH) [INTERVALSPLIT] e (PITCH) <CONTOUR> [DY/DX].	<b>(RUIDO, D. INC. E INC.)</b> (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)		(RESP) [NORM], <RESP> [NORM] e (EDA) [SIGSMOOTH, NORM].		<b>(BALANC. E ETIQ.)</b> (EMG, EDA, PPG(BVP(HR)), RESP) [LABELING].
<b>Rajita Sinha</b> (Rajita Sinha, 1996)		(EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM].		<b>(RUIDO, D. INC. E INC.)</b> (BP(DBP)) [DISCARDATA] e (EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EMG) [MANSELECT]. <b>(TEC. AMOSTRAGEM)</b> (EMG, ST) [SYSTEMATIC].
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	(EMOTIONS) [QUALI-QUANTI].	(EMG) [SIGAMP, LPF, HPF].		<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [DISCARDATA].
<b>R Sinha et al.</b> (R Sinha et al., 1992)		(ECG(HR)) [SIGAMP].	(ECG) [R-R].	<b>(RUIDO, D. INC. E INC.)</b> (ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDATA]. <b>(RED. DIM. E RED. OBJS)</b>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

				(BP(SBP, DBP), ECG(HR)) [MANSELECT].
--	--	--	--	---

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

### 4.3. AMOSTRAGEM E META-INFORMAÇÃO

Nesta secção abordam-se as técnicas de amostragem que permitem a criação de subconjuntos de dados (i.e. sub-conjunto de objetos e de atributos) com o objetivo de promover a melhoria de desempenho dos algoritmos. Aborda-se também o balanceamento entre classes e o enriquecimento dos objetos com meta-informação (i.e. etiquetagem).

Apesar dos *datasets* poderem conter grandes volumes de informação, não quer dizer que todos os objetos e atributos façam falta ao processamento dos algoritmos. Além disso, a utilização de grandes *datasets* pode conduzir à saturação de memória ou quebras de desempenho em alguns algoritmos (e.g. *k-nearest neighbours* (KNN)) (Gama et al., 2012) (Phinyomark et al., 2012). Por este motivo, os investigadores utilizam amostras em representação do *dataset* completo. A amostra, além de ser representativa de todo o *dataset*, deve também atender ao balanceamento entre classes. Quando um conjunto de dados desbalanceado é utilizado, os algoritmos tendem a classificar na classe maioritária (i.e. classe com maior número de objetos) (Gama et al., 2012).

#### 4.3.1. Técnicas de amostragem

O equilíbrio entre a quantidade de dados e o desempenho computacional é um desafio para os processos de indução (Gama et al., 2012). Se por um lado, um maior conjunto de dados está associado a uma maior taxa de acerto dos classificadores, mais dados significa mais informação para processar, maior peso computacional e menor desempenho dos sistemas (Gama et al., 2012) (Zhao et al., 2016). Nesta secção apresentam-se as técnicas de amostragem utilizadas pelos autores da literatura em revisão na fase de pré-processamento, i.e. após o processo de recolha de dados de contexto.

Uma amostra é um sub-conjunto de dados de tamanho  $n$ , representativo do conjunto de dados principal (i.e. população, universo ou *dataset* original) de tamanho  $N$  (Pocinho, 2009) (Brandão, n.d.). A utilização de sub-conjuntos de dados em detrimento do *dataset* completo reduz a quantidade de informação a processar e pode promover o aumento de desempenho dos sistemas (Zhao et al., 2016). No entanto a amostra deve ser representativa dos dados do *dataset* original, sob pena de se sacrificar a qualidade dos resultados para se conseguir desempenho (e.g. a média dos atributos deve ser equivalente e o número de objetos por classe deve ser proporcional) (Gama et al., 2012). O ideal é que a amostra seja pequena mas representativa do *dataset* original do ponto de vista da sua distribuição estatística, para ser possível retirar informação do conjunto completo de dados a partir de um seu subconjunto (Investopedia, 2017) (Gama et al., 2012). Em processamento de sinal, a redução da taxa de amostragem (i.e. *downsampling*) é conhecida por *decimation* [DECIMATION] (Lyons, 2004) (e.g. Kim et al. (K. H. Kim et al., 2004)).

São várias as técnicas probabilísticas utilizadas para amostragem: amostragem aleatória simples [RANDOM] em que os objetos a considerar para a amostra são sorteados (e.g. Zhang et al. escolheu aleatoriamente objetos da sua experiência (Z. Zhang et al., 2016)); amostragem

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

estratificada **[STRATIFIED]** em que os objetos são inicialmente divididos em subconjuntos (i.e. estratos) e, de seguida, são selecionados objetos dentro de cada subconjunto (diz-se estratificada proporcional quando a quantidade de objetos selecionados para a amostra atende à quantidade de objetos de cada estrato); e amostragem sistemática **[SYSTEMATIC]** em que se seleciona um objeto a cada intervalo  $r$  ocorrências de objetos ( $r = N/n$ ), iniciando no elemento  $k$  sorteado ( $0 < k \leq r$ ). Além das probabilísticas, utilizam-se também outras técnicas não probabilísticas (i.e. não aleatórias) (e.g. amostragem intencional **[INTENTIONAL]** em que os objetos são selecionados com base num critério definido pelo investigador (IPLeitura, 2009)).

INVESTIGAÇÃO	AMOSTRAGEM E META-INFORMAÇÃO	
	TEC. AMOSTRAGEM	OUTRAS
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	(HEAD, FACS) [RANDOM].	<b>Balanc. e etiq.:</b> (FACS) [LABELING].  <b>(RED. DIM. E RED. OBJS)</b> (HEAD, FACS) [PCA]. <b>(OUTRAS)</b> (FACS) [FINDREGION, SI-SSM]. {ZFACE}.
<b>Aracena et al.</b> (Aracena et al., 2016)	(PUPIL) [SYSTEMATIC].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) [LPF, NORM].
<b>Soleymani et al.</b> (Soleymani et al., 2013)	[HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC].	<b>Balanc. e etiq.:</b> (EMOTIONS) [LABELING].  <b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDDATA] e (EEG) [-NOISE]. <b>(CONV. SINAL)</b> (EEG) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>(SEG. E GER. SINAL)</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] <DISTANCE> [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION]. <b>(OUTRAS)</b> {FEELTRACE}.
<b>Babiker et al.</b> (Babiker et al., 2013)	(PUPIL) [SYSTEMATIC].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], <PUPIL> [NORM [[-NOISE, -OUTLIERS][FAKEDATA, DISCARDDATA]]]. <b>(NORM., AMP E FILTR.)</b> <PUPIL> [NORM]. <b>(SEG. E GER. SINAL)</b> (PUPIL) <INTERVALSPLIT>. <b>(OUTRAS)</b> (PUPIL) [FINDREGION].
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	(EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].	<b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (ECG, PR, BVP, EDA) [LPF, HPF, NORM]. <b>(SEG. E GER. SINAL)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(ECG, PR, BVP, EDA) [R-R]. <b>(OUTRAS)</b> (ECG, BVP, PR) [PEAKDETECT].
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	(ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED].	<b>Balanc. e etiq.:</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING].  <b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA]. <b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(ECG(HRV), EDA) [DECIMATION].	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]]. <b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Vrijotte et al.</b> (Vrijotte et al., 2000)	(STRESS) [INTENTIONAL, STRATIFIED].	<b>Balanc. e etiq.:</b> BP(SBP, DBP) [LABELING].  <b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS]. <b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(EMG, ST) [SYSTEMATIC].	<b>(RUIDO, D. INC. E INC.)</b> (BP(DBP)) [DISCARDATA] e (EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EMG) [MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

#### 4.3.2. Balanceamento e etiquetagem

O balanceamento de classes é um problema relacionado com os algoritmos de classificação (Gama et al., 2012). Quando treinados com um conjunto de dados desbalanceado, os algoritmos tendem a classificar os novos dados sempre na classe maioritária (i.e. classe com maior número de objetos) (Gama et al., 2012). A solução natural para este problema pode passar pela recolha de mais dados de contexto. No entanto, quando não é possível aumentar ao número de objetos pela forma natural, torna-se necessário utilizar técnicas artificiais para resolver o problema do balanceamento (e.g. redefinir o tamanho do *dataset* eliminando objetos às classes mais lotadas ou inserir objetos utilizando valores estatísticos como mediana e moda dos atributos, etc.)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Gama et al., 2012). Os investigadores considerados neste levantamento bibliográfico recorreram essencialmente à geração artificial de dados **[+ARTIFICIALDATA]** para corrigir a distribuição do número de objetos por classe (i.e. aumentando objetos sintéticos às classes minoritárias) (e.g. Wang et al. consideraram em duplicado as imagens recolhidas de olhos fechados para melhorar o equilíbrio com as imagens de olhos abertos (H. Wang et al., 2010) Gogia et al. recorreram à +ARTIFICIALDATA para equilibrar o número de objetos nas classes minoritárias (Gogia et al., 2016), etc.). Alguns autores escolheram outras formas para resolver o problema do balaceamento. Alzoubi et al. resolveram o problema do desbalaceamento entre classes dos dados recolhidos por *self-reports* através da aplicação de uma técnica de *downsampling* do WEKA **[SPREADSUBSAMPLE]** que produz um subconjunto aleatório balanceado a partir do *dataset* inicial (Algorithmia, 2017) (“Class SpreadSubsample,” n.d.) (Alzoubi et al., 2013);

As técnicas de etiquetagem **[LABELING]** são utilizadas pelos autores para anotar os dados com informação adicional de suporte. São vários os autores que recorrem ao LABELING para acrescentar meta-informação aos seus dados: Gogia et al. anotaram o sinal EEG recolhido com informação acerca do estado de atenção dos participantes da sua experiência durante a visualização de videos (i.e. utilizou o valor *Patt* para significar “*Paying attention*” e *P’att* para “*Not paying attention*”) (Gogia et al., 2016); Zhang et al. acrescentaram metadados na sua base de dados acerca de ocorrência e intensidade de alterações nas *Action Units* da face dos seus participantes (Z. Zhang et al., 2016); Zenonos et al. dividiram as intensidades da MOOD sentidas pelos participantes em classes com o objetivo das as utilizar na classificação (Zenonos et al., 2016); e Basu et al. etiquetaram as imagens utilizadas na indução emocional em função da respetiva intensidade emocional (e.g. *high valence high arousal* (HVHA), *high valence low arousal* (HVLA), etc.) (Basu et al., 2016).

INVESTIGAÇÃO	AMOSTRAGEM E META-INFORMAÇÃO	
	BALANC. E ETIQ.	OUTRAS
Gogia et al. (Gogia et al., 2016)	(EEG) [[[-EYEBLINK, -DUPLICATE] [LABELING]] [+ARTIFICIALDATA]].	<b>(RUIDO, D. INC. E INC.)</b> (EEG) [-EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> (EEG) [-DUPLICATE].
Z. Zhang et al. (Z. Zhang et al., 2016)	(FACS) [LABELING].	<b>Tec. amostragem:</b> (HEAD, FACS) [RANDOM].  <b>(RED. DIM. E RED. OBJS)</b> (HEAD, FACS) [PCA]. <b>(OUTRAS)</b> (FACS) [FINDREGION, SI-SSM]. {ZFACE}.
Sano & Eng (Sano & Eng, 2016)	(SLEEP, EDA) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
Zenonos et al.	(EMOTIONS) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (MOOD, EMOTIONS) [TOLERANCE].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Zenonos et al., 2016)		<b>(NORM., AMP E FILTR.)</b> (IBI) [NORM]. <b>(SEG. E GER. SINAL)</b> (IBI) [BANDS].
<b>Turan et al.</b> (Turan et al., 2015)	(FACE, EYES) [LABELING].	<b>(RED. DIM. E RED. OBJS)</b> (FACE, EYES) [SLPP, DCC]. <b>(OUTRAS)</b> (EYES) [FINDREGION].
<b>Jaques et al.</b> (Jaques et al., 2015)	(HAPPY) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]]. <b>(RED. DIM. E RED. OBJS)</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]] e <ACC> [NORM]. <b>(SEG. E GER. SINAL)</b> (LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX].
<b>Matiko et al.</b> (Matiko et al., 2014)	(EDA) [LABELING].	<b>(RED. DIM. E RED. OBJS)</b> (EEG) [SCATTER, FDA]. <b>(NORM., AMP E FILTR.)</b> (EDA) [FDA [NORM]].
<b>Soleymani et al.</b> (Soleymani et al., 2013)	(EMOTIONS) [LABELING].	<b>Tec. amostragem:</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC].  <b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDATA] e (EEG) [-NOISE]. <b>(CONV. SINAL)</b> (EEG) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>(SEG. E GER. SINAL)</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] <DISTANCE> [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION]. <b>(OUTRAS)</b> {FEELTRACE}.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	(ECG(HRV), RESP, EDA, EMG) [SPREADSUBSAMPLE].	<b>(RED. DIM. E RED. OBJS)</b> (ECG(HRV), RESP, EDA, EMG) [X?]. <b>(OUTRAS)</b> {AUBT}.
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	(MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] <PERIODS <COUNT, STD <MEAN, MAX>>> [LABELING] e (APPS) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY]. <b>(RED. DIM. E RED. OBJS)</b> <MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL> [SFS, CORRELATION]. <b>(NORM., AMP E FILTR.)</b> (CALL, SMS, EMAIL) <COUNT> [NORM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM [NORM]] e (APPS) [LABELING] <COUNT, DURATION> [NORM]. <b>(SEG. E GER. SINAL)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<p><b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM], (APPS) &lt;DURATION&gt; [HISTOGRAM] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [HISTOGRAM].</p>
<p><b>Murad &amp; Malkawi</b> (Murad &amp; Malkawi, 2012)</p>	<p>(HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS [LABELING]].</p>	<p><b>(SEG. E GER. SINAL)</b> (EEG, HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS].</p>
<p><b>Hernandez et al.</b> (Hernandez et al., 2011)</p>	<p>(CALL) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(NORM., AMP E FILTR.)</b> (EDA, STRESS) [NORM] e &lt;EDA, STRESS&gt; [NORM]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>	<p>(EYES) [+ARTIFICIALDATA, LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EYES&gt; [ADABOOST]. <b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]]. <b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG]. <b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].</p>
<p><b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)</p>	<p>(RESP(RR)) &lt;AMP&gt; [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (RESP) [-PEAK]. <b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG&gt; e (EMOTIONS) [CORRELATION, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF].</p>
<p><b>Mandryk &amp; Atkins</b> (Mandryk &amp; Atkins, 2007)</p>	<p>(ECG(HR), EDA, EMG, EMOTIONS) [LABELING].</p>	<p><b>Tec. amostragem:</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED].</p> <p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA]. <b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].</p>
<p><b>J. A. Healey &amp; Picard</b> (J. A. Healey &amp; Picard, 2005) e (Rosalind W. Picard et al., 2001)</p>	<p>(STRESS) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EDA, EMG, RESP, ECG(HR, HRV)&gt; [SCATTER, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS]. <b>(OUTRAS)</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(EDA) [PEAKDETECT].
<b>Van Eck et al.</b> (van Eck et al., 2005)	(STRESS) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (HEALTH) [DISCARDATA] e (CORT) [-OUTLIERS]. <b>(RED. DIM. E RED. OBJS)</b> (LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH) [PCA [AGGREGATION]].
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	(PUPIL) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [DISCARDATA, -EYEBLINK]. <b>(OUTRAS)</b> (PUPIL) [PEAKDETECT, TTEST].
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)	(EMOTIONS) [LABELING].	
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)	(EMG) [LABELING].	<b>(CONV. SINAL)</b> (RESP) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PPG(BVP(HR)), ECG(HR, HRV), RESP, EDA) [SIGSMOOTH, NORM]. <b>(OUTRAS)</b> {MATLAB}.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	BP(SBP, DBP) [LABELING].	<b>Tec. amostragem:</b> (STRESS) [INTENTIONAL, STRATIFIED].  <b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS]. <b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	(EMG, EDA, PPG(BVP(HR)), RESP) [LABELING].	<b>(NORM., AMP E FILTR.)</b> (RESP) [NORM], <RESP> [NORM] e (EDA) [SIGSMOOTH, NORM].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

### 4.3.3. Análise

O desempenho dos algoritmos está relacionado com o número de objetos do *dataset* e o seu processamento pode ser penalizado por grandes volumes de informação (Zhao et al., 2016) (Gama et al., 2012). É neste contexto que as técnicas de amostragem e os critérios para definição da amostra (e.g. representatividade dos dados originais), assumem um papel importante na fase de pré-processamento (Zhao et al., 2016) (Investopedia, 2017). No entanto, a definição de subconjuntos de dados para utilização como *input* em algoritmos de classificação, deve também atender ao equilíbrio do número de objetos entre classes. A utilização de conjuntos desbalanceados pode originar problemas, já que alguns algoritmos tendem a classificar os novos dados na classe maioritária (Gama et al., 2012).

A utilização de amostras em representação do *dataset* completo é uma prática habitual em investigação. Das investigações em análise, não são muitas as que referem as técnicas de

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

amostragem utilizadas. No entanto, a maior parte dos investigadores que relatou a utilização de técnicas deste tipo, optou por considerar um objeto a cada intervalo de ocorrências de objetos (i.e. SYSTEMATIC). Como normalmente os *datasets* recolhidos no contexto da deteção emocional representam dados no tempo (i.e. *time-series*), a opção pelo SYSTEMATIC estará relacionada com a necessidade de garantir na amostra objetos provenientes de diferentes momentos de recolha de dados de contexto. Esta será também a justificação para a baixa utilização de técnicas como o RANDOM e INTENTIONAL, já que a sua utilização não asseguraria a representatividade temporal do *dataset* original da amostra.

Apesar de serem poucas as investigações que evidenciam a utilização de técnicas de balanceamento, acreditámos que a sua utilização será mais expressiva do que a que é relatada. Ainda assim, das investigações analisadas, destacámos a utilização do +ARTIFICIALDATA como forma de preencher lacunas no equilíbrio entre o número de objetos de diferentes classes, e a utilização residual de técnicas de *downsampling* na produção de subconjuntos aleatórios mas balanceados do *dataset* original (Algorithmia, 2017) (“Class SpreadSubsample,” n.d.) (Alzoubi et al., 2013).

De realçar também o grande número de autores que recorrem a técnicas de LABELING. A anotação do *dataset* original com metadados permite acrescentar informação útil ao conjunto de dados. Estes metadados, muitas vezes utilizados como *ground-truth*, são importantes na fase de aprendizagem dos algoritmos. O LABELING de emoções assume um papel importante no contexto das investigações relacionadas com a deteção emocional, porque é a forma geralmente utilizada pelos investigadores para adicionar informação emocional *ground-truth* aos *datasets* processados pelos algoritmos (i.e. informação intangível e de medição direta impossível (Kreibig, 2010)). O LABELING de informação emocional é utilizado transversalmente nos dados dos diversos contextos de recolha (cf. expressão facial, oral e postura corporal; contexto fisiológico; e contexto social).

INVESTIGAÇÃO	TEC. AMOSTRAGEM	BALANC. E ETIQ.	OUTRAS
Gogia et al. (Gogia et al., 2016)		(EEG) [[[-EYEBLINK, -DUPLICATE] [LABELING]] [+ARTIFICIALDATA]].	<b>(RUIDO, D. INC. E INC.)</b> (EEG) [-EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> (EEG) [-DUPLICATE].
Z. Zhang et al. (Z. Zhang et al., 2016)	(HEAD, FACS) [RANDOM].	(FACS) [LABELING].	<b>(RED. DIM. E RED. OBJS)</b> (HEAD, FACS) [PCA]. <b>(OUTRAS)</b> (FACS) [FINDREGION, SI-SSM]. {ZFACE}.
Sano & Eng (Sano & Eng, 2016)		(SLEEP, EDA) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]]. <b>(OUTRAS)</b> (ACC) [MOTIONDETECT].
Zenonos et al. (Zenonos et al., 2016)		(EMOTIONS) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (MOOD, EMOTIONS) [TOLERANCE].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			<p><b>(NORM., AMP E FILTR.)</b> (IBI) [NORM]. <b>(SEG. E GER. SINAL)</b> (IBI) [BANDS].</p>
<p><b>Aracena et al.</b> (Aracena et al., 2016)</p>	(PUPIL) [SYSTEMATIC].		<p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) [LPF, NORM].</p>
<p><b>Turan et al.</b> (Turan et al., 2015)</p>		(FACE, EYES) [LABELING].	<p><b>(RED. DIM. E RED. OBJS)</b> (FACE, EYES) [SLPP, DCC]. <b>(OUTRAS)</b> (EYES) [FINDREGION].</p>
<p><b>Jaques et al.</b> (Jaques et al., 2015)</p>		(HAPPY) [LABELING].	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [LPF [NORM [-PEAK]]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]]. <b>(RED. DIM. E RED. OBJS)</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH, ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEI, ALCOH DRUGS) [WFS, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]] e &lt;ACC&gt; [NORM]. <b>(SEG. E GER. SINAL)</b> (LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX].</p>
<p><b>Matiko et al.</b> (Matiko et al., 2014)</p>		(EDA) [LABELING].	<p><b>(RED. DIM. E RED. OBJS)</b> (EEG) [SCATTER, FDA]. <b>(NORM., AMP E FILTR.)</b> (EDA) [FDA [NORM]].</p>
<p><b>Soleymani et al.</b> (Soleymani et al., 2013)</p>	[HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC].	(EMOTIONS) [LABELING].	<p><b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDATA] e (EEG) [-NOISE]. <b>(CONV. SINAL)</b> (EEG) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>(SEG. E GER. SINAL)</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] &lt;DISTANCE&gt; [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION]. <b>(OUTRAS)</b> {FEELTRACE}.</p>
<p><b>Alzoubi et al.</b> (Alzoubi et al., 2013)</p>		(ECG(HRV), RESP, EDA, EMG) [SPREADSUBSAMPLE].	<p><b>(RED. DIM. E RED. OBJS)</b> (ECG(HRV), RESP, EDA, EMG) [X<sup>2</sup>]. <b>(OUTRAS)</b> {AUBT}.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Babiker et al.</b> (Babiker et al., 2013)</p>	<p>(PUPIL) [SYSTEMATIC].</p>		<p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], &lt;PUPIL&gt; [NORM] [[-NOISE, -OUTLIERS][FAKEDATA, DISCARDATA]]. <b>(NORM., AMP E FILTR.)</b> &lt;PUPIL&gt; [NORM]. <b>(SEG. E GER. SINAL)</b> (PUPIL) &lt;INTERVALSPLIT&gt;. <b>(OUTRAS)</b> (PUPIL) [FINDREGION].</p>
<p><b>LikamWa et al.</b> (LiKamWa et al., 2013)</p>		<p>(MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] &lt;PERIODS &lt;COUNT, STD &lt;MEAN, MAX&gt;&gt;&gt; [LABELING] e (APPS) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY]. <b>(RED. DIM. E RED. OBJS)</b> &lt;MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL&gt; [SFS, CORRELATION]. <b>(NORM., AMP E FILTR.)</b> (CALL, SMS, EMAIL) &lt;COUNT&gt; [NORM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM [NORM]] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [NORM]. <b>(SEG. E GER. SINAL)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]]. <b>(OUTRAS)</b> (CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM], (APPS) &lt;DURATION&gt; [HISTOGRAM] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [HISTOGRAM].</p>
<p><b>Murad &amp; Malkawi</b> (Murad &amp; Malkawi, 2012)</p>		<p>(HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS [LABELING]].</p>	<p><b>(SEG. E GER. SINAL)</b> (EEG, HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS].</p>
<p><b>C. Y. Chang et al.</b> (Chang et al., 2012)</p>	<p>(EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].</p>		<p><b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [[LFP, HPF] [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (ECG, PR, BVP, EDA) [LFP, HPF, NORM]. <b>(SEG. E GER. SINAL)</b> (ECG, PR, BVP, EDA) [R-R]. <b>(OUTRAS)</b> (ECG, BVP, PR) [PEAKDETECT].</p>
<p><b>Hernandez et al.</b> (Hernandez et al., 2011)</p>		<p>(CALL) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(NORM., AMP E FILTR.)</b> (EDA, STRESS) [NORM] e &lt;EDA, STRESS&gt; [NORM]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>		<p>(EYES) [+ARTIFICIALDATA, LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EYES&gt; [ADABOOST]. <b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]]]. <b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG]. <b>(OUTRAS)</b> (EYES) [FINDREGION, CROP, COLORCORR].</p>
<p><b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)</p>		<p>(RESP(RR)) &lt;AMP&gt; [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (RESP) [-PEAK]. <b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG&gt; e (EMOTIONS) [CORRELATION, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF].</p>
<p><b>Mandryk &amp; Atkins</b> (Mandryk &amp; Atkins, 2007)</p>	<p>(ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED].</p>	<p>(ECG(HR), EDA, EMG, EMOTIONS) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA]. <b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION]. <b>(OUTRAS)</b> (ECG(HR), EDA, EMG) [HISTOGRAM].</p>
<p><b>J. A. Healey &amp; Picard</b> (J. A. Healey &amp; Picard, 2005) e (Rosalind W. Picard et al., 2001)</p>		<p>(STRESS) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDATA] e (STRESS) [RELIABILITY]. <b>(RED. DIM. E RED. OBJS)</b> &lt;EDA, EMG, RESP, ECG(HR, HRV)&gt; [SCATTER, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS]. <b>(OUTRAS)</b> (EDA) [PEAKDETECT].</p>
<p><b>Van Eck et al.</b> (van Eck et al., 2005)</p>		<p>(STRESS) [LABELING].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (HEALTH) [DISCARDATA] e (CORT) [-OUTLIERS]. <b>(RED. DIM. E RED. OBJS)</b></p>

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			(LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH) [PCA [AGGREGATION]].
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(ECG(HRV), EDA) [DECIMATION].		<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]]. <b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT]. <b>(OUTRAS)</b> (ECG(HR, HRV)) [PEAKDETECT].
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)		(PUPIL) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [DISCARDATA, -EYEBLINK]. <b>(OUTRAS)</b> (PUPIL) [PEAKDETECT, TTEST].
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)		(EMOTIONS) [LABELING].	
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)		(EMG) [LABELING].	<b>(CONV. SINAL)</b> (RESP) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PPG(BVP(HR)), ECG(HR, HRV), RESP, EDA) [SIGSMOOTH, NORM]. <b>(OUTRAS)</b> {MATLAB}.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	(STRESS) [INTENTIONAL, STRATIFIED].	BP(SBP, DBP) [LABELING].	<b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS]. <b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]]. <b>(OUTRAS)</b> [AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)		(EMG, EDA, PPG(BVP(HR)), RESP) [LABELING].	<b>(NORM., AMP E FILTR.)</b> (RESP) [NORM], <RESP> [NORM] e (EDA) [SIGSMOOTH, NORM].
<b>Rajita Sinha</b> (Rajita Sinha, 1996)		(EMG, ST) [SYSTEMATIC].	<b>(RUIDO, D. INC. E INC.)</b> (BP(DBP)) [DISCARDATA] e (EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EMG) [MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

## 4.4. OUTRAS TÉCNICAS E INSTRUMENTOS

Esta secção contempla as técnicas de apoio à aplicação de outras técnicas de pré-processamento. Como não foram consideradas nas secções anteriores são agora apresentadas. Incluem-se também nesta secção as técnicas utilizadas na representação de dados e os instrumentos usados na fase de pré-processamento.

Ao nível do tratamento de VIDEO, AUDIO e PICTURES, identificaram-se as seguintes técnicas de suporte ao pré-processamento: deteção de regiões ou bordas em imagens [**FINDREGION**] (e.g. Mokhayeri et al. utilizaram o *Genetic Algorithm* (GA), *Fuzzy Image Processing* (FIP) para deteção do olho e da sua borda (Mokhayeri & Toosizadeh, 2011); Eckert et al. utilizaram o algoritmo *Viola-Jones* (Viola & Jones, 2004) para detetar face e olhos (Eckert et al., 2016); Zhang et al. utilizaram o *Constrained Local Model* (CLM) para detetar pontos de referência da face (Cristinacce & Cootes, 2008) (Z. Zhang et al., 2016); etc.); deteção do piscar de olhos [**BLINKDETECT**] em VIDEO (Mokhayeri & Toosizadeh, 2011); *clustering* [**CLUSTERING**] para identificar zonas de imagem (e.g. Lee et al. utilizaram o reconhecimento e análise de *clusters* da face em sequências de vídeo (S. H. Lee et al., 2016); Dhall et al. utilizaram o algoritmo *k-means* (Duda et al., 2001) para fazer CLUSTERING em imagens (Dhall et al., 2011)); *crop* [**CROP**] para recortar imagens (e.g. Lee et al. utilizou CROP para recortar faces de imagens (S. H. Lee et al., 2016); operações morfológicas [**MORPHOPS**] (e.g. Eckert et al. utilizaram MORPHOPS em imagens BINARY para reconhecer EYES, EYEBROWS e MOUTH (Eckert et al., 2016)); Zhang et al. utilizou o *Index-based Shape Index-based Statistical shape model* [**SI-SSM**] para rastrear propriedades diretamente de faces em 3D (Z. Zhang et al., 2016); deteção de movimento [**MOTIONDETECT**] (e.g. Eckert et al. detetaram movimento na face analisando as alterações entre imagens (Eckert et al., 2016); e Sano & Eng. utilizaram MOTIONDETECT a partir do ACC para determinar as ADL (Sano & Eng, 2016)); Raudonis criou um algoritmo para rastreamento do GAZE que considerasse a influência da variação da luminosidade na PUPIL [**RAUDONIS2**] (Raudonis, 2013); e Kawai et al. utilizaram uma técnica própria para atenuar os efeitos do brilho específico de cada imagem apresentada aos participantes na sua experiência [**KAWAI1**] (Kawai et al., 2013).

Identificaram-se ainda outras técnicas específicas ao contexto de recolha: Zhao et al. recorreram à deteção de picos no sinal RESP [**PEAKDETECT**] para identificar cada ciclo de respiração (Zhao et al., 2016); e Lane et al. criaram um algoritmo para estimar a duração do sono com base na frequência e momentos de recarga da bateria do *smartphone* (e.g. ausência de movimento, silêncio do ambiente envolvente, etc.) [**LANE1**] (N. Lane et al., 2011).

Alguns autores utilizaram também técnicas de representação de dados para facilitar os processos de classificação: Lee et al. utilizaram *Sparse Representation* [**SPARSEREP**] como suporte à classificação emocional com base em imagens da face (S. H. Lee et al., 2016) (o SPARSEREP permite representar os dados de forma mais compacta (Wen, Jia, Lian, Zhou, & Lu, 2016), e combina técnicas de *machine learning* com *compressed sensing* (L. Zhang et al., 2012)) (Rigamonti, Brown, & Lepetit, 2011) (Wright, Yang, Ganesh, Sastry, & Ma, 2009); LikamWa et al. utilizaram histogramas [**HISTOGRAM**] para avaliar a distribuição de dados de CALL, SMS e EMAIL (LiKamWa et al., 2013); Yang et al. criaram um algoritmo para representar de forma generalizada faces humanas em avatares [**YANG1**] (S. Yang & Bhanu, 2011); Wang et al. utilizaram o *Color Correlogram* [**COLORCORR**] para representar cada olho em vez das informações do contorno e

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

circulos (J. Huang, Kumar, Mitra, Zhu, & Zabih, 1997a) (J. Huang, Kumar, Mitra, Zhu, & Zabih, 1997b) (H. Wang et al., 2010); Partala et al. utilizaram t-tests [**TTEST**] para analisar as diferenças de níveis de *valence* sentido pelos participantes (T. K. Kim, 2015) (Ugoni & Walker, 1995) (Partala et al., 2005); e a análise de VAR [**ANOVA**] que permite encontrar diferenças entre grupos ou experiências (Sthle & Wold, 1989) (Howard, 2012) (Martin, 1000).

No pré-processamento também foram utilizados **instrumentos**: Lee et al. utilizaram o MATLAB e a função *Hierarchical Agglomerative Clustering* para extrair a transição de expressões parciais da face (S. H. Lee et al., 2016) [**HAC**]; Zhang et al. utilizaram o zface [**ZFACE**] para rastrear expressões faciais em 2D (Z. Zhang et al., 2016); Alzoubi et al. utilizaram também o *MATLAB-based Augsburg Biosignal Toolbox* [**AUBT**] na fase de pré-processamento e extração de propriedades a partir do *raw data* (Wagner, 2006) (Alzoubi et al., 2013); o KUBIOS HRV [**KHRV**] é um *software* para análise do HRV da *Kubios* (empresa que desenvolve tecnologia médica para análise de sinais fisiológicos (Tarvainen, Niskanen, Lipponen, Ranta-aho, & Karjalainen, 2014)), apropriado para investigação relacionada com a saúde e utilizado em várias investigações do bem-estar humano e animal (Ditor et al., 2005) (por e.g. Basu et al. analisaram o HRV do *log* de dados recolhidos (Basu et al., 2016)); o *Feeltrace* [**FEELTRACE**] permite rastrear e provocar emoções em simultâneo (Cowie et al., 2000) (e.g. Soleymani et al. utilizaram o FEELTRACE para anotar o *valence* continuamente nos videos gravados na sua experiência (Soleymani et al., 2013)); o EEGLab [**EEGLAB**] é uma ferramenta que permite trabalhar o sinal EEG (e.g. Bos utilizou o BPF do EEGLab na segmentação do sinal em BANDS (Bos, 2010)); o *General Linear Models* [**GLM**] é uma ferramenta do SPSS utilizada para analisar a relação entre variáveis (IBM Statistics, n.d.); e o *EyesWeb* [**EYESWEB**] de Camurri et al., é um *software* de arquitetura aberta e utilização livre utilizado na monitorização em tempo real de movimento corporal com base em câmeras de vídeo e outros sensores, análise de ocupação em espaços 2D para extração de movimentos de baixo nível (e.g. análise gestual), e análise de trajetórias em espaços 2D (Camurri, Mazarino, & Volpe, 2004)) (por exemplo, Castellano et al. utilizaram o EYESWEB para extrair dados acerca silhueta e das mãos, e outras variáveis relacionadas com o movimento (e.g. ACC) (Castellano et al., 2007)).

Além destes instrumentos foram utilizados utilitários ou bibliotecas não identificadas em detalhe mas pertencentes a plataformas de análise e tratamento de dados: o MATLAB [**MATLAB**] (The Mathworks Inc., 2016); o Origin [**ORIGIN**] é um software gráfico para análise de dados bastante usado tanto na investigação como nas atividades profissionais (OriginLab Corporation, n.d.) (e.g. Basu et al. utilizou o ORIGIN (Basu et al., 2016)); o *Waikato Environment for Knowledge Analysis* [**WEKA**] é uma ferramenta que pode ser utilizada diretamente ou através da sua API, é composta por um conjunto de algoritmos de *machine learning* (ML) utilizados em tarefas de *data mining*, e contém ferramentas para pré-processamento, classificação, regressão, *clustering*, associação e visualização de dados (Machine Learning Group at the University of Waikato, n.d.) (são vários os investigadores que utilizam as ferramentas do WEKA: Basu et al. (Basu et al., 2016); Kumar et al. (Kumar & Chadha, 2011); Mower et al. (Mower, Matari, & Narayanan, 2011); Miluzzo et al. (Miluzzo et al., 2008); Papamatthaiakis et al. (Papamatthaiakis, Polyzos, & Xylomenos, 2010); Chen et al (Z. Chen et al., 2013); Lichtenstein et al. (Lichtenstein, Antje; Oehme, 2008); Alzoubi et al utilizou o WEKA para classificação de dados (Alzoubi et al., 2013); etc.).

INVESTIGAÇÃO	PRÉ-PROCESSAMENTO	
	OUTROS	ANTERIORES

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	(FACS, EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH) [CLUSTERING, SPARSEREPE] e (EYEBROWS, EYELIDS) [FINDREGION, CROP]. {HAC}.	<b>(RUIDO, D. INC. E INC.)</b> (FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)) [FAKEDATA]. <b>(NORM., AMP E FILTR.)</b> (EYEBROWS, EYELIDS) [NORM].
<b>Eckert et al.</b> (Eckert et al., 2016)	(EYES, EYEBROWS, NOSE, MOUTH) [FINDREGION, [GREYSCALE [BINARY [MORPHOPS]]]] e (FACS, CAU) [MOTIONDETECT].	<b>(CONV. SINAL)</b> (EYES, EYEBROWS, NOSE, MOUTH) [GREYSCALE [BINARY]]. <b>(NORM., AMP E FILTR.)</b> (EYES, EYEBROWS, NOSE, MOUTH) [IMGCONTRAST].
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	(FACS) [FINDREGION, SI-SSM]. {ZFACE}.	<b>(RED. DIM. E RED. OBJS)</b> (HEAD, FACS) [PCA]. <b>(TEC. AMOSTRAGEM)</b> (HEAD, FACS) [RANDOM]. <b>(BALANC. E ETIQ.)</b> (FACS) [LABELING].
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	(ACC) [MOTIONDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]]. <b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING].
<b>Zhao et al.</b> (Zhao et al., 2016)	(RESP) [LPF [PEAKDETECT]].	<b>(RUIDO, D. INC. E INC.)</b> (RESP, HR) [-NOISE]. <b>(NORM., AMP E FILTR.)</b> (RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF]. <b>(SEG. E GER. SINAL)</b> (RESP, HR) [D2Y/DX2, ZHAO2].
<b>Basu et al.</b> (Basu et al., 2016)	{KHRV, WEKA, LABCHART, MATLAB, ORIGIN}.	<b>(RED. DIM. E RED. OBJS)</b> (ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM [MANSELECT]]. <b>(NORM., AMP E FILTR.)</b> (ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM].
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	(GAZE) [FINDREGION].	<b>(NORM., AMP E FILTR.)</b> (FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)) [NORM].
<b>Turan et al.</b> (Turan et al., 2015)	(EYES) [FINDREGION].	<b>(RED. DIM. E RED. OBJS)</b> (FACE, EYES) [SLPP, DCC]. <b>(BALANC. E ETIQ.)</b> (FACE, EYES) [LABELING].
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)	(ECG) [PEAKDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (ECG, ICG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI]. <b>(NORM., AMP E FILTR.)</b> (ECG, EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (ECG, ICG) [SIGSPPLIT].
<b>Agrawal et al.</b> (Agrawal et al., 2013)	(SKIN, EYES, MOUTH) [FINDREGION]. {MATLAB}.	<b>(CONV. SINAL)</b> (EYES, MOUTH, LIPS, SKIN) [VIDEO-PICS].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Soleymani et al.</b> (Soleymani et al., 2013)</p>	<p>{FEELTRACE}.</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDATA] e (EEG) [-NOISE]. <b>(CONV. SINAL)</b> (EEG) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>(SEG. E GER. SINAL)</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] &lt;DISTANCE&gt; [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION]. <b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].</p>
<p><b>Alzoubi et al.</b> (Alzoubi et al., 2013)</p>	<p>{AUBT}.</p>	<p><b>(RED. DIM. E RED. OBJS)</b> (ECG(HRV), RESP, EDA, EMG) [X<sup>2</sup>]. <b>(BALANC. E ETIQ.)</b> (ECG(HRV), RESP, EDA, EMG) [SPREADSUBSAMPLE].</p>
<p><b>Sano &amp; Picard</b> (Sano &amp; Picard, 2013b)</p>	<p>(EDA) [[LPF [DY/DX [PEAKDETECT]]]].</p>	<p><b>(RED. DIM. E RED. OBJS)</b> &lt;EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS&gt; [CORRELATION, PCA, SFFS]. <b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [DY/DX]] e (ACC) [ADL].</p>
<p><b>Raudonis</b> (Raudonis, 2013)</p>	<p>(PUPIL) [FINDREGION, RAUDONIS2].</p>	<p><b>(CONV. SINAL)</b> (PUPIL) [GREYSCALE].</p>
<p><b>Kawai et al.</b> (Kawai et al., 2013)</p>	<p>(PUPIL) [FINDREGION, CLUSTERING, KAWAI1].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) &lt;DIAMETER&gt; [MANADJUST, -NOISE, MITIGATION]. <b>(CONV. SINAL)</b> (PUPIL) [BINARY]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) &lt;DIAMETER&gt; [KAWAI2 [NORM]].</p>
<p><b>Babiker et al.</b> (Babiker et al., 2013)</p>	<p>(PUPIL) [FINDREGION].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], &lt;PUPIL&gt; [NORM [[-NOISE, -OUTLIERS][FAKEDATA, DISCARDATA]]]. <b>(NORM., AMP E FILTR.)</b> &lt;PUPIL&gt; [NORM]. <b>(SEG. E GER. SINAL)</b> (PUPIL) &lt;INTERVALSPLIT&gt;. <b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].</p>
<p><b>LikamWa et al.</b> (LiKamWa et al., 2013)</p>	<p>(CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM], (APPS) &lt;DURATION&gt; [HISTOGRAM] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [HISTOGRAM].</p>	<p><b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY]. <b>(RED. DIM. E RED. OBJS)</b> &lt;MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL&gt; [SFS, CORRELATION]. <b>(NORM., AMP E FILTR.)</b> (CALL, SMS, EMAIL) &lt;COUNT&gt; [NORM], (APPS, BROWSER, LOCAL) &lt;USUAL&gt; [HISTOGRAM [NORM]] e (APPS) [LABELING] &lt;COUNT, DURATION&gt; [NORM]. <b>(SEG. E GER. SINAL)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] <PERIODS <COUNT, STD <MEAN, MAX>>> [LABELING] e (APPS) [LABELING].
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	(ECG, BVP, PR) [PEAKDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [[LPF, HPF] [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (ECG, PR, BVP, EDA) [LPF, HPF, NORM]. <b>(SEG. E GER. SINAL)</b> (ECG, PR, BVP, EDA) [R-R]. <b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	(HEAD, FACE) [FINDREGION, YANG1].	<b>(CONV. SINAL)</b> (HEAD, FACE) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (HEAD, FACE) [VIDEO-PICS [IMGALIGN]].
<b>Dhall et al.</b> (Dhall et al., 2011)	(FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].	<b>(RED. DIM. E RED. OBJS)</b> (FACE) [VIDEO-PICS [-FRAMES [PCA]]. <b>(CONV. SINAL)</b> (FACE) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (FACE) [VIDEO-PICS [NORM]].
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	(PUPIL) [FINDREGION, BLINKDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [-NOISE, -EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HRV), PPG, PUPIL> [GA]. <b>(CONV. SINAL)</b> (PUPIL) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) [IMGSIZE, IMGINTENSITY]. <b>(SEG. E GER. SINAL)</b> (ECG(HRV)) [BANDS].
<b>Hernandez et al.</b> (Hernandez et al., 2011)	(EDA) [PEAKDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(NORM., AMP E FILTR.)</b> (EDA, STRESS) [NORM] e <EDA, STRESS> [NORM]. <b>(BALANC. E ETIQ.)</b> (CALL) [LABELING].
<b>N. Lane et al.</b> (N. Lane et al., 2011)	(SLEEP) [LANE1] e (SLEEP, PHYSI) [MANADJUST].	<b>(RUIDO, D. INC. E INC.)</b> (SLEEP, PHYSI) [MANINSERT]. <b>(SEG. E GER. SINAL)</b> (ACC) [ADL].
<b>H. Wang et al.</b> (H. Wang et al., 2010)	(EYES) [FINDREGION, CROP, COLORCORR].	<b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [- NOISE]]]]]. <b>(RED. DIM. E RED. OBJS)</b> <EYES> [ADABOOST]. <b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]]. <b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG]. <b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING].
<b>Bos</b> (Bos, 2010)	{EEGLAB}.	<b>(RUIDO, D. INC. E INC.)</b> (EEG) [-NOISE].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<p><b>(RED. DIM. E RED. OBJS)</b> &lt;EEG&gt; [PCA].</p> <p><b>(CONV. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER]]].</p> <p><b>(NORM., AMP E FILTR.)</b> (EEG) [-NOISE [BPF].</p> <p><b>(SEG. E GER. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]].</p>
<p><b>Setz et al.</b> (Setz et al., 2010)</p>	(EDA) [PEAKDETECT].	<p><b>(RUIDO, D. INC. E INC.)</b> (EDA) [DISCARDATA, MANADJUST [-NOISE]].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;EDA&gt; [WFA].</p> <p><b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, LPF [HPF [LPF]]].</p>
<p><b>J. Kim &amp; André</b> (J. Kim &amp; André, 2008)</p>	(ECG(HR, HRV)) [PEAKDETECT].	<p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE].</p> <p><b>(RED. DIM. E RED. OBJS)</b> &lt;ECG(HR, HRV), RESP(RR, BRV), EDA, EMG&gt; [SBS].</p> <p><b>(CONV. SINAL)</b> (ECG(HR, HRV)) [FOURIER].</p> <p><b>(NORM., AMP E FILTR.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM].</p> <p><b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]].</p>
<p><b>Gunes &amp; Piccardi</b> (Gunes &amp; Piccardi, 2007)</p>	(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.	<p><b>(RED. DIM. E RED. OBJS)</b> (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST].</p> <p><b>CONV. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY].</p> <p><b>(NORM., AMP E FILTR.)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST].</p> <p><b>(SEG. E GER. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].</p>
<p><b>Castellano et al.</b> (Castellano et al., 2007)</p>	{EYESWEB}.	<p><b>(RED. DIM. E RED. OBJS)</b> (ARMS) [DISCARDATA].</p> <p><b>(NORM., AMP E FILTR.)</b> (ARMS) &lt;MOTION &lt;MAX, MIN&gt;&gt; [NORM].</p> <p><b>(SEG. E GER. SINAL)</b> (ARMS) [-IMGBKG].</p>
<p><b>Mandryk &amp; Atkins</b> (Mandryk &amp; Atkins, 2007)</p>	(ECG(HR), EDA, EMG) [HISTOGRAM].	<p><b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA].</p> <p><b>(NORM., AMP E FILTR.)</b></p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED]. <b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING].
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	(EDA) [PEAKDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDDATA] e (STRESS) [RELIABILITY]. <b>(RED. DIM. E RED. OBJS)</b> <EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT]. <b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS]. <b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].
<b>Partala et al.</b> (Partala et al., 2005)	(EMG) [TTEST].	<b>(RUIDO, D. INC. E INC.)</b> (EMG) [-EYEBLINK]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP [HPF, LPF]]. <b>(SEG. E GER. SINAL)</b> (EMG) e (EMOTIONS) [LABELING].
<b>Busso et al.</b> (Busso et al., 2004)	(FOREHEAD, EYEBROWS, EYES, CHEEKS) [FINDREGION, CLUSTERING].	<b>(RED. DIM. E RED. OBJS)</b> <PITCH, VOLUME> [SBS], <FOREHEAD, EYEBROWS, EYES, CHEEKS> [PCA] e <PITCH, VOLUME, FOREHEAD, EYEBROWS, EYES, CHEEKS> [SBS [AGGREGATION], MANSELECT].
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(ECG(HR, HRV)) [PEAKDETECT].	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [-OUTLIERS]]. <b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT]. <b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION].
<b>Haag et al.</b> (Haag et al., 2004)	(PPG(BVP(HR))) [HISTOGRAM].	<b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [LPF [HPF]], (ECG(HR)) [[DY/DX, D2Y/DX2] [SIGSMOOTH]], (EDA) [NORM [LPF]], (EMG) [SIGSMOOTH] e <PPG(BVP(HR)), ECG, RESP, EDA, ST, EMG> [NORM]. <b>(SEG. E GER. SINAL)</b> (ECG(HR)) [DY/DX, D2Y/DX2] e (PPG(BVP(HR)), RESP) [INTERVALSPLIT].
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	(PUPIL) [PEAKDETECT, TTEST].	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [DISCARDDATA, -EYEBLINK]. <b>(BALANC. E ETIQ.)</b> (PUPIL) [LABELING].

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)	{MATLAB}.	<b>(CONV. SINAL)</b> (RESP) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PPG(BVP(HR)), ECG(HR, HRV), RESP, EDA) [SIGSMOOTH, NORM]. <b>(BALANC. E ETIQ.)</b> (EMG) [LABELING].
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	[AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.	<b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS]. <b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]]. <b>(TEC. AMOSTRAGEM)</b> (STRESS) [INTENTIONAL, STRATIFIED]. <b>(BALANC. E ETIQ.)</b> BP(SBP, DBP) [LABELING].
<b>Ritz et al.</b> (Ritz et al., 2000)	(HR, BP(SBP, DBP), ROS, RR, VT, EDA, EMOTIONS) [ANOVA].	<b>(RED. DIM. E RED. OBJS)</b> (BP(SBP)) [CORRELATION]. <b>(SEG. E GER. SINAL)</b> (BP(SBP)) [INTERVALSPLIT].

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

## 4.5. ANÁLISE

Nesta secção são resumidas as técnicas de pré-processamento identificadas na literatura em revisão.

A limpeza e preparação dos dados é um tópico crucial da investigação em várias áreas das ciências da computação, e pode representar uma grande parte do peso do processamento dos sistemas (S. Zhang et al., 2010). A existência de problemas nos dados pode conduzir: i) à ocultação de padrões úteis e interessantes dos dados; ii) ao baixo desempenho dos algoritmos; e iii) a resultados ineficientes (i.e. com baixa qualidade) (S. Zhang et al., 2010). Um dos requisitos mais importantes dos sistemas onde são utilizados algoritmos de aprendizagem automática é a capacidade de lidar com *datasets* imperfeitos (Gama et al., 2012). O pré-processamento é importante porque acrescenta qualidade aos dados RAW, preparando-os para a fase de processamento seguinte (S. Zhang et al., 2010). A ordem de aplicação das técnicas não é pré-estabelecida, podendo o *input* de uma técnica ser o *output* de outra previamente aplicada no mesmo sistema sobre os mesmos dados (Gama et al., 2012).

As técnicas de pré-processamento tem por objetivo mitigar os fatores que podem condicionar o desempenho dos algoritmos (e.g. remoção de ruído e imperfeições nos dados; conversão, normalização e segmentação de dados; etc.) (Gama et al., 2012). Na literatura em revisão, as técnicas mais utilizadas pelos investigadores são as relacionadas com a normalização, filtragem e segmentação de dados, evidenciando a preocupação dos investigadores com a qualidade dos dados a serem sujeitos ao processamento algorítmico. No entanto, os investigadores também utilizam muito técnicas relacionadas com a redução dimensional do *dataset* e com o tratamento inicial dos dados (i.e. remoção de ruído, tratamento de dados incompletos ou inconsistentes).

De salientar a necessidade do tratamento de dados com origem no contexto fisiológico. Conseguir um *dataset* de dados fisiológicos de boa qualidade é vital para o desenvolvimento de um bom sistema de reconhecimento emocional (K. H. Kim et al., 2004). Os dados RAW fisiológicos estão sempre contaminados com ruído (Jerritta et al., 2011). Por exemplo, os sinais

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

ECG e EMG recolhido na face, têm necessidade de serem pré-processados com vários tipos de filtro (e.g. LPF), e o EDA é normalmente pré-processado com SIGSMOOTH (Rigas, 2007) (Chang, Zheng, & Wang, 2010) (Jerritta et al., 2011).

Apesar de serem muitos os investigadores que utilizam técnicas para tratamento inicial dos dados, são poucos os que relatam a aplicação de técnicas de pré-processamento em dados provenientes do contexto social. A importância destes dados para um sistema de reconhecimento emocional faz com que seja necessário ter em conta possíveis problemas existentes nos dados: receção de SMS e EMAIL irrelevantes do ponto de vista emocional (i.e. ruído) (e.g. publicidade); CALL efetuadas ou recebidas por engano; preenchimento de dados incompletos (e.g. papel desempenhado pelas visitas ou interlocutores de SMS, CALL ou EMAIL, na rede social (e.g. filhos, pais, colegas de trabalho, vizinhos, etc.)); etc.

A utilização de técnicas como a TOLERANCE, MANADJUST e MANINSERT podem levantar questões de validade dos resultados obtidos. No entanto, acredita-se ser difícil investigar um tema tão subjetivo e intangível como as emoções das pessoas sem considerar a existência de uma margem para o erro humano. Contudo, será importante a utilização de técnicas de controlo (e.g. RELIABILITY, CONSISTENCY, etc.) com o objetivo de assegurar o menor impacto possível no *dataset* e, conseqüentemente, nos resultados dos algoritmos.

A escolha das melhores propriedades a considerar de um *dataset* é fundamental para criar um classificador compacto, eficiente e preciso (Gilad-bachrach, 2004) (Hoque, Ahmed, Bhattacharyya, & Kalita, 2016). Quando se consegue isolar um conjunto pequeno e significativo de propriedades até os classificadores mais básicos conseguem bons níveis de desempenho (Gilad-bachrach, 2004). Nesta revisão bibliográfica, são muitos os investigadores que utilizam técnicas automáticas para a redução dimensional. No entanto, não são tantos os que comparam os resultados obtidos entre várias técnicas. Acreditamos que um estudo comparativo de eficiência entre vários algoritmos de *feature selection*, testando até outros métodos com provas dadas e não presentes nesta revisão (e.g. Simba (Gilad-bachrach, 2004) (Rigas, 2007), *Fuzzy Mutual Information-based Feature Selection Method for Classification* (FMIFS-ND)) (Hoque et al., 2016), etc.) poderia ser importante para aumentar a precisão de um sistema de deteção emocional. É crucial que, na fase de aprendizagem, se encontre o melhor e mais pequeno subconjunto de propriedades, capaz de predizer as *target labels* dos classificadores com o melhor desempenho (Gilad-bachrach, 2004).

A crescente complexidade dos sistemas resulta da diversificação dos dispositivos de recolha (Caballe, 2015) e das origens dos dados (cf. sensores, instrumentos e EXISTINGDATA). A INTEGRATION necessária dos dados provenientes de diferentes fontes, aumenta a necessidade de manutenção do *dataset* e do sinal (e.g. mais ruído e dados incompletos ou inconsistentes, maior dimensionalidade, novas redundâncias, normalização, etc.). No entanto, a existência de mais dados pode também enriquecer o conteúdo do *dataset* (e.g. pode tornar possível expor padrões de dados até então desconhecidos, pode permitir a geração de novo sinal que seria impossível de obter sem a integração de novos dados). Neste contexto, consideramos importante efetuar um estudo exploratório dos dados a normalizar e a segmentar, com o objetivo de tentar descobrir o conhecimento escondido por detrás dos dados e que pode ser extraído através da utilização de técnicas de segmentação.

A técnica de amostragem mais utilizada na literatura em revisão será o SYSTEMATIC. A relação natural com os *datasets* do tipo *time-series* torna este método num dos mais adequados a utilizar num sistema que se baseia na recolha de dados de contexto orientada ao tempo. Apesar

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

de parecer lógica a utilização desta técnica de amostragem, não excluímos a hipótese de a conjugar com a STRATIFIED. A seleção estratificada de objetos poderá ser apropriada considerando a possibilidade de existência de várias dimensões ou contextos de recolha: na presença de diferentes elementos da rede social (e.g. pais, filhos, colegas de trabalho, vizinhos, etc.); em determinado ambiente, local ou contexto (e.g. no escritório a trabalhar, em casa a descansar, na lida doméstica, no almoço com amigos, num jantar no restaurante, em oração na igreja, etc.); etc. Apesar de não utilizada nas investigações desta revisão, poderá ser interessante testar a amostragem progressiva em que o valor de  $n$  vai aumentando enquanto a taxa de acerto dos algoritmos continue também a aumentar (Gama et al., 2012) (IPLeiria, 2009) (Pocinho, 2009). A amostragem accidental, também não presente nas investigações em análise, é uma técnica não probabilística em que os objetos vão sendo selecionados à medida que vão surgindo. Apenas consideramos a hipótese de utilizar esta técnica nos testes iniciais de sistema para validação de bom funcionamento.

O balanceamento de dados é um tópico importante de investigação e pode pôr em causa o resultado dos algoritmos (Lemnaru & Potolea, 2018). Um *dataset* está desbalanceado quando os dados se agrupam mais numa determinada classe (Chawla, Bowyer, Hall, & Kegelmeyer, 2002). Apesar de a preocupação com este tópico não ser sempre clara nas investigações em revisão, atribuímos-lhe uma importância significativa por causa do impacto que pode ter na precisão dos resultados obtidos pelos classificadores. Como forma de atenuar o problema do balanceamento se existir, considerámos redefinir o tamanho do *dataset*, seja pela via da eliminação de objetos da classe maioritária ou pelo aumento natural ou sintético de objetos nas minoritárias (i.e. recolha de mais dados de contexto, ou através de técnicas como o +ARTIFICIALDATA) (Gama et al., 2012). É nossa convicção que a solução de aumentar o número de objetos pela via natural é uma técnica amplamente utilizada pelos investigadores e, apenas não é documentada, por causa do cariz natural e óbvio da solução. Outras soluções poderão ser estudadas para resolver o problema do balanceamento: atribuição de custos de classificação a cada classe definindo pesos para cada uma; e induzir um modelo individual de classificação para cada classe individualmente (e.g. a classe maioritária e minoritária são aprendidas separadamente) (Gama et al., 2012).

O LABELING é fortemente utilizado pelos investigadores nesta revisão bibliográfica, nomeadamente para acrescentar informação emocional *ground-truth* aos *datasets*. No entanto, apesar de ser a técnica mais utilizada para este efeito, considerámos a hipótese de a substituir recorrendo à integração com outros sistemas que já reconhecem emoções com taxas de acerto interessantes (e.g. *Microsoft Cognitive Services* (Microsoft, 2017b), *Affectiva Emotion as a Service* (Affectiva Inc., 2017), etc.). Contudo, poderemos vir a utilizar o LABELING para etiquetar dados nos casos em que seja difícil ou até impossível a sua recolha do contexto (e.g. categorização da afinidade de uma visita ou interlocutor de uma conversa (i.e. proximidade na rede social), grau de alcoolémia de uma bebida ingerida, etc.).

INVESTIGAÇÃO	MANUTENÇÃO DO DATASET	MANUTENÇÃO DE SINAL	AMOSTRAGEM E META-INFORMAÇÃO	OUTRAS TÉCNICAS
Perdiz et al. (Perdiz et al., 2017) e (Phinyomark et al., 2012)	(RED. DIM. E RED. OBJS) (EMG) [SCATTER, LDA [AGGREGATION]].	(NORM., AMP E FILTR.) (EMG) [BPF, SIGAMP, NORM].		
S. H. Lee et al.	(RUIDO, D. INC. E INC.)	(NORM., AMP E FILTR.)		(FACS, EYEBROWS,

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(S. H. Lee et al., 2016)	(FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)) [FAKEDATA].	(EYEBROWS, EYELIDS) [NORM].		EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH) [CLUSTERING, SPARSEREP] e (EYEBROWS, EYELIDS) [FINDREGION, CROP]. {HAC}.
Eckert et al. (Eckert et al., 2016)		<b>(CONV. SINAL)</b> (EYES, EYEBROWS, NOSE, MOUTH) [GREYSCALE [BINARY]]. <b>(NORM., AMP E FILTR.)</b> (EYES, EYEBROWS, NOSE, MOUTH) [IMGCONTRAST].		(EYES, EYEBROWS, NOSE, MOUTH) [FINDREGION, [GREYSCALE [BINARY [MORPHOPS]]] e (FACS, CAU) [MOTIONDETECT].
Matlovic et al. (Matlovic et al., 2016)		<b>(SEG. E GER. SINAL)</b> (EEG) [DWT].		
Gogia et al. (Gogia et al., 2016)	<b>(RUIDO, D. INC. E INC.)</b> (EEG) [-EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> (EEG) [-DUPLICATE].		<b>(BALANC. E ETIQ.)</b> (EEG) [[[-EYEBLINK, -DUPLICATE] [LABELING]] [+ARTIFICIALDATA]].	
Z. Zhang et al. (Z. Zhang et al., 2016)	<b>(RED. DIM. E RED. OBJS)</b> (HEAD, FACS) [PCA].		<b>(TEC. AMOSTRAGEM)</b> (HEAD, FACS) [RANDOM]. <b>(BALANC. E ETIQ.)</b> (FACS) [LABELING].	(FACS) [FINDREGION, SI-SSM]. {ZFACE}.
Sano & Eng (Sano & Eng, 2016)	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EDA) [LPF [DY/DX [DISTINCTOBJ]]].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [NORM [DY/DX]]] e (ACC) [MOTIONDETECT [ADL]].	<b>(BALANC. E ETIQ.)</b> (SLEEP, EDA) [LABELING].	(ACC) [MOTIONDETECT].
Zhao et al. (Zhao et al., 2016)	<b>(RUIDO, D. INC. E INC.)</b> (RESP, HR) [-NOISE].	<b>(NORM., AMP E FILTR.)</b> (RESP, HR) [D2Y/DX2 [ZHAO1]] e (RESP) [LPF]. <b>(SEG. E GER. SINAL)</b> (RESP, HR) [D2Y/DX2, ZHAO2].		(RESP) [LPF [PEAKDETECT]].
Zenonos et al. (Zenonos et al., 2016)	<b>(RUIDO, D. INC. E INC.)</b> (MOOD, EMOTIONS) [TOLERANCE].	<b>(NORM., AMP E FILTR.)</b> (IBI) [NORM]. <b>(SEG. E GER. SINAL)</b> (IBI) [BANDS].	<b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].	
Basu et al. (Basu et al., 2016)	<b>(RED. DIM. E RED. OBJS)</b>	<b>(NORM., AMP E FILTR.)</b>		{KHRV, WEKA, LABCHART, MATLAB, ORIGIN}.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	(ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM [MANSELECT]].	(ECG, HR, PR, RESP(RR), EDA, ST, EMG) [NORM].		
<b>Aracena et al.</b> (Aracena et al., 2016)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL, GAZE) [-NOISE, -EYEBLINK, -SACCADE].	<b>(NORM., AMP E FILTR.)</b> (PUPIL) [LPF, NORM].	<b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].	
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)		<b>(NORM., AMP E FILTR.)</b> (FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)) [NORM].		(GAZE) [FINDREGION].
<b>Turan et al.</b> (Turan et al., 2015)	<b>(RED. DIM. E RED. OBJS)</b> (FACE, EYES) [SLPP, DCC].		<b>(BALANC. E ETIQ.)</b> (FACE, EYES) [LABELING].	(EYES) [FINDREGION].
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)		<b>(CONV. SINAL)</b> (SPPECH) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (SPPECH) [SIGAMP]. <b>(SEG. E GER. SINAL)</b> (SPEECH) [[FOURIER, SIGAMP] [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]].		
<b>Lalitha et al.</b> (Lalitha et al., 2015)		<b>(SEG. E GER. SINAL)</b> (SPEECH) [DWT].		
<b>Singh et al.</b> (Singh et al., 2015)		<b>(CONV. SINAL)</b> (SHOULDERS, HANDS) [VIDEO-PICS]. <b>(SEG. E GER. SINAL)</b> (SHOULDERS, HANDS) [VIDEO-PICS [-IMGBKG]].		
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)	<b>(RUIDO, D. INC. E INC.)</b> (ECG, ICG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) [MURALI].	<b>(NORM., AMP E FILTR.)</b> (ECG, EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (ECG, ICG) [SIGSPLIT].		(ECG) [PEAKDETECT].
<b>Jaques et al.</b> (Jaques et al., 2015)	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [LPF [NORM [-PEAK]], (SCREEN) [DISCARDATA], (EDA, ST, ACC) [MITIGATION] e (LOCAL) [INTEGRATION [FAKEDATA, NULL]]. <b>(RED. DIM. E RED. OBJS)</b> (EDA, ST, ACC, SLEEP, NAP, STRESS, HEALTH,	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF [NORM]] e <ACC> [NORM]. <b>(SEG. E GER. SINAL)</b> (LOCAL) [INTEGRATION [FAKEDATA, NULL] [PATHSTAKEN]] e (EDA) [DY/DX].	<b>(BALANC. E ETIQ.)</b> (HAPPY) [LABELING].	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	ENERGY, ALERT, CALM, HAPPY, LOCAL, SCREEN, CALL, SMS, SOCIAL, ACADCL, ACADST, PHYSI, ACADEX, CAFFEL, ALCOH DRUGS) [WFS, MANSELECT].			
<b>Cruz et al.</b> (Cruz et al., 2015)		<b>(NORM., AMP E FILTR.)</b> (EOG) [BPF]. <b>(SEG. E GER. SINAL)</b> (EOG) [INTERVALSPLIT].		
<b>Saha et al.</b> (Saha et al., 2014)		<b>(CONV. SINAL)</b> (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [VIDEO-PICS]. <b>(SEG. E GER. SINAL)</b> (HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN) [-IMGBKG].		
<b>Matiko et al.</b> (Matiko et al., 2014)	<b>(RED. DIM. E RED. OBJS)</b> (EEG) [SCATTER, FDA].	<b>(NORM., AMP E FILTR.)</b> (EDA) [FDA [NORM]].	<b>(BALANC. E ETIQ.)</b> (EDA) [LABELING].	
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	<b>(RED. DIM. E RED. OBJS)</b> (PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [CORELATION, BOGOMOLOV [MANSELECT]].	<b>(NORM., AMP E FILTR.)</b> (PERSON, STRESS, CALL, SMS, PROXIMITY, WEATHER) [NORM].		
<b>Agrawal et al.</b> (Agrawal et al., 2013)		<b>(CONV. SINAL)</b> (EYES, MOUTH, LIPS, SKIN) [VIDEO-PICS].		(SKIN, EYES, MOUTH) [FINDREGION]. {MATLAB}.
<b>Soleymani et al.</b> (Soleymani et al., 2013)	<b>(RUIDO, D. INC. E INC.)</b> (EMOTIONS) [DISCARDATA] e (EEG) [-NOISE].	<b>(CONV. SINAL)</b> (EEG) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG) [NORM]. <b>(SEG. E GER. SINAL)</b> (EEG) [BANDS], (HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH) [NORM] <DISTANCE> [DY/DX] e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [INTEGRATION].	<b>(TEC. AMOSTRAGEM)</b> [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH, EEG, EMOTIONS] [SYSTEMATIC]. <b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].	{FEELTRACE}.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Vermun et al.</b> (Vermun et al., 2013)		<b>(CONV. SINAL)</b> (HEAD, LIPS, MOUTH, EYEBROWS, ARMS, SHOULDERS, HIP e KNEES) [VIDEO-PICS].		
<b>Kusserow et al.</b> (Kusserow et al., 2013)		<b>(SEG. E GER. SINAL)</b> (ACC) [TASKSPLIT] e (HR, ACC) [INTEGRATION].		
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	<b>(RED. DIM. E RED. OBJS)</b> (ECG(HRV), RESP, EDA, EMG) [X <sup>2</sup> ].		<b>(BALANC. E ETIQ.)</b> (ECG(HRV), RESP, EDA, EMG) [SPREADSUBSAMPLE].	{AUBT}.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)		<b>(CONV. SINAL)</b> (NIBP, RESP(RR)) [HHT].		
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	<b>(RED. DIM. E RED. OBJS)</b> <EDA, ACC, PERSON, SLEEP, NAP, HEALTH, MOOD, ALERT, TIRED, LOCAL, SCREEN, ELECTR, CALL, SMS, ALCOH, CAFFEI, STRESS> [CORRELATION, PCA, SFFS].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF]. <b>(SEG. E GER. SINAL)</b> (EDA) [LPF [DY/DX]] e (ACC) [ADL].		(EDA) [[LPF [DY/DX [PEAKDETECT]]]].
<b>Raudonis</b> (Raudonis, 2013)		<b>(CONV. SINAL)</b> (PUPIL) [GREYSCALE].		(PUPIL) [FINDREGION, RAUDONIS2].
<b>Kawai et al.</b> (Kawai et al., 2013)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) <DIAMETER> [MANADJUST, -NOISE, MITIGATION].	<b>(CONV. SINAL)</b> (PUPIL) [BINARY]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) <DIAMETER> [KAWAI2 [NORM]].		(PUPIL) [FINDREGION, CLUSTERING, KAWAI1].
<b>Babiker et al.</b> (Babiker et al., 2013)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [MITIGATION], <PUPIL> [NORM [[-NOISE, -OUTLIERS][FAKEDATA, DISCARDATA]]].	<b>(NORM., AMP E FILTR.)</b> <PUPIL> [NORM]. <b>(SEG. E GER. SINAL)</b> (PUPIL) <INTERVALSPLIT>.	<b>(TEC. AMOSTRAGEM)</b> (PUPIL) [SYSTEMATIC].	(PUPIL) [FINDREGION].
<b>LikamWa et al.</b> (LiKamWa et al., 2013)	<b>(RUIDO, D. INC. E INC.)</b> (MOOD) [RELIABILITY, CONSISTENCY]. <b>(RED. DIM. E RED. OBJS)</b> <MOOD, CALL, EMAIL, SMS, APPS, BROWSER, LOCAL> [SFS, CORRELATION].	<b>(NORM., AMP E FILTR.)</b> (CALL, SMS, EMAIL) <COUNT> [NORM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM [NORM]] e (APPS) [LABELING] <COUNT, DURATION> [NORM]. <b>(SEG. E GER. SINAL)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]].	<b>(BALANC. E ETIQ.)</b> (MOOD) [[RELIABILITY, CONSISTENCY] [INTERVALSPLIT]] <PERIODS <COUNT, STD <MEAN, MAX>>> [LABELING] e (APPS) [LABELING].	(CALL, SMS, EMAIL) [HISTOGRAM], (APPS, BROWSER, LOCAL) <USUAL> [HISTOGRAM], (APPS) <DURATION> [HISTOGRAM] e (APPS) [LABELING] <COUNT, DURATION> [HISTOGRAM].
<b>Murad &amp; Malkawi</b>		<b>(SEG. E GER. SINAL)</b>	<b>(BALANC. E ETIQ.)</b>	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Murad & Malkawi, 2012)		(EEG, HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS].	(HR, HRV, PEP, SV, EDA, RESP(VT, ROS, RR), NSRR, ST) [BANDS [LABELING]].	
<b>C. Y. Chang et al.</b> (Chang et al., 2012)	<b>(RUIDO, D. INC. E INC.)</b> (ECG, PR, BVP, EDA) [LFP, HPF] [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> (ECG, PR, BVP, EDA) [MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (ECG, PR, BVP, EDA) [LFP, HPF, NORM]. <b>(SEG. E GER. SINAL)</b> (ECG, PR, BVP, EDA) [R-R].	<b>(TEC. AMOSTRAGEM)</b> (EDA) [SYSTEMATIC] e (BVP, PR) [R-R [SYSTEMATIC]].	(ECG, BVP, PR) [PEAKDETECT].
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)		<b>(SEG. E GER. SINAL)</b> (LOCAL) [INTEGRATION, USUALPLACES].		
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)		<b>(CONV. SINAL)</b> (HEAD, FACE) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (HEAD, FACE) [VIDEO-PICS [IMGALIGN]].		(HEAD, FACE) [FINDREGION, YANG1].
<b>Dhall et al.</b> (Dhall et al., 2011)	<b>(RED. DIM. E RED. OBJS)</b> (FACE) [VIDEO-PICS [-FRAMES [PCA]].	<b>(CONV. SINAL)</b> (FACE) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (FACE) [VIDEO-PICS [NORM]].		(FACE) [VIDEO-PICS [FINDREGION, CROP, NORM [CLUSTERING]]].
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [-NOISE, -EYEBLINK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HRV), PPG, PUPIL> [GA].	<b>(CONV. SINAL)</b> (PUPIL) [VIDEO-PICS]. <b>(NORM., AMP E FILTR.)</b> (PUPIL) [IMGSIZE, IMGINTENSITY]. <b>(SEG. E GER. SINAL)</b> (ECG(HRV)) [BANDS].		(PUPIL) [FINDREGION, BLINKDETECT].
<b>Hernandez et al.</b> (Hernandez et al., 2011)	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [-NOISE].	<b>(NORM., AMP E FILTR.)</b> (EDA, STRESS) [NORM] e <EDA, STRESS> [NORM].	<b>(BALANC. E ETIQ.)</b> (CALL) [LABELING].	(EDA) [PEAKDETECT].
<b>N. Lane et al.</b> (N. Lane et al., 2011)	<b>(RUIDO, D. INC. E INC.)</b> (SLEEP, PHYSI) [MANINSERT].	<b>(SEG. E GER. SINAL)</b> (ACC) [ADL].		(SLEEP) [LANE1] e (SLEEP, PHYSI) [MANADJUST].
<b>H. Wang et al.</b> (H. Wang et al., 2010)	<b>(RUIDO, D. INC. E INC.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY [-NOISE]]]]]. <b>(RED. DIM. E RED. OBJS)</b> <EYES> [ADABOOST].	<b>(NORM., AMP E FILTR.)</b> (EYES) [-IMGBKG [NORM [IMGSIZE [IMGINTENSITY]]]]. <b>(SEG. E GER. SINAL)</b> (EYES) [-IMGBKG].	<b>(BALANC. E ETIQ.)</b> (EYES) [+ARTIFICIALDATA, LABELING].	(EYES) [FINDREGION, CROP, COLORCORR].
<b>Bos</b> (Bos, 2010)	<b>(RUIDO, D. INC. E INC.)</b> (EEG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> <EEG> [PCA].	<b>(CONV. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER]]]. <b>(NORM., AMP E FILTR.)</b>		{EEGLAB}.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(EEG) [-NOISE [BPF]. <b>(SEG. E GER. SINAL)</b> (EEG) [-NOISE [BPF [FOURIER [BANDS]]]].		
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)		<b>(CONV. SINAL)</b> (EEG) [FD] e [EMOTIONS] [2D- DISCRETE]. <b>(NORM., AMP E FILTR.)</b> <EEG> [BPF]. <b>(SEG. E GER. SINAL)</b> <EEG> [INTERVALSPLIT].		
<b>Setz et al.</b> (Setz et al., 2010)	<b>(RUIDO, D. INC. E INC.)</b> (EDA) [DISCARDATA, MANADJUST [-NOISE]]. <b>(RED. DIM. E RED. OBJS)</b> <EDA> [WFA].	<b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, LPF [HPF [LPF]]].		(EDA) [PEAKDETECT].
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HR, HRV), RESP(RR, BRV), EDA, EMG> [SBS].	<b>(CONV. SINAL)</b> (ECG(HR, HRV)) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [ABPF, LPF] e (EDA, EMG) [NORM]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP(RR, BRV), EDA, EMG) [INTERVALSPLIT], (ECG(HR, HRV), RESP (RR, BRV)) [FOURIER [BANDS]] e (EDA) [NORM [LPF [DY/DX, D2Y/DX2]]].		(ECG(HR, HRV)) [PEAKDETECT].
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	<b>(RUIDO, D. INC. E INC.)</b> (RESP) [-PEAK]. <b>(RED. DIM. E RED. OBJS)</b> <ECG(HR, HRV, IBI), RESP(RR, RDEP), EDA, ST, EMG> e (EMOTIONS) [CORRELATION, MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (EDA) [LPF].	<b>(BALANC. E ETIQ.)</b> (RESP(RR)) <AMP> [LABELING].	
<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [FAKEDATA].	<b>(NORM., AMP E FILTR.)</b> (PUPIL, EDA) [NORM].		
<b>Gunes &amp; Piccardi</b> (Gunes & Piccardi, 2007)	<b>(RED. DIM. E RED. OBJS)</b> (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-FRAMES] e	<b>(CONV. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW)		(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW,

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	(LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW, SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BESTFIRST].	[IMGCONTRAST [BINARY]] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [BINARY]. <b>(NORM., AMP E FILTR.)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [IMGCONTRAST] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [IMGSIZE, IMGCONTRAST]. <b>(SEG. E GER. SINAL)</b> (LIPS, MOUTH, EYES, EYEBROWS, EYELIDS, NOSE, CHEEKS, FOREHEAD, JAW) [COLORSEG] e (SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [-IMGBKG].		SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK) [MORPHOPS, FINDREGION]. {WEKA}.
Castellano et al. (Castellano et al., 2007)	<b>(RED. DIM. E RED. OBJS)</b> (ARMS) [DISCARDATA].	<b>(NORM., AMP E FILTR.)</b> (ARMS) <MOTION <MAX, MIN>> [NORM]. <b>(SEG. E GER. SINAL)</b> (ARMS) [-IMGBKG].		{YESWEB}.
Mandryk & Atkins (Mandryk & Atkins, 2007)	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [MANADJUST, FAKEDATA].	<b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [FAKEDATA [SIGSMOOTH [NORM]]], (EMG) [SIGSMOOTH [NORM]] e (EDA) [BPF [NORM]]. <b>(SEG. E GER. SINAL)</b> (ECG(HR), EDA, EMG) e {VIDEO, AUDIO} [INTEGRATION].	<b>(TEC. AMOSTRAGEM)</b> (ECG(HR)) [SYSTEMATIC], (ECG(HR), EDA, EMG) [STRATIFIED]. <b>(BALANC. E ETIQ.)</b> (ECG(HR), EDA, EMG, EMOTIONS) [LABELING].	(ECG(HR), EDA, EMG) [HISTOGRAM].
Sebe et al. (Sebe et al., 2006)	<b>(RED. DIM. E RED. OBJS)</b> (PITCH) [CORRELATION].	<b>(CONV. SINAL)</b> (HEAD, EYEBROWS, EYELIDS, MOUTH) [3D2D]. <b>(SEG. E GER. SINAL)</b> (HEAD, EYEBROWS, EYELIDS, MOUTH, VOLUME, SPEECH, PITCH) [INTEGRATION].		
Zhai & Barreto (Zhai & Barreto, 2006)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) <DIAMETER>[-NOISE [FAKEDATA]].	<b>(NORM., AMP E FILTR.)</b>		

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(ST) [SIGAMP [LPF [NORM]]] e (BVP(IBI), EDA) [NORM].		
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	<b>(RUIDO, D. INC. E INC.)</b> (EDA, ECG(HR, HRV)) [DISCARDDATA] e (STRESS) [RELIABILITY]. <b>(RED. DIM. E RED. OBJS)</b> <EDA, EMG, RESP, ECG(HR, HRV)> [SCATTER, MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (STRESS, EMG, RESP, ECG(HR), EDA) [NORM] e (EMG) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV), RESP, EDA, EMG) e {VIDEO} [INTEGRATION], (ECG(HR, HRV), RESP, EDA, EMG) [INTERVALSPLIT] e (RESP) [BANDS].	<b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].	(EDA) [PEAKDETECT].
<b>Herbon et al.</b> (Herbon et al., 2005)	<b>(RUIDO, D. INC. E INC.)</b> (HR, EDA, PUPIL, EMOTIONS) [DISCARDDATA] e (HR, EDA, PUPIL) <STD <THRESHOLD>> [DISCARDDATA].	<b>(CONV. SINAL)</b> (HR, EDA, ST, PUPIL) [ZTRANSFORM].		
<b>Partala et al.</b> (Partala et al., 2005)	<b>(RUIDO, D. INC. E INC.)</b> (EMG) [-EYEBLINK].	<b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP [HPF, LPF]]. <b>(SEG. E GER. SINAL)</b> (EMG) e (EMOTIONS) [LABELING].		(EMG) [TTEST].
<b>Van Eck et al.</b> (van Eck et al., 2005)	<b>(RUIDO, D. INC. E INC.)</b> (HEALTH) [DISCARDDATA] e (CORT) [-OUTLIERS]. <b>(RED. DIM. E RED. OBJS)</b> (LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS, PHYSI, SMOKING, FOOD, CAFFEI, ALCOH) [PCA [AGGREGATION]].		<b>(BALANC. E ETIQ.)</b> (STRESS) [LABELING].	
<b>Busso et al.</b> (Busso et al., 2004)	<b>(RED. DIM. E RED. OBJS)</b> <PITCH, VOLUME> [SBS], <FOREHEAD, EYEBROWS, EYES, CHEEKS> [PCA] e <PITCH, VOLUME, FOREHEAD, EYEBROWS, EYES, CHEEKS> [SBS [AGGREGATION], MANSELECT].			(FOREHEAD, EYEBROWS, EYES, CHEEKS) [FINDREGION, CLUSTERING].

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Lisetti & Nasoz (Lisetti & Nasoz, 2004)		<b>(NORM., AMP E FILTR.)</b> (HR, EDA, ST) [NORM].		
K. H. Kim et al. (K. H. Kim et al., 2004)	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R [FAKEDATA]]] e (ECG(HRV), EDA) [THRESHOLD [- OUTLIERS]].	<b>(NORM., AMP E FILTR.)</b> (EDA) [SIGAMP, BPF] e (ECG(HR, HRV), EDA, ST, PPG) [NORM, SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (ECG(HR, HRV)) [PEAKDETECT [R-R]], (ECG(HRV)) [BANDS] e (EDA) [INTERVALSPLIT].	<b>(TEC. AMOSTRAGEM)</b> (ECG(HRV), EDA) [DECIMATION].	(ECG(HR, HRV)) [PEAKDETECT].
Haag et al. (Haag et al., 2004)		<b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [LPF [HPF]], (ECG(HR)) [[DY/DX, D2Y/DX2] [SIGSMOOTH]], (EDA) [NORM [LPF]], (EMG) [SIGSMOOTH] e <PPG(BVP(HR)), ECG, RESP, EDA, ST, EMG> [NORM]. <b>(SEG. E GER. SINAL)</b> (ECG(HR)) [DY/DX, D2Y/DX2] e (PPG(BVP(HR)), RESP) [INTERVALSPLIT].		(PPG(BVP(HR))) [HISTOGRAM].
Partala & Surakka (Partala & Surakka, 2003)	<b>(RUIDO, D. INC. E INC.)</b> (PUPIL) [DISCARDATA, -EYEBLINK].		<b>(BALANC. E ETIQ.)</b> (PUPIL) [LABELING].	(PUPIL) [PEAKDETECT, TTEST].
C J Harmer et al. (C J Harmer et al., 2003)	<b>(RED. DIM. E RED. OBJS)</b> (MOOD, ENERGY) [PCA].			
Nwe et al. (Nwe et al., 2001)		<b>(CONV. SINAL)</b> (SPEECH) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (SPEECH) [SIGSMOOTH]. <b>(SEG. E GER. SINAL)</b> (SPEECH) [INTERVALSPLIT].		
Buchanan & Lovallo (Buchanan & Lovallo, 2001)			<b>(BALANC. E ETIQ.)</b> (EMOTIONS) [LABELING].	
Jennifer a Healey et al. (Jennifer a Healey et al., 2000)		<b>(CONV. SINAL)</b> (RESP) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PPG(BVP(HR)), ECG(HR, HRV), RESP,	<b>(BALANC. E ETIQ.)</b> (EMG) [LABELING].	{MATLAB}.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		EDA) [SIGSMOOTH, NORM].		
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	<b>(RUIDO, D. INC. E INC.)</b> (BP(SBP, DBP)) [-NOISE, -OUTLIERS].	<b>(SEG. E GER. SINAL)</b> (PHYSI, ECG(HR, HRV, IBI(RMSSD(VAGAL))), ACC) [INTEGRATION [ADL]].	<b>(TEC. AMOSTRAGEM)</b> (STRESS) [INTENTIONAL, STRATIFIED]. <b>(BALANC. E ETIQ.)</b> BP(SBP, DBP) [LABELING].	[AGE, BMI, WAIST, SMOKING, ALCOH, ACADDG, WORKYEARS, PHYSI, MOOD] [ANOVA]. {GLM}.
<b>Ritz et al.</b> (Ritz et al., 2000)	<b>(RED. DIM. E RED. OBJS)</b> (BP(SBP)) [CORRELATION].	<b>(SEG. E GER. SINAL)</b> (BP(SBP)) [INTERVALSPLIT].		(HR, BP(SBP, DBP), ROS, RR, VT, EDA, EMOTIONS) [ANOVA].
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	<b>(RUIDO, D. INC. E INC.)</b> (EYES, EYEBROWS, MOUTH, WRINKLES, FROWN) [MANINSERT].	<b>(CONV. SINAL)</b> (EYES, MOUTH) [FOURIER]. <b>(NORM., AMP E FILTR.)</b> (PITCH) [NORM]. <b>(SEG. E GER. SINAL)</b> (SPEECH) [INTERVALSPLIT] e (PITCH) <CONTOUR> [DY/DX].		
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)		<b>(NORM., AMP E FILTR.)</b> (RESP) [NORM], <RESP> [NORM] e (EDA) [SIGSMOOTH, NORM].	<b>(BALANC. E ETIQ.)</b> (EMG, EDA, PPG(BVP(HR)), RESP) [LABELING].	
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	<b>(RUIDO, D. INC. E INC.)</b> (BP(DBP)) [DISCARDATA] e (EMG) [-NOISE]. <b>(RED. DIM. E RED. OBJS)</b> (EMG) [MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, BPF, NORM], (ST) [SIGAMP] e (ECG(HR), BP(SBP, DBP), EDA, EOG) [NORM].	<b>(TEC. AMOSTRAGEM)</b> (EMG, ST) [SYSTEMATIC].	
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	<b>(RUIDO, D. INC. E INC.)</b> (ECG(HR)) [DISCARDATA].	<b>(CONV. SINAL)</b> (EMOTIONS) [QUALI-QUANTI]. <b>(NORM., AMP E FILTR.)</b> (EMG) [SIGAMP, LPF, HPF].		
<b>R Sinha et al.</b> (R Sinha et al., 1992)	<b>(RUIDO, D. INC. E INC.)</b> (ICG(SV, CO, PVR, PEP, LVET)) [MANINSERT] e (ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)) [DISCARDATA]. <b>(RED. DIM. E RED. OBJS)</b> (BP(SBP, DBP), ECG(HR)) [MANSELECT].	<b>(NORM., AMP E FILTR.)</b> (ECG(HR)) [SIGAMP]. <b>(SEG. E GER. SINAL)</b> (ECG) [R-R].		

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado, e <> uma propriedade extraída.

## 5. PROPRIEDADES EXTRAÍDAS

A precisão dos algoritmos depende da qualidade das propriedades *input* do sistema (Matlovic et al., 2016), fazendo da sua escolha um passo importante para os algoritmos de classificação (Adams & Robinson, 2015). As propriedades podem ser extraídas diretamente do sinal recolhido pelos instrumentos e sensores (i.e. RAW) ou de qualquer *output* resultante da aplicação de técnicas de pré-processamento. As propriedades são mais apropriadas ao processo de classificação e podem ser vistas como *inputs* complementares ou de substituição aos atributos do *dataset* original (Haag et al., 2004). Depois do pré-processamento é necessário definir quais as medidas estatísticas ou propriedades ideais para reconhecimento emocional a extrair do sinal (Jerritta et al., 2011). Por e.g. Kim & André, tendo por base os sinais *raw* ECG, EMG, EDA e RESP, extraíram várias propriedades a partir do sinal pré-processado para o domínio do tempo, e domínio de frequência (J. Kim & André, 2008).

Nesta revisão bibliográfica identificamos quatro categorias de propriedades: domínio; específicas de contexto; matemáticas e análise de sinal; e as genéricas. As **propriedades de domínio** foram identificadas na secção das variáveis de contexto, pelo facto do método de obtenção ser confundível com o utilizado na própria recolha. Como a literatura analisada também não as distingue formalmente das variáveis de contexto e são, em alguns casos, determinadas automaticamente pelos próprios instrumentos de recolha, decidimos também considerá-las na secção 2 (variáveis de contexto) (e.g. o IBI utilizado por Zenonos et al. foi cedido diretamente pelo SILMEEW2X sem necessidade de qualquer pré-processamento (Zenonos et al., 2016); o HRV é uma propriedade extraída a partir do ECG, no entanto, alguns dispositivos fornecem-na diretamente (Lichtenstein, Antje; Oehme, 2008); etc.). As **propriedades específicas de contexto**, que aumentam a variedade e qualidade do *input* dos sistemas (Matlovic et al., 2016) são objeto de análise nesta secção. Como são dependentes do contexto de onde são extraídas, decidiu-se dividir esta secção em função das variáveis de contexto originais. As **propriedades matemáticas e de análise de sinal**, e as **propriedades genéricas**, apesar de bastante referenciadas pela literatura, não são abordadas em detalhe neste documento por considerarmos serem de conhecimento geral. São, no entanto, resumidas de seguida por serem referenciadas nos vários textos desta secção.

As **medidas estatísticas** permitem a extração de propriedades relacionadas com a organização, caracterização e análise de dados. Neste levantamento bibliográfico foram identificadas: medidas de tendência central; medidas de dispersão; e medidas de distribuição.

As medidas de tendência central são muito utilizadas pelos investigadores (e.g. Lang et al. (Peter J. Lang, Levin, Miller, & Kozak, 1983), Miller et al. (Miller et al., 1987), etc.)) (Rajita Sinha, 1996). As medidas de tendência central são utilizadas em várias realidades (e.g. na prevenção do impacto de *outliers* no sinal) (Rajita Sinha, 1996). São várias as medidas de tendência central utilizadas pelas investigações em revisão: média **<MEAN>** para indicar o ponto médio de valores numéricos; mediana **<MEDIAN>** que representa o ponto central da distribuição dos dados; a **<MODE>** que representa o valor mais frequente numa distribuição; média dos valores absolutos **<MAV>** (também conhecido como *Averaged Absolute Value* ou *Average Rectified Value*) (Phinyomark et al., 2012); MAV pesada por *windows functions* **<MAVS>** (Phinyomark et al., 2012); média dos valores absolutos da primeira diferença **<MAV1D>** (Basu et al., 2016) (R.W. Picard, Vyzas, & Healey, 2001); média dos valores absolutos da segunda diferença **<MAV2D>** (Basu et al., 2016) (R.W. Picard et al., 2001); e o quantil **<QUANTILE>**. Os investigadores também utilizam medidas de dispersão para analisar a variabilidade de valores num *dataset*. Na literatura

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

analisada identificaram-se as seguintes medidas de dispersão: variância <VAR>; desvio padrão <STD>; desvio absoluto <AD>; amplitude <AMP>; máximo <MAX>; mínimo <MIN>; e covariância <COVAR> que permite analisar a dispersão entre dois ou mais atributos (Gama et al., 2012). Estas medidas são calculadas sobre a totalidade ou partes do sinal (e.g. Sano & Eng. calculou a média da AMP do sinal recolhido por vários elétrodos (Sano & Eng, 2016)). As medidas de distribuição permitem caracterizar a disposição dos dados representados num histograma. Na literatura analisada foram identificadas as seguintes medidas: obliquidade <SKEWNESS> que mede a simetria da distribuição à volta da média; e curtose <KURTOSIS> que representa o achatamento da função de distribuição (Gama et al., 2012) (Korkmaz & Atasoy, 2015).

As **medidas geométricas** estão relacionadas com o sentido espacial, forma, dimensões de superfícies, volumes, etc. (e.g. formas, perímetros, raios, diâmetros, ângulos, distâncias, volumes, comprimentos, larguras, alturas, etc.). São vários os investigadores que utilizam a geometria nas suas investigações: Gogia et al. utilizaram o *pitch, yaw e roll*, para representar os ângulos <ANGLE> da HEAD no eixo vertical, horizontal e horizontal sem virar o pescoço (Gogia et al., 2016); Mokhayeri et al. calcularam o diâmetro <DIAMETER> da PUPIL (Mokhayeri & Toosizadeh, 2011); Sano et al. calcularam o raio <RADIUS> aproximado de movimentação dos participantes da sua experiência (Sano & Picard, 2013b); Eckert et al. calcularam a área <AREA> de SHAPE reconhecidas (Eckert et al., 2016); Jaques et al. determinaram as distâncias percorridas <DISTANCE> com base nos dados do LOCAL ao longo do dia (Jaques et al., 2015) (Lee et al. também calcularam a DISTANCE entre zonas da face (e.g. EYEBROWS e EYELIDS) (S. H. Lee et al., 2016) e Eckert et al. calcularam a DISTANCE entre pontos (e.g. de uma SHAPE (Eckert et al., 2016))); declive <SLOPE> (e.g. Singh et al. utilizaram o SLOPE dos SHOULDERS para prever o estado emocional das pessoas (Singh et al., 2015)); tamanho <SIZE> (e.g. Sano & Picard e LikamWa et al. utilizaram o tamanho de SMS como propriedade extraída (Sano & Picard, 2013b) (LiKamWa et al., 2013)); e o centroide <CENTROID> na determinação do centro geométrico de clusters (S. H. Lee et al., 2016). Alguns autores fazem a identificação de padrões <SHAPE> formados por linhas conetoras entre grupos de pontos (e.g. Lee et al. (S. H. Lee et al., 2016)): Eckert et al. fizeram reconhecimento de padrões para avaliar o triângulo formado pelos grupos de pontos dos EYES e EYEBROWS (Eckert et al., 2016); Zhang et al. utilizaram o *Active Shape Model* para detetar a SHAPE da face (Cootes, Taylor, Cooper, & Graham, 1995) (Z. Zhang et al., 2016); etc.

A partir da **análise de sinal** torna-se possível extrair várias propriedades no domínio do tempo e da frequência. A extração de propriedades a partir do sinal no domínio do tempo, tem sido também bastante utilizada pela medicina e engenharia, talvez por não implicar transformações de fundo ao sinal recolhido pelos instrumentos e sensores (Phinyomark et al., 2012) (Hudgins, Parker, & Scott, 1993). São várias as propriedades extraídas da análise a partir do domínio do tempo: o *Waveform Length* <WL> mede a complexidade de um sinal (e.g. Phinyomark et al. (Phinyomark et al., 2012)); o *Willison Amplitude* <WAMP> representa a quantidade de vezes em que a diferença entre dois segmentos adjacentes de sinal excedem um limiar pré-definido (Phinyomark et al., 2012); o *Auto-Regressive* <AR> descreve cada amostra de sinal como uma combinação de várias amostras (Phinyomark et al., 2012). As propriedades do espectro ou domínio de frequência são bastante utilizadas pelos investigadores, sendo a *Power (Energy) Spectral Density* <PSD> uma das análises mais usadas e que mostra a distribuição da VAR em função da frequência (Zenonos et al., 2016) (Phinyomark et al., 2012) (Soleymani et al., 2013). São várias as propriedades extraídas a partir da análise do domínio de frequência: pico de frequência <PKF>; pico da baixa frequência <PLF>; pico de alta frequência <PHF> (e.g. Zhao et

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

al. (Zhao et al., 2016)); frequência dominante <DMF> (e.g. Kim et al. (J. Kim & André, 2008)); rácio entre baixa frequência e alta frequência <LF/HF>; e rácio entre a soma da baixa e média frequência com a alta frequência <LFMF/HF>.

Identificaram-se ainda outras propriedades possíveis de extrair dos sinais: magnitude <MAG> (e.g. Jaques et al. utilizaram a MAG para detetar movimento e normalizar o EDA (utilizando um THRESHOLD o autor estimou o número de passos do utilizador) (Jaques et al., 2015)); raiz do valor quadrático médio ou valor eficaz <RMS> (*Root-Mean-Square*) (Wikipédia, n.d.) (Weisstein, 2017); *power* <POWER> e força <STRENGTH> (e.g. Matlovic et al. calcularam o POWER e STRENGTH das ondas ALPHA e BETA do (EEG) [DWT] (Matlovic et al., 2016)); pico principal do sinal <MAINPEAK> (e.g. Castellano et al. (Castellano et al., 2007)); área debaixo da curva de uma função <INTEGRAL> (e.g. Jaques et al. (Jaques et al., 2015)); tempo de subida do sinal <RISETIME> (e.g. Jaques et al. (Jaques et al., 2015)); a primeira e segunda diferença de valores <1DIFF> <2DIFF> que são utilizados como aproximação à  $DY/DX$  e  $D^2Y/DX^2$  (e.g. Alzoubi et al. utilizaram a 1DIFF e 2DIFF para calcular rácios com EDA, RESP, etc. (Alzoubi et al., 2013)); cruzamentos do zero ( $y = 0$ ) (*zero crossings*) <ZEROCROSSINGS> (e.g. Hernandez et al. (Hernandez et al., 2011)); pontos de viragem do sinal (*turning points*) <TPOINTS> (e.g. Lichtenstein et al. (Lichtenstein, Antje; Oehme, 2008)); e variação ou alteração de sinal ou dados <CHANGES> (e.g. aumento ou diminuição de tamanho, diâmetro, aceleração ou desaceleração de HR) (e.g. Bradley et al. (Margaret M. Bradley et al., 2008), Lichtenstein et al. (Lichtenstein, Antje; Oehme, 2008) Healey et al. (J. Healey & Picard, 1998) e Vrana (Scott R. Vrana, 1993)).

Os investigadores recorrem ainda a outro tipo de análises para extrair propriedades: *poincaré plots* <POINCARE> que permite avaliar visualmente a similaridade de dados (A. C. C. Yang, 2006) (Kamen, Krum, & Tonkin, 1996) (e.g. Zenonos et al. utilizaram POINCARE para analisar as similaridades do IBI atual com os anteriores, assumindo o pressuposto que o IBI atual é influenciado pelo anterior (Zenonos et al., 2016)); medidas de entropia utilizadas para avaliar a complexidade de *time series* <ENTROPY> (*spectral entropy*, *sample entropy* (SAMPEN), que é uma modificação da *approximate entropy* (APEN)) (Aboy, Cuesta-Frau, Austin, & Mico-Tormos, 2007) (Lake, Richman, Griffin, & Moorman, 2002) (Zenonos et al., 2016) (J. Kim & André, 2008); e *detrend fluctuation analysis* <DFA> que se baseia no conceito que um sistema ou forma pode ser decomposto em vários peças e que cada peça se assemelha com as restantes mas a escalas diferentes (o objetivo é encontrar propriedades semelhantes em *non-stationary time series*) (Zenonos et al., 2016) (Penzel, Kantelhardt, Grote, Peter, & Bunde, 2003).

Além destas propriedades, **outros** conceitos matemáticos mais genéricos são também utilizados: rácio <RATIO> para medir a relação entre valores (e.g. Matlovic et al. calcularam o RATIO entre BETA/ALPHA para avaliar o nível *arousal* dos participantes na sua experiência (Matlovic et al., 2016)); número de vezes <COUNT> que ocorre determinada ação ou tarefa; soma de valores <SUM> (e.g. J. Healey et al. sumaram as MAG do sinal EDA segmentado (J. A. Healey & Picard, 2005)); tempo dispendido ou duração de uma ou várias tarefas ou ações <DURATION>; agrupamento de dados em períodos de tempo ou outro critério pré-estabelecido (i.e. conjuntos, ciclos, etc.) <PERIODS> (e.g. diários, 6am-12am, períodos de sono, etc.); tempo decorrido entre ações <ELAPSED TIME> (e.g. Bogomolov et al. utilizaram o intervalo entre CALL, SMS e EMAIL (Bogomolov et al., 2014)); latência <LATENCY>; deslocamento <DISPLACEMENT> (i.e. quantidade de deslocação ocorrida) (e.g. Lee et al. calcularam o deslocamento geométrico de zonas da face entre *frames* de vídeo (S. H. Lee et al., 2016)); movimento <MOTION> (e.g. Vermun et al. utilizaram os movimentos da cabeça (cf. *nodding*, *shaking*, *tilting*, *turning*) como propriedades no seu sistema (Vermun et al., 2013)); velocidade <SPEED> (e.g. Saha et al.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

calcularam a SPEED com base no DISPLACEMENT das articulações na parte superior do corpo humano recolhidas pelo KINECT (Saha et al., 2014)); subtração de dados <SUBTRACT> (e.g. Matlovic et al. calcularam as diferenças de atividade elétrica entre hemisférios do cérebro para avaliar o *valence* (Matlovic et al., 2016) e Saha et al. calcularam a SPEED com base na diferença (i.e. SUBTRACT) do DISPLACEMENT de articulações em dois *frames* consecutivos); posição <POSITION> (e.g. Saha et al. utilizaram a POSITION dos membros superiores das pessoas para inferir emoções (Saha et al., 2014), Soleymani et al. utilizaram pontos de referencia dos EYES e NOSE para corrigir a POSITION da HEAD (Soleymani et al., 2013)); intensidade <INTENSITY>; localização <LOCATION> (e.g. Raudonis estimou as coordenadas da PUPIL em imagens (Raudonis, 2013)); direção <DIRECTION> (e.g. Adams & Robtinson e Aracena et al. utilizaram a DIRECTION do GAZE nas suas investigações (Adams & Robinson, 2015) (Aracena et al., 2016)); correlação (CORRELATION) (e.g. Agrawal et al. utilizaram coeficientes de correlação para avaliar a alteração da posição dos EYES e LIPS entre *frames* (Agrawal et al., 2013), Soleymani et al. calcularam a CORRELATION entre o sinal EEG e a movimentação muscular da face para comprovar a forte interferência da atividade dos músculos e movimentos do olho no sinal EEG (Soleymani et al., 2013)); e limiar de dados para definir o ponto a partir do qual determinada ação ou valor ganha ou perde efeito <THRESHOLD> (e.g. Perdiz et al. utilizaram THRESHOLD na classificação do sinal EOG (Perdiz et al., 2017), Eckert et al. utilizaram THRESHOLD para avaliar quando existem alterações nas CAU (Eckert et al., 2016)).

Ainda a indicação de algumas etiquetas genéricas de suporte à categorização: esquerda <LEFT>, direita <RIGHT> e centro <CENTER> (e.g. Vermun et al. mediram as coordenadas do LEFT e RIGHT KNEE e determinou o CENTER do SHOULDER (Vermun et al., 2013)); início <BEGIN> e fim <END> de uma ação ou evento; primeira <FIRST>, segunda <SECOND>, terceira <THIRD>, etc. ocorrência de uma ação ou evento; identificação do(s) momento(s) em que uma ação, recolha ou tarefa acontece <TIMING>; última vez que ocorreu uma ação ou foi desempenhada uma tarefa <LASTTIME>; regularidade qualitativa de uma determinada ação ou evento (e.g. pouco ou muito frequente) <REGULARITY>; utilização de objetos ou dispositivos <USAGE>; execução planeada de uma ação ou evento <PLANNING>; razão para que uma ação ou evento aconteça <WHY>; qualidade de algo ou com que uma tarefa ou ação acontece <QUALITY>; quantidade <QUANTITY>; nível de medição genérica <LEVEL>; fases de processos, experiências ou eventos <PHASES>; eventos, ações ou interações mais usuais <USUAL>; estado de uma tarefa, objeto ou componente <STATUS> (e.g. Wang et al. utilizaram o STATUS dos EYES na sua investigação acerca da fadiga (H. Wang et al., 2010)); e altura <HEIGHT>.

As secções seguintes utilizam estas propriedades sem atender à sua categorização matemática. A organização assumida agrupa as propriedades extraídas em função da origem das respetivas variáveis de contexto. Pretende-se facilitar a leitura do documento dando ênfase às **propriedades específicas de contexto** de recolha.

Algumas variáveis de contexto podem ser decompostas em várias, por exemplo, por serem recolhidas por múltiplos métodos de introspeção de contexto ou serem compostas por vários dados recolhidos do contexto. Assim, nesta secção discriminam-se também as várias propriedades originais (i.e. atributos RAW) que compõem e perfazem as variáveis de contexto compostas. Por e.g., para recolher a variável de contexto PHYSI, os investigadores Jaques et al. estimaram o número de passos através do ACC e, conjuntamente, solicitaram o preenchimento de questionários acerca da atividade física diária (Jaques et al., 2015). A variável de contexto WEATHER utilizada por Bogomolov et al. é composta por dados acerca da temperatura ambiente (i.e. TEMP), pressão atmosférica, precipitação, humidade, vento, etc. (Bogomolov et al., 2014).

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Ainda outro exemplo, Jaques et al. recolheram a variável LOCAL com base em dados provenientes de várias origens: coordenadas de GPS; sinal WiFi; e antena do operador de comunicações móveis (Jaques et al., 2015)).

Aquando da necessidade de especificar várias variáveis de contexto (i.e. recolha multimodal) (e.g. [EDA, SLEEP] (contexto fisiológico, e contexto social e psicológico)) optar-se-á pela categorização que mais se relacione com a natureza dos valores das propriedades extraídas.

Muitas das técnicas de pré-processamento analisadas na secção anterior preparam o sinal RAW para que seja mais adequado a serem *input* dos algoritmos de classificação (Gama et al., 2012). No entanto, algumas das técnicas derivam o RAW noutros sinais (i.e. geram novo sinal a partir do RAW) (e.g. DY/DX, ADL, etc.). Com o objetivo de simplificar a leitura deste documento, o sinal resultante da aplicação das técnicas de pré-processamento para manutenção de sinal (e.g. RAW) será apenas referido como dados finais de contexto <FINALRAW>, fazendo-se apenas referências às técnicas de pré-processamento quando aplicadas às propriedades extraídas. Na referência a um sinal derivado (i.e. um sinal novo), será utilizado o *token* entretanto já atribuído para o simbolizar. Assim (EDA) [RAW, FINALRAW, DY/DX] <MEAN, MAX> indica as propriedades MEAN e MAX extraídas diretamente do sinal RAW do EDA, propriedades MEAN e MAX extraídas do FINALRAW, e propriedades MEAN e MAX extraídas do novo sinal DY/DX. Podem também existir encadeamentos de propriedades extraídas. Por e.g. (LOCAL) [RAW] <<LATITUDE, LONGITUDE>><MEDIAN>> representa a propriedade MEDIAN calculada com base na propriedade LATITUDE e na propriedade MEDIAN calculada com base na propriedade LONGITUDE do sinal RAW da variável de contexto LOCAL.

Para simplificação da notação e quando subentendível, o termo FINALRAW poderá ser omitido utilizando-se os parêntesis retos para identificar o sinal final pretendido. Assim, na sequência da simplificação já anteriormente introduzida em que (EDA) [RAW] seria equivalente a mencionar apenas (EDA), e (EDA) [FINALRAW] poderá ser representado apenas por [EDA] assumindo o mesmo significado.

O quadro seguinte resume as várias propriedades específicas de contexto utilizadas pelos autores das investigações analisadas neste levantamento bibliográfico. As propriedades matemáticas já apresentadas não serão explicitadas neste quadro resumo, porque são de conhecimento comum e não serão detalhadas posteriormente.

DESCRIÇÃO	ID	GRUPO (categoria)
<b>EXPRESSÃO FACIAL, EXPRESSÃO ORAL E POSTURA CORPORAL</b>		
Brow raising (elevação ou descida das sobrancelhas)	BROWSRAISING	Expressão facial e postura
Clusters (imagem ou vídeo)	CLUSTERS	Expressão facial e postura
Pitch countour	COUNTOUR	Expressão oral
Crossed arms (cruzamento dos braços)	CROSSEDARMS	Expressão facial e postura
DWTC (Discrete Wavelet Transform Coefficients)	DWTC	Expressão oral
Erect back (costas direitas)	ERECTBACK	Expressão facial e postura
Eye corners (extremidades dos olhos)	EYECORNERS	Expressão facial e postura
Finger tapping (batidas dos dedos)	FINGERTAPPING	Expressão facial e postura
GABOR (Gabor wavelets)	GABOR	Expressão facial

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Harmonic to Noise Ratio</b>	<b>HNR</b>	Expressão oral
<b>Iris</b> (iris do olho)	<b>IRIS</b>	Expressão facial e postura
<b>LBP</b> (local binary pattern)	<b>LBP</b>	Expressão facial
<b>Lip bite</b> (morder dos lábios)	<b>LIPBITE</b>	Expressão facial e postura
<b>Lips pucker</b> (franzir dos lábios)	<b>LIPSPUCKER</b>	Expressão facial e postura
<b>Lip wipe</b> (limpar dos lábios)	<b>LIPWIPE</b>	Expressão facial e postura
<b>LPCC</b> (Linear Predictive Cepstral Coefficients)	<b>LPCC</b>	Expressão oral
<b>LPQ</b> (local phase quantization)	<b>LPQ</b>	Expressão facial
<b>MEDC</b> (Mel Energy Spectral Dynamic Coefficients)	<b>MEDC</b>	Expressão oral
<b>MFCC</b> (Mel Frequency Cepstral Coefficients)	<b>MFCC</b>	Expressão oral
<b>Mouth corners</b> (extremidades da boca)	<b>MOUTHCORNERS</b>	Expressão facial e postura
<b>Mouth opening</b> (abertura da boca)	<b>MOUTHOPENING</b>	Expressão facial e postura
<b>Mouth stretch</b> (alongamento da boca)	<b>MOUTHSTRETCH</b>	Expressão facial e postura
<b>PHOG</b> (Pyramid of histogram of oriented gradients)	<b>PHOG</b>	Expressão facial
<b>Shimmer</b>	<b>SHIM</b>	Expressão oral
<b>Stick pose</b>	<b>SINGH</b>	Expressão oral
<b>Sitting posture</b> (postura sentada)	<b>SITTINGPOSTURE</b>	Expressão facial e postura
<b>Spectral centroid</b>	<b>SPCE</b>	Expressão oral
<b>Spectral flux</b>	<b>SPFL</b>	Expressão oral
<b>Spectral roll off</b>	<b>SPRO</b>	Expressão oral
<b>TEAE</b> (Teager Energy)	<b>TEAE</b>	Expressão oral
<b>WLD</b> (weber local descriptor)	<b>WLD</b>	Expressão facial
<b>Wrinkled eyelid</b> (pálpebra enrugada)	<b>WRINKLEDEL</b>	Expressão facial e postura
<b>Wrinkled eyes</b> (olhos enrugados)	<b>WRINKLEDEYES</b>	Expressão facial e postura
<b>Wrinkled forehead</b> (testa enrugada)	<b>WRINKLEDFH</b>	Expressão facial e postura
<b>Wrinkled nose</b> (nariz enrugado)	<b>WRINKLEDNOSE</b>	Expressão facial e postura
<b>Zero Crossing Rate</b>	<b>ZCR</b>	Expressão oral
<b>CONTEXTO FISIOLÓGICO</b>		
<b>Alpha waves</b> (ondas alpha)	<b>ALPHA</b>	Atividade cerebral
<b>Attention level</b> (nível de atenção)	<b>ATTENTION</b>	Atividade cerebral
<b>Beta waves</b> (ondas beta)	<b>BETA</b>	Atividade cerebral
<b>Muscle contractions</b> (contrações musculares)	<b>CONTRACTIONS</b>	Atividade muscular
<b>Delta waves</b> (ondas delta)	<b>DELTA</b>	Atividade cerebral
<b>Pupil dilation</b> (dilatação da pupila)	<b>DILATION</b>	Atividade ocular
<b>Corrugator supercilli muscle</b> (atividade do...)	<b>EMGCOR</b>	Atividade muscular
<b>Zygomaticus major muscle</b>	<b>EMGZYG</b>	Atividade muscular
<b>Eye horizontal movement</b> (movimento horizontal do olho)	<b>EOGH</b>	Atividade ocular
<b>Eye vertical movement</b> (movimento vertical do olho)	<b>EOGV</b>	Atividade ocular
<b>Eye fixation</b> (fixação do olhar)	<b>FIXATION</b>	Atividade ocular
<b>Frowning</b> (franzir de sobrancelhas, ar carrancudo)	<b>FROWNING</b>	Atividade muscular
<b>Gamma waves</b> (ondas gamma)	<b>GAMMA</b>	Atividade cerebral
<b>Hemisphere activity</b> (atividade dos hemisférios esquerdo e direito)	<b>HEMISPHERE</b>	Atividade cerebral

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Heart Rate Variability Index</b>	<b>HRVI</b>	Atividade cardíaca
<b>Heart Rate Variability Triangular Index</b>	<b>HRVTI</b>	Atividade cardíaca
<b>Levator labii superioris</b>	<b>LEVATOR</b>	Atividade muscular
<b>Meditation level</b> (nível de meditação)	<b>MEDITATION</b>	Atividade cerebral
<b>Muscle</b> (atividade muscular)	<b>MUSCLE</b>	Atividade muscular
<b>pNNx</b> (percentagem de intervalos N-N que diferem em mais que $x$ milissegundos)	<b>PNNX</b>	Atividade cardíaca
<b>Eye saccade</b> (quick eye movements)	<b>SACCADE</b>	Atividade ocular
<b>Standard Deviation of N-N intervals</b>	<b>SDNNI</b>	Atividade cardíaca
<b>Smiling</b> (sorrindo)	<b>SMILING</b>	Atividade muscular
<b>Muscle tension</b> (tensão muscular)	<b>TENSION</b>	Atividade muscular
<b>Theta waves</b> (ondas theta)	<b>THETA</b>	Atividade cerebral
<b>Triangular interpolation of N-N Interval Histogram</b>	<b>TINN</b>	Atividade cardíaca
<b>CONTEXTO SOCIAL E PSICOLÓGICO</b>		
<b>Afiinity</b> (afinidade com os interlocutores)	<b>AFFINITY</b>	(utilizado na variável SOCIAL)
<b>Agreeableness</b>	<b>AGREEABLENESS</b>	(utilizado na variável PERSON)
<b>Answer</b> (chamadas como resposta a outras chamadas)	<b>ANSWER</b>	(utilizado nas variáveis CALL, SMS e EMAIL)
<b>Awakenings</b> (despertares durante o sono)	<b>AWAKENINGS</b>	(utilizado na variável SLEEP)
<b>Categorical data</b> (dados qualitativos nominais, ordinais, escalas, etc.)	<b>CATEGORICAL</b>	(utilizado nos questionários)
<b>Classroom</b> (tempo dispendido em salas de aula físicas)	<b>CLASSROOM</b>	(utilizado na variável ACADCL)
<b>Conscientiousness</b>	<b>CONSCIENTIOUSNESS</b>	(utilizado na variável PERSON)
<b>Controllability</b> (controlabilidade)	<b>CONTROLLABILITY</b>	(utilizado na variável STRESS)
<b>Devices</b> (número de dispositivos detetados na proximidade)	<b>DEVICES</b>	(utilizado na variável PROXIMITY)
<b>Effort</b> (esforço)	<b>EFFORT</b>	(utilizado na variável STRESS)
<b>Extraversion</b>	<b>EXTRAVERSION</b>	(utilizado na variável PERSON)
<b>Group work</b> (trabalhos de grupo)	<b>GROUPWORK</b>	(utilizado na variável ACADCL)
<b>Importante</b> (importância)	<b>IMPORTANCE</b>	(utilizado na variável STRESS)
<b>Incoming</b> (chamadas, SMS e emails recebidos)	<b>INCOMING</b>	(utilizado nas variáveis CALL, SMS e EMAIL)
<b>Iniated only</b> (chamadas apenas iniciadas)	<b>INITIATEDONLY</b>	(utilizado nas variáveis CALL, SMS e EMAIL)
<b>Interactions</b> (qualidade das interações sociais)	<b>INTERACTIONS</b>	(utilizado na variável SOCIAL)
<b>Interlocutors</b> (número de interlocutores)	<b>INTERLOCUTORS</b>	(utilizado nas variáveis CALL, SMS e EMAIL)
<b>Laboratories</b> (tempo dispendido em laboratórios)	<b>LAB</b>	(utilizado na variável ACADCL)
<b>Last stress event</b> (último evento stressante)	<b>LASTSTRESS</b>	(utilizado na variável STRESS)
<b>Latitude</b> (Global Position System...)	<b>LATITUDE</b>	(utilizado na variável LOCAL)
<b>Longitude</b> (Global Position System...)	<b>LONGITUDE</b>	(utilizado na variável LOCAL)
<b>Missed call</b> (chamadas não atendidas)	<b>MISSEDCALL</b>	(utilizado nas variáveis CALL, SMS e EMAIL)
<b>Neuroticism</b>	<b>NEUROTICISM</b>	(utilizado na variável PERSON)
<b>Online class</b> (tempo dispendido em salas de aula virtuais)	<b>ONLINECLASS</b>	(utilizado na variável ACADCL)
<b>Openness</b>	<b>OPENNESS</b>	(utilizado na variável PERSON)
<b>Outgoing</b> (chamadas efetuadas, SMS e emails enviados)	<b>OUTGOING</b>	(utilizado nas variáveis CALL, SMS e EMAIL)

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Overcommitment (capacidade de superação)	OVERCOMMITMENT	(utilizado na variável STRESS)
Predictability (previsibilidade)	PREDICTABILITY	(utilizado na variável STRESS)
Reward (recompensa)	REWARD	(utilizado na variável STRESS)
Regions of Interest (locais de interesse)	ROI	(utilizado na variável LOCAL)
Seminars (tempo dispendido em seminários)	SEMINAR	(utilizado na variável ACADCL)
Sleep conditioners (condicionantes do sono)	SLEEPCONDITIONERS	(utilizado na variável SLEEP)
Sleep kind (tipo de sono)	SLEEPKIND	(utilizado na variável SLEEP)
Unpleasantness (desagradabilidade)	UNPLEASANTNESS	(utilizado na variável STRESS)
Wakeup kind (tipo de acordar)	WAKEUPKIND	(utilizado na variável SLEEP)

### 5.1. EXPRESSÃO FACIAL, ORAL E POSTURA CORPORAL

Nesta secção incluem-se as propriedades relacionadas com a análise da expressão facial, oral e postura corporal, e que são essencialmente baseadas na análise de VIDEO, AUDIO e PICTURES.

Na expressão facial e postura corporal são extraídas propriedades a partir de VIDEO e PICTURES. São várias as propriedades identificadas nesta secção: *clusters* <CLUSTERS> (e.g. para analisar VIDEO, Lee et al. fizeram CLUSTERING para reconhecimento de partes da face para depois calcular o DISPLACEMENT geométrico de algumas zonas (S. H. Lee et al., 2016)); iris do olho <IRIS> e as extremidades dos olhos <EYECORNERS> (e.g. Soleymani et al. utilizaram a IRIS e os EYECORNERS como pontos de referência (Soleymani et al., 2013)); franzir dos lábios <LIPSPUCKER>; Limpar dos lábios <LIPWIPE>; abertura e alongamento da boca <MOUTHOPENING> <MOUTHSTRETCH>; extremidades da boca <MOUTHCORNERS>; morder os lábios <LIPBITE>; elevação ou descida das sobrancelhas <BROWSRAISING>; cruzamento de braços <CROSSEDARMS>; costas direitas <ERECTBACK>; postura sentada <SITTINGPOSTURE>; nariz enrugado <WRINKLEDNOSE>; testa enrugada <WRINKLEDFH>; pálpebra enrugada <WRINKLEDEL>; olhos enrugados <WRINKLEDEYES>; e batidas dos dedos <FINGERTAPPING>.

Mais especificamente na expressão facial, os autores utilizam estratégias baseadas na aparência analisando texturas, fissuras e relevos (Turan et al., 2015). Investigadores como Turan et al., (Turan et al., 2015), Shan et al. (Shan, Gong, & McOwan, 2009), Yang et al. (S. Yang & Bhanu, 2011), Dhall et al. (Dhall et al., 2011) e Liu et al. (S. Liu, Zhang, & Liu, 2014), utilizaram descritores por serem mais adequados ao reconhecimento da raça, menos sensíveis à intensidade luminosa e menos dependentes da pose das pessoas nas imagens e vídeos. De entre os descritores presentes na literatura, destacam-se: *local binary pattern* <LBP>; *local phase quantization* <LPQ>; *weber local descriptor* <WLD>; *pyramid of histogram of oriented gradients* <PHOG>; e os *gabor wavelets* <GABOR>. O LBP é o descritor relativo à textura com base na intensidade. O LPQ é também descritor da textura mas com base na análise do *blur*. O descritor WLD relaciona o estímulo da imagem com a intensidade do estímulo original (lei de Weber). O PHOG é o descritor usado para reconhecimento de objetos. Por fim, os filtros GABOR facilitam a representação de propriedades faciais (Shen, Bai, & Fairhurst, 2007). Estes descritores são muito usados e conseguem representar expressões faciais a vários níveis: intensidade; fase; e forma (Turan et al., 2015).

Na expressão oral foram várias as propriedades encontradas: os *Mel Frequency Cepstral Coefficients* <MFCC> são ideais para processar as propriedades relacionadas com os problemas de reconhecimento emocional (Sato, N.; Obuchi, 2007) (Korkmaz & Atasoy, 2015) (são muito usados em sistemas de reconhecimento automático de discurso oral e de oradores (Cryptography, 2009), porque imitam o funcionamento do ouvido humano (Korkmaz & Atasoy,

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

2015)); o *Teager Energy* <TEAE>; *Discrete Wavelet Transform coefficients* <DWTC>; *Linear Predictive Cepstral Coefficients* <LPCC>; *Mel Energy Spectral Dynamic Coefficients* <MEDC>; *shimmer* <SHIM> (frequência de alteração da variabilidade de pico para pico da amplitude); *Spectral Roll Off* <SPRO>; *spectral flux* <SPFL>; *Spectral Centroid* <SPCE>; e *Harmonic to Noise Ratio* <HNR>; e o *zero Crossing Rate* <ZCR> representa a velocidade de alteração de sinal (e.g. positivo / negativo) num determinado periodo de tempo (Lalitha et al., 2015).

Identificaram-se ainda outras propriedades menos utilizadas: Chen et al. calcularam o *contour* <CONTOUR> do PITCH (L. S. Chen et al., 1998); Singh et al. utilizaram uma estimativa para a postura corporal das pessoas (*stick pose*) <SINGH> (Singh et al., 2015).

INVESTIGAÇÃO	PROPRIEDADES EXTRAÍDAS	
	EXP. FACIAL, ORAL E POSTURA CORPORAL	OUTRAS
Perdiz et al. (Perdiz et al., 2017) e (Phinyomark et al., 2012)	(HEAD) <ANGLE>.	(CONTEXTO FISIOLÓGICO) (EMG) <WL, WAMP, AR, MAV, MAVS>, [EMG] <<EMGCOR, EMGZYG> <MAX, MIN>> e (EOG) <SACCADE <THRESHOLD, MAX>>.
S. H. Lee et al. (S. H. Lee et al., 2016)	[FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)] <LBP, LPQ, GABOR, DISTANCE, SHAPE, CLUSTERS <CENTROID>, DISPLACEMENT>.	(OUTRAS) {HAC}.
Eckert et al. (Eckert et al., 2016)	[FACS, CAU] <THRESHOLD, SHAPE <AREA, DISTANCE>>.	
Gogia et al. (Gogia et al., 2016)	(HEAD) <ANGLE <TIMING>>.	(CONTEXTO FISIOLÓGICO) [EEG] <THRESHOLD, MEDITATION, ATTENTION>.
Z. Zhang et al. (Z. Zhang et al., 2016)	(HEAD) <GABOR>, [HEAD] <POSITION, ANGLE <STD>> e [FACS] <SHAPE>.	(CONTEXTO SOCIAL E PSICOLÓGICO) [EMOTIONS] <CATEGORICAL>.
Adams & Robinson (Adams & Robinson, 2015)	(HEAD) <ANGLE> e [FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)] <INTENSITY>.	(CONTEXTO FISIOLÓGICO) (GAZE) <DIRECTION>.
Turan et al. (Turan et al., 2015)	(FACE) <LBP, LPQ, WLD, PHOG> e (EYES) <DISTANCE>.	
Korkmaz & Atasoy (Korkmaz & Atasoy, 2015)	(VOLUME) <MEAN, MEDIAN, SKEWNESS, KURTOSIS, MAX, MIN, AMP> e [SPEECH [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]] <MFCC <MEAN, MEDIAN, SKEWNESS, KURTOSIS, MAX, MIN, AMP, ZCR>>.	
Lalitha et al. (Lalitha et al., 2015)	(SPEECH) <TEAE, DWTC, LPCC, MEDC, SHIM, SPRO, SPFL, SPCE, HNR, ZCR>.	
Singh et al. (Singh et al., 2015)	[SHOULDERS, HANDS] <SINGH, SLOPE, ANGLE>.	
Saha et al. (Saha et al., 2014)	[HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN] <POSITION, ANGLE, DISTANCE>.	(OUTRAS) (ACC) <MAX, SPEED <SUBTRACT <DISPLACEMENT>>>.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Agrawal et al.</b> (Agrawal et al., 2013)</p>	<p>[EYES, LIPS] &lt;CENTROID &lt;AREA&gt;, CORRELATION &lt;THRESHOLD&gt;&gt;.</p>	
<p><b>Soleymani et al.</b> (Soleymani et al., 2013)</p>	<p>[HEAD] &lt;POSITION&gt;, [EYES] &lt;IRIS &lt;MEAN&gt;, [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] &lt;DISTANCE&gt;, [EYES, EYEBROWS, LIPS] &lt;EYECORNERS &lt;MEAN, ANGLE&gt;&gt; e [LIPS, MOUTH] &lt;DISTANCE&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> (EEG) &lt;PSD &lt;THETA, ALPHA, BETA, GAMMA&gt;, SUBTRACT &lt;PSD &lt;HEMISPHERE &lt;LEFT, RIGHT&gt;&gt;&gt;&gt; e (EEG) e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] &lt;CORRELATION, MEAN, STD&gt;. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) &lt;CATEGORICAL&gt;.</p>
<p><b>Vermun et al.</b> (Vermun et al., 2013)</p>	<p>[HEAD] &lt;MOTION, ANGLE&gt;, [LIPS] &lt;LIPSPUCKER&gt;, [MOUTH] &lt;MOUTHOPENING&gt;, (EYEBROWS) &lt;BROWSRAISING&gt;, [ARMS] &lt;CROSSEDARMS&gt;, [HIP, SHOULDERS, KNEES] &lt;ERECTBACK, SITTINGPOSTURE &lt;LEFT, RIGHT, CENTER&gt;&gt; e [HIP, KNEES] &lt;CENTER &lt;ANGLE&gt;&gt;.</p>	
<p><b>Yang &amp; Bhanu</b> (S. Yang &amp; Bhanu, 2011)</p>	<p>[HEAD, FACE] &lt;LBP, LPQ&gt;.</p>	
<p><b>Dhall et al.</b> (Dhall et al., 2011)</p>	<p>[FACE] &lt;LPQ, PHOG&gt;.</p>	
<p><b>H. Wang et al.</b> (H. Wang et al., 2010)</p>	<p>[EYES] &lt;STATUS, THRESHOLD, LBP, PERIODS &lt;RATIO &lt;STATUS, DURATION&gt;&gt;&gt;.</p>	
<p><b>Gunes &amp; Piccardi</b> (Gunes &amp; Piccardi, 2007)</p>	<p>[LIPS] &lt;LIPEBITE, LIPEWIPE, STATUS, LIPSPUCKER&gt;, [MOUTH] &lt;MOUTHSTRETCH, STATUS, MOUTHCORNERS&gt;, [EYES] &lt;MOTION, SPEED, WRINKLEDEYES&gt;, [EYEBROWS] &lt;BROWSRAISING, SHAPE&gt;, [EYELIDS] &lt;POSITION, WRINKLEDEL&gt;, [CHEEKS, JAW] &lt;POSITION&gt;, [NOSE] &lt;WRINKLEDNOSE&gt;, [FOREHEAD] &lt;WRINKLEDFH&gt;, [HANDS, PALMS] &lt;POSITION&gt;, [FINGERS] &lt;MOTION, FINGERTAPPING, POSITION&gt;, [HANDS, FISTS] &lt;STATUS&gt;, [SHOULDERS] &lt;MOTION&gt; e [SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK] &lt;CENTROID, AREA, RATIO &lt;DILATION&gt;&gt;.</p>	
<p><b>Castellano et al.</b> (Castellano et al., 2007)</p>	<p>(ARMS) &lt;MOTION &lt;QUANTITY, MAX, MIN&gt;, SPEED, DISPLACEMENT, SLOPE, AMP, ACC, MAINPEAK &lt;SLOPE, MAX, MIN&gt;, MAX, MEAN, RATIO &lt;MEAN, MAX&gt;, RATIO &lt;MAX, MAINPEAK &lt;DURATION&gt;&gt;, RATIO &lt;MAINPEAK &lt;DURATION&gt;, DURATION&gt;, POWER &lt;CENTROID&gt;, DISTANCE &lt;MAX, CENTROID&gt;, MAX &lt;POSITION&gt;&gt;.</p>	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Sebe et al.</b> (Sebe et al., 2006)	[HEAD] <MOTION <DIRECTION, INTENSITY>>, [SPEECH] <SPEED> e [PITCH] <MAX>.	
<b>Busso et al.</b> (Busso et al., 2004)	(PITCH, VOLUME) <MEAN, STD, MAX, MIN, MEDIAN> e [FOREHEAD, EYEBROWS, EYES, CHEEKS] <CLUSTERS, AREA>.	
<b>Nwe et al.</b> (Nwe et al., 2001)	[SPEECH] <MFCC <POWER>>.	
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	[PITCH] <CONTOUR <MAX, MIN, MEAN, STD, THRESHOLD>>, (SPEECH) <RMS <POWER>> e (PITCH) <CONTOUR> [DY/DX] <MAX, MIN>.	

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado; e <> uma propriedade extraída.

## 5.2. CONTEXTO FISIOLÓGICO

Nesta secção apresentam-se as propriedades específicas de contexto relacionadas com as variáveis de contexto fisiológico.

São várias as propriedades extraídas relacionadas com a atividade cerebral (i.e. EEG): ondas alpha <ALPHA>, beta <BETA>, theta <THETA>, delta <DELTA> e gama <GAMMA> (e.g. Matlovic et al. utilizaram (EEG) [DWT] para extrair ALPHA e BETA (Matlovic et al., 2016), Sano & Eng. calcularam o PSD no domínio das frequências para extrair ALPHA, BETA, THETA e DELTA (Sano & Eng, 2016), e Soleymani et al. utilizaram como propriedades o PSD de THETA, ALPHA, BETA e GAMMA (Soleymani et al., 2013)); nível de meditação <MEDITATION> e atenção <ATTENTION> (Gogia et al. mediram o MEDITATION e ATTENTION em ambientes de aprendizagem a partir do (EEG) (Gogia et al., 2016)); e Matiko et al. utilizaram a atividade dos hemisférios <HEMISPHERE> esquerdo e direito (Matiko et al., 2014).

Também na atividade cardíaca os autores extraem propriedades: o pNNx <PNNX> é uma métrica utilizada na análise do sinal HRV e representa o número médio de vezes por unidade de tempo no qual a alteração de intervalos *normal sinus* N-N excede  $x$  milissegundos (e.g. PNN50 representa a percentagem dos intervalos que sucessivamente diferem em mais de 50 milissegundos (Zenonos et al., 2016)) (Mietus, Peng, Henry, Goldsmith, & AL, 2015) (Electrophysiology, 1996b); o *Heart Rate Variability Index* <HRVI> que representa a divisão do IBI pela altura do histograma de todos os IBI (Zenonos et al., 2016); o *Heart Rate Variability Triangular Index* <HRVTI> é também uma métrica do HRV que representa o integral da densidade dos intervalos N-N dividida pelo máximo da densidade de distribuição (Electrophysiology, 1996b) adequada para utilização em estudos longitudinais (Mehta et al., 2002); o *Triangular Interpolation of N-N Interval Histogram* <TINN> é o tamanho base da distribuição medida como a base de um triângulo aproximando a distribuição do intervalo N-N (Jarkovska et al., 2016) (Electrophysiology, 1996b); e o *Standard Deviation of N-N Intervals* <SDNNI> (análise do SDNN em intervalos) (Bonnemeier et al., 2003).

A atividade muscular é medida essencialmente através da colocação de sensores sobre o grupo de músculos *corrugator supercilli muscle* <EMGCOR>, *zygomaticus major muscle* <EMGZYG> e *Levator labii superioris* <LEVATOR> (e.g. Basu et al. utilizaram o EMGCOR e EMGZYG na sua investigação (Basu et al., 2016), e Vrana que utilizou o EMGCOR, EMGZYG e o LEVATOR (Scott R.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

Vrana, 1993)). Alguns autores caracterizam a atividade muscular através de propriedades que representam a atividade funcional dos músculos (e.g. Mandryk et al. (Mandryk & Atkins, 2007) extraíram o *smiling* e *frowning* do EMG <SMILING> <FROWNING> que representa a atividade dos músculos *zygomaticus major* e *corrugator supercilli* respetivamente (Partala et al., 2005)). Foram ainda identificadas as seguintes propriedades extraídas: contrações musculares <CONTRACTIONS> (e.g. utilizado por Lichtenstein et al. (Lichtenstein, Antje; Oehme, 2008)); tensão muscular <TENSION> (e.g. utilizado por Vrana (Scott R. Vrana, 1993)); e atividade muscular <MUSCLE> (e.g. utilizado Lichtenstein et al. (Lichtenstein, Antje; Oehme, 2008)).

Aos investigadores utilizam também propriedades extraídas relacionadas com a atividade ocular: os movimentos repentinos dos olhos em simultâneo a fixar dois ou mais pontos <SACCADE> (Aracena et al., 2016) (e.g. utilizado por Perdiz et al. (Perdiz et al., 2017)); dilatação <DILATION> da PUPIL (e.g. utilizado por Aracena et al. (Aracena et al., 2016)); fixação do olhar <FIXATION> (e.g. utilizado por Babiker et al. (Babiker et al., 2013)); e movimentação ocular horizontal <EOGH> e vertical <EOGV> (e.g. Cruz et al. detetaram os movimentos do olho aplicando o LDA nos dados recolhidos do EOG com o objetivo de classificar o tipo de movimento (Cruz et al., 2015). Uma das propriedades mais utilizadas ao nível da atividade ocular é a dimensão da PUPIL. Alguns autores referem-se ao tamanho da PUPIL como DIAMETER, outros como SIZE, e outros ainda como DILATION. A DILATION pode referir-se à quantidade de aumento ou diminuição da PUPIL. No entanto, DIAMETER e SIZE são ambos valores que indicam a dimensão da PUPIL. Por este motivo, decidimos unificá-las no token único DIAMETER.

INVESTIGAÇÃO	PROPRIEDADES EXTRAÍDAS	
	CONTEXTO FISIOLÓGICO	OUTRAS
Perdiz et al. (Perdiz et al., 2017) e (Phinyomark et al., 2012)	(EMG) <WL, WAMP, AR, MAV, MAVS>, [EMG] <<EMGCOR, EMGZYG> <MAX, MIN>> e (EOG) <SACCADE <THRESHOLD, MAX>>.	(EXP. FACIAL, ORAL E POSTURA CORPORAL) (HEAD) <ANGLE>.
Matlovic et al. (Matlovic et al., 2016)	(EEG) <<ALPHA, BETA> <STRENGTH, SUBTRACT, POWER, MEAN, RATIO>>.	
Gogia et al. (Gogia et al., 2016)	[EEG] <THRESHOLD, MEDITATION, ATTENTION>.	(EXP. FACIAL, ORAL E POSTURA CORPORAL) (HEAD) <ANGLE <TIMING>>.
Sano & Eng (Sano & Eng, 2016)	(EEG) <PSD <PERIODS <<ALPHA, BETA, THETA, DELTA>>, AMP <MEAN, STD, MEDIAN>>, [EDA] <THRESHOLD, PKF <MEAN, STD, MEDIAN>> e [EDA] e (ST) <PERIODS <ADL <AMP <MEAN, MEDIAN, STD>>>>.	(CONTEXTO SOCIAL E PSICOLÓGICO) (AGE, PERSON, ACADGR) <MEAN, MEDIAN, STD>, (STRESS, HEALTH, ANXIETY, ACADDG, ACADCL, ACADGR, MOOD, HAPPY, ALERT, ENERGY, CALM, PERSON) <CATEGORICAL <MEAN, MEDIAN, STD>>, (PHYSI) <CATEGORICAL <DURATION>>, (SLEEP) e [ACC] <<MOTION <LEVEL>> <SLEEPKIND>>, [SLEEP] <<WAKEUPKIND, DURATION, COUNT, TIMING, REGULARITY, LATENCY, AWAKENINGS> <MEAN, MEDIAN, STD>>, (NAP) <DURATION, COUNT>, (EMAIL) <<OUTGOING, INCOMING, INTERLOCUTORS> <PERIODS <COUNT, MEAN, STD>>, (CALL) <DURATION, TIMING <MEAN, MEDIAN, STD>, INTERLOCUTORS <OUTGOING, INCOMING> <COUNT>>, (SMS) <TIMING <MEAN, MEDIAN, STD>, COUNT, INTERLOCUTORS, INCOMING, PERIODS <OUTGOING <COUNT>>>, (SOCIAL, FTF) <<AFFINITY, <INTERACTIONS <QUALITY>> <COUNT, TIMING, REGULARITY>>, (SCREEN) <COUNT, TIMING, PERIODS <DURATION>>, (LOCAL) <PERIODS <DISTANCE <MEDIAN, STD>>>, (CAFFEI) <LASTTIME>, (ACADST, ACADCL) <DURATION> e (ACADCL) <<CLASSROOM,

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		ONLINECLASS, SEMINAR, LAB, GROUPWORK> <DURATION>>. <b>(OUTRAS)</b> [ACC] <MEAN, STD, MEDIAN, MAG <THRESHOLD>, MOTION <LEVEL>, <MEAN, STD>>, [ACC [ADL]] <PERIODS <COUNT, MEAN, MEDIAN, STD>> e (LIGHT) <PERIODS <MEAN, STD>>.
<b>Zhao et al.</b> (Zhao et al., 2016)	[IBI] <SDNNI, PNNX, HRVTI, TINN, HR <MEAN, STD>, PSD <LF/HF>, POINTCARE <STD>, ENTROPY, DFA> e [RESP] <PKF, MEAN, MEDIAN, PSD <PLF, PHF>, POINTCARE <STD>, DFA>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> [EMOTIONS] <CATEGORICAL>.
<b>Zenonos et al.</b> (Zenonos et al., 2016)	[IBI] <MEAN, STD, PNNX, HRVI, TINN, POINCARE <STD>>, [IBI [BANDS]] <PSD <LF/HF>> e (HR) <ENTROPY, DFA>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (MOOD, EMOTIONS) <CATEGORICAL>.
<b>Basu et al.</b> (Basu et al., 2016)	(EMG) <EMGCOR, EMGZYG>, (ECG, HR, PR, RESP(RR), EDA, ST, EMG <EMGCOR, EMGZYG>) <MEAN, STD, MAV1D, MAV2D> e [ECG, HR, PR, RESP(RR), EDA, ST, EMG <EMGCOR, EMGZYG>] <MAV1D, MAV2D>.	
<b>Aracena et al.</b> (Aracena et al., 2016)	(PUPIL) <DIAMETER>, [PUPIL] <DILATION <DIAMETER>, SIZE <MEAN>> e [GAZE] <DIRECTION>.	
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	(GAZE) <DIRECTION>.	<b>(EXP. FACIAL, ORAL E POSTURA CORPORAL)</b> (HEAD) <ANGLE> e [FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)] <INTENSITY>.
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)	[[[ECG, ICG](PEP, PTT), ICG, NIBP, RESP(RR), EDA] <MEAN, MEDIAN, STD>.	
<b>Jaques et al.</b> (Jaques et al., 2015)	(EDA) [RAW, FINALRAW, DY/DX] <PERIODS <MEAN, MAX, MIN>>, [EDA [DY/DX]] <THRESHOLD, AMP, DURATION, SHAPE, PERIODS <COUNT>, INTEGRAL, RISETIME> e [ST] <PERIODS>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (SOCIAL, CAFFEI, ALCOH, DRUGS) <CATEGORICAL>, (CALL, SMS, SCREEN) <STD>, (CALL, SMS, SCREEN) <PERIODS <MEAN, MEDIAN>>, (CALL, SMS, SCREEN, ACADCL, PHYSI, ACADEX) <COUNT>, (CALL, SCREEN, ACADCL, PHYSI, ACADEX, ACADST) <DURATION>, (SLEEP, NAP) <PERIODS <DURATION>>, (CALL, SMS) <TIMING, <INCOMING, OUTGOING, INTERLOCUTORS> <COUNT>>, (LOCAL) <<LATITUDE, LONGITUDE> <MEDIAN>> e [LOCAL [PATHSTAKEN]] <DISTANCE>. <b>(OUTRAS)</b> (ACC) <MAG> e [ACC] <PERIODS>.
<b>Cruz et al.</b> (Cruz et al., 2015)	[EOG] <<EOGH, EOGV> <THRESHOLD, MAX, MIN, MEAN, AMP>>.	
<b>Matiko et al.</b> (Matiko et al., 2014)	(EEG) <HEMISPHERE <LEFT, RIGHT>, ALPHA <MEAN, STD, MAV1D, MAV2D, POWER>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>. <b>(OUTRAS)</b> (EEG) <MATIKO>.
<b>Soleymani et al.</b> (Soleymani et al., 2013)	(EEG) <PSD <THETA, ALPHA, BETA, GAMMA>, SUBTRACT <PSD <HEMISPHERE <LEFT, RIGHT>>>> e (EEG) e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] <CORRELATION, MEAN, STD>.	<b>(EXP. FACIAL, ORAL E POSTURA CORPORAL)</b> [HEAD] <POSITION>, [EYES] <IRIS <MEAN>, [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] <DISTANCE>, [EYES, EYEBROWS, LIPS] <EYECORNERS <MEAN, ANGLE>> e [LIPS, MOUTH] <DISTANCE>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		(EMOTIONS) <CATEGORICAL>.
<b>Kusserow et al.</b> (Kusserow et al., 2013)	[HR] <MAX>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (MOOD, STRESS) <CATEGORICAL>. <b>(OUTRAS)</b> (ACC) <MOTION>.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	(EMG) <EMGCOR, EMGZYG>, (ECG(HRV), RESP, EDA, EMG <EMGCOR, EMGZYG>) <MEAN, MEDIAN, STD, MAX, MIN, AMP>, (EDA) <RATIO <2DIFF, MIN>, RATIO <2DIFF, MAX>, RATIO <1DIFF, MIN>, RATIO <1DIFF, MAX>>, (EMG <EMGZYG>) <RATIO <1DIFF, MAX>, RATIO <1DIFF, MIN>, SUBTRACT <2DIFF, MEAN>, RATIO <2DIFF, MIN>, RATIO <2DIFF, MAX>> e (RESP) <SUBTRACT <2DIFF, MIN>, SUBTRACT <AMP, 2DIFF, MAX>, RATIO <2DIFF, MAX>, RATIO <1DIFF, MAX>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>. <b>(OUTRAS)</b> {AUBT}.
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)	[NIBP] <MEAN>.	
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	[EDA] <SLOPE <THRESHOLD <COUNT>>> e [EDA] <PERIODS <AMP <MEAN, STD, MEDIAN>>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (SCREEN) <PERIODS <COUNT, STD>>, (LOCAL) <<DISTANCE, RADIUS> <MEDIAN, STD>>, (SLEEP) <<DURATION, TIMING, QUALITY> <MEAN, STD, MEDIAN>>, (SLEEP) <SLEEPCONDITIONERS>, (ELECTR) <<USAGE <LASTTIME>> <MEAN, STD, MEDIAN>>, (HEALTH, MOOD, ALERT, TIRED, STRESS) <<LEVEL <PERIODS, TIMING>> <MEAN, STD, MEDIAN>>, (NAP) <TIMING, DURATION>, (CAFFEI) <<COUNT> <MEAN, STD, MEDIAN>>, (ALCOH) <<LASTTIME, COUNT, TIMING> <MEAN, STD, MEDIAN>>, (PERSON) <EXTRAVERSION, NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS>, (CALL) <PERIODS <TIMING, DURATION, COUNT, RATIO> <MEAN, STD, MEDIAN>>>>, (CALL) <<INCOMING, OUTGOING> <TIMING, DURATION, COUNT, RATIO> <MEAN, STD, MEDIAN>>, (CALL) <<INTERLOCUTORS> <MEAN, STD, MEDIAN>>, (CALL) <<MISSEDCALL <MEAN, STD, MEDIAN>>, RATIO <MISSEDCALL <OUTOING, INCOMING>>>>, (SMS) <PERIODS <<TIMING, SIZE, COUNT, RATIO> <MEAN, STD, MEDIAN>>>>, (SMS) <<SIZE <INCOMING, OUTGOING>> <MEAN, STD, MEDIAN>> e (SMS) <<INTERLOCUTORS> <MEAN, STD, MEDIAN>>.
<b>Raudonis</b> (Raudonis, 2013)	[PUPIL] <DIAMETER <MIN, MAX>, LOCATION <THRESHOLD> e (EYES) <MOTION <SPEED>>.	
<b>Kawai et al.</b> (Kawai et al., 2013)	[PUPIL] <DIAMETER, AREA, MOTION, LOCATION>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Babiker et al.</b> (Babiker et al., 2013)	[PUPIL] <DIAMETER <DILATION, MEAN, STD>>, (EYES) <MOTION> e (GAZE) <SACCADES, FIXATION>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)	(EEG) <ALPHA, BETA THETA, DELTA>.	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>C. Y. Chang et al.</b> (Chang et al., 2012)	[BVP] e [ECG, BVP, PR] <MAX>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)	[ECG(HRV)] <PSD, MEAN, MIN, MAX, VAR, STD, SKEWNESS>, (PPG) <MEAN, VAR, STD, SKEWNESS, KURTOSIS> e [PUPIL] <DILATION, DIAMETER <MEAN, MAX, KURTOSIS>>.	
<b>Hernandez et al.</b> (Hernandez et al., 2011)	[EDA] [PEAKDETECT] <MEAN> e [EDA] <MEAN, DURATION, MAX, MIN, STD, SLOPE, ZEROCROSSINGS <COUNT>, QUANTILE <THRESHOLD>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (STRESS) <CATEGORICAL>, (CALL) [LABELING] <COUNT, MEAN, DURATION, MAX, MIN, STD, SLOPE, ZEROCROSSINGS <COUNT>, QUANTILE <THRESHOLD>>.
<b>Bos</b> (Bos, 2010)	[EEG] <ALPHA, BETA, RATIO <BETA, ALPHA>, POWER <ALPHA>, POWER <BETA>, POWER <ALPHA, BETA>, RATIO <BETA, POWER <ALPHA>>, RATIO <POWER <BETA>, POWER <ALPHA>>>.	
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	(EEG) <ALPHA, THETA, BETA, DELTA, GAMMA> e (EEG) [FD] <MEAN, HEMISPHERE <LEFT, RIGHT>, THRESHOLD>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL, LEVEL>.
<b>Setz et al.</b> (Setz et al., 2010)	(EDA) [PEAKDETECT] <RATIO <COUNT, DURATION>, HEIGHT <MEAN>, TIMING, QUANTILE <THRESHOLD>> e [EDA] <PHASES <LEVEL <MEAN, MAX, MIN, SLOPE>>>.	
<b>J. Kim &amp; André</b> (J. Kim & André, 2008)	(ECG(HR, HRV)) [FOURIER [BANDS]] <POWER <MEAN, LF/HF>, MAG <MAX>>, (ECG) [PEAKDETECT] <ENTROPY>, [ECG(HRV)] <N-N <MEAN, STD, COUNT>, 1DIFF <STD>, RATIO, R-R <POINCARÉ, STD>, ENTROPY>, [ECG(HRV)] [BANDS] <PSD <POWER, DMF>, LF/HF>, (RESP (RR, BRV)) [BANDS] <POWER <MEAN>, MAG <MAX>>, (RESP (RR)) <MEAN> [LPF] <ZEROCROSSINGS <COUNT>>, (RESP (BRV)) <MEAN, STD, 1DIFF <STD>, POINCARÉ>, (RESP (BRV)) [BANDS] <PKF, POWER, RATIO <POWER, BANDS>>, [EDA] <MEAN, STD, ZEROCROSSINGS <COUNT>, MAX>, [EDA] [DY/DX, D2Y/DX2] <MEAN>, (EMG) <MEAN> e [EMG] <STD>.	
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	(ECG(HRV)) <PNNX>, (ECG(HR, HRV, IBI)) <LF/HF>, (RESP(RR)) <AMP>, (RESP(RDEP)) <COUNT, THRESHOLD>, [EDA] <MEDIAN, AMP, DURATION>, (EDA) [LPF] <TPOINTS <COUNT>, CHANGES>, (EMG) <<EMGCOR, EMGZYG> <CONTRACTIONS <COUNT>, MUSCLE <CHANGES>, STD>> e (ST) <MEAN, CHANGES>.	(EMOTIONS) <CATEGORICAL>.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)	[PUPIL] <DIAMETER <CHANGES, MEAN, AMP, MAX>>, [EDA] <MAX, VAR> e (ECG(HR, IBI)) <PERIODS <MEAN>>.	
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	[EDA] <MIN, MAX>, [EMG] <SMILING, FROWNING> e [ECG(HR), EDA, EMG] <MEAN, STD>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	(PUPIL) <DIAMETER> [-NOISE [FAKEDATA]] <MEAN>, (BVP(ABI)) <PSD <LF/HF>, MEAN, STD, AMP>, [EDA] <COUNT, MEAN, AMP, RISETIME, POWER> e [ST] <SLOPE, MEAN>.	<b>(OUTRAS)</b> (TEMP, LIGHT) <INTENSITY>.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	[EDA] <PERIODS <MAG <SUM>, DURATION <SUM>>, INTEGRAL <SUM>, MEAN, VAR>, (EDA) [PEAKDETECT] <COUNT>, [EMG] [NORM] <MEAN, VAR>, [RESP] <VAR, MEAN>, (RESP) [BANDS] <PSD <POWER <MEAN>>>, (ECG(HR)) <LF/HF, MEAN>, (ECG(HRV)) <PERIODS <LF/HF, LFMF/HF>, MEAN> e [EDA, EMG, RESP, ECG(HR, HRV) e [STRESS] <COVAR, STD>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> [STRESS] <LEVEL <PERIODS <MEAN, STD>>>.
<b>Herbon et al.</b> (Herbon et al., 2005)	(PUPIL) <DILATION> e (HR, EDA, ST, PUPIL) <STD <THRESHOLD>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL <STD>>.
<b>Partala et al.</b> (Partala et al., 2005)	[EMG] <<EMGZYG <SMILING>, EMGCOR <FROWNING>> <MEAN>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Van Eck et al.</b> (van Eck et al., 2005)	[CORT] <TIMING, MEAN, SLOPE, VAR, COVAR, STD>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS) <CATEGORICAL> e (STRESS) <STD, MEAN, TIMING, UNPLEASANTNESS, IMPORTANCE, PREDICTABILITY, CONTROLLABILITY, LASTSTRESS>.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	[HR, EDA, ST] <MIN, MAX, MEAN, VAR>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	[ECG(HRV)] <MEAN, STD, DY/DX>, (EDA) <MEAN, ZEROCROSSINGS <COUNT>, MAX, AMP, DURATION> e [EDA] <DY/DX>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Haag et al.</b> (Haag et al., 2004)	[ECG(HR)] <MIN, MAX, MEAN, STD>, [PPG(BVP(HR))] <MIN, MAX, AMP, STD, RATIO <SUM>>, [EDA] <SLOPE, MEAN, STD>, [RESP] <SLOPE, MEAN, STD, AMP <STD>, SPEED <STD>>, [EMG] <SLOPE, MEAN, STD, AMP> e (ST) <SLOPE, MEAN, STD>.	
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	[PUPIL] <DIAMETER, DILATION <MEAN>, FIXATION, VAR>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	(SEROT) <TIMING, LEVEL, VAR, MEDIAN>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (MOOD, ENERGY, EMOTIONS, ANXIETY) <CATEGORICAL>.
<b>Buchanan &amp; Lovallo</b>	(CORT) <MEAN>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Buchanan & Lovallo, 2001)		(EMOTIONS) <CATEGORICAL>.
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)	[ECG(HR, HRV), EDA, EMG] <MEAN, VAR, 1DIFF <MEAN>, SLOPE>, [EMG] <PERIODS <MEAN>>, [EDA] <PERIODS <MAX, MIN>>, [PPG(BVP(HR))]] <MEAN, 1DIFF <MEAN>> e [RESP] <MEAN, VAR, PSD>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (STRESS) <CATEGORICAL>.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	[ECG(HR, IBI(RMSSD))] <<PERIODS, TIMING, DURATION> <MEAN, STD>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (STRESS) <EFFORT, REWARD, OVERCOMMITMENT, RATIO <EFFORT, REWARD>>, (PHYSI) e (ACC) <MOTION>, (CAFFEI, ALCOH, SMOKING) <COUNT>, (MOOD) <LEVEL> e (PERSON) <CATEGORICAL>.
<b>Ritz et al.</b> (Ritz et al., 2000)	[BP(SBP)] <CHANGES> e [HR, BP(SBP, DBP), ROS, RR, VT, EDA] <MEAN, STD>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)	[EMG] <PHASES <MUSCLE <MEAN>>, [EDA] <PHASES <MEAN, 1DIFF <SLOPE <MEAN>>>>, (PPG(BVP(HR)))] <PHASES <MEAN, 1DIFF <CHANGES <MEAN>>>> e [RESP] <MEAN, VAR, PSD>.	
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(EOG) <QUANTILE <MOTION>, MEDIAN>, [ECG(HR), BP(SBP, DBP), EDA, EOG] <PERIODS <MEDIAN>>, (ST, EMG) <PERIODS <MEDIAN>> e (BP(DBP)) <CHANGES>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	[EMG] <<EMGCOR, EMGZYG, LEVATOR> <PERIODS <TENSION>>>>, [ECG(HR)] <CHANGES> e (EDA) <PERIODS <MEAN>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>R Sinha et al.</b> (R Sinha et al., 1992)	[ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)] <CHANGES <MEAN, STD>, PERIODS <MEAN>> e [BP(SBP, DBP)] <MEAN>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado; e <> uma propriedade extraída.

### 5.3. CONTEXTO SOCIAL E PSICOLÓGICO

Como já referido anteriormente, os instrumentos mais utilizados para a recolha de dados do contexto social e psicológico são os questionários. Estes instrumentos recolhem informação qualitativa nominal ou ordinal, através de escalas representativas de intensidades (e.g. *Likert*), ou um número finito de símbolos, etiquetas ou nomes (e.g. {positivo, negativo}, {regular, irregular}, {pouco, médio, muito}, etc.). Como são possíveis de extrair várias propriedades com base nas respostas dadas pelos respondentes (i.e. COUNT, MEAN, etc.) e os autores analisados nesta revisão bibliográfica nem sempre indicam pormenores das propriedades extraídas a partir dos questionários, decidimos, nestes casos, agrupar as propriedades possíveis de extrair com o *token* <CATEGORICAL> atendendo à natureza categórica dos dados recolhidos. Incluem-se neste grupo as propriedades extraídas a partir de questionários respondidos em vários momentos do experimento (e.g. Sano e Eng utilizaram duas variáveis de contexto para o STRESS (cf. pré e pós-estudo) (Sano & Eng, 2016)).

Com o objetivo de compor a variável de contexto LOCAL: Jaques et al. aplicaram a propriedade estatística MEDIAN à latitude <LATITUDE> e longitude <LONGITUDE> do *Global Position System*

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(GPS) na integração de dados com o WiFi e antenas de operadores móveis (Jaques et al., 2015); Bauer et al. chamaram às localizações habitualmente utilizadas pelos participantes *regions of interest* <ROI> e utilizou esta informação no seu estudo do STRESS (Bauer & Lukowicz, 2012);

Ao nível das variáveis de contexto CALL, SMS e EMAIL, identificaram-se várias propriedades de contexto: comunicações recebidas <INCOMING>; comunicações efetuadas <OUTGOING>; número distinto de interlocutores <INTERLOCUTORS>; quantidade de interações apenas iniciadas e não concretizadas <INITIATEDONLY> (e.g. CALL, SMS ou EMAIL apenas iniciados e não terminados ou enviados); quantidade de interações efetuadas como resposta <ANSWER> (e.g. SMS em resposta a um SMS, CALL resposta a um MISSEDCALL, EMAIL resposta a outro EMAIL); e CALL perdidas (i.e. não atendidas) <MISSEDCALL>.

Relativamente à variável PROXIMITY os investigadores utilizam o número de dispositivos detetados <DEVICES> (e.g. bluetooth) para determinar a existência de outras pessoas nas proximidades. Na variável de contexto SOCIAL, utilizam-se as propriedades: qualidade das interações sociais <INTERACTIONS>; e afinidade com interlocutores (i.e. proximidade na rede social) <AFFINITY>. Quanto à variável ACADCL os investigadores discriminam o tempo despendido: em salas de aula físicas <CLASSROOM>; salas de aula virtuais <ONLINECLASS>; seminários <SEMINAR>; laboratórios <LAB>; e trabalhos de grupo <GROUPWORK>. Relativamente às variáveis ACADST, ACADEX e PHYSI os investigadores utilizam essencialmente propriedades genéricas como DURATION (e.g. Sano & Eng calculou a DURATION de ACADST, ACADEX e PHYSI na sua investigação (Sano & Eng, 2016)).

As propriedades relacionadas com a variável SLEEP incluem propriedades relacionadas com o sono e o acordar: forma de acordar <WAKEUPKIND> (e.g. acordar espontâneo, despertador, etc.); despertar inesperado durante a noite <AWAKENINGS>; diferenciação dos tipos de sono <SLEEPKIND> (e.g. dormir noturno, sesta, etc.); e condicionantes do sono (e.g. hora estabelecida para ir dormir e para acordar) <SLEEPCONDITIONERS>.

Relativamente à variável STRESS são utilizadas propriedades com o objetivo de melhor categorizar o STRESS: *unpleasantness* <UNPLEASANTNESS>; *importance* <IMPORTANCE>; *predictability* <PREDICTABILITY>; *controllability* <CONTROLLABILITY>; último evento stressante <LASTSTRESS>; esforço extrínseco (i.e. nível de exigência no emprego (Vrijkotte et al., 2000)) <EFFORT>; recompensa (e.g. salário, estatuto, apreço, etc. (Vrijkotte et al., 2000)) <REWARD>; e capacidade de superação <OVERCOMMITMENT>. A variável PERSON é muito avaliada através do BFIPT. Este instrumento mede os traços de personalidade com base em cinco dimensões: *extraversion* <EXTRAVERSION>; *neuroticism* <NEUROTICISM>; *agreeableness* <AGREEABLENESS>; *conscientiousness* <CONSCIENTIOUSNESS>; e *openness to experience* <OPENNESS>.

INVESTIGAÇÃO	PROPRIEDADES EXTRAÍDAS	
	CONTEXTO SOCIAL E PSICOLÓGICO	OUTRAS
Z. Zhang et al. (Z. Zhang et al., 2016)	[EMOTIONS] <CATEGORICAL>.	(EXP. FACIAL, ORAL E POSTURA CORPORAL) (HEAD) <GABOR>, [HEAD] <POSITION, ANGLE <STD>> e [FACS] <SHAPE>.
Sano & Eng (Sano & Eng, 2016)	(AGE, PERSON, ACADGR) <MEAN, MEDIAN, STD>, (STRESS, HEALTH, ANXIETY, ACADDG, ACADCL, ACADGR, MOOD, HAPPY, ALERT, ENERGY, CALM, PERSON) <CATEGORICAL <MEAN, MEDIAN,	(CONTEXTO FISIOLÓGICO) (EEG) <PSD <PERIODS <<ALPHA, BETA, THETA, DELTA>>, AMP <MEAN, STD, MEDIAN>>, [EDA] <THRESHOLD, PKF <MEAN, STD, MEDIAN>> e [EDA] e (ST) <PERIODS <ADL <AMP <MEAN, MEDIAN, STD>>>>. (OUTRAS)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	<p>STD&gt;&gt;, (PHYSI) &lt;CATEGORICAL &lt;DURATION&gt;&gt;, (SLEEP) e [ACC] &lt;&lt;MOTION &lt;LEVEL&gt;&gt; &lt;SLEEPKIND&gt;&gt;, [SLEEP] &lt;&lt;WAKEUPKIND, DURATION, COUNT, TIMING, REGULARITY, LATENCY, AWAKENINGS&gt; &lt;MEAN, MEDIAN, STD&gt;&gt;, (NAP) &lt;DURATION, COUNT&gt;, (EMAIL) &lt;&lt;OUTGOING, INCOMING, INTERLOCUTORS&gt; &lt;PERIODS &lt;COUNT, MEAN, STD&gt;&gt;, (CALL) &lt;DURATION, TIMING &lt;MEAN, MEDIAN, STD&gt;, INTERLOCUTORS &lt;OUTGOING, INCOMING&gt; &lt;COUNT&gt;&gt;, (SMS) &lt;TIMING &lt;MEAN, MEDIAN, STD&gt;, COUNT, INTERLOCUTORS, INCOMING, PERIODS &lt;OUTGOING &lt;COUNT&gt;&gt;&gt;, (SOCIAL, FTF) &lt;&lt;AFFINITY, &lt;INTERACTIONS &lt;QUALITY&gt;&gt; &lt;COUNT, TIMING, REGULARITY&gt;&gt;, (SCREEN) &lt;COUNT, TIMING, PERIODS &lt;DURATION&gt;&gt;, (LOCAL) &lt;PERIODS &lt;DISTANCE &lt;MEDIAN, STD&gt;&gt;&gt;, (CAFFEI) &lt;LASTTIME&gt;, (ACADST, ACADEX) &lt;DURATION&gt; e (ACADCL) &lt;&lt;CLASSROOM, ONLINECLASS, SEMINAR, LAB, GROUPWORK&gt; &lt;DURATION&gt;&gt;.</p>	<p>[ACC] &lt;MEAN, STD, MEDIAN, MAG &lt;THRESHOLD&gt;, MOTION &lt;LEVEL&gt;, &lt;MEAN, STD&gt;&gt;, [ACC [ADL]] &lt;PERIODS &lt;COUNT, MEAN, MEDIAN, STD&gt;&gt; e (LIGHT) &lt;PERIODS &lt;MEAN, STD&gt;&gt;.</p>
<p><b>Zhao et al.</b> (Zhao et al., 2016)</p>	<p>[EMOTIONS] &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [IBI] &lt;SDNNI, PNNX, HRVTI, TINN, HR &lt;MEAN, STD&gt;, PSD &lt;LF/HF&gt;, POINTCARE &lt;STD&gt;, ENTROPY, DFA&gt; e [RESP] &lt;PKF, MEAN, MEDIAN, PSD &lt;PLF, PHF&gt;, POINTCARE &lt;STD&gt;, DFA&gt;.</p>
<p><b>Zenonos et al.</b> (Zenonos et al., 2016)</p>	<p>(MOOD, EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [IBI] &lt;MEAN, STD, PNNX, HRVI, TINN, POINCARE &lt;STD&gt;&gt;, [IBI [BANDS]] &lt;PSD &lt;LF/HF&gt;&gt; e (HR) &lt;ENTROPY, DFA&gt;.</p>
<p><b>Jaques et al.</b> (Jaques et al., 2015)</p>	<p>(SOCIAL, CAFFEI, ALCOH, DRUGS) &lt;CATEGORICAL&gt;, (CALL, SMS, SCREEN) &lt;STD&gt;, (CALL, SMS, SCREEN) &lt;PERIODS &lt;MEAN, MEDIAN&gt;&gt;, (CALL, SMS, SCREEN, ACADCL, PHYSI, ACADEX) &lt;COUNT&gt;, (CALL, SCREEN, ACADCL, PHYSI, ACADEX, ACADST) &lt;DURATION&gt;, (SLEEP, NAP) &lt;PERIODS &lt;DURATION&gt;&gt;, (CALL, SMS) &lt;TIMING, &lt;INCOMING, OUTGOING, INTERLOCUTORS&gt; &lt;COUNT&gt;&gt;, (LOCAL) &lt;&lt;LATITUDE, LONGITUDE&gt; &lt;MEDIAN&gt;&gt; e [LOCAL [PATHSTAKEN]] &lt;DISTANCE&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> (EDA) [RAW, FINALRAW, DY/DX] &lt;PERIODS &lt;MEAN, MAX, MIN&gt;&gt;, [EDA [DY/DX]] &lt;THRESHOLD, AMP, DURATION, SHAPE, PERIODS &lt;COUNT&gt;, INTEGRAL, RISETIME&gt; e [ST] &lt;PERIODS&gt;. <b>(OUTRAS)</b> (ACC) &lt;MAG&gt; e [ACC] &lt;PERIODS&gt;.</p>
<p><b>Matiko et al.</b> (Matiko et al., 2014)</p>	<p>EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> (EEG) &lt;HEMISPHERE &lt;LEFT, RIGHT&gt;, ALPHA &lt;MEAN, STD, MAV1D, MAV2D, POWER&gt;&gt;. <b>(OUTRAS)</b> (EEG) &lt;MATIKO&gt;.</p>
<p><b>Bogomolov et al.</b> (Bogomolov et al., 2014)</p>	<p>(STRESS) &lt;CATEGORICAL &lt;SKEWNESS, KURTOSIS&gt;&gt;, (PERSON) &lt;EXTRAVERSION,</p>	<p><b>(OUTRAS)</b> (WEATHER) &lt;PERIODS &lt;TEMP &lt;MEAN&gt;, PRESSURE, PRECIPITATION, HUMIDITY, VISIBILITY, WIND &lt;SPEED&gt;&gt;&gt;.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	<p>NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS&gt;, (CALL) &lt;&lt;INCOMING, OUTGOING, MISSEDCALL&gt; &lt;COUNT&gt;&gt;, (CALL) &lt;INTERLOCUTORS &lt;OUTGOING, INCOMING, MISSEDCALL&gt; &lt;COUNT, ENTROPY&gt;&gt;, (CALL) &lt;RATIO &lt;INTERLOCUTORS &lt;CALL, SMS, PROXIMITY&gt;&gt;&gt;, (SMS) &lt;INCOMING, OUTGOING &lt;COUNT&gt;&gt;, (SMS) &lt;INTERLOCUTORS &lt;INCOMING, OUTGOING&gt; &lt;COUNT, ENTROPY&gt;&gt;, (SMS) &lt;RATIO &lt;INTERLOCUTORS &lt;CALL, SMS, PROXIMITY&gt;&gt;&gt;, (CALL) &lt;PERIODS &lt;INCOMING, OUTGOING&gt;&gt;, (CALL, SMS) &lt;INITIATEDONLY &lt;PERIODS &lt;&lt;COUNT&gt;&gt;, ELAPSEDTIME &lt;MEAN, VAR&gt;&gt;, [SMS] &lt;ANSWER &lt;RATIO, LATENCY&gt;&gt;, (CALL, SMS) &lt;PERIODS &lt;MEAN, MEDIAN, MIN, MAX, QUANTILE, STD, VAR&gt;&gt; e (PROXIMITY) &lt;DEVICES &lt;ELAPSEDTIME &lt;MEAN, VAR&gt;, ENTROPY&gt;, PERIODS &lt;USUAL &lt;COUNT&gt;&gt;&gt;.</p>	
<p><b>Soleymani et al.</b> (Soleymani et al., 2013)</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(EXP. FACIAL, ORAL E POSTURA CORPORAL)</b> [HEAD] &lt;POSITION&gt;, [EYES] &lt;IRIS &lt;MEAN&gt;, [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] &lt;DISTANCE&gt;, [EYES, EYEBROWS, LIPS] &lt;EYECORNERS &lt;MEAN, ANGLE&gt;&gt; e [LIPS, MOUTH] &lt;DISTANCE&gt;.</p> <p><b>(CONTEXTO FISIOLÓGICO)</b> (EEG) &lt;PSD &lt;THETA, ALPHA, BETA, GAMMA&gt;, SUBTRACT &lt;PSD &lt;HEMISPHERE &lt;LEFT, RIGHT&gt;&gt;&gt;&gt; e (EEG) e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] &lt;CORRELATION, MEAN, STD&gt;.</p>
<p><b>Kusserow et al.</b> (Kusserow et al., 2013)</p>	<p>(MOOD, STRESS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [HR] &lt;MAX&gt;.</p> <p><b>(OUTRAS)</b> (ACC) &lt;MOTION&gt;.</p>
<p><b>Alzoubi et al.</b> (Alzoubi et al., 2013)</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> (EMG) &lt;EMGCOR, EMGZYG&gt;, (ECG(HRV), RESP, EDA, EMG &lt;EMGCOR, EMGZYG&gt;) &lt;MEAN, MEDIAN, STD, MAX, MIN, AMP&gt;, (EDA) &lt;RATIO &lt;2DIFF, MIN&gt;, RATIO &lt;2DIFF, MAX&gt;, RATIO &lt;1DIFF, MIN&gt;, RATIO &lt;1DIFF, MAX&gt;&gt;, (EMG &lt;EMGZYG&gt;) &lt;RATIO &lt;1DIFF, MAX&gt;, RATIO &lt;1DIFF, MIN&gt;, SUBTRACT &lt;2DIFF, MEAN&gt;, RATIO &lt;2DIFF, MIN&gt;, RATIO &lt;2DIFF, MAX&gt;&gt; e (RESP) &lt;SUBTRACT &lt;2DIFF, MIN&gt;, SUBTRACT &lt;AMP, 2DIFF, MAX&gt;, RATIO &lt;2DIFF, MAX&gt;, RATIO &lt;1DIFF, MAX&gt;&gt;.</p> <p><b>(OUTRAS)</b> {AUBT}.</p>
<p><b>Sano &amp; Picard</b> (Sano &amp; Picard, 2013b)</p>	<p>(SCREEN) &lt;PERIODS &lt;COUNT, STD&gt;&gt;, (LOCAL) &lt;&lt;DISTANCE, RADIUS&gt; &lt;MEDIAN, STD&gt;&gt;, (SLEEP) &lt;&lt;DURATION, TIMING, QUALITY&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (SLEEP) &lt;SLEEPCONDITIONERS&gt;, (ELECTR) &lt;&lt;USAGE &lt;LASTTIME&gt;&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (HEALTH, MOOD, ALERT, TIRED, STRESS) &lt;&lt;LEVEL</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [EDA] &lt;SLOPE &lt;THRESHOLD &lt;COUNT&gt;&gt;&gt;&gt; e [EDA] &lt;PERIODS &lt;AMP &lt;MEAN, STD, MEDIAN&gt;&gt;&gt;&gt;.</p> <p><b>(OUTRAS)</b> (ACC) &lt;PERIODS &lt;MEDIAN, STD&gt;&gt; e (ACC) &lt;PERIODS &lt;MOTION &lt;LEVEL &lt;MEAN&gt;&gt;&gt;&gt;.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

	<p>&lt;PERIODS, TIMING&gt;&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (NAP) &lt;TIMING, DURATION&gt;, (CAFFEI) &lt;&lt;COUNT&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (ALCOH) &lt;&lt;LASTTIME, COUNT, TIMING&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (PERSON) &lt;EXTRAVERSION, NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS&gt;, (CALL) &lt;PERIODS &lt;TIMING, DURATION, COUNT, RATIO&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;&gt;&gt;, (CALL) &lt;&lt;INCOMING, OUTGOING&gt; &lt;TIMING, DURATION, COUNT, RATIO&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (CALL) &lt;&lt;INTERLOCUTORS&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;, (CALL) &lt;&lt;MISSEDCALL &lt;MEAN, STD, MEDIAN&gt;&gt;, RATIO &lt;MISSEDCALL &lt;OUTOING, INCOMING&gt;&gt;&gt;&gt;, (SMS) &lt;PERIODS &lt;&lt;TIMING, SIZE, COUNT, RATIO&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;&gt;&gt;, (SMS) &lt;&lt;SIZE &lt;INCOMING, OUTGOING&gt;&gt; &lt;MEAN, STD, MEDIAN&gt;&gt; e (SMS) &lt;&lt;INTERLOCUTORS&gt; &lt;MEAN, STD, MEDIAN&gt;&gt;.</p>	
<p><b>Kawai et al.</b> (Kawai et al., 2013)</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [PUPIL] &lt;DIAMETER, AREA, MOTION, LOCATION&gt;.</p>
<p><b>Babiker et al.</b> (Babiker et al., 2013)</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [PUPIL] &lt;DIAMETER &lt;DILATION, MEAN, STD&gt;&gt;, (EYES) &lt;MOTION&gt; e (GAZE) &lt;SACCADES, FIXATION&gt;.</p>
<p><b>LikamWa et al.</b> (LiKamWa et al., 2013)</p>	<p>[MOOD] &lt;PERIODS &lt;COUNT, STD &lt;MEAN, MAX&gt;&gt;&gt;&gt;, (EMAIL, SMS) &lt;INTERLOCUTORS &lt;USUAL &lt;COUNT, SIZE&gt;&gt;&gt;&gt;, (CALL) &lt;INTERLOCUTORS &lt;USUAL &lt;COUNT, DURATION&gt;&gt;&gt;&gt;, (APPS) &lt;COUNT, DURATION&gt; e (BROWSER, LOCAL) &lt;COUNT&gt;.</p>	
<p><b>C. Y. Chang et al.</b> (Chang et al., 2012)</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [BVP] e [ECG, BVP, PR] &lt;MAX&gt;.</p>
<p><b>Bauer &amp; Lukowicz</b> (Bauer &amp; Lukowicz, 2012)</p>	<p>(LOCAL) [USUALPLACES] &lt;DIAMETER &lt;MAX&gt;, DURATION &lt;MEAN, THRESHOLD&gt;&gt;, [LOCAL] &lt;ROI &lt;TIMING, REGULARITY, COUNT &lt;MEAN, AD, STD&gt;&gt;&gt;&gt;, (PROXIMITY) &lt;TIMING, DURATION &lt;THRESHOLD, AD, MEAN, STSD&gt;, COUNT &lt;AD, MEAN, STD&gt;&gt; e (CALL, SMS) &lt;&lt;INCOMING, OUTGOING&gt; &lt;INTERLOCUTORS &lt;COUNT &lt;MEAN, STD&gt;&gt;, COUNT &lt;AD, MEAN, STD&gt;&gt;&gt;&gt;.</p>	
<p><b>Hernandez et al.</b> (Hernandez et al., 2011)</p>	<p>(STRESS) &lt;CATEGORICAL&gt;, (CALL) [LABELING] &lt;COUNT, MEAN, DURATION, MAX, MIN, STD, SLOPE, ZEROCROSSINGS &lt;COUNT&gt;, QUANTILE &lt;THRESHOLD&gt;&gt;.</p>	<p><b>(CONTEXTO FISIOLÓGICO)</b> [EDA] [PEAKDETECT] &lt;MEAN&gt; e [EDA] &lt;MEAN, DURATION, MAX, MIN, STD, SLOPE, ZEROCROSSINGS &lt;COUNT&gt;, QUANTILE &lt;THRESHOLD&gt;&gt;.</p>

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>N. Lane et al.</b> (N. Lane et al., 2011)	(DEPRESSION, SLEEP, WELLBEING) <CATEGORICAL> e [SLEEP, PHYSI, TALK] <DURATION, MEAN, VAR>.	<b>(OUTRAS)</b> (ACC) <MEAN, VARIANCE, PERIODS <MOTION <COUNT, DURATION>>>.
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)	(EMOTIONS) <CATEGORICAL, LEVEL>.	<b>(CONTEXTO FISIOLÓGICO)</b> (EEG) <ALPHA, THETA, BETA, DELTA, GAMMA> e (EEG) [FD] <MEAN, HEMISPHERE <LEFT, RIGHT>, THRESHOLD>.
<b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> (ECG(HRV)) <PNNX>, (ECG(HR, HRV, IBI)) <LF/HF>, (RESP(RR)) <AMP>, (RESP(RDEP)) <COUNT, THRESHOLD>, [EDA] <MEDIAN, AMP, DURATION>, (EDA) [LPF] <TPOINTS <COUNT>, CHANGES>, (EMG) <<EMGCOR, EMGZYG> <CONTRACTIONS <COUNT>, MUSCLE <CHANGES>, STD>> e (ST) <MEAN, CHANGES>.
<b>Mandryk &amp; Atkins</b> (Mandryk & Atkins, 2007)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [EDA] <MIN, MAX>, [EMG] <SMILING, FROWNING> e [ECG(HR), EDA, EMG] <MEAN, STD>.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)	[STRESS] <LEVEL <PERIODS <MEAN, STD>>>.	<b>(CONTEXTO FISIOLÓGICO)</b> [EDA] <PERIODS <MAG <SUM>, DURATION <SUM>>>, INTEGRAL <SUM>, MEAN, VAR>, (EDA) [PEAKDETECT] <COUNT>, [EMG] [NORM] <MEAN, VAR>, [RESP] <VAR, MEAN>, (RESP) [BANDS] <PSD <POWER <MEAN>>>>, (ECG(HR)) <LF/HF, MEAN>, (ECG(HRV)) <PERIODS <LF/HF, LFMF/HF>, MEAN> e [EDA, EMG, RESP, ECG(HR, HRV) e [STRESS] <COVAR, STD>.
<b>Herbon et al.</b> (Herbon et al., 2005)	(EMOTIONS) <CATEGORICAL <STD>>>.	<b>(CONTEXTO FISIOLÓGICO)</b> (PUPIL) <DILATION> e (HR, EDA, ST, PUPIL) <STD <THRESHOLD>>>.
<b>Partala et al.</b> (Partala et al., 2005)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [EMG] <<EMGZYG <SMILING>, EMGCOR <FROWNING>> <MEAN>>>.
<b>Van Eck et al.</b> (van Eck et al., 2005)	(LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS) <CATEGORICAL> e (STRESS) <STD, MEAN, TIMING, UNPLEASANTNESS, IMPORTANCE, PREDICTABILITY, CONTROLLABILITY, LASTSTRESS>.	<b>(CONTEXTO FISIOLÓGICO)</b> [CORT] <TIMING, MEAN, SLOPE, VAR, COVAR, STD>.
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [HR, EDA, ST] <MIN, MAX, MEAN, VAR>.
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [ECG(HRV)] <MEAN, STD, DY/DX>, (EDA) <MEAN, ZEROCROSSINGS <COUNT>, MAX, AMP, DURATION> e [EDA] <DY/DX>.
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [PUPIL] <DIAMETER, DILATION <MEAN>, FIXATION, VAR>.
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)	(MOOD, ENERGY, EMOTIONS, ANXIETY) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> (SEROT) <TIMING, LEVEL, VAR, MEDIAN>.
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> (CORT) <MEAN>.
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)	(STRESS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [ECG(HR, HRV), EDA, EMG] <MEAN, VAR, 1DIFF <MEAN>, SLOPE>, [EMG] <PERIODS <MEAN>>>, [EDA] <PERIODS

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<MAX, MIN>, [PPG(BVP(HR))] <MEAN, 1DIFF <MEAN>> e [RESP] <MEAN, VAR, PSD>.
<b>Vrijkotte et al.</b> (Vrijkotte et al., 2000)	(STRESS) <EFFORT, REWARD, OVERCOMMITMENT, RATIO <EFFORT, REWARD>>, (PHYSI) e (ACC) <MOTION>, (CAFFEI, ALCOH, SMOKING) <COUNT>, (MOOD) <LEVEL> e (PERSON) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [ECG(HR, IBI(RMSSD))] <<PERIODS, TIMING, DURATION>> <MEAN, STD>>.
<b>Ritz et al.</b> (Ritz et al., 2000)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [BP(SBP)] <CHANGES> e [HR, BP(SBP, DBP), ROS, RR, VT, EDA] <MEAN, STD>.
<b>Rajita Sinha</b> (Rajita Sinha, 1996)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> (EOG) <QUANTILE <MOTION>, MEDIAN>, [ECG(HR), BP(SBP, DBP), EDA, EOG] <PERIODS <MEDIAN>>, (ST, EMG) <PERIODS <MEDIAN>> e (BP(DBP)) <CHANGES>.
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [EMG] <<EMGCOR, EMGZYG, LEVATOR>> <PERIODS <TENSION>>>, [ECG(HR)] <CHANGES> e (EDA) <PERIODS <MEAN>>.
<b>R Sinha et al.</b> (R Sinha et al., 1992)	(EMOTIONS) <CATEGORICAL>.	<b>(CONTEXTO FISIOLÓGICO)</b> [ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)] <CHANGES <MEAN, STD>, PERIODS <MEAN>> e [BP(SBP, DBP)] <MEAN>.

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado; e <> uma propriedade extraída.

## 5.4. OUTRAS

Esta secção inclui outras propriedades extraídas não incluídas nas secções anteriores e que estão relacionadas com as outras variáveis de contexto.

A variável de contexto WEATHER foi determinada através da recolha de vários sensores: temperatura ambiente (TEMP) (já apresentada neste documento como variável de contexto); humidade <HUMIDITY>; visibilidade <VISIBILITY>; vento <WIND>; pressão <PRESSURE>; e precipitação <PRECIPITATION>.

Foram também identificadas propriedades extraídas que já haviam sido apresentadas como variáveis recolhidas diretamente do contexto (e.g. Castellano et al. extraíu o <ACC> com base na diferença entre *frames* de VIDEO utilizando o EYESWEB (Castellano et al., 2007)).

Por fim, incluem-se nesta secção também as propriedades específicas dos autores: Matiko et al. criaram uma propriedade oscilatória <MATIKO> que é calculada a partir do máximo e mínimo local do sinal EEG, e que informa como é que o POWER do sinal está relacionado com as ativações e inativações de regiões do cérebro (Matiko et al., 2014).

Também nesta secção foram identificados alguns instrumentos de suporte às propriedades extraídas: S. H. Lee et al. utilizaram o HAC do MATLAB para apoio à determinação de CLUSTERS (S. H. Lee et al., 2016); e Alzoubi et al. utilizaram o AUBT no pré-processamento e na extração de propriedades dos dados fisiológicos (Alzoubi et al., 2013).

INVESTIGAÇÃO	PROPRIEDADES EXTRAÍDAS	
	OUTRAS	ANTERIORES
S. H. Lee et al.	{HAC}.	(EXP. FACIAL, ORAL E POSTURA CORPORAL)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(S. H. Lee et al., 2016)		[FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)] <LBP, LPQ, GABOR, DISTANCE, SHAPE, CLUSTERS <CENTROID>, DISPLACEMENT>.
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)	[ACC] <MEAN, STD, MEDIAN, MAG <THRESHOLD>, MOTION <LEVEL>, <MEAN, STD>>, [ACC [ADL]] <PERIODS <COUNT, MEAN, MEDIAN, STD>> e (LIGHT) <PERIODS <MEAN, STD>>.	<b>(CONTEXTO FISIOLÓGICO)</b> (EEG) <PSD <PERIODS <<ALPHA, BETA, THETA, DELTA>>, AMP <MEAN, STD, MEDIAN>>, [EDA] <THRESHOLD, PKF <MEAN, STD, MEDIAN>> e [EDA] e (ST) <PERIODS <ADL <AMP <MEAN, MEDIAN, STD>>>>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (AGE, PERSON, ACADGR) <MEAN, MEDIAN, STD>, (STRESS, HEALTH, ANXIETY, ACADDG, ACADCL, ACADGR, MOOD, HAPPY, ALERT, ENERGY, CALM, PERSON) <CATEGORICAL <MEAN, MEDIAN, STD>>, (PHYSI) <CATEGORICAL <DURATION>>, (SLEEP) e [ACC] <<MOTION <LEVEL>> <SLEEPKIND>>>, [SLEEP] <<WAKEUPKIND, DURATION, COUNT, TIMING, REGULARITY, LATENCY, AWAKENINGS> <MEAN, MEDIAN, STD>>, (NAP) <DURATION, COUNT>, (EMAIL) <<OUTGOING, INCOMING, INTERLOCUTORS> <PERIODS <COUNT, MEAN, STD>>, (CALL) <DURATION, TIMING <MEAN, MEDIAN, STD>, INTERLOCUTORS <OUTGOING, INCOMING> <COUNT>>, (SMS) <TIMING <MEAN, MEDIAN, STD>, COUNT, INTERLOCUTORS, INCOMING, PERIODS <OUTGOING <COUNT>>>>, (SOCIAL, FTF) <<AFFINITY, <INTERACTIONS <QUALITY>> <COUNT, TIMING, REGULARITY>>, (SCREEN) <COUNT, TIMING, PERIODS <DURATION>>, (LOCAL) <PERIODS <DISTANCE <MEDIAN, STD>>>, (CAFFEI) <LASTTIME>, (ACADST, ACADEX) <DURATION> e (ACADCL) <<CLASSROOM, ONLINECLASS, SEMINAR, LAB, GROUPWORK> <DURATION>>>.
<b>Jaques et al.</b> (Jaques et al., 2015)	(ACC) <MAG> e [ACC] <PERIODS>.	<b>(CONTEXTO FISIOLÓGICO)</b> (EDA) [RAW, FINALRAW, DY/DX] <PERIODS <MEAN, MAX, MIN>>, [EDA [DY/DX]] <THRESHOLD, AMP, DURATION, SHAPE, PERIODS <COUNT>, INTEGRAL, RISETIME> e [ST] <PERIODS>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (SOCIAL, CAFFEI, ALCOH, DRUGS) <CATEGORICAL>, (CALL, SMS, SCREEN) <STD>, (CALL, SMS, SCREEN) <PERIODS <MEAN, MEDIAN>>, (CALL, SMS, SCREEN, ACADCL, PHYSI, ACADEX) <COUNT>, (CALL, SCREEN, ACADCL, PHYSI, ACADEX, ACADST) <DURATION>, (SLEEP, NAP) <PERIODS <DURATION>>, (CALL, SMS) <TIMING, <INCOMING, OUTGOING, INTERLOCUTORS> <COUNT>>, (LOCAL) <<LATITUDE, LONGITUDE> <MEDIAN>> e [LOCAL [PATHSTAKEN]] <DISTANCE>.
<b>Saha et al.</b> (Saha et al., 2014)	(ACC) <MAX, SPEED <SUBTRACT <DISPLACEMENT>>>>.	<b>(EXP. FACIAL, ORAL E POSTURA CORPORAL)</b> [HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN] <POSITION, ANGLE, DISTANCE>.
<b>Matiko et al.</b> (Matiko et al., 2014)	(EEG) <MATIKO>.	<b>(CONTEXTO FISIOLÓGICO)</b> (EEG) <HEMISPHERE <LEFT, RIGHT>, ALPHA <MEAN, STD, MAV1D, MAV2D, POWER>>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)	(WEATHER) <PERIODS <TEMP <MEAN>, PRESSURE, PRECIPITATION, HUMIDITY, VISIBILITY, WIND <SPEED>>>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (STRESS) <CATEGORICAL <SKEWNESS, KURTOSIS>>, (PERSON) <EXTRAVERSION, NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS>, (CALL) <<INCOMING, OUTGOING, MISSEDCALL> <COUNT>>, (CALL) <INTERLOCUTORS <OUTGOING, INCOMING, MISSEDCALL> <COUNT, ENTROPY>>, (CALL)

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		<RATIO <INTERLOCUTORS <CALL, SMS, PROXIMITY>>>, (SMS) <INCOMING, OUTGOING <COUNT>>, (SMS) <INTERLOCUTORS <INCOMING, OUTGOING> <COUNT, ENTROPY>>, (SMS) <RATIO <INTERLOCUTORS <CALL, SMS, PROXIMITY>>>, (CALL) <PERIODS <INCOMING, OUTGOING>>, (CALL, SMS) <INITIATEDONLY <PERIODS <<COUNT>>, ELAPSEDTIME <MEAN, VAR>>, [SMS] <ANSWER <RATIO, LATENCY>>, (CALL, SMS) <PERIODS <MEAN, MEDIAN, MIN, MAX, QUANTILE, STD, VAR>> e (PROXIMITY) <DEVICES <ELAPSEDTIME <MEAN, VAR>, ENTROPY>, PERIODS <USUAL <COUNT>>>>.
<b>Kusserow et al.</b> (Kusserow et al., 2013)	(ACC) <MOTION>.	<b>(CONTEXTO FISIOLÓGICO)</b> [HR] <MAX>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (MOOD, STRESS) <CATEGORICAL>.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)	{AUBT}.	<b>(CONTEXTO FISIOLÓGICO)</b> (EMG) <EMGCOR, EMGZYG>, (ECG(HRV), RESP, EDA, EMG <EMGCOR, EMGZYG>) <MEAN, MEDIAN, STD, MAX, MIN, AMP>, (EDA) <RATIO <2DIFF, MIN>, RATIO <2DIFF, MAX>, RATIO <1DIFF, MIN>, RATIO <1DIFF, MAX>>, (EMG <EMGZYG>) <RATIO <1DIFF, MAX>, RATIO <1DIFF, MIN>, SUBTRACT <2DIFF, MEAN>, RATIO <2DIFF, MIN>, RATIO <2DIFF, MAX>> e (RESP) <SUBTRACT <2DIFF, MIN>, SUBTRACT <AMP, 2DIFF, MAX>, RATIO <2DIFF, MAX>, RATIO <1DIFF, MAX>>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (EMOTIONS) <CATEGORICAL>.
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)	(ACC) <PERIODS <MEDIAN, STD>> e (ACC) <PERIODS <MOTION <LEVEL <MEAN>>>>.	<b>(CONTEXTO FISIOLÓGICO)</b> [EDA] <SLOPE <THRESHOLD <COUNT>>>> e [EDA] <PERIODS <AMP <MEAN, STD, MEDIAN>>>>. <b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (SCREEN) <PERIODS <COUNT, STD>>, (LOCAL) <<DISTANCE, RADIUS> <MEDIAN, STD>>, (SLEEP) <<DURATION, TIMING, QUALITY> <MEAN, STD, MEDIAN>>, (SLEEP) <SLEEPCONDITIONERS>, (ELECTR) <<USAGE <LASTTIME>> <MEAN, STD, MEDIAN>>, (HEALTH, MOOD, ALERT, TIRED, STRESS) <<LEVEL <PERIODS, TIMING>> <MEAN, STD, MEDIAN>>, (NAP) <TIMING, DURATION>, (CAFFEI) <<COUNT> <MEAN, STD, MEDIAN>>, (ALCOH) <<LASTTIME, COUNT, TIMING> <MEAN, STD, MEDIAN>>, (PERSON) <EXTRAVERSION, NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS>, (CALL) <PERIODS <TIMING, DURATION, COUNT, RATIO> <MEAN, STD, MEDIAN>>>>, (CALL) <<INCOMING, OUTGOING> <TIMING, DURATION, COUNT, RATIO> <MEAN, STD, MEDIAN>>, (CALL) <<INTERLOCUTORS> <MEAN, STD, MEDIAN>>, (CALL) <<MISSEDCALL <MEAN, STD, MEDIAN>>, RATIO <MISSEDCALL <OUTOING, INCOMING>>>>, (SMS) <PERIODS <<TIMING, SIZE, COUNT, RATIO> <MEAN, STD, MEDIAN>>>>, (SMS) <<SIZE <INCOMING, OUTGOING>> <MEAN, STD, MEDIAN>> e (SMS) <<INTERLOCUTORS> <MEAN, STD, MEDIAN>>.
<b>N. Lane et al.</b> (N. Lane et al., 2011)	(ACC) <MEAN, VARIANCE, PERIODS <MOTION <COUNT, DURATION>>>>.	<b>(CONTEXTO SOCIAL E PSICOLÓGICO)</b> (DEPRESSION, SLEEP, WELLBEING) <CATEGORICAL> e [SLEEP, PHYSI, TALK] <DURATION, MEAN, VAR>.
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)	(TEMP, LIGHT) <INTENSITY>.	<b>(CONTEXTO FISIOLÓGICO)</b> (PUPIL) <DIAMETER> [-NOISE [FAKEDATA]] <MEAN>, (BVP(ABI)) <PSD <LF/HF>, MEAN, STD, AMP>, [EDA] <COUNT, MEAN, AMP, RISETIME, POWER> e [ST] <SLOPE, MEAN>.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

*() representa um sinal raw; {} um instrumento; [] um sinal pré-processado; e <> uma propriedade extraída.*

## 5.5. ANÁLISE

O quadro seguinte resume as propriedades extraídas identificadas em cada investigação desta revisão bibliográfica.

Após a fase do pré-processamento segue-se a extração de propriedades que possam conter conteúdo emocional (Jerritta et al., 2011). Estas propriedades podem ser vistas como *input* de substituição ou adicional ao *dataset* original, e podem ser extraídas diretamente a partir do sinal recolhido de contexto ou a partir do sinal já pré-processado (Haag et al., 2004). A estratégia seguida na extração de propriedades está relacionada com o desempenho dos algoritmos (Matlovic et al., 2016) (Adams & Robinson, 2015) (Lisetti & Nasoz, 2004).

Esta secção de propriedades extraídas foca-se essencialmente nas propriedades específicas de contexto por causa da sua possível relação com a eficiência dos classificadores na deteção automática de emoções (Matlovic et al., 2016). A forte presença de propriedades genéricas (e.g. matemáticas, análise de sinal), motivou-nos a iniciar com uma apresentação resumida destas propriedades amplamente utilizadas pelos investigadores. No entanto, apesar de se poder vir a utilizar essas propriedades genéricas não utilizadas nas investigações em revisão, pretende-se manter o foco nas propriedades específicas de contexto por se acreditar ser este o tipo de propriedades que mais poderá conduzir a um aumento da precisão dos algoritmos.

As investigações que utilizam a expressão facial, oral e postura corporal para deteção emocional, utilizam muito descritores como propriedades extraídas (e.g. LBP, LPQ, GABOR, MFC), e são poucas as que extraem propriedades de outras modalidades em simultâneo. No entanto, as emoções podem ser descodificadas a partir de outras propriedades extraídas (e.g. POSITION e ANGLE das variáveis de contexto HANDS, HEAD, SHOULDERS e SPIN) (Saha et al., 2014). A MEAN, STD, MAX, MIN, COUNTOUR e POWER, são propriedades muito utilizadas no contexto de SPEECH (Dellaert, Polzin, & Waibel, 1973) (Busso et al., 2004).

São muitos os investigadores que extraem propriedades de dados provenientes do contexto fisiológico. Apesar de serem poucos os que o fazem de várias modalidades em simultâneo, são estes investigadores que mais diversificam a escolha de propriedades extraídas (e.g. Jaques et al. (Jaques et al., 2015), Soleymani et al. (Soleymani et al., 2013), Sano & Picard (Sano & Picard, 2013b), etc.). A diversidade de propriedades extraídas é maior quando os dados tem origem na atividade cerebral (e.g. ALPHA, BETA, THETA, DELTA, etc.), atividade muscular (e.g. EMGCOR, EMGZYG, SMILING, FROWNING, etc.), atividade ocular (e.g. EOGV, EOGH, SACCADE, DILATION, FIXATION, etc.) e atividade cardíaca (e.g. PNNX, HRVI, TINN, SDNNI, etc.). De salientar a existência de vários níveis de abstração de propriedades extraídas que diversificam informação mais próxima dos dados de origem e outra mais próxima do significado para o ser humano (e.g. na atividade muscular extraem-se propriedades que significam o SMILING e o FROWNING mas com base num nível mais baixo de propriedades, i.e. atividade do EMGCOR e EMGZYG).

Ainda não são muitas as investigações que extraem propriedades relacionadas com o contexto social e psicológico. No entanto, quando o fazem, diversificam apresentando uma maior quantidade de propriedades específicas do contexto (e.g. Santo & Eng (Sano & Eng, 2016), Jaques et al. (Jaques et al., 2015), Sano & Picard (Sano & Picard, 2013b), Bogomolov et al. (Bogomolov et al., 2014), LikamWa et al. (LiKamWa et al., 2013), Bauer & Lukowicz (Bauer & Lukowicz, 2012), etc.). Esta diversidade de propriedades extraídas a partir dos dados

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

provenientes do contexto social e psicológico sustenta a hipótese de ser possível criar um sistema de deteção emocional mais eficiente se o *input* dos algoritmos contiver mais informação desta modalidade. Apesar de ser perceptível o aumento do número de propriedades extraídas em todas as modalidades ao longo do tempo, a gradação é mais evidente nas extraídas dos dados de contexto social e psicológico. Esta diversificação das investigações mais recentes, evidencia o interesse dos investigadores em correlacionar propriedades extraídas deste contexto, sustentando a hipótese de poderem ser um *input* importante para um classificador emocional.

São muitos os investigadores que recolhem dados de contexto através de questionários (e.g. EMOTIONS, MOOD, STRESS, etc.). Apesar de muito utilizados na literatura em revisão, nem sempre é claro quais são as propriedades estatísticas retiradas da análise destes dados, o que nos motivou a agrupar no *token* CATEGORICAL o conjunto das propriedades possíveis de extrair a partir destes instrumentos.

INVESTIGAÇÃO	EXP. FACIAL, ORAL E POSTURA CORPORAL	CONTEXTO FISIOLÓGICO	CONTEXTO SOCIAL E PSICOLÓGICO	OUTRAS
<b>Perdiz et al.</b> (Perdiz et al., 2017) e (Phinyomark et al., 2012)	(HEAD) <ANGLE>.	(EMG) <WL, WAMP, AR, MAV, MAVS>, [EMG] <<EMGCOR, EMGZYG> <MAX, MIN>> e (EOG) <SACCADE <THRESHOLD, MAX>>.		
<b>S. H. Lee et al.</b> (S. H. Lee et al., 2016)	[FACS (EYEBROWS, EYELIDS, NOSE, LIPS, WRINKLES, LIPS, CHEEKS, JAW, MOUTH)] <LBP, LPQ, GABOR, DISTANCE, SHAPE, CLUSTERS <CENTROID>, DISPLACEMENT>.			{HAC}.
<b>Eckert et al.</b> (Eckert et al., 2016)	[FACS, CAU] <THRESHOLD, SHAPE <AREA, DISTANCE>>.			
<b>Matlovic et al.</b> (Matlovic et al., 2016)		(EEG) <<ALPHA, BETA> <STRENGTH, SUBTRACT, POWER, MEAN, RATIO>>.		
<b>Gogia et al.</b> (Gogia et al., 2016)	(HEAD) <ANGLE <TIMING>>.	[EEG] <THRESHOLD, MEDITATION, ATTENTION>.		
<b>Z. Zhang et al.</b> (Z. Zhang et al., 2016)	(HEAD) <GABOR>, [HEAD] <POSITION, ANGLE <STD>> e [FACS] <SHAPE>.		[EMOTIONS] <CATEGORICAL>.	
<b>Sano &amp; Eng</b> (Sano & Eng, 2016)		(EEG) <PSD <PERIODS <<ALPHA, BETA, THETA, DELTA>>, AMP <MEAN, STD, MEDIAN>>, [EDA] <THRESHOLD, PKF <MEAN, STD, MEDIAN>> e [EDA] e	(AGE, PERSON, ACADGR) <MEAN, MEDIAN, STD>, (STRESS, HEALTH, ANXIETY, ACADDG, ACADCL, ACADGR, MOOD, HAPPY, ALERT, ENERGY, CALM, PERSON) <CATEGORICAL	[ACC] <MEAN, STD, MEDIAN, MAG <THRESHOLD>, MOTION <LEVEL>, <MEAN, STD>>, [ACC [ADL]] <PERIODS

**RELATÓRIO TÉCNICO**

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

		(ST) <PERIODS <ADL <AMP <MEAN, MEDIAN, STD>>>>.	<MEAN, MEDIAN, STD>>, (PHYSI) <CATEGORICAL <DURATION>>, (SLEEP) e [ACC] <<MOTION <LEVEL>> <SLEEPKIND>>, [SLEEP] <<WAKEUPKIND, DURATION, COUNT, TIMING, REGULARITY, LATENCY, AWAKENINGS> <MEAN, MEDIAN, STD>>, (NAP) <DURATION, COUNT>, (EMAIL) <<OUTGOING, INCOMING, INTERLOCUTORS> <PERIODS <COUNT, MEAN, STD>>, (CALL) <DURATION, TIMING <MEAN, MEDIAN, STD>, INTERLOCUTORS <OUTGOING, INCOMING> <COUNT>>, (SMS) <TIMING <MEAN, MEDIAN, STD>, COUNT, INTERLOCUTORS, INCOMING, PERIODS <OUTGOING <COUNT>>>, (SOCIAL, FTF) <<AFFINITY, <INTERACTIONS <QUALITY>> <COUNT, TIMING, REGULARITY>>, (SCREEN) <COUNT, TIMING, PERIODS <DURATION>>, (LOCAL) <PERIODS <DISTANCE <MEDIAN, STD>>>, (CAFFEI) <LASTTIME>, (ACADST, ACADEX) <DURATION> e (ACADCL) <<CLASSROOM, ONLINECLASS, SEMINAR, LAB, GROUPWORK> <DURATION>>.	<COUNT, MEAN, MEDIAN, STD>> e (LIGHT) <PERIODS <MEAN, STD>>.
<b>Zhao et al.</b> (Zhao et al., 2016)		[IBI] <SDNNI, PNNX, HRVTI, TINN, HR <MEAN, STD>, PSD <LF/HF>, POINTCARE <STD>, ENTROPY, DFA> e [RESP] <PKF, MEAN, MEDIAN, PSD <PLF, PHF>, POINTCARE <STD>, DFA>.	[EMOTIONS] <CATEGORICAL>.	
<b>Zenonos et al.</b> (Zenonos et al., 2016)		[IBI] <MEAN, STD, PNNX, HRVI, TINN, POINCARE <STD>>,	(MOOD, EMOTIONS) <CATEGORICAL>.	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		[IBI [BANDS]] <PSD <LF/HF>> e (HR) <ENTROPY, DFA>.		
<b>Basu et al.</b> (Basu et al., 2016)		(EMG) <EMGCOR, EMGZYG>, (ECG, HR, PR, RESP(RR), EDA, ST, EMG <EMGCOR, EMGZYG>) <MEAN, STD, MAV1D, MAV2D> e [ECG, HR, PR, RESP(RR), EDA, ST, EMG <EMGCOR, EMGZYG>] <MAV1D, MAV2D>.		
<b>Aracena et al.</b> (Aracena et al., 2016)		(PUPIL) <DIAMETER>, [PUPIL] <DILATION <DIAMETER>, SIZE <MEAN>> e [GAZE] <DIRECTION>.		
<b>Adams &amp; Robinson</b> (Adams & Robinson, 2015)	(HEAD) <ANGLE> e [FACS (EYEBROWS, CHEEKS, EYELIDS, CHEEKS, NOSE, WRINKLES, LIPS, JAW, EYES, HEAD, CHIN)] <INTENSITY>.	(GAZE) <DIRECTION>.		
<b>Turan et al.</b> (Turan et al., 2015)	(FACE) <LBP, LPQ, WLD, PHOG> e (EYES) <DISTANCE>.			
<b>Korkmaz &amp; Atasoy</b> (Korkmaz & Atasoy, 2015)	(VOLUME) <MEAN, MEDIAN, SKEWNESS, KURTOSIS, MAX, MIN, AMP> e [SPEECH [INTERVALSPLIT, DY/DX, D <sup>2</sup> Y/DX <sup>2</sup> ]] <MFCC <MEAN, MEDIAN, SKEWNESS, KURTOSIS, MAX, MIN, AMP, ZCR>>.			
<b>Lalitha et al.</b> (Lalitha et al., 2015)	(SPEECH) <TEAE, DWTC, LPCC, MEDC, SHIM, SPRO, SPFL, SPCE, HNR, ZCR>.			
<b>Singh et al.</b> (Singh et al., 2015)	[SHOULDERS, HANDS] <SINGH, SLOPE, ANGLE>.			
<b>Murali et al.</b> (Murali et al., 2015) e (Padmanabhan et al., 2015)		(((ECG, ICG)(PEP, PTT), ICG, NIBP, RESP(RR), EDA) <MEAN, MEDIAN, STD>.		
<b>Jaques et al.</b> (Jaques et al., 2015)		(EDA) [RAW, FINALRAW, DY/DX] <PERIODS <MEAN, MAX, MIN>>, [EDA [DY/DX]] <THRESHOLD, AMP, DURATION, SHAPE,	(SOCIAL, CAFFEI, ALCOH, DRUGS) <CATEGORICAL>, (CALL, SMS, SCREEN) <STD>, (CALL, SMS, SCREEN) <PERIODS <MEAN, MEDIAN>>, (CALL, SMS,	(ACC) <MAG> e [ACC] <PERIODS>.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

		PERIODS <COUNT>, INTEGRAL, RISETIME> e [ST] <PERIODS>.	SCREEN, ACADCL, PHYSI, ACADEX) <COUNT>, (CALL, SCREEN, ACADCL, PHYSI, ACADEX, ACADST) <DURATION>, (SLEEP, NAP) <PERIODS <DURATION>>, (CALL, SMS) <TIMING, <INCOMING, OUTGOING, INTERLOCUTORS> <COUNT>>, (LOCAL <<LATITUDE, LONGITUDE> <MEDIAN>> e [LOCAL [PATHSTAKEN]] <DISTANCE>.	
<b>Cruz et al.</b> (Cruz et al., 2015)		[EOG] <<EOGH, EOGV> <THRESHOLD, MAX, MIN, MEAN, AMP>>.		
<b>Saha et al.</b> (Saha et al., 2014)	[HEAD, SHOULDERS, HANDS, WRISTS, ELBOWS, SPIN] <POSITION, ANGLE, DISTANCE>.			(ACC) <MAX, SPEED <SUBTRACT <DISPLACEMENT> >>.
<b>Matiko et al.</b> (Matiko et al., 2014)		(EEG) <HEMISPHERE <LEFT, RIGHT>, ALPHA <MEAN, STD, MAV1D, MAV2D, POWER>>.	(EMOTIONS) <CATEGORICAL>.	(EEG) <MATIKO>.
<b>Bogomolov et al.</b> (Bogomolov et al., 2014)			(STRESS) <CATEGORICAL <SKEWNESS, KURTOSIS>>, (PERSON) <EXTRAVERSION, NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS>, (CALL) <<INCOMING, OUTGOING, MISSEDCALL> <COUNT>>, (CALL) <INTERLOCUTORS <OUTGOING, INCOMING, MISSEDCALL> <COUNT, ENTROPY>>, (CALL) <RATIO <INTERLOCUTORS <CALL, SMS, PROXIMITY>>>, (SMS) <INCOMING, OUTGOING <COUNT>>, (SMS) <INTERLOCUTORS <INCOMING, OUTGOING> <COUNT, ENTROPY>>, (SMS) <RATIO <INTERLOCUTORS <CALL, SMS,	(WEATHER) <PERIODS <TEMP <MEAN>, PRESSURE, PRECIPITATION, HUMIDITY, VISIBILITY, WIND <SPEED>>>.

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			PROXIMITY>>>, (CALL <PERIODS <INCOMING, OUTGOING>>, (CALL, SMS) <INITIATEDONLY <PERIODS <<COUNT>>, ELAPSEDTIME <MEAN, VAR>>, [SMS] <ANSWER <RATIO, LATENCY>>, (CALL, SMS) < PERIODS <MEAN, MEDIAN, MIN, MAX, QUANTILE, STD, VAR>> e (PROXIMITY) <DEVICES <ELAPSEDTIME <MEAN, VAR>, ENTROPY>, PERIODS <USUAL <COUNT>>>>.	
<b>Agrawal et al.</b> (Agrawal et al., 2013)	[EYES, LIPS] <CENTROID <AREA>, CORRELATION <THRESHOLD>>.			
<b>Soleymani et al.</b> (Soleymani et al., 2013)	[HEAD] <POSITION>, [EYES] <IRIS <MEAN>, [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] <DISTANCE>, [EYES, EYEBROWS, LIPS] <EYECORNERS <MEAN, ANGLE>> e [LIPS, MOUTH] <DISTANCE>.	(EEG) <PSD <THETA, ALPHA, BETA, GAMMA>, SUBTRACT <PSD <HEMISPHERE <LEFT, RIGHT>>>> e (EEG) e [HEAD, EYES, NOSE, EYEBROWS, LIPS, MOUTH] <CORRELATION, MEAN, STD>.	(EMOTIONS) <CATEGORICAL>.	
<b>Vermun et al.</b> (Vermun et al., 2013)	[HEAD] <MOTION, ANGLE>, [LIPS] <LIPSPUCKER>, [MOUTH] <MOUTHOPENING>, (EYEBROWS) <BROWSRAISING>, [ARMS] <CROSSEDARMS>, [HIP, SHOULDERS, KNEES] <ERECTBACK, SITTINGPOSTURE <LEFT, RIGHT, CENTER>> e [HIP, KNEES] <CENTER <ANGLE>>.			
<b>Kusserow et al.</b> (Kusserow et al., 2013)		[HR] <MAX>.	(MOOD, STRESS) <CATEGORICAL>.	{ACC} <MOTION>.
<b>Alzoubi et al.</b> (Alzoubi et al., 2013)		(EMG) <EMGCOR, EMGZYG>, (ECG(HRV), RESP, EDA, EMG <EMGCOR, EMGZYG>) <MEAN, MEDIAN, STD, MAX, MIN, AMP>, (EDA) <RATIO <2DIFF, MIN>, RATIO <2DIFF, MAX>, RATIO	(EMOTIONS) <CATEGORICAL>.	{AUBT}.

**RELATÓRIO TÉCNICO**

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

		<1DIFF, MIN>, RATIO <1DIFF, MAX>>, (EMG <EMGZYG>) <RATIO <1DIFF, MAX>, RATIO <1DIFF, MIN>, SUBTRACT <2DIFF, MEAN>, RATIO <2DIFF, MIN>, RATIO <2DIFF, MAX>> e (RESP) <SUBTRACT <2DIFF, MIN>, SUBTRACT <AMP, 2DIFF, MAX>, RATIO <2DIFF, MAX>, RATIO <1DIFF, MAX>>.		
<b>Nawasalkar et al.</b> (Nawasalkar et al., 2013)		[NIBP] <MEAN>.		
<b>Sano &amp; Picard</b> (Sano & Picard, 2013b)		[EDA] <SLOPE <THRESHOLD <COUNT>>> e [EDA] <PERIODS <AMP <MEAN, STD, MEDIAN>>>.	(SCREEN) <PERIODS <COUNT, STD>>, (LOCAL) <<DISTANCE, RADIUS> <MEDIAN, STD>>, (SLEEP) <<DURATION, TIMING, QUALITY> <MEAN, STD, MEDIAN>>, (SLEEP) <SLEEPCONDITIONERS>, (ELECTR) <<USAGE <LASTTIME>> <MEAN, STD, MEDIAN>>, (HEALTH, MOOD, ALERT, TIRED, STRESS) <<LEVEL <PERIODS, TIMING>> <MEAN, STD, MEDIAN>>, (NAP) <TIMING, DURATION>, (CAFFEI) <<COUNT> <MEAN, STD, MEDIAN>>, (ALCOH) <<LASTTIME, COUNT, TIMING> <MEAN, STD, MEDIAN>>, (PERSON) <EXTRAVERSION, NEUROTICISM, AGREEABLENESS, CONSCIENTIOUSNESS, OPENNESS>, (CALL) <PERIODS <TIMING, DURATION, COUNT, RATIO> <MEAN, STD, MEDIAN>>>, (CALL) <<INCOMING, OUTGOING> <TIMING, DURATION, COUNT, RATIO> <MEAN, STD, MEDIAN>>, (CALL) <<INTERLOCUTORS> <MEAN, STD, MEDIAN>>, (CALL) <<MISSEDCALL <MEAN, STD, MEDIAN>>>, RATIO	(ACC) <PERIODS <MEDIAN, STD>> e (ACC) <PERIODS <MOTION <LEVEL <MEAN>>>>.

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			<MISSEDCALL <OUTOING, INCOMING>>>, (SMS) <PERIODS <<TIMING, SIZE, COUNT, RATIO> <MEAN, STD MEDIAN>>>, (SMS) <<SIZE <INCOMING, OUTGOING>> <MEAN, STD, MEDIAN>> e (SMS) <<INTERLOCUTORS> <MEAN, STD, MEDIAN>>.	
<b>Raudonis</b> (Raudonis, 2013)		[PUPIL] <DIAMETER <MIN, MAX>, LOCATION <THRESHOLD> e (EYES) <MOTION <SPEED>>.		
<b>Kawai et al.</b> (Kawai et al., 2013)		[PUPIL] <DIAMETER, AREA, MOTION, LOCATION>.	(EMOTIONS) <CATEGORICAL>.	
<b>Babiker et al.</b> (Babiker et al., 2013)		[PUPIL] <DIAMETER <DILATION, MEAN, STD>>, (EYES) <MOTION> e (GAZE) <SACCADES, FIXATION>.	(EMOTIONS) <CATEGORICAL>.	
<b>LikamWa et al.</b> (LiKamWa et al., 2013)			[MOOD] <PERIODS <COUNT, STD <MEAN, MAX>>>, (EMAIL, SMS) <INTERLOCUTORS <USUAL <COUNT, SIZE>>>, (CALL) <INTERLOCUTORS <USUAL <COUNT, DURATION>>>, (APPS) <COUNT, DURATION> e (BROWSER, LOCAL) <COUNT>.	
<b>Murad &amp; Malkawi</b> (Murad & Malkawi, 2012)		(EEG) <ALPHA, BETA THETA, DELTA>.		
<b>C. Y. Chang et al.</b> (Chang et al., 2012)		[BVP] e [ECG, BVP, PR] <MAX>.	(EMOTIONS) <CATEGORICAL>.	
<b>Bauer &amp; Lukowicz</b> (Bauer & Lukowicz, 2012)			(LOCAL) [USUALPLACES] <DIAMETER <MAX>, DURATION <MEAN, THRESHOLD>>>, [LOCAL] <ROI <TIMING, REGULARITY, COUNT <MEAN, AD, STD>>>, (PROXIMITY) <TIMING, DURATION <THRESHOLD, AD, MEAN, STSD>, COUNT <AD, MEAN, STD>> e (CALL, SMS)	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			<<INCOMING, OUTGOING> <INTERLOCUTORS <COUNT <MEAN, STD>>,&br/>COUNT <AD, MEAN, STD>>>.	
<b>Yang &amp; Bhanu</b> (S. Yang & Bhanu, 2011)	[HEAD, FACE] <LBP, LPQ>.			
<b>Dhall et al.</b> (Dhall et al., 2011)	[FACE] <LPQ, PHOG>.			
<b>Mokhayeri &amp; Toosizadeh</b> (Mokhayeri & Toosizadeh, 2011)		[ECG(HRV)] <PSD, MEAN, MIN, MAX, VAR, STD, SKEWNESS>, (PPG) <MEAN, VAR, STD, SKEWNESS, KURTOSIS> e [PUPIL] <DILATION, DIAMETER <MEAN, MAX, KURTOSIS>>.		
<b>Hernandez et al.</b> (Hernandez et al., 2011)		[EDA] [PEAKDETECT] <MEAN> e [EDA] <MEAN, DURATION, MAX, MIN, STD, SLOPE, ZEROCROSSINGS <COUNT>, QUANTILE <THRESHOLD>>.	(STRESS) <CATEGORICAL>, (CALL) [LABELING] <COUNT, MEAN, DURATION, MAX, MIN, STD, SLOPE, ZEROCROSSINGS <COUNT>, QUANTILE <THRESHOLD>>.	
<b>N. Lane et al.</b> (N. Lane et al., 2011)			(DEPRESSION, SLEEP, WELLBEING) <CATEGORICAL> e [SLEEP, PHYSI, TALK] <DURATION, MEAN, VAR>.	(ACC) <MEAN, VARIANCE, PERIODS <MOTION <COUNT, DURATION>>>.
<b>H. Wang et al.</b> (H. Wang et al., 2010)	[EYES] <STATUS, THRESHOLD, LBP, PERIODS <RATIO <STATUS, DURATION>>>.			
<b>Bos</b> (Bos, 2010)		[EEG] <ALPHA, BETA, RATIO <BETA, ALPHA>, POWER <ALPHA>, POWER <BETA>, POWER <ALPHA, BETA>, RATIO <BETA, POWER <ALPHA>>, RATIO <POWER <BETA>, POWER <ALPHA>>>.		
<b>Y. Liu et al.</b> (Y. Liu et al., 2010)		(EEG) <ALPHA, THETA, BETA, DELTA, GAMMA> e (EEG) [FD] <MEAN, HEMISPHERE <LEFT, RIGHT>, THRESHOLD>.	(EMOTIONS) <CATEGORICAL, LEVEL>.	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Setz et al.</b> (Setz et al., 2010)</p>		<p>(EDA) [PEAKDETECT] &lt;RATIO &lt;COUNT, DURATION&gt;, HEIGHT &lt;MEAN&gt;, TIMING, QUANTILE &lt;THRESHOLD&gt;&gt; e [EDA] &lt;PHASES &lt;LEVEL &lt;MEAN, MAX, MIN, SLOPE&gt;&gt;&gt;.</p>		
<p><b>J. Kim &amp; André</b> (J. Kim &amp; André, 2008)</p>		<p>(ECG(HR, HRV)) [FOURIER [BANDS]] &lt;POWER &lt;MEAN, LF/HF&gt;, MAG &lt;MAX&gt;&gt;, (ECG) [PEAKDETECT] &lt;ENTROPY&gt;, [ECG(HRV)] &lt;N-N &lt;MEAN, STD, COUNT&gt;, 1DIFF &lt;STD&gt;, RATIO, R-R &lt;POINCAIRE, STD&gt;, ENTROPY&gt;, [ECG(HRV)] [BANDS] &lt;PSD &lt;POWER, DMF&gt;, LF/HF&gt;, (RESP (RR, BRV)) [BANDS] &lt;POWER &lt;MEAN&gt;, MAG &lt;MAX&gt;&gt;, (RESP (RR)) &lt;MEAN&gt; [LPF] &lt;ZEROCROSSINGS &lt;COUNT&gt;&gt;, (RESP (BRV)) &lt;MEAN, STD, 1DIFF &lt;STD&gt;, POINCAIRE&gt;, (RESP (BRV)) [BANDS] &lt;PKF, POWER, RATIO &lt;POWER, BANDS&gt;&gt;, [EDA] &lt;MEAN, STD, ZEROCROSSINGS &lt;COUNT&gt;, MAX&gt;, [EDA] [DY/DX, D2Y/DX2] &lt;MEAN&gt;, (EMG) &lt;MEAN&gt; e [EMG] &lt;STD&gt;.</p>		
<p><b>Lichtenstein et al.</b> (Lichtenstein, Antje; Oehme, 2008)</p>		<p>(ECG(HRV)) &lt;PNNX&gt;, (ECG(HR, HRV, IBI)) &lt;LF/HF&gt;, (RESP(RR)) &lt;AMP&gt;, (RESP(RDEP)) &lt;COUNT, THRESHOLD&gt;, [EDA] &lt;MEDIAN, AMP, DURATION&gt;, (EDA) [LPF] &lt;TPOINTS &lt;COUNT&gt;, CHANGES&gt;, (EMG) &lt;&lt;EMGCOR, EMGZYG&gt; &lt;CONTRACTIONS &lt;COUNT&gt;, MUSCLE &lt;CHANGES&gt;, STD&gt;&gt; e (ST) &lt;MEAN, CHANGES&gt;.</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<p><b>Margaret M. Bradley et al.</b> (Margaret M. Bradley et al., 2008)</p>		<p>[PUPIL] &lt;DIAMETER &lt;CHANGES, MEAN, AMP, MAX&gt;&gt;, [EDA] &lt;MAX, VAR&gt; e (ECG(HR, IBI)) &lt;PERIODS &lt;MEAN&gt;&gt;.</p>		
<p><b>Gunes &amp; Piccardi</b> (Gunes &amp; Piccardi, 2007)</p>	<p>[LIPS] &lt;LIPEBITE, LIPEWIPE, STATUS, LIPSPUCKER&gt;, [MOUTH] &lt;MOUTHSTRETCH, STATUS, MOUTHCORNERS&gt;, [EYES] &lt;MOTION, SPEED, WRINKLEDEYES&gt;, [EYEBROWS] &lt;BROWSRAISING, SHAPE&gt;, [EYELIDS] &lt;POSITION, WRINKLEDEL&gt;, [CHEEKS, JAW] &lt;POSITION&gt;, [NOSE] &lt;WRINKLEDNOSE&gt;, [FOREHEAD] &lt;WRINKLEDFH&gt;, [HANDS, PALMS] &lt;POSITION&gt;, [FINGERS] &lt;MOTION, FINGERTAPPING, POSITION&gt;, [HANDS, FISTS] &lt;STATUS&gt;, [SHOULDERS] &lt;MOTION&gt; e [SHOULDERS, HANDS, FINGERS, FISTS, PALMS, NECK] &lt;CONTROID, AREA, RATIO &lt;DILATION&gt;&gt;.</p>			
<p><b>Castellano et al.</b> (Castellano et al., 2007)</p>	<p>(ARMS) &lt;MOTION &lt;QUANTITY, MAX, MIN&gt;, SPEED, DISPLACEMENT, SLOPE, AMP, ACC, MAINPEAK &lt;SLOPE, MAX, MIN&gt;, MAX, MEAN, RATIO &lt;MEAN, MAX&gt;, RATIO &lt;MAX, MAINPEAK &lt;DURATION&gt;&gt;, RATIO &lt;MAINPEAK &lt;DURATION&gt;, DURATION&gt;, POWER &lt;CENTROID&gt;, DISTANCE &lt;MAX, CENTROID&gt;, MAX &lt;POSITION&gt;&gt;.</p>			
<p><b>Mandryk &amp; Atkins</b></p>		<p>[EDA] &lt;MIN, MAX&gt;, [EMG] &lt;SMILING,</p>	<p>(EMOTIONS) &lt;CATEGORICAL&gt;.</p>	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

(Mandryk & Atkins, 2007)		FROWNING> e [ECG(HR), EDA, EMG] <MEAN, STD>.		
<b>Sebe et al.</b> (Sebe et al., 2006)	[HEAD] <MOTION <DIRECTION, INTENSITY>>, [SPEECH] <SPEED> e [PITCH] <MAX>.			
<b>Zhai &amp; Barreto</b> (Zhai & Barreto, 2006)		(PUPIL) <DIAMETER> [-NOISE [FAKEDATA]] <MEAN>, (BVP(IBI)) <PSD <LF/HF>, MEAN, STD, AMP>, [EDA] <COUNT, MEAN, AMP, RISETIME, POWER> e [ST] <SLOPE, MEAN>.		(TEMP, LIGHT) <INTENSITY>.
<b>J. A. Healey &amp; Picard</b> (J. A. Healey & Picard, 2005) e (Rosalind W. Picard et al., 2001)		[EDA] <PERIODS <MAG <SUM>, DURATION <SUM>>, INTEGRAL <SUM>, MEAN, VAR>, (EDA) [PEAKDETECT] <COUNT>, [EMG] [NORM] <MEAN, VAR>, [RESP] <VAR, MEAN>, (RESP) [BANDS] <PSD <POWER <MEAN>>>, (ECG(HR)) <LF/HF, MEAN>, (ECG(HRV)) <PERIODS <LF/HF, LFMF/HF>, MEAN> e [EDA, EMG, RESP, ECG(HR, HRV) e [STRESS] <COVAR, STD>.	[STRESS] <LEVEL <PERIODS <MEAN, STD>>>.	
<b>Herbon et al.</b> (Herbon et al., 2005)		(PUPIL) <DILATION> e (HR, EDA, ST, PUPIL) <STD <THRESHOLD>>.	(EMOTIONS) <CATEGORICAL <STD>>.	
<b>Partala et al.</b> (Partala et al., 2005)		[EMG] <<EMGZYG <SMILING>, EMGCOR <FROWNING>> <MEAN>>.	(EMOTIONS) <CATEGORICAL>.	
<b>Van Eck et al.</b> (van Eck et al., 2005)		[CORT] <TIMING, MEAN, SLOPE, VAR, COVAR, STD>.	(LIFEEVENTS, DIFFICULTIES, HEALTH, DEPRESSION, ANXIETY, ANGER, MOOD, WELLBEING, STRESS, EMOTIONS) <CATEGORICAL> e (STRESS) <STD, MEAN, TIMING, UNPLEASANTNESS, IMPORTANCE, PREDICTABILITY, CONTROLLABILITY, LASTSTRESS>.	

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

<b>Busso et al.</b> (Busso et al., 2004)	(PITCH, VOLUME) <MEAN, STD, MAX, MIN, MEDIAN> e [FOREHEAD, EYEBROWS, EYES, CHEEKS] <CLUSTERS, AREA>.			
<b>Lisetti &amp; Nasoz</b> (Lisetti & Nasoz, 2004)		[HR, EDA, ST] <MIN, MAX, MEAN, VAR>.	(EMOTIONS) <CATEGORICAL>.	
<b>K. H. Kim et al.</b> (K. H. Kim et al., 2004)		[ECG(HRV)] <MEAN, STD, DY/DX>, (EDA) <MEAN, ZEROCROSSINGS <COUNT>, MAX, AMP, DURATION> e [EDA] <DY/DX>.	(EMOTIONS) <CATEGORICAL>.	
<b>Haag et al.</b> (Haag et al., 2004)		[ECG(HR)] <MIN, MAX, MEAN, STD>, [PPG(BVP(HR))] <MIN, MAX, AMP, STD, RATIO <SUM>>, [EDA] <SLOPE, MEAN, STD>, [RESP] <SLOPE, MEAN, STD, AMP <STD>, SPEED <STD>>, [EMG] <SLOPE, MEAN, STD, AMP> e (ST) <SLOPE, MEAN, STD>.		
<b>Partala &amp; Surakka</b> (Partala & Surakka, 2003)		[PUPIL] <DIAMETER, DILATION <MEAN>, FIXATION, VAR>.	(EMOTIONS) <CATEGORICAL>.	
<b>C J Harmer et al.</b> (C J Harmer et al., 2003)		(SEROT) <TIMING, LEVEL, VAR, MEDIAN>.	(MOOD, ENERGY, EMOTIONS, ANXIETY) <CATEGORICAL>.	
<b>Nwe et al.</b> (Nwe et al., 2001)	[SPEECH] <MFCC <POWER>>.			
<b>Buchanan &amp; Lovallo</b> (Buchanan & Lovallo, 2001)		(CORT) <MEAN>.	(EMOTIONS) <CATEGORICAL>.	
<b>Jennifer a Healey et al.</b> (Jennifer a Healey et al., 2000)		[ECG(HR, HRV), EDA, EMG] <MEAN, VAR, 1DIFF <MEAN>, SLOPE>, [EMG] <PERIODS <MEAN>>, [EDA] <PERIODS <MAX, MIN>>, [PPG(BVP(HR))] <MEAN, 1DIFF <MEAN>> e [RESP] <MEAN, VAR, PSD>.	(STRESS) <CATEGORICAL>.	
<b>Vrijotte et al.</b> (Vrijotte et al., 2000)		[ECG(HR, IBI(RMSSD))] <<PERIODS, TIMING, DURATION> <MEAN, STD>>.	(STRESS) <EFFORT, REWARD, OVERCOMMITMENT, RATIO <EFFORT,	

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

			REWARD>>, (PHYSI) e (ACC) <MOTION>, (CAFFEI, ALCOH, SMOKING) <COUNT>, (MOOD) <LEVEL> e (PERSON) <CATEGORICAL>.	
<b>Ritz et al.</b> (Ritz et al., 2000)		[BP(SBP)] <CHANGES> e [HR, BP(SBP, DBP), ROS, RR, VT, EDA] <MEAN, STD>.	(EMOTIONS) <CATEGORICAL>.	
<b>L. S. Chen et al.</b> (L. S. Chen et al., 1998)	[PITCH] <CONTOUR <MAX, MIN, MEAN, STD, THRESHOLD>>, (SPEECH) <RMS <POWER>> e (PITCH) <CONTOUR> [DY/DX] <MAX, MIN>.			
<b>J. Healey &amp; Picard</b> (J. Healey & Picard, 1998)		[EMG] <PHASES <MUSCLE <MEAN>>, [EDA] <PHASES <MEAN, 1DIFF <SLOPE <MEAN>>>>, (PPG(BVP(HR))) <PHASES <MEAN, 1DIFF <CHANGES <MEAN>>>> e [RESP] <MEAN, VAR, PSD>.		
<b>Rajita Sinha</b> (Rajita Sinha, 1996)		(EOG) <QUANTILE <MOTION>, MEDIAN>, [ECG(HR), BP(SBP, DBP), EDA, EOG] <PERIODS <MEDIAN>>, (ST, EMG) <PERIODS <MEDIAN>> e (BP(DBP)) <CHANGES>.	(EMOTIONS) <CATEGORICAL>.	
<b>Scott R. Vrana</b> (Scott R. Vrana, 1993)		[EMG] <<EMGCOR, EMGZYG, LEVATOR> <PERIODS <TENSION>>>, [ECG(HR)] <CHANGES> e (EDA) <PERIODS <MEAN>>.	(EMOTIONS) <CATEGORICAL>.	
<b>R Sinha et al.</b> (R Sinha et al., 1992)		[ICG(SV, CO, PVR, PEP, LVET), ECG(HR), BP(SBP, DBP)] <CHANGES <MEAN, STD>, PERIODS <MEAN>> e [BP(SBP, DBP)] <MEAN>.	(EMOTIONS) <CATEGORICAL>.	

() representa um sinal raw; {} um instrumento; [] um sinal pré-processado; e <> uma propriedade extraída.

## 6. CONCLUSÃO

O número de investigações relacionadas com o *Affective Computing* (AC) tem vindo a aumentar nos últimos anos e é expectável que continue a crescer nos próximos. Esta probabilidade, motivou os autores a desenhar este relatório técnico de forma a que pudesse ser complementado com nova informação de forma flexível e rápida aquando de novas iterações de atualização do estado da arte acerca da deteção automática de emoções.

A principal preocupação dos autores durante o desenho da estrutura deste relatório técnico, era permitir o registo de forma sistemática, sintética e organizada, da informação obtida a partir da revisão do estado da arte na área do AC. A estratégia passava por: i) âncorar a informação obtida a secções representativas das diferentes etapas do modelo genérico utilizado na investigação emocional (Figura 1); e ii) catalogar essa informação em quadros resumo através de *tokens* representativos do conteúdo, para facilitar a procura e leitura da informação processada.

Esta organização sistemática da informação facilita o registo do conhecimento obtido pela leitura das várias investigações analisados. Permite facilmente incluir novas variáveis de contexto e propriedades de domínio, novos instrumentos & sensores, novas técnicas de pré-processamento e novas propriedades extraídas. À medida que cada investigação é analisada, o seu conteúdo é dissecado e catalogado em quadros resumo. O resultado final é uma ferramenta que permite documentar e analisar o conteúdo processado nas várias investigações.

Além de ser possível crescer em largura este relatório com a análise de mais investigações, pretende-se também vir a melhorá-lo na componente vertical. Nesta primeira versão não considerámos as últimas fases do modelo genérico proposto pelos autores para uma investigação emocional. Assim, no futuro, pretende-se incluir uma secção para sistematizar também a informação acerca dos algoritmos de classificação utilizados pelos investigadores, e uma secção para resumir os instrumentos através dos quais os investigadores representam as emoções classificadas. Existe também a vontade para incluir um anexo com quadros resumo com os instrumentos de provocação emocional utilizados nas investigações (e.g. áudio, vídeo).

Este levantamento bibliográfico serviu de suporte à preparação da experiência dos autores na área do AC. Pretende-se verificar a hipótese de ser possível detetar o bem-estar em trabalhadores de escritório, tendo por base uma recolha multimodal de variáveis de contexto. O conhecimento obtido a partir deste levantamento bibliográfico vai permitir-nos planear uma experiência para a recolha de um *dataset* em ambiente real. Serão recolhidas várias variáveis de contexto filiológico, social e religioso de vários participantes, trabalhadores de escritório de várias organizações.

As organizações são cada vez mais dinâmicas e exigentes com os seus trabalhadores. O *stress* relacionado com o aglomerar de tarefas e cumprimento de prazos, faz com que muitas vezes o local de trabalho seja um ambiente agressivo onde se experienciam emoções negativas. No entanto, a realização pessoal resultante do reconhecimento por outros, o bom espírito de equipa, e o cumprimento de objetivos, poderá ajudar no contra balanceamento emocional com emoções positivas (e.g. concretização de negócios, volumes de faturação, cumprimento de prazos, etc.). A motivação dos autores em estudar o ambiente emocional dos escritórios resulta: i) da necessidade de se estudar o ambiente em que trabalham as pessoas com base na

## **RELATÓRIO TÉCNICO**

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

monitorização das suas variáveis de contexto; e ii) da ligação próxima que os autores têm ao nível profissional com o mundo empresarial.

Os autores estão convictos que será possível criar sistemas de escritório mais inteligentes do ponto de vista afetivo para que, no futuro, possa ser melhorado o bem-estar dos seus trabalhadores.

## 7. BIBLIOGRAFIA

- 4iiii Innovations Inc. (2018). I Love Viiiiva. Retrieved January 28, 2018, from <https://4iiii-innovations.myshopify.com/collections/heart-rate-monitors>
- Aaron T.Beck. (1967). *Depression: Clinical, Experimental, and Theoretical Aspects*. Philadelphia: University of Pennsylvania Press.
- Aboy, M., Cuesta-Frau, D., Austin, D., & Mico-Tormos, P. (2007). Characterization of sample entropy in the context of biomedical signal analysis. *Conference Proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, 2007*, 5943–5946. <https://doi.org/10.1109/IEMBS.2007.4353701>
- Adams, A., & Robinson, P. (2015). Automated recognition of complex categorical emotions from facial expressions and head motions. *2015 International Conference on Affective Computing and Intelligent Interaction, ACII 2015*, 355–361. <https://doi.org/10.1109/ACII.2015.7344595>
- Adhikari, P. R. (2016). How is chi test used for feature selection in machine learning? Retrieved October 29, 2017, from <https://www.quora.com/How-is-chi-test-used-for-feature-selection-in-machine-learning>
- ADInstruments. (n.d.-a). ADInstruments FE116 GSR Amp (FE116-DCW-15A).
- ADInstruments. (n.d.-b). ADInstruments ML135 Dual Bio Amp (ML135-DC-05A).
- ADInstruments. (n.d.-c). ADInstruments ML309 Thermistor Pod (ML309-DCW-15A).
- ADInstruments. (n.d.-d). ADInstruments ML870 PowerLab 8/30 (ML870-DC-05A).
- ADInstruments. (n.d.-e). LabChart for Research | ADInstruments. Retrieved June 12, 2017, from <https://www.adinstruments.com/products/labchart/labchart-for-research>
- Affectiva Inc. (2013). Affectiva Q User manual.
- Affectiva Inc. (2014). Q Sensor 2.0 Datasheet 2.0.
- Affectiva Inc. (2017). Affectiva | Emotion as a Service. Retrieved August 16, 2017, from <https://www.affectiva.com/product/emotion-as-a-service/>
- Agrawal, U., Giripunje, S., & Bajaj, P. (2013). Emotion and gesture recognition with soft computing tool for drivers assistance system in human centered transportation. *Proceedings - 2013 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2013*, 4612–4616. <https://doi.org/10.1109/SMC.2013.785>
- Aharony, N., & Gardner, W. (2011). Funf: Open Sensing Framework. Retrieved April 23, 2016, from <http://www.funf.org>
- Ahlstrom, C., Johansson, A., Uhlin, F., L?nne, T., & Ask, P. (2005). Noninvasive investigation of blood pressure changes using the pulse wave transit time: A novel approach in the monitoring of hemodialysis patients. *Journal of Artificial Organs*, 8(3), 192–197. <https://doi.org/10.1007/s10047-005-0301-4>
- Alabdulkarim, A. (2015). Towards hand-gesture frustration detection in interactive systems. *Proceedings - 2014 3rd International Conference on User Science and Engineering: Experience. Engineer. Engage, i-USEr 2014*, 153–157.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

<https://doi.org/10.1109/IUSER.2014.7002694>

- Algorithmia. (2017). SpreadSubsample. Retrieved October 29, 2017, from <https://algorithmia.com/algorithms/weka/SpreadSubsample>
- Alqaraawi, A., Alwosheel, A., & Alasaad, A. (2016). Heart rate variability estimation in photoplethysmography signals using Bayesian learning approach. *Healthcare Technology Letters*, 3(2), 136–142. <https://doi.org/10.1049/htl.2016.0006>
- Alzoubi, O., Fossati, D., D’Mello, S., & Calvo, R. A. (2013). Affect detection and classification from the non-stationary physiological data. *Proceedings - 2013 12th International Conference on Machine Learning and Applications, ICMLA 2013*, 1, 240–245. <https://doi.org/10.1109/ICMLA.2013.49>
- Ambulatory Monitoring, I. (n.d.). AMI: Physiological Actigraph monitoring of ambulatory subjects for sleep, psychiatric and movement disorders. Retrieved July 1, 2017, from [http://www.ambulatory-monitoring.com/micro\\_sensors.html](http://www.ambulatory-monitoring.com/micro_sensors.html)
- Ancoli-Israel, S., Cole, R., Alessi, C., Chambers, M., Moorcroft, W., & Pollak, C. P. (2003). The role of actigraphy in the study of sleep and circadian rhythms. *Sleep*, 26(3), 342–392.
- Andale. (2012). Pearson Correlation: Definition and Easy Steps for Use. Retrieved October 28, 2017, from <http://www.statisticshowto.com/what-is-the-pearson-correlation-coefficient/>
- Angel, M. F., & Bonarini, A. (2014). Studying People ’ s Emotional Responses to Robot ’ s Movements in a Small Scene.
- Antonucci, T. C. (2001). Social relations: an examination of social networks, social support, and sense of control. *Handbook of the Psychology of Aging*, (November), 427–453.
- Applied Science Laboratories. (2006). Applied Science Laboratories Model 504 Eye Tracker and Gaze Tracker System Setup and Operations Manual. *Science*, (October), 1–55.
- Aracena, C., Basterrech, S., Snael, V., & Velasquez, J. (2016). Neural Networks for Emotion Recognition Based on Eye Tracking Data. *Proceedings - 2015 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2015*. <https://doi.org/10.1109/SMC.2015.460>
- Arduino. (2018). ARDUINO. Retrieved from <https://www.arduino.cc/>
- Armon, C. (2016). Polysomnography: Overview, Parameters Monitored, Procedures. Retrieved July 1, 2017, from <http://emedicine.medscape.com/article/1188764-overview>
- Arnold, M. B. (1970). Perennial problems in the field of emotion. In *Feelings and emotions : The Loyola Symposium* (Vol. 7, pp. 169–185).
- Aschoff, J. (1983). Circadian control of body temperature. *Journal of Thermal Biology*, 8(1–2), 143–147. [https://doi.org/10.1016/0306-4565\(83\)90094-3](https://doi.org/10.1016/0306-4565(83)90094-3)
- Attanasio, V., Andrasik, F., Blanchard, E. B., & Arena, J. G. (1984). Psychometric properties of the SUNYA revision of the psychosomatic symptom checklist. *Journal of Behavioral Medicine*, 7(2), 247–257. <https://doi.org/10.1007/BF00845390>
- Ax, A. F. (1953). The physiological differentiation between fear and anger in humans. *Psychosomatic Medicine*, 15(5), 433–442. <https://doi.org/10.1097/00006842-195309000-00007>
- Babiker, A., Faye, I., & Malik, A. (2013). Pupillary behavior in positive and negative emotions.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

*IEEE ICSIPA 2013 - IEEE International Conference on Signal and Image Processing Applications*, 7–11. <https://doi.org/10.1109/ICSIPA.2013.6708037>

- Backs, R. W., Navidzadeh, H. T., & Xu, X. (2000). Cardiorespiratory indices of mental workload during simulated air traffic control. *Proceedings of the IEA 2000/HFES 2000 Congress*, 3(13), 89–92. <https://doi.org/10.1177/154193120004401323>
- Bagby, M., Parker, J. D. a, & Taylor, G. J. (1994). the Twenty-Item Item Selection Toronto and Cross-Validation Structure. *Journal of Psychosomatic Research*, 38(1), 23–32. [https://doi.org/10.1016/0022-3999\(94\)90005-1](https://doi.org/10.1016/0022-3999(94)90005-1)
- Bago d’Uva, T., Van Doorslaer, E., Lindeboom, M., & O’Donnell, O. (2008). Does reporting heterogeneity bias the measurement of health disparities? *Health Economics*, 17(3), 351–375. <https://doi.org/10.1002/hec.1269>
- Bakhtiyari, K., & Husain, H. (2014). Fuzzy Model on Human Emotions Recognition. *ArXiv Preprint ArXiv:1407.1474*, 77–82. <https://doi.org/10.13140/2.1.1595.8081>
- Barea, R., Boquete, L., Rodriguez-Ascariz, J. M., Ortega, S., & López, E. (2011). Sensory system for implementing a human-computer interface based on electrooculography. *Sensors*, 11(1), 310–328. <https://doi.org/10.3390/s110100310>
- Basu, S., Bag, A., Mahadevappa, M., Mukherjee, J., & Guha, R. (2016). Affect detection in normal groups with the help of biological markers. *12th IEEE International Conference Electronics, Energy, Environment, Communication, Computer, Control: (E3-C3), INDICON 2015*, 1–6. <https://doi.org/10.1109/INDICON.2015.7443733>
- Batson, C. D., Shaw, L. L., & Oleson, K. C. (1992). Differentiating affect, mood, and emotion: Toward functionally based conceptual distinctions. *Emotion*, 13, 294–326.
- Battaglia, M., Ogliari, A., Zanoni, A., Citterio, A., Pozzoli, U., Giorda, R., ... Marino, C. (2005). Influence of the serotonin transporter promoter gene and shyness on children’s cerebral responses to facial expressions. *Archives of General Psychiatry*, 62(1), 85–94. <https://doi.org/10.1001/archpsyc.62.1.85>
- Bauer, G., & Lukowicz, P. (2012). Can smartphones detect stress-related changes in the behaviour of individuals? *2012 IEEE International Conference on Pervasive Computing and Communications Workshops, PERCOM Workshops 2012*, (March), 423–426. <https://doi.org/10.1109/PerComW.2012.6197525>
- Baumeister, R. F., Campbell, J. D., Krueger, J. I., Vohs, K. D., Solomon, L. J., Rothblum, E. D., ... Fend, H. a. (2013). Mindfulness and Self-esteem: A Systematic Review. *Personality and Individual Differences*, 35(2), 213–240. <https://doi.org/10.1007/s12671-015-0407-6>
- Beck, A.T.; Steer, R.A., Brown, G. . (1996). Beck Depression Inventory-Second Edition ( BDI-II ) | National Child Traumatic Stress Network - Child Trauma Home. Retrieved June 18, 2017, from <http://www.nctsn.org/content/beck-depression-inventory-second-edition>
- Beedie, C. J., Terry, P. C., & Lane, A. M. (2005). Distinctions between emotion and mood. *Cognition and Emotion*. <https://doi.org/10.1080/02699930541000057>
- Bellman, R. E. (1961). Adaptive control processes: A guided tour. *Princeton University Press*, 28, 1–19. Retrieved from <http://arxiv.org/abs/1302.6677>
- Biondi, M., & Picardi, A. (1999). Psychological stress and neuroendocrine function in humans: the last two decades of research. *Psychotherapy and Psychosomatics*, 68(3), 114–150. <https://doi.org/12323>

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Biopac Systems. (2017). Cardiac Output Estimate from BP. Retrieved April 20, 2017, from <https://www.biopac.com/?app-advanced-feature=cardiac-output-estimate-from-bp>
- Biopac Systems Inc. (2017a). Data Acquisition, Loggers, Amplifiers, Transducers, Electrodes | BIOPAC. Retrieved June 17, 2017, from <https://www.biopac.com/>
- Biopac Systems Inc. (2017b). ECG: Cardiology | RMSSD for HRV Analysis | Research | BIOPAC. Retrieved April 17, 2017, from <https://www.biopac.com/application/ecg-cardiology/advanced-feature/rmssd-for-hrv-analysis/>
- Biopac Systems Inc. (2017c). MP System Comparison: MP150 vs. MP100 | BIOPAC. Retrieved June 17, 2017, from <https://www.biopac.com/knowledge-base/mp-system-comparison-mp150-vs-mp100/>
- Biopac Systems Inc. (2017d). Noninvasive Blood Pressure Amplifier - NIBP100D.
- Biopac Systems Inc. (2017e). Upgrade to MP160 with AcqKnowledge Windows | MP160U-W, MP160U-M | Research | BIOPAC. Retrieved June 17, 2017, from <https://www.biopac.com/product/mp100-system-upgrades/>
- Biosemi. (n.d.). Analog Input Box, AIB. Retrieved June 16, 2017, from <https://www.biosemi.com/aib.htm>
- Birdwhistell, R. L. (1970). *Kinesics and Context: Essays on Body-motion Communication*. University of Pennsylvania press. Retrieved from <https://books.google.com/books?id=NvzCSAAACAAJ&pgis=1>
- Blascovich, J., & Tomaka, J. (1996). The Biopsychosocial Model of Arousal Regulation. In *Advances in Experimental Social Psychology* (Vol. 28, pp. 1–51). [https://doi.org/10.1016/S0065-2601\(08\)60235-X](https://doi.org/10.1016/S0065-2601(08)60235-X)
- Blood, N. N., & Monitoring, P. (2017). Product sheet, 1–3.
- Bogomolov, A., Lepri, B., & Pianesi, F. (2013). Happiness recognition from mobile phone data. *Proceedings - SocialCom/PASSAT/BigData/EconCom/BioMedCom 2013*, 790–795. <https://doi.org/10.1109/SocialCom.2013.118>
- Bogomolov, A., Trento, I.-P., Lepri, B., Pianesi, F., Kessler, F. B., Kessler, F. B., & Pentland, A. S. (2014). Daily Stress Recognition from Mobile Phone Data , Weather Conditions and Individual Traits, 477–486. <https://doi.org/10.1145/2647868.2654933>
- Bonatti, L. (2006). Psyscope X. Retrieved June 2, 2017, from <http://psy.ck.sissa.it/>
- Bonnemeier, H., Richardt, G., Potratz, J., Wiegand, U. K. H., Brandes, A., Kluge, N., & Katus, H. A. (2003). Circadian profile of cardiac autonomic nervous modulation in healthy subjects: differing effects of aging and gender on heart rate variability. *Journal of Cardiovascular Electrophysiology*, 14(8), 791–799. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/12890036>
- Bos, D. (2010). EEG-based Emotion Recognition. *IEEE Transactions on Biomedical Engineering*, 57(7), 1798–1806. <https://doi.org/10.1109/TBME.2010.2048568>
- Boucsein, W. (2012). Electrodermal Activity. *Electrodermal Activity*, 3(1973), 3–67. <https://doi.org/10.1007/978-1-4614-1126-0>
- Boudreau, P., Dumont, G., Kin, N. M. K. N. Y., Walker, C. D., & Boivin, D. B. (2011). Correlation of heart rate variability and circadian markers in humans. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*,

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

681–684. <https://doi.org/10.1109/IEMBS.2011.6090153>

Bound, J. (1991). Self-Reported vs. Objective Measures of Health in Retirement Models. *The Journal of Human Resources*, 26(1), 106–138. <https://doi.org/10.3386/w2997>

Boyle, G. J. (1984). Reliability and validity of Izard 's Differential Emotions Scale undergraduates under each of four imaginal mood-induction conditions (labelled : General Depression ,. *Depression*, 5(6), 747–750.

Bracewell, R. N. (2014). The Fourier Transform. *Diagnostic Ultrasound Imaging: Inside Out*, 260(6), 765–783. <https://doi.org/10.1016/B978-0-12-396487-8.00029-X>

Bradley, M.M., & Lang, P. J. (1999). International affective digitized sounds (IADS): Stimuli, instruction manual and affective ratings. *Technical Report B-2*.

Bradley, Margaret M., & Lang, P. J. (1994). Measuring emotion: The self-assessment manikin and the semantic differential. *Journal of Behavior Therapy and Experimental Psychiatry*, 25(1), 49–59. [https://doi.org/10.1016/0005-7916\(94\)90063-9](https://doi.org/10.1016/0005-7916(94)90063-9)

Bradley, Margaret M., Miccoli, L., Escrig, M. A., & Lang, P. J. (2008). The pupil as a measure of emotional arousal and autonomic activation. *Psychophysiology*, 45(4), 602–607. <https://doi.org/10.1111/j.1469-8986.2008.00654.x>

Bradley, P. C., & Holloway, R. (n.d.). W-BQ12 (Portuguese for Portugal), 3, 96.

Brainquiry. (n.d.). PET 4.0 - 4 channels EEG with active electrodes. *Brainquiry.Com*.

Brainquiry. (2017). BioExplorer Software License – brainquiry – Wireless, high quality signal EEG, EMG, ECG. Retrieved July 15, 2017, from <http://www.brainquiry.com/bioexplorer-software-license/>

Brandão, R. M. (n.d.). Conceitos Básicos em Estatística.

Branquiry. (2017). brainquiry – Wireless, high quality signal EEG, EMG, ECG. Retrieved July 15, 2017, from <http://www.brainquiry.com/>

Briggs, M. I. (2015). MBTI - Careers For Your Personality. *PhD Proposal*, 1. <https://doi.org/10.1017/CBO9781107415324.004>

Brugha, T., Bebbington, P., Tennant, C., & Hurry, J. (1985). The List of Threatening Experiences: a subset of 12 life event categories with considerable long-term contextual threat. *Psychological Medicine*, 15(01), 189. <https://doi.org/10.1017/S003329170002105X>

Brugha, T. S., & Cragg, D. (1990). The List of Threatening Experiences: the reliability and validity of a brief life events questionnaire. *Acta Psychiatrica Scandinavica*, 82(1), 77–81. <https://doi.org/10.1111/j.1600-0447.1990.tb01360.x>

Buchanan, T. W., & Lovallo, W. R. (2001). Enhanced memory for emotional material following stress-level cortisol treatment in humans. *Psychoneuroendocrinology*, 26(3), 307–317. [https://doi.org/10.1016/S0306-4530\(00\)00058-5](https://doi.org/10.1016/S0306-4530(00)00058-5)

Bulling, A., Blanke, U., & Schiele, B. (2014). A tutorial on human activity recognition using body-worn inertial sensors. *ACM Computing Surveys (CSUR)*, 1(June), 1–33. <https://doi.org/http://dx.doi.org/10.1145/2499621>

Burnett, S., Bird, G., Moll, J., Frith, C., & Blakemore, S. J. (2009). Development during Adolescence of the Neural Processing of Social Emotion. *Journal of Cognitive Neuroscience*, 21(9), 1736–1750. <https://doi.org/10.1162/jocn.2009.21121>.Development

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Business Wire. (2007). Cisbio Bioassays and Orion Diagnostica Oy Sign an Agreement for Steroid Radioimmunoassays | Business Wire. Retrieved June 11, 2017, from <http://www.businesswire.com/news/home/20131007006186/en/Cisbio-Bioassays-Orion-Diagnostica-Oy-Sign-Agreement>
- Busso, C., Deng, Z., Yildirim, S., Bulut, M., Lee, C. M., Kazemzadeh, A., ... Narayanan, S. (2004). Analysis of emotion recognition using facial expressions, speech and multimodal information. *Proceedings of the 6th International Conference on Multimodal Interfaces - ICMI '04*, 205. <https://doi.org/10.1145/1027933.1027968>
- Butcher, N. N., Graham, J. R., Ben-Porath, Y. S., Tellegen, Y. S., Dahlstrom, W. G., & Kaemmer, B. (2001). *Minnesota Multiphasic Personality Inventory-2*. Psychological Corporation. <https://doi.org/10.1002/9781119311263.app1>
- Buysse, D. J., Reynolds, rd C. F., Monk, T. H., Berman, S. R., & Kupfer, D. J. (1989). The Pittsburgh Sleep Quality Index: a new instrument for psychiatric practice and research. *Psychiatry Research*. [https://doi.org/10.1016/0165-1781\(89\)90047-4](https://doi.org/10.1016/0165-1781(89)90047-4)
- Č, J. Š., Škoda, J., Krbal, M., & Wasserbauer, V. Č. (2016). Comparison of Light Sources for Household Use due Circadian Effect, *1*, 2–5.
- Caballe, S. (2015). Towards a Multi-modal Emotion-Awareness e-Learning System. *Proceedings - 2015 International Conference on Intelligent Networking and Collaborative Systems, IEEE INCoS 2015*, 280–287. <https://doi.org/10.1109/INCoS.2015.88>
- Cacioppo, J.T., Berntson, G.G., Larsen, J.T., Poehlmann, K.M., Ito, T. A. (2000). *Cacioppo, JT - The psychophysiology of emotion. The psychophysiology of emotion*. New York, USA: The Guilford Press.
- Cahn, J. E. (1990). Generating Expression in Synthesized Speech, 177.
- Cajochen, C., Zeitzer, J. M., Czeisler, C. a, & Dijk, D. J. (1999). Dose-response relationship for light intensity and alertness and its ocular and EEG correlates. *Behavioural Brain Research*, *115*, 75–83.
- Calvert, C. A. (1998). Heart rate variability. *Vet Clin North Am Small Anim Pract*, *28*(6), 1409–1427, viii. <https://doi.org/10.1016/B978-0-444-53491-0.00031-6>
- Cambridge University. (2008). Feature selection Chi2 Feature selection. Retrieved October 29, 2017, from <https://nlp.stanford.edu/IR-book/html/htmledition/feature-selectionchi2-feature-selection-1.html>
- Camurri, A., Mazzarino, B., & Volpe, G. (2004). Analysis of expressive gesture: The eyesweb expressive gesture processing library. In *Gesture-Based Communication in Human-Computer Interaction, LNAI 2915*, 460–467. [https://doi.org/10.1007/978-3-540-24598-8\\_42](https://doi.org/10.1007/978-3-540-24598-8_42)
- Canini, L., Benini, S., Migliorati, P., & Leonardi, R. (2009). Emotional identity of movies. *Proceedings - International Conference on Image Processing, ICIP*, 1821–1824. <https://doi.org/10.1109/ICIP.2009.5413556>
- Canli, T., Desmond, J. E., Zhao, Z., Glover, G., & Gabrieli, J. D. E. (1998). Hemispheric asymmetry for emotional stimuli detected with fMRI. *Neuroreport*, *9*(14), 3233–3239.
- Capineri, L. (2014). Resistive sensors with smart textiles for wearable technology: From fabrication processes to integration with electronics. *Procedia Engineering*, *87*, 724–727. <https://doi.org/10.1016/j.proeng.2014.11.748>

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Castellano, G., Villalba, S. D., & Camurri, A. (2007). Recognising Human Emotions from Body Movement and Gesture Dynamics. *Affective Computing and Intelligent Interaction*, 71–82. [https://doi.org/10.1007/978-3-540-74889-2\\_7](https://doi.org/10.1007/978-3-540-74889-2_7)
- Chan, G. S. H., Middleton, P. M., Lovell, N. H., & Celler, B. G. (2005). Extraction of photoplethysmographic waveform variability by lowpass filtering. *Proceedings of the 2005 IEEE, c*, 5568–5571.
- Chan, M., Estève, D., Fourniols, J.-Y., Escriba, C., & Campo, E. (2012). Smart wearable systems: Current status and future challenges. *Artif Intell Med*, 56(3), 137–156. <https://doi.org/http://dx.doi.org/10.1016/j.artmed.2012.09.003>
- Chandler, C., & Cornes, R. (2012). Biometric Measurement of Human Emotions, 4(2).
- Chanel, G. (2009). Emotion assessment for affective computing based on brain and peripheral signals. *PhD Thesis*, 194. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.155.4044&rep=rep1&type=pdf>
- Chang, C.-Y., Lin, Y.-M., & Zheng, J.-Y. (2012). Physiological Angry Emotion Detection Using Support Vector Regression. *2012 15th International Conference on Network-Based Information Systems*, 592–596. <https://doi.org/10.1109/NBiS.2012.78>
- Chang, C.-Y., Zheng, J.-Y., & Wang, C.-J. (2010). Based on Support Vector Regression for emotion recognition using physiological signals. *The 2010 International Joint Conference on Neural Networks (IJCNN)*, (April 2015), 1–7. <https://doi.org/10.1109/IJCNN.2010.5596878>
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16, 321–357. <https://doi.org/10.1613/jair.953>
- Cheever, N. A., Rosen, L. D., Carrier, L. M., & Chavez, A. (2014). Out of sight is not out of mind: The impact of restricting wireless mobile device use on anxiety levels among low, moderate and high users. *Computers in Human Behavior*, 37, 290–297. <https://doi.org/10.1016/j.chb.2014.05.002>
- Chellappa, S. L., Steiner, R., Blattner, P., Oelhafen, P., Götz, T., & Cajochen, C. (2011). Non-Visual Effects of Light on Melatonin, Alertness and Cognitive Performance: Can Blue-Enriched Light Keep Us Alert? *PLoS ONE*, 6(1), e16429. <https://doi.org/10.1371/journal.pone.0016429>
- Chen, D., & Vertegaal, R. (2004). Using mental load for managing interruptions in physiologically attentive user interfaces. *Extended Abstracts of the 2004 Conference on Human Factors and Computing Systems - CHI '04*, (January 2004), 1513. <https://doi.org/10.1145/985921.986103>
- Chen, L. S., Huang, T. S., Miyasato, T., & Nakatsu, R. (1998). Multimodal Human Emotion Expression Recognition. *Third International Conf Automatic Face and Gesture Recognition*, 13(7), 366–371. <https://doi.org/10.1109/AFGR.1998.670976>
- Chen, W., Jaques, N., Taylor, S., Sano, A., Fedor, S., & Picard, R. W. (2014). WAVELET-BASED MOTION ARTIFACT REMOVAL FOR ELECTRODERMAL ACTIVITY Electrodermal Activity Motion Artifact in EDA Our Method A . Stationary wavelet transform C . Inverse wavelet transform • EDA data containing motion artifacts was obtained from a.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Chen, Z., Lin, M., Chen, F., Lane, N., Cardone, G., Wang, R., ... Cambell, A. (2013). Unobtrusive Sleep Monitoring using Smartphones. *Proceedings of the ICTs for Improving Patients Rehabilitation Research Techniques*.  
<https://doi.org/10.4108/icst.pervasivehealth.2013.252148>
- Chittaranjan, G., Jan, B., & Gatica-Perez, D. (2011). Who's who with big-five: Analyzing and classifying personality traits with smartphones. *Proceedings - International Symposium on Wearable Computers, ISWC*, 29–36. <https://doi.org/10.1109/ISWC.2011.29>
- Choppin, A. (2000). EEG-Based Human Interface for Disabled Individuals : Emotion Expression with Neural Networks Submitted for the Master Degree. *Emotion*.
- Christie, M. J. (1981). Electrodermal activity in the 1980s: a review. *Journal of the Royal Society of Medicine*, 74(April), 616–622.
- Cisbio. (2016). Trousse pour le dosage radioimmunologique du cortisol sérique et salivaire | Cisbio. Retrieved June 11, 2017, from <http://www.cisbio.com/diagnostics/products/endocrinologie/dosage-radioimmunologique-cortisol-serique-salivaire>
- Class SpreadSubsample. (n.d.). Retrieved October 29, 2017, from <http://weka.sourceforge.net/doc.stable/weka/filters/supervised/instance/SpreadSubsample.html>
- Coburn, K. L., & Moreno, M. a. (1988). Facts and artifacts in brain electrical activity mapping. *Brain Topography*, 1(1), 37–45. <https://doi.org/10.1007/BF01129338>
- Cohen, J., MacWhinney, B., Flatt, M., & Provost, J. (1993). PsyScope: An interactive graphic system for designing and controlling experiments in the psychology laboratory using Macintosh computers. *Behavior Research Methods, Instruments, & Computers*, 25(2), 257–271. <https://doi.org/10.3758/BF03204507>
- Cohen, S., Kamarck, T., & Mermelstein, R. (1983). A Global Measure of Perceived Stress. *Journal of Health and Social Behavior*. <https://doi.org/10.2307/2136404>
- Cohen, S, & Wills, T. A. (1985). Stress, social support, and the buffering hypothesis. *Psychological Bulletin*, 98(2), 310–357. <https://doi.org/10.1037/0033-2909.98.2.310>
- Cohen, Sheldon, & Herbert, T. B. (1996). HEALTH PSYCHOLOGY: Psychological Factors and Physical Disease from the Perspective of Human Psychoneuroimmunology. *Annu. Rev. Psychol*, 47(1993), 113–142. <https://doi.org/doi:10.1146/annurev.psych.47.1.113>
- Cole, R. J., Kripke, D. F., Gruen, W., Mullaney, D. J., & Gillin, J. C. (1992). Automatic sleep/wake identification from wrist activity. *Sleep*, 15(5), 461–469.  
<https://doi.org/10.1093/sleep/15.5.461>
- Cootes, T. F., Taylor, C. J., Cooper, D. H., & Graham, J. (1995). Active Shape Models-Their Training and Application. *Computer Vision and Image Understanding*, 61(1), 38–59.  
<https://doi.org/10.1006/cviu.1995.1004>
- Cornelissen, J., & Waterman, H. I. (2016). Advanced Biosignal Acquisition, Proecssing and Analysis - Product Catalogue.
- Cowie, R., Douglas-Cowie, E., Savvidou, S., McMahan, E., Sawey, M., & Schröder, M. (2000). "Feeltrace": An instrument for recording perceived emotion in real time. *ISCA Workshop on Speech {&} Emotion*, 19–24. <https://doi.org/citeulike-article-id:3721917>

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Cristinacce, D., & Cootes, T. (2008). Automatic feature localisation with constrained local models. *Pattern Recognition*, 41(10), 3054–3067. <https://doi.org/10.1016/j.patcog.2008.01.024>
- Cronbach, L. (1951). Coefficient alpha and the internal structure of tests, *Psychometrika*. *Psychometrika*, 16(3), 297–334.
- Cronbach, L. J. (1951). Coefficient alpha and the internal structure of tests. *Psychometrika*, 16(3), 297–334. <https://doi.org/10.1007/BF02310555>
- Crossman, A. (2017). Correlation Analysis in Sociological Research. Retrieved October 29, 2017, from <https://www.thoughtco.com/what-is-correlation-analysis-3026696>
- Crowne, D P, & Marlowe, D. (1960). Marlowe-Crowne Social Desirability Scale. *Journal of Consulting Psychology*, 24(4), 349–354. <https://doi.org/10.1037/h0047358>
- Crowne, Douglas P., & Marlowe, D. (1960). A new scale of social desirability independent of psychopathology. *Journal of Consulting Psychology*, 24(4), 349–354. <https://doi.org/10.1037/h0047358>
- Cruz, A., Garcia, D., Pires, G., & Nunes, U. (2015). Facial Expression Recognition based on EOG toward Emotion Detection for Human-Robot Interaction. *Biosignals*, 2, 31–37. Retrieved from <http://www.dblp.org/rec/bibtex/conf/biostec/CruzGPN15%5Cnpapers2://publication/uuid/F0A7D9E6-D8E8-4967-B20B-7EE34D518E7D>
- Cryptography, P. (2009). Mel Frequency Cepstral Coefficient (MFCC) tutorial. Retrieved March 13, 2017, from <http://practicalcryptography.com/miscellaneous/machine-learning/guide-mel-frequency-cepstral-coefficients-mfcc/>
- Csail, M. I. T. (n.d.). The AdaBoost algorithm, (0), 17.
- Curcio, G., Piccardi, L., Ferlazzo, F., Giannini, A. M., Burattini, C., & Bisegna, F. (2016). LED lighting effect on sleep, sleepiness, mood and vigor. *EEEIC 2016 - International Conference on Environment and Electrical Engineering*, 0–4. <https://doi.org/10.1109/EEEIC.2016.7555791>
- Czeisler, C. A., Allan, J. S., Strogatz, S. H., Ronda, J. M., Sanchez, R., Rios, C. D., ... Kronauer, R. E. (1986). Bright light resets the human circadian pacemaker independent of the timing of the sleep-wake cycle. *Science*, 233(4764), 667–671. <https://doi.org/10.1126/science.3726555>
- DeGiorgio, C. M., Miller, P., Meymandi, S., Chin, A., Epps, J., Gordon, S., ... Harper, R. M. (2010). RMSSD, a measure of vagus-mediated heart rate variability, is associated with risk factors for SUDEP: The SUDEP-7 Inventory. *Epilepsy and Behavior*, 19(1), 78–81. <https://doi.org/10.1016/j.yebeh.2010.06.011>
- Dellaert, F., Polzin, T., & Waibel, A. (1973). Recognizing emotion in speech. *Proceeding of Fourth International Conference on Spoken Language Processing. ICSLP '96*, 3, 1970–1973. <https://doi.org/10.1109/ICSLP.1996.608022>
- Denissen, J. J. a, Butalid, L., Penke, L., & van Aken, M. a G. (2008). The effects of weather on daily mood: a multilevel approach. *Emotion (Washington, D.C.)*, 8(5), 662–667. <https://doi.org/10.1037/a0013497>
- Desmet, P. (2003). Measuring Emotion: Development and Application of an Instrument to Measure Emotional Responses to Products (pp. 111–123). Springer Netherlands.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

[https://doi.org/10.1007/1-4020-2967-5\\_12](https://doi.org/10.1007/1-4020-2967-5_12)

- Desmet, P. M. a. (2005). Measuring Emotion: Development and Application of an Instrument to Measure Emotional Responses to Products. *Funology: From Usability to Enjoyment*, 3, 111–124. <https://doi.org/10.1007/1-4020-2967-5>
- Dhall, A., Asthana, A., Goecke, R., & Gedeon, T. (2011). Emotion recognition using PHOG and LPQ features. *2011 IEEE International Conference on Automatic Face and Gesture Recognition and Workshops, FG 2011*, 878–883. <https://doi.org/10.1109/FG.2011.5771366>
- Dickerson, S. S., & Kemeny, M. E. (2004). Acute stressors and cortisol responses: a theoretical integration and synthesis of laboratory research. *Psychological Bulletin*, 130(3), 355–391. <https://doi.org/10.1037/0033-2909.130.3.355>
- Diener, E., Emmons, R. A., Larsen, R. J., & Griffin, S. (1985). The Satisfaction With Life Scale. *Journal of Personality Assessment*. [https://doi.org/10.1207/s15327752jpa4901\\_13](https://doi.org/10.1207/s15327752jpa4901_13)
- Dienstbier, R. A. (1989). Arousal and physiological toughness: implications for mental and physical health. *Psychological Review*, 96(1), 84–100. <https://doi.org/10.1037/0033-295X.96.1.84>
- Dimensional Imaging LTD. (2017). DI3D System - 3D Facial Image Capture. Retrieved July 1, 2017, from <http://www.di4d.com/systems/di3d-system/>
- Ding, X., Boney-montoya, J., Owen, B. M., Bookout, A. L., Coate, C., Mangelsdorf, D. J., & Kliewer, S. a. (2013). BKloto is required for fibroblast growth factor 21 effects on growth and metabolism. *Cell Metabolism*, 16(3), 387–393. <https://doi.org/10.1016/j.cmet.2012.08.002>
- Dishman, R. K., Nakamura, Y., Garcia, M. E., Thompson, R. W., Dunn, a L., & Blair, S. N. (2000). Heart rate variability, trait anxiety, and perceived stress among physically fit men and women. *International Journal of Psychophysiology*, 37, 121–133.
- Ditor, D. S., Macdonald, M. J., Kamath, M. V, Bugaresti, J., Adams, M., McCartney, N., & Hicks, a L. (2005). Kubios HRV - Heart rate variability analysis software. <https://doi.org/10.1016/j.cmpb.2013.07.024>
- Dong, W., Lepri, B., & Pentland, A. (2011). Modeling the co-evolution of behaviors and social relationships using mobile phone data. *Proceedings of the 10th International Conference on Mobile and Ubiquitous Multimedia - MUM '11*, 134–143. <https://doi.org/10.1145/2107596.2107613>
- Duda, R. O., Hart, P. E., & Stork, D. G. (2001). Pattern Classification. *New York: John Wiley, Section*. <https://doi.org/10.1007/BF01237942>
- Dunbar, M., Ford, G., & Hunt, K. (1998). Why is the receipt of social support associated with increased psychological distress? An examination of three hypotheses. *Psychology and Health*, 13(3), 37–41. <https://doi.org/10.1080/08870449808407308>
- Dunst & Trivette, C. M., C. L. (1990). Assessment of social support in early intervention programs. *Handbook of Early Childhood Intervention*, 326–349.
- Eagle, N., & Pentland, A. (2006). Reality mining: Sensing complex social systems. *Personal and Ubiquitous Computing*, 10(4), 255–268. <https://doi.org/10.1007/s00779-005-0046-3>
- Eckert, M., Gil, A., Zapatero, D., Meneses, J., & Mart??nez Ortega, J. F. (2016). Fast facial

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

- expression recognition for emotion awareness disposal. *IEEE International Conference on Consumer Electronics - Berlin, ICCE-Berlin, 2016-October*, 179–183.  
<https://doi.org/10.1109/ICCE-Berlin.2016.7684749>
- Ehrampoosh, A., Yousefi-koma, A., & Mohtasebi, S. (2016). EMG-Based Estimation of Shoulder Kinematic Using Neural Network and Quadratic Discriminant Analysis, 471–476.
- Ekman, Paul; Friesen, W. V. (2003). *Unmasking The Face: A guide to recognizing emotions from facial expressions*. Malor Books.
- Ekman, Paul; Friesen, W. (1978). *Facial Action Coding System: A Technique for the Measurement of Facial Movement*. Palo Alto: Consulting Psychologists Press.
- Ekman, P. (1989). The argument and evidence about universals in facial expressions of emotion. *Handbook of Social Psychophysiology*. Retrieved from <https://www.paulekman.com/wp-content/uploads/2013/07/The-Argument-And-Evidence-About-Universals-In-FacialExpressi.pdf>
- Electrophysiology, T. F. o. t. E. S. o. C. t. N. A. S. (1996a). Heart Rate Variability : Standards of Measurement, Physiological Interpretation, and Clinical Use. *Circulation*, 93(5), 1043–1065. <https://doi.org/10.1161/01.CIR.93.5.1043>
- Electrophysiology, T. F. o. t. E. S. o. C. t. N. A. S. (1996b). Heart Rate Variability : Standards of Measurement, Physiological Interpretation, and Clinical Use. *Circulation*, 93(5), 1043–1065. <https://doi.org/10.1161/01.CIR.93.5.1043>
- Ellenbogen, M. a, Schwartzman, A. E., Stewart, J., & Walker, C.-D. C.-D. (2002). Stress and selective attention : The interplay of mood,cortisol levels, and emotional information processing. *Psychophysiology*, 39(6), 723–732.  
<https://doi.org/10.1017/S0048577202010739>
- Emotiv. (2017). EMOTIV SDK and Apps for Developers and proprietary research. Retrieved July 15, 2017, from <https://www.emotiv.com/developer/>
- Empatica Inc. (2017). Embrace Seizure Detection | Manage Epilepsy | SUDEP. Retrieved June 24, 2018, from <https://www.empatica.com/embrace/>
- ERIKG Group. (2011). ERIKG Group - Grass Technologies Full Sleep Study Solutions Provider. Retrieved from <http://www.erikg.com/grass.html>
- Estrada, E., Nazeran, H., Barragan, J., Burk, J. R., Lucas, E. A., & Behbehani, K. (2006). EOG and EMG: Two important switches in automatic sleep stage classification. *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 2458–2461. <https://doi.org/10.1109/IEMBS.2006.260075>
- Expert tools for Heart Rate analysis. (2016). CardioMood.
- Fasel, B., & Luettin, J. (2003). Automatic facial expression analysis: a survey. *Pattern Recognition*, 36(1), 259–275. [https://doi.org/10.1016/S0031-3203\(02\)00052-3](https://doi.org/10.1016/S0031-3203(02)00052-3)
- Fatourechi, M., Bashashatiemail, A., Wardemail, R. K., & Birchemail, G. E. (2007). EMG and EOG Artifacts in Brain-Computer Interface Systems: A Survey. *Clinical Neurophysiology*, 118(3), 480–494.
- Faust, V., Weidmann, M., & Wehner, W. (1974). The influence of meteorological factors on children and youths: a 10 per cent random selection of 16000 pupils and apprentices of Basle City (Switzerland). *Acta Paedopsychiatrica*, 40(4), 150–156. Retrieved from

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

<http://www.ncbi.nlm.nih.gov/pubmed/4597618>

- Fergus, A. (n.d.). How To Easily Measure Your Heart Rate Variability. Retrieved September 9, 2018, from <https://www.alexfergus.com/blog/how-to-easily-measure-your-heart-rate-variability>
- Finapres Medical Systems BV. (2012). Finapres Medical Systems | Products - Finapres® NOVA. Retrieved June 16, 2017, from <http://www.finapres.com/Products/Finapres-NOVA>
- Fiori, K. L., Antonucci, T. C., & Cortina, K. S. (2006). Social Network Typologies and Mental Health among Older Adults. *Journals of Gerontology Series B: Psychological Sciences and Social Sciences*, *61B*(1), 25–32. Retrieved from <http://search.proquest.com/docview/61610848?accountid=13374>
- Fisher, R. A. (1936a). the Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, *7*(2), 179–188. <https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>
- Fisher, R. A. (1936b). THE USE OF MULTIPLE MEASUREMENTS IN TAXONOMIC PROBLEMS. *Annals of Eugenics*, *7*(2), 179–188. <https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>
- FLIR Systems, I. (n.d.). FLIR Advanced Thermal Solutions: FLIR X6-8000sc Infrared Camera for Research & Science. Retrieved July 1, 2017, from <http://www.flir.com/science/display/?id=46802>
- Fonte, R. (2015). Fazer um exame ao nível de serotonina. Retrieved April 9, 2017, from <http://www.vladman.net/blog/fazer-um-exame-ao-nivel-de-serotonina>
- Fortin, J., Marte, W., Gr?llenberger, R., Hacker, A., Habenbacher, W., Heller, A., ... Skrabal, F. (2006). Continuous non-invasive blood pressure monitoring using concentrically interlocking control loops. *Computers in Biology and Medicine*, *36*(9), 941–957. <https://doi.org/10.1016/j.compbiomed.2005.04.003>
- Fraunhofer IIS. (2017). SHORE™ – pioneering facial analysis. Retrieved from <https://www.iis.fraunhofer.de/en/ff/bsy/tech/bildanalyse/shore-gesichtsdetektion.html>
- Frazão, A. (2016a). Entenda o que é Cortisol e para que serve. Retrieved April 8, 2017, from <https://www.tuasaude.com/cortisol/>
- Frazão, A. (2016b). Indicações e Modo de uso da Melatonina. Retrieved April 8, 2017, from <https://www.tuasaude.com/melatonina/>
- Frijda, N. H. (1986). *The Emotions*. Cambridge University Press. Retrieved from <https://books.google.pt/books?id=QkNuuVf-pBMC>
- Fuke, S. (2013). Blood pressure estimation from pulse wave velocity measured on the chest. *Psychophysiology*, *1*(1), 3–6. <https://doi.org/10.1109/JSEN.2014.2345779>
- Fukumto, M., & Nagamatsu, R. (2016). Feedback of Laughter by Detecting Variation in Respiration Amplitude for Augmenting Laughter. *2016 10th International Conference on Innovative Mobile and Internet Services in Ubiquitous Computing (IMIS)*, 139–142. <https://doi.org/10.1109/IMIS.2016.122>
- Fukunaga, K. (1990). *Introduction to Statistical Pattern Recognition*. *Pattern Recognition* (Vol. 22). [https://doi.org/10.1016/0098-3004\(96\)00017-9](https://doi.org/10.1016/0098-3004(96)00017-9)
- Fuller, R. W. (1996). The influence of fluoxetine on aggressive behavior. *Neuropsychopharmacology*, *14*(2), 77–81. [https://doi.org/10.1016/0893-133X\(95\)00110-Y](https://doi.org/10.1016/0893-133X(95)00110-Y)

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Fulton, B., & Medlock, M. (2003). Beyond Focus Groups : Getting More Useful Feedback from Consumers. *Game Developers Conference*. San Jose, CA.
- g.tec. (2017). g.tec medical engineering. Retrieved July 8, 2017, from <http://www.gtec.at/Products/Hardware-and-Accessories/g.MOBllab-Specs-Features>
- Gama, J., Carvalho, A., Faceli, K., Lorena, A., & Oliveira, M. (2012). *Extração de Conhecimento de Dados - Data Mining* (2nd ed.). Lisboa: Edições Sílabo, Lda.
- Gao, M., Olivier, N. B., & Mukkamala, R. (2016). Comparison of noninvasive pulse transit time estimates as markers of blood pressure using invasive pulse transit time measurements as a reference. *Physiological Reports*, 4(10), e12768. <https://doi.org/10.14814/phy2.12768>
- Garica-Ceja, E., Osmani, V., & Mayora, O. (2015). Automatic Stress Detection in Working Environments from Smartphones' Accelerometer Data: A First Step. *Biomedical and Health Informatics, IEEE Journal Of*, (to appear), 1–8. <https://doi.org/10.1109/JBHI.2015.2446195>
- Geerts, B. F., Aarts, L. P., & Jansen, J. R. (2011). Methods in pharmacology: Measurement of cardiac output. *British Journal of Clinical Pharmacology*, 71(3), 316–330. <https://doi.org/10.1111/j.1365-2125.2010.03798.x>
- George, L. K., Blazer, D. G., Hughes, D. C., & Fowler, N. (1989). Social support and the outcome of major depression. *The British Journal of Psychiatry*, 154(4), 478–485. <https://doi.org/10.1192/bjp.154.4.478>
- Giakoumis, D., Vogianou, A., Kosunen, I., Moustakas, K., Tzovaras, D., & Hassapis, G. (2010). Identifying Psychophysiological Correlates of Boredom and Negative Mood Induced During HCI. *Bio-Inspired Human-Machine Interfaces and Healthcare Applications*, 3–12. <https://doi.org/10.5220/0002812600030012>
- Gil, E. A., Aubert, X. L., & Beersma, D. G. M. (2014). Ambulatory estimation of human circadian phase using models of varying complexity based on non-invasive signal modalities. *Conference Proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, 2014*, 2278–2281. <https://doi.org/10.1109/EMBC.2014.6944074>
- Gilad-bachrach, R. (2004). Margin Based Feature Selection - Theory and Algorithms.
- Gimeno, F., van der Weele, L. T., Koëter, G. H., de Monchy, J. G., & van Alena, R. (1993). Variability of forced oscillation (Siemens Siregnost FD 5) measurements of total respiratory resistance in patients and healthy subjects. *Annals of Allergy*, 71(1), 56–60. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/8328715>
- Giri, E. P., Fanany, M. I., & Arymurthy, A. M. (2016). Ischemic Stroke Identification Based on EEG and EOG using 1D Convolutional Neural Network and Batch Normalization, 1–13. Retrieved from <http://arxiv.org/abs/1610.01757>
- GM Instruments. (2015). GM Instruments - Rhinomanometer, Acoustic Rhinometer, Rhinospirometer, Audiometer & Pneumotachograph.
- Gogia, Y., Singh, E., Mohatta, S., & Sreejith, V. (2016). Multi-modal Affect Detection for Learning Applications. In *2016 IEEE Region 10 Conference (TENCON)* (pp. 3747–3751).
- Goldberg, D., Bridges, K., Duncan-Jones, P., & Grayson, D. (1988). Detecting anxiety and depression in general medical settings. *Bmj*, 297(6653), 897–899.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

<https://doi.org/10.1136/bmj.297.6653.897>

- Gorestein, C. (1998). Inventário de depressão de Beck : propriedades psicométricas da versão em português, (January).
- Gouveia, M. J., & Marques, M. (2009). Versão portuguesa do questionário de bem-estar espiritual (SWBQ): análise confirmatória da sua estrutura factorial. *Psicologia, Saúde & Doenças, 10*(2), 285–293.
- Gow, R., Thomson, S., Rieder, M., Van Uum, S., & Koren, G. (2010). An assessment of cortisol analysis in hair and its clinical applications. *Forensic Science International, 196*(1–3), 32–37. <https://doi.org/10.1016/j.forsciint.2009.12.040>
- Gradisar, M., & Lack, L. (2004). Relationships between the circadian rhythms of finger temperature, core temperature, sleep latency, and subjective sleepiness. *Journal of Biological Rhythms, 19*(2), 157–163. <https://doi.org/10.1177/0748730403261560>
- Group, T. W. (1998). Development of the World Health Organization WHOQOL-BREF quality of life assessment. The WHOQOL Group. *Psychol Med, 28*(3), 551–558. <https://doi.org/10.5.12>
- Guillotel, P., Fleureau, J., Orlac, I., & Silveira, F. (2013). On the fly user’s emotion capture. *Proceedings - 2013 Humaine Association Conference on Affective Computing and Intelligent Interaction, ACII 2013, 713–714*. <https://doi.org/10.1109/ACII.2013.128>
- Guinot Jimeno, F. A., Yuste Bielsa, S., Cuadros Fernández, C., Lorente Rodríguez, A. I., & Mercadé Bellido, M. (2011). Objective and subjective measures for assessing anxiety in paediatric dental patients. *European Journal of Paediatric Dentistry, 12*(4), 239–244.
- Gunes, H., & Piccardi, M. (2007). Bi-modal emotion recognition from expressive face and body gestures. *Journal of Network and Computer Applications, 30*(4), 1334–1345. <https://doi.org/10.1016/j.jnca.2006.09.007>
- Gutmann, M., Grausberg, P., Kyamakya, K., & Klagenfurt, A. U. (2015). Detecting Human Driver ’ s Physiological Stress and Emotions Using Sophisticated One-Person Cockpit Vehicle Simulator, 15–18.
- Guyon, I., & Elisseeff, A. (2003). An Introduction to Variable and Feature Selection. *Journal of Machine Learning Research (JMLR), 3*(3), 1157–1182. <https://doi.org/10.1016/j.aca.2011.07.027>
- Haag, A., Goronzy, S., Schaich, P., & Williams, J. (2004). Emotion Recognition Using Bio-sensors: First Steps towards an Automatic System. *Affective Dialogue Systems, i*, 36–48. [https://doi.org/10.1007/978-3-540-24842-2\\_4](https://doi.org/10.1007/978-3-540-24842-2_4)
- Haddy, F. J., Overbeck, H. W., & Daugherty, R. M. (1968). Peripheral vascular resistance. <https://doi.org/10.1146/annurev.me.19.020168.001123>
- Hammerla, N. Y., Kirkham, R., Andras, P., & Ploetz, T. (2013). On preserving statistical characteristics of accelerometry data using their empirical cumulative distribution. *Proceedings of the 17th Annual International Symposium on International Symposium on Wearable Computers - ISWC '13, 65*. <https://doi.org/10.1145/2493988.2494353>
- Harb, F., Hidalgo, M. P., & Martau, B. (2014). Lack of exposure to natural light in the workspace is associated with physiological, sleep and depressive symptoms. *Chronobiology International, 1*(1), 1–8. <https://doi.org/10.3109/07420528.2014.982757>

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Hardt, J., & Gerbershagen, H. U. (1999). No changes in mood with the seasons: observations in 3000 chronic pain patients. *Acta Psychiatrica Scandinavica*, *100*(4), 288–294. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/10510698>
- Hareli, Shlomo; Parkinson, B. (2017). *What's Social About Social Emotions?*
- Haritaoglu, I., Cozzi, A., Koons, D., Flickner, M., Zotkin, D., & Yacoob, Y. (2001). ATTENTIVE TOYS IBM Almaden Research , San Jose , CA 95120 , USA Computer Vision Laboratory University of Maryland , College Park , MD 20742 , USA.
- Harmer, C J, Bhagwagar, Z., Perrett, D. I., Völlm, B. A., Cowen, P. J., & Goodwin, G. M. (2003). Acute SSRI administration affects the processing of social cues in healthy volunteers. *Neuropsychopharmacology : Official Publication of the American College of Neuropsychopharmacology*, *28*(1), 148–152. <https://doi.org/10.1038/sj.npp.1300004>
- Harmer, Catherine J., Shelley, N. C., Cowen, P. J., & Goodwin, G. M. (2004). Increased positive versus negative affective perception and memory in healthy volunteers following selective serotonin and norepinephrine reuptake inhibition. *American Journal of Psychiatry*, *161*(7), 1256–1263. <https://doi.org/10.1176/appi.ajp.161.7.1256>
- Harsono, B. (2012). Rancang Bangun Alat Pemantau Detak Jantung Saat Latihan Fisik. *Jurnal Teknik Dan Ilmu Komputer*, *1*(4), 338–346.
- Hawkley, L. C., & Cacioppo, J. T. (2010). Loneliness Matters: A Theoretical and Empirical Review of Consequences and Mechanisms. *Annals of Behavioral Medicine*, *40*(2), 218–227. <https://doi.org/10.1007/s12160-010-9210-8>
- Healey, J. A., & Picard, R. W. (2005). Detecting stress during real-world driving tasks using physiological sensors. *IEEE Transactions on Intelligent Transportation Systems*, *6*(2), 156–166. <https://doi.org/10.1109/TITS.2005.848368>
- Healey, J., & Picard, R. (1998). Digital processing of affective signals. *Proceedings of the 1998 IEEE International Conference on Acoustics, Speech and Signal Processing, ICASSP '98 (Cat. No.98CH36181)*, *6*, 3749–3752. <https://doi.org/10.1109/ICASSP.1998.679699>
- Healey, Jennifer a, Picard, R. W., & Smith, A. C. (2000). Wearable and Automotive Systems for A ect Recognition from Physiology Accepted by Wearable and Automotive Systems for A ect Recognition by, 158.
- Heimann, H., Bobon-Schrod, H., Schmocker, A. M., & Bobon, D. P. (1975). Self-rating of mood using a list of adjectives, Zersen's Befindlichkeits-Skala (BS). *L'Encéphale*, *1*(2), 165–183. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/1175501>
- Heitzmann, C. A., & Kaplan, R. M. (1988). Assessment of methods for measuring social support. *Health Psychology*, *7*(1), 75–109. <https://doi.org/10.1037//0278-6133.7.1.75>
- Helander, M. (1978). Applicability of drivers' electrodermal response to the design of the traffic environment. *Journal of Applied Psychology*, *63*(4), 481.
- Hendriks, A. A. J., Ormel, J., & van de Willige, G. (1990). Long-term difficulties measured by a self-report questionnaire and semi-structured interview: a comparison of methods [in Dutch]. *Gedrag En Gezondheid*, *18*, 273–283.
- Herbon, A., Peter, C., Markert, L., & Meer, E. Van Der. (2005). Emotion studies in HCI – a new approach. *Proceedings of the 2005 HCI International Conference*, (1986). Retrieved from [http://www.prometei.de/fileadmin/prometei.de/publikationen/Herbon\\_etal\\_2005.pdf](http://www.prometei.de/fileadmin/prometei.de/publikationen/Herbon_etal_2005.pdf)

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Hermida, R. C., Halberg, F., & Chavarria, F. (1988). Numerical resampling supports melatonin as a potential marker of breast cancer risk. In *IEEE/Engineering in Medicine and Biology Society Annual Conference* (Vol. 10 pt 3, pp. 1088–1089 vol.3). IEEE.  
<https://doi.org/10.1109/IEMBS.1988.94720>
- Hernandez, J., Morris, R. R., & Picard, R. W. (2011). Call Center Stress Recognition with Person-Specific Models. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 6974 LNCS(PART 1), 125–134.
- Hess, E. H., & Polt, J. M. (1960). Pupil size as related to interest value of visual stimuli. *Science (New York, N.Y.)*, 132(3423), 349–350. <https://doi.org/10.1126/science.132.3423.349>
- Hey, S., Gharbi, A., Von Haaren, B., Walter, K., König, N., & Löffler, S. (2009). Continuous noninvasive pulse transit time measurement for psychophysiological stress monitoring. *Proceedings - International Conference on EHealth, Telemedicine, and Social Medicine, ETELEMED 2009*, 113–116. <https://doi.org/10.1109/eTELEMED.2009.35>
- Hills, P., & Argyle, M. (2002). The Oxford Happiness Questionnaire: A compact scale for the measurement of psychological well-being. *Personality and Individual Differences*, 33(7), 1073–1082. [https://doi.org/10.1016/S0191-8869\(01\)00213-6](https://doi.org/10.1016/S0191-8869(01)00213-6)
- Hohaus, L., & Berah, E. (1996). Stress, achievement, marriage and social support: Effects on the psychological well-being of physicians entering mid-life/ mid-career. *Psychology and Health*, 11(5), 715–731. <https://doi.org/10.1080/08870449608405000>
- Holmes, T. H., & Rahe, R. H. (1967). The social readjustment rating scale. *Journal of Psychosomatic Research*, 11(2), 213–218. [https://doi.org/10.1016/0022-3999\(67\)90010-4](https://doi.org/10.1016/0022-3999(67)90010-4)
- Hoque, N., Ahmed, H. A., Bhattacharyya, D. K., & Kalita, J. K. (2016). A Fuzzy Mutual Information-based Feature Selection Method for Classification. *Fuzzy Information and Engineering*, 8(3), 355–384. <https://doi.org/10.1016/j.fiae.2016.09.004>
- Hormone Health Network. (2016). Learn answers to "What is Cortisol" | Hormone Health Network. Retrieved April 8, 2017, from <http://www.hormone.org/hormones-and-health/what-do-hormones-do/cortisol>
- Horne, J. A., & Ostberg, O. (1976). A self-assessment questionnaire to determine morningness–eveningness in human circadian rhythms. *International Journal of Chrono-Biology*, 4(April), 97–110.
- Hossain, M. S., Huda, K., Rahman, S. M. S., & Ahmad, M. (2016). Implementation of an EOG based security system by analyzing eye movement patterns. *Proceedings of 2015 3rd International Conference on Advances in Electrical Engineering, ICAEE 2015*, 149–152. <https://doi.org/10.1109/ICAEE.2015.7506818>
- Howard, S. (2012). One-way ANOVA. *Experimental Design and Analysis*, 171–190. Retrieved from <http://www.stat.cmu.edu/~hseltman/309/Book/chapter7.pdf>
- Howarth, E., & Hoffman, M. S. (1984). A multidimensional approach to the relationship between mood and weather. *British Journal of Psychology (London, England : 1953)*. <https://doi.org/10.1111/j.2044-8295.1984.tb02785.x>
- Hsu, Y. J., Shih, J. L., & Chen, C. H. (2012). Emotion labyrinth: Learning to rationalize emotions through 3D game environment. *Proceedings of the 2012 IIAI International Conference on Advanced Applied Informatics, IIAIAI 2012*, (1998), 153–158. <https://doi.org/10.1109/IIAI-AAI.2012.39>

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Huang, J., Kumar, S. R., Mitra, M., Zhu, W.-J., & Zabih, R. (1997a). Image indexing using color correlograms. *IEEE Int. Conf. of Computer Vision and Pattern Recognition*, 762--768. <https://doi.org/10.1109/CVPR.1997.609412>
- Huang, J., Kumar, S. R., Mitra, M., Zhu, W.-J., & Zabih, R. (1997b). Image indexing using color correlograms. In *Computer Vision and Pattern Recognition, 1997. Proceedings., 1997 IEEE Computer Society Conference on* (pp. 762–768). <https://doi.org/10.1109/CVPR.1997.609412>
- Huang, N. E., & Wu, Z. (2008). A Review on Hilbert-Huang Transform : Method and Its Applications. *Reviews of Geophysics*, 46(2007), 1–23. <https://doi.org/10.1029/2007RG000228.1.INTRODUCTION>
- Hudgins, B., Parker, P., & Scott, R. N. (1993). A New Strategy for Multifunction Myoelectric Control. *IEEE Transactions on Biomedical Engineering*, 40(1), 82–94. <https://doi.org/10.1109/10.204774>
- IBM Statistics. (n.d.). Generalized Linear Models. Retrieved November 26, 2017, from [https://www.ibm.com/support/knowledgecenter/en/SSLVMB\\_22.0.0/com.ibm.spss.statistics.help/spss/advanced/idh\\_idd\\_genlin\\_typeofmodel.htm](https://www.ibm.com/support/knowledgecenter/en/SSLVMB_22.0.0/com.ibm.spss.statistics.help/spss/advanced/idh_idd_genlin_typeofmodel.htm)
- IES Cities Project. (2016). Bristol Healthy Office - Application. Retrieved June 18, 2017, from <https://play.google.com/store/apps/details?id=eu.iescities.HealthyOffice>
- IMDb.com. (2016). Retrieved December 31, 2016, from <http://www.imdb.com/>
- Imholz, B. P. M., Montfrans, G. A. Van, Settels, J. J., Hoeven, G. M. A. Van Der, Karemaker, J. M., & Wieling, W. (1988). Continuous non-invasive blood pressure monitoring: Reliability of finapres device during the valsalva manoeuvre. *Cardiovascular Research*. <https://doi.org/10.1093/cvrese/22.6.390>
- Imholz, B. P. M., Wieling, W., Van Montfrans, G. A., & Wesseling, K. H. (1998, June 1). Fifteen years experience with finger arterial pressure monitoring: Assessment of the technology. *Cardiovascular Research*. Oxford University Press. [https://doi.org/10.1016/S0008-6363\(98\)00067-4](https://doi.org/10.1016/S0008-6363(98)00067-4)
- IMotions. (2016). GSR Pocket Guide The pocket guide, 1–36.
- Infiniti, P. (2008a). *Physiology Suite Biograph Infiniti*.
- Infiniti, P. (2008b). ProComp Infiniti, 2(800), 1–45.
- Investopedia. (2017). Sampling. Retrieved November 1, 2017, from <http://www.investopedia.com/terms/s/sampling.asp>
- IPLeiria. (2009). Técnicas de Amostragem - WikiEducacao. Retrieved October 1, 2017, from [http://wiki.ued.ipleiria.pt/wikiEducacao/index.php/Técnicas\\_de\\_Amostragem](http://wiki.ued.ipleiria.pt/wikiEducacao/index.php/Técnicas_de_Amostragem)
- Ismailoglu, N., & Yalcin, T. (1999). Low-power design of a digital FM demodulator based on zero-cross detection at IF. In *IEEE Vehicular Technology Conference* (Vol. 50, pp. 810–813). <https://doi.org/10.1109/VETEFC.1999.798441>
- Iwasaki, K., Miyaki, T., & Rekimoto, J. (2010). AffectPhone: A Handset Device to Present User's Emotional State with Warmth / Coolness. *B-Interface*, 1, 83–88.
- Izard E., C. (1972). *Patterns of emotions; a new analysis of anxiety and depression [by] Carroll E. Izard. With chapters coauthored by Edmund S. Bartlett [and] Alan G. Marshall*. New York.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Jack, R. E., Garrod, O. G. B., & Schyns, P. G. (2014). Dynamic facial expressions of emotion transmit an evolving hierarchy of signals over time. *Current Biology*, 24(2), 187–192.
- Jamshidnejad, A., & Jamshidined, A. (2009). Facial emotion recognition for human computer interaction using a fuzzy model in the e-business. *2009 Conference on Innovative Technologies in Intelligent Systems and Industrial Applications (CITISIA)*, (July), 202–204. <https://doi.org/10.1109/CITISIA.2009.5224214>
- Janković, D., & Stojanović, R. (2017). Flexible system for HRV analysis using PPG signal (pp. 705–712). Springer, Singapore. [https://doi.org/10.1007/978-981-10-4166-2\\_106](https://doi.org/10.1007/978-981-10-4166-2_106)
- Jaques, N., Taylor, S., Azaria, A., Ghandeharioun, A., Sano, A., & Picard, R. (2015). Predicting students' happiness from physiology, phone, mobility, and behavioral data. *2015 International Conference on Affective Computing and Intelligent Interaction, ACII 2015*, 222–228. <https://doi.org/10.1109/ACII.2015.7344575>
- Jarkovska, D., Valesova, L., Chvojka, J., Benes, J., Svirglerova, J., Florova, B., ... Stengl, M. (2016). Heart rate variability in porcine progressive peritonitis-induced sepsis. *Frontiers in Physiology*, 6(JAN). <https://doi.org/10.3389/fphys.2015.00412>
- Jawbone. (2017). UP by Jawbone | Fitness trackers for a healthier you. Retrieved July 22, 2017, from <https://jawbone.com/?rf=bodymedia>
- Jennings, J. R., Bberg, W. K., Hutcheson, J. S., Obrist, P., Porges, S., & Turpin, G. (1981). Publication Guidelines for Heart Rate Studies in Man. *Psychophysiology*, 18(3), 226–231. <https://doi.org/10.1111/j.1469-8986.1981.tb03023.x>
- Jerritta, S., Murugappan, M., Nagarajan, R., & Wan, K. (2011). Physiological signals based human emotion Recognition: a review. *Signal Processing and Its Applications (CSPA), 2011 IEEE 7th International Colloquium On*, 410–415. <https://doi.org/10.1109/CSPA.2011.5759912>
- John, O. P., & Srivastava, S. (1999). Big Five Inventory (BFI). *Handbook of Personality: Theory and Research*, 2, 102–138. <https://doi.org/10.1525/fq.1998.51.4.04a00260>
- Johnston, D. W., Propper, C., & Shields, M. A. (2009). Comparing Subjective and Objective Measures of Health : Evidence from Hypertension for the Income / Health Gradient Comparing Subjective and Objective Measures of Health : Evidence from Hypertension for the Income / Health Gradient, 2737(2737), 540–552.
- Jones, N. A. (1992). Electroencephalogram Asymmetry during Emotionally Evocative Films and Its Relation to Positive and Negative Affectivity. *Brain and Cognition*, 299(2), 280–299.
- Kahn, R. L., & Antonucci, T. C. (1980). Convoys over the life course: Attachment, roles, and social support. *Life-Span Development and Behavior*, (3), 253–286.
- Kamen, P. W., Krum, H., & Tonkin, A. M. (1996). Poincaré plot of heart rate variability allows quantitative display of parasympathetic nervous activity in humans. *Clinical Science (London, England : 1979)*, 91(2), 201–208. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/8795444>
- Kandel, E. R., Schwartz, J. H. H., & Jessell, T. M. (2000). *Principles of Neural Science* (Vol. 4). McGraw-hill New York. <https://doi.org/10.1007/s13398-014-0173-7.2>
- Kataoka, H., Kano, H., Yoshida, H., Saijo, A., Yasuda, M., & Osumi, M. (1998). Development of a skin temperature measuring system for non-contact stress evaluation. In *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International*

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

*Conference of the IEEE* (Vol. 2, pp. 940–943).

Kawai, S., Takano, H., & Nakamura, K. (2013). Pupil diameter variation in positive and negative emotions with visual stimulus. *Proceedings - 2013 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2013*, 4179–4183. <https://doi.org/10.1109/SMC.2013.712>

Kemper, T. D. (1978). *A social interactional theory of emotion*. *American Sociological Review* (Vol. 61 (5)). Wiley New York.

Kemper, T. P. (1991). Predicting Emotions from Social Relations. *Social Psychology Quarterly*, 54(4), 330–342. Retrieved from <http://www.jstor.org/stable/2786845>

Kessler, R. C., Price, R. H., & Wortman, C. B. (1985). Social Factors in Psychopathology: Stress, Social Support, and Coping Processes. *Annual Review of Psychology*, 36(1), 531–572. <https://doi.org/10.1146/annurev.ps.36.020185.002531>

Khalifa, S., Isabelle, P., Jean-Pierre, B., & Manon, R. (2002). Event-related skin conductance responses to musical emotions in humans. *Neuroscience Letters*, 328(2), 145–149. [https://doi.org/10.1016/S0304-3940\(02\)00462-7](https://doi.org/10.1016/S0304-3940(02)00462-7)

Kim, J., & André, E. (2008). Emotion recognition based on physiological changes in music listening. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 30(12), 2067–2083. <https://doi.org/10.1109/TPAMI.2008.26>

Kim, K. H., Bang, S. W., & Kim, S. R. (2004). Emotion recognition system using short term monitoring of physiological signals. *Medical Biological Engineering and Computing*, 42(Journal Article), 419–427. <https://doi.org/10.1007/BF02344719>

Kim, S., Anh, N., & Thi, N. (2016). Feature Extraction of Emotional States for EEG-based Rage Control. *39th International Conference on Telecommunications and Signal Processing (TSP)*, 361–364. <https://doi.org/10.1109/TSP.2016.7760897>

Kim, T. K. (2015). T test as a parametric statistic. *Korean Journal of Anesthesiology*, 68(6), 540–546. <https://doi.org/10.4097/kjae.2015.68.6.540>

Kim, T. K., Kittler, J., & Cipolla, R. (2007). Discriminative learning and recognition of image set classes using canonical correlations. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(6), 1005–1018. <https://doi.org/10.1109/TPAMI.2007.1037>

Kirschbaum, C., Pirke, K. M., & Hellhammer, D. H. (1993). The 'Trier Social Stress Test'--a tool for investigating psychobiological stress responses in a laboratory setting. *Neuropsychobiology*. <https://doi.org/119004>

Knutson, B., Wolkowitz, O. M., Cole, S. W., Chan, T., D, P., Moore, E. A., ... Reus, V. I. (1998). Selective Alteration of Personality and Social Behavior by Serotonergic Intervention. *The American Journal Of Psychiatry*, 155(3), 373–379. <https://doi.org/10.1176/ajp.155.3.373>

Koch, C. (2012). Estudo das propriedades métricas da versão portuguesa para Portugal do Well-Being Questionnaire12 ( W-BQ12 ) em mulheres com perda de gravidez. *Revista Latino-Americana de Enfermagem*, 20(3). <https://doi.org/10.1590/S0104-11692012000300019>

Kohavi, R., & John, G. H. (1997). Wrappers for feature subset selection. *Artificial Intelligence*, 97(1–2), 273–324. [https://doi.org/10.1016/S0004-3702\(97\)00043-X](https://doi.org/10.1016/S0004-3702(97)00043-X)

Koralewski. (n.d.). Koralewski Elektronik. Retrieved July 16, 2017, from

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

<http://www.koralewski.de/english/index.php>

- Korf, R. E. (1993). Linear-space best-first search. *Artificial Intelligence*, 62(1), 41–78. [https://doi.org/10.1016/0004-3702\(93\)90045-D](https://doi.org/10.1016/0004-3702(93)90045-D)
- Korkmaz, O. E., & Atasoy, A. (2015). Emotion Recognition from Speech Signal Using Mel-Frequency Cepstral Coefficients, 1254–1257.
- Kosaka, T., Tanahashi, F., Matsui, N., & Fujitsuna, M. (2002). Current zero cross detection-based position sensorless control of synchronous reluctance motors. In *Industry Applications Conference, 2002. 37th IAS Annual Meeting. Conference Record of the* (Vol. 3, pp. 1610–1616 vol.3). <https://doi.org/10.1109/IAS.2002.1043750>
- Kreibig, S. D. (2010). Autonomic nervous system activity in emotion: A review. *Biological Psychology*, 84(3), 394–421. <https://doi.org/10.1016/j.biopsycho.2010.03.010>
- Kroenke, K., Spitzer, R. L., & Williams, J. B. W. (2001). The PHQ-9: Validity of a brief depression severity measure. *Journal of General Internal Medicine*, 16(9), 606–613. <https://doi.org/10.1046/j.1525-1497.2001.016009606.x>
- Kumar, V., & Chadha, A. (2011). An empirical study of the applications of data mining techniques in higher education. ... *Journal of Advanced Computer Science and ...*, 2, 80–84. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.214.4184&rep=rep1&type=pdf#page=84%5Cnwww.ijacsa.thesai.org>
- Kusserow, M., Amft, O., & Troster, G. (2013). Monitoring Stress Arousal in the Wild. *IEEE Pervasive Computing*, 12(2), 28–37. <https://doi.org/10.1109/MPRV.2012.56>
- KWMC. (2016). Bristol Healthy Office. Retrieved June 18, 2017, from <http://kwmc.org.uk/projects/bristolhealthyoffice/>
- LabX. (2017). Applied Science Laboratories 4000SU Eye Tracking System | For Sale | LabX Ad 3688478. Retrieved June 2, 2017, from <http://www.labx.com/item/applied-science-laboratories-4000su-eye-tracking-system/3688478>
- Lack, L. C., Gradisar, M., Van Someren, E. J. W., Wright, H. R., & Lushington, K. (2008). The relationship between insomnia and body temperatures. *Sleep Medicine Reviews*, 12(4), 307–317. <https://doi.org/10.1016/j.smr.2008.02.003>
- Laerd. (2013). Pearson Product-Moment Correlation. Retrieved November 3, 2017, from <https://statistics.laerd.com/statistical-guides/pearson-correlation-coefficient-statistical-guide.php>
- Lai, H., Ramanathan, V., & Wechsler, H. (2008). Reliable face recognition using adaptive and robust correlation filters. *Computer Vision and Image Understanding*, 111(3), 329–350. <https://doi.org/10.1016/j.cviu.2008.01.003>
- Lake, D. E., Richman, J. S., Griffin, M. P., & Moorman, J. R. (2002). Sample entropy analysis of neonatal heart rate variability. *American Journal of Physiology - Regulatory, Integrative and Comparative Physiology*, 283(3), R789–R797. <https://doi.org/10.1152/ajpregu.00069.2002>
- Lalitha, S., Mudupu, A., Nandyala, B. V., & Munagala, R. (2015). Speech emotion recognition using DWT. In *2015 IEEE International Conference on Computational Intelligence and Computing Research (ICICR)* (Vol. 6, pp. 1–4). IEEE. <https://doi.org/10.1109/ICICR.2015.7435630>

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Lane, N. D., Miluzzo, E., Lu, H., Peebles, D., Choudhury, T., & Campbell, A. T. (2010). A survey of mobile phone sensing. *IEEE Communications Magazine*, 48(9), 140–150. <https://doi.org/10.1109/MCOM.2010.5560598>
- Lane, N., Mohammad, M., Lin, M., & Yang, X. (2011). Bewell: A smartphone application to monitor, model and promote wellbeing. ... *Computing Technologies ...*. Retrieved from <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.298.2259&rep=rep1&type=pdf>
- Lane, R. D., Reiman, E. M., Bradley, M. M., Lang, P. J., Ahern, G. L., Davidson, R. J., & Schwartz, G. E. (1997). Neuroanatomical correlates of pleasant and unpleasant emotion. *Neuropsychologia*, 35(11), 1437–1444.
- Lang, P.J., Bradley, M. M., & Cuthbert, B. N. (2005). International affective picture system (IAPS): Affective ratings of pictures and instruction manual. *Tech. Rep. A-6*.
- Lang, Peter J. (1995). The emotion probe: Studies of motivation and attention. *American Psychologist*, 50(5), 372–385. <https://doi.org/10.1037//0003-066X.50.5.372>
- Lang, Peter J., Levin, D. N., Miller, G. A., & Kozak, M. J. (1983). Fear behavior, fear imagery, and the psychophysiology of emotion: The problem of affective response integration. *Journal of Abnormal Psychology*, 92(3), 276–306. <https://doi.org/10.1037/0021-843X.92.3.276>
- Larsen. (1993). The Affect Intensity Measure (AIM).
- Larsen, J. T., Mcgraw, P. A., & Cacioppo, J. T. (2001). Can People Feel Happy and Sad at the Same Time? *Journal of Personality and Social Psychology*, 81(4), 684–696.
- Larsen, R. J. (1984). Theory and Measurement of Affect Intensity As an Individual difference characteristic., 85.
- Larsen, Randy J., & Diener, E. (1987). Affect intensity as an individual difference characteristic: A review. *Journal of Research in Personality*, 21(1), 1–39. [https://doi.org/10.1016/0092-6566\(87\)90023-7](https://doi.org/10.1016/0092-6566(87)90023-7)
- Lazarus, R. S., & Launier, R. (1978). Stress-Related Transactions between Person and Environment. In *Perspectives in Interactional Psychology* (pp. 287–327). Springer. [https://doi.org/10.1007/978-1-4613-3997-7\\_12](https://doi.org/10.1007/978-1-4613-3997-7_12)
- Lee, C., Yoo, S. K., Park, Y., Kim, N., Jeong, K., & Lee, B. (2005). Using neural network to recognize human emotions from heart rate variability and skin resistance. *Conference Proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Conference*, 5, 5523–5525. <https://doi.org/10.1109/IEMBS.2005.1615734>
- Lee, S. H., Member, S., Ro, Y. M., & Member, S. (2016). Partial Matching of Facial Expression Sequence Using Over-Complete Transition Dictionary for Emotion Recognition, 7(4), 389–408.
- Lee, Y. C., Chou, C. C., Fang, W. C., & Huang, H. C. (2011). Portable sleep monitoring and awaking system based on EEG, ECG, tri-axis accelerometers and LED array panel. *Digest of Technical Papers - IEEE International Conference on Consumer Electronics*, 133–136. <https://doi.org/10.1109/ICCE-Berlin.2011.6031867>
- Leite, W. L. (2005). Validation of Scores on the Marlowe-Crowne Social Desirability Scale and the Balanced Inventory of Desirable Responding. *Educational and Psychological Measurement*, 65(1), 140–154. <https://doi.org/10.1177/0013164404267285>

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Lemnaru, C., & Potolea, R. (2018). Evolutionary Cost-Sensitive Balancing: A Generic Method for Imbalanced Classification Problems (pp. 194–209). [https://doi.org/10.1007/978-3-319-69710-9\\_14](https://doi.org/10.1007/978-3-319-69710-9_14)
- Leonetti, A., & Foderaro, G. (2007). Beck Depression Inventory (BDI). *Apa.Org*. Retrieved from <http://www.apa.org/pi/about/publications/caregivers/practice-settings/assessment/tools/beck-depression.aspx>
- Levenson, R. W., Ekman, P., & Friesen, W. V. (1990). Voluntary Facial Action Generates Emotion Specific Autom. *Psychophysiology*. <https://doi.org/10.1111/j.1469-8986.1990.tb02330.x>
- Lewy, a J., & Sack, R. L. (1989). The dim light melatonin onset as a marker for circadian phase position. *Chronobiology International*, 6(1), 93–102. <https://doi.org/10.3109/07420528909059144>
- Leyvand, T., Meekhof, C., Wei, Y. C., Sun, J., & Guo, B. (2011). Kinect identity: Technology and experience. *Computer*, 44(4), 94–96. <https://doi.org/10.1109/MC.2011.114>
- Li, Z., Shi, D., Wang, F., & Liu, F. (2016). Loneliness Recognition Based on Mobile Phone Data, (Isaece), 165–172.
- Lichtenstein, Antje; Oehme, A. K. S. J. T. (2008). *Comparing Two Emotion Models for Deriving Affective States from Physiological Data. Affect and Emotion in HCI, LNCS*. Retrieved from <http://www.ulb.tu-darmstadt.de/tocs/59142804.pdf>
- LiKamWa, R., Liu, Y., Lane, N. D., & Zhong, L. (2013). MoodScope: Building a Mood Sensor from Smartphone Usage Patterns. *Proceeding of the 11th Annual International Conference on Mobile Systems, Applications, and Services - MobiSys '13*, 389. <https://doi.org/10.1145/2462456.2464449>
- Lim, Y. G., Kim, K. K., & Park, K. S. (2006). ECG measurement on a chair without conductive contact. *IEEE Transactions on Biomedical Engineering*, 53(5), 956–959. <https://doi.org/10.1109/TBME.2006.872823>
- Linder, B. (2015). Toshiba unveils Silmee W20/W21 health trackers - Liliputing. Retrieved May 28, 2017, from <https://liliputing.com/2015/07/toshiba-unveils-silmee-w20w21-health-trackers.html>
- Linh, T. (2008). EMOTIV EPOC+ 14 Channel Mobile EEG. Retrieved June 11, 2017, from <https://www.emotiv.com/store/>
- Linton Instrumentation. (2011). Biopac Biopac MP100 - BIOPAC MP100 MP100 : Linton Instruments. Retrieved June 17, 2017, from [http://www.lintoninst.co.uk/Products/tabid/63/ProdID/487/Language/en-US/CatID/127/Biopac\\_MP100\\_.aspx](http://www.lintoninst.co.uk/Products/tabid/63/ProdID/487/Language/en-US/CatID/127/Biopac_MP100_.aspx)
- Lisetti, C. L., & Nasoz, F. (2004). Using Noninvasive Wearable Computers to Recogniza Human Emotions from Physiological Signals. *Journal of Applied Signal Processing*, 11, 1672–1687. <https://doi.org/10.1155/S1110865704406192>
- Liu, C., Yuen, J., & Torralba, A. (2015). Sift flow: Dense correspondence across scenes and its applications. *Dense Image Correspondences for Computer Vision*, 15–49. [https://doi.org/10.1007/978-3-319-23048-1\\_2](https://doi.org/10.1007/978-3-319-23048-1_2)
- Liu, L., Chen, X., Lu, Z., Cao, S., Wu, D., & Zhang, X. (2017). Development of an EMG-ACC-Based Upper, 25(3), 244–253.

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Liu, S., Zhang, Y., & Liu, K. (2014). Facial expression recognition under partial occlusion based on Weber Local Descriptor histogram and decision fusion. *Proceedings of the 33rd Chinese Control Conference, CCC 2014*, 4664–4668. <https://doi.org/10.1109/ChiCC.2014.6895725>
- Liu, Y., Sourina, O., & Nguyen, M. K. (2010). Real-time EEG-based human emotion recognition and visualization. *Proceedings - 2010 International Conference on Cyberworlds, CW 2010*, 262–269. <https://doi.org/10.1109/CW.2010.37>
- Long, X., Fonseca, P., Foussier, J., Haakma, R., & Aarts, R. M. (2014). Sleep and wake classification with actigraphy and respiratory effort using dynamic warping. *IEEE Journal of Biomedical and Health Informatics*, 18(4), 1272–1284. <https://doi.org/10.1109/JBHI.2013.2284610>
- Lopes, P. N., Salovey, P., & Straus, R. (2003). Emotional intelligence, personality, and the perceived quality of social relationships. *Personality and Individual Differences*, 35(3), 641–658. [https://doi.org/10.1016/S0191-8869\(02\)00242-8](https://doi.org/10.1016/S0191-8869(02)00242-8)
- Lu, Y., Lu, C., Qi, M., & Wang, S. (2010). Local Matching Algorithm for Face Recognition, 28–37.
- Luefeng, C., Min, W. U., Mengtian, Z., Jinhua, S. H. E., & Kaoru, H. (2016). Dynamic Emotion Understanding Using FCM Based SVR in Human-Robot Interaction \*, 7064–7069.
- Lyons, R. G. (2004). *Understanding Digital Signal Processing. Angewandte Chemie International Edition* (Vol. 40). [https://doi.org/10.1002/1521-3773\(20010316\)40:6<9823::AID-ANIE9823>3.3.CO;2-C](https://doi.org/10.1002/1521-3773(20010316)40:6<9823::AID-ANIE9823>3.3.CO;2-C)
- Machine Learning Group at the University of Waikato. (n.d.). Weka 3 - Data Mining with Open Source Machine Learning Software in Java. Retrieved June 24, 2017, from <http://www.cs.waikato.ac.nz/ml/weka/>
- Mackworth, A., & Goebel, R. (1998). Best-first Search. *Computational Intelligence*, 1–8.
- Madan, A., Cebrian, M., Moturu, S., Farrahi, K., & Pentland, A. S. (2012). Sensing the health state of a community. *IEEE Pervasive Computing*, 11(4), 36–45. <https://doi.org/10.1109/MPRV.2011.79>
- Malik, A. S. (2009). Simulation-based analysis of the resolution and SNR properties of partial k-space EPI. *Concepts in Magnetic Resonance Part B: Magnetic Resonance Engineering*, 35(4), 232–237. <https://doi.org/10.1002/cmr.b.20147>
- Mandryk, R. L., & Atkins, M. S. (2007). A fuzzy physiological approach for continuously modeling emotion during interaction with play technologies. *International Journal of Human Computer Studies*, 65(4), 329–347. <https://doi.org/10.1016/j.ijhcs.2006.11.011>
- Mandryk, R. L., Atkins, M. S., & Inkpen, K. M. (2006). A continuous and objective evaluation of emotional experience with interactive play environments. *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems CHI 06*, 2(October 2016), 1027. <https://doi.org/10.1145/1124772.1124926>
- Mandryk, R. L., & Inkpen, K. M. (2004). Physiological indicators for the evaluation of co-located collaborative play. *Proceedings of the 2004 ACM Conference on Computer Supported Cooperative Work - CSCW '04*, (January 2004), 102. <https://doi.org/10.1145/1031607.1031625>
- Manuck, S. B., Cohen, S., Rabin, B. S., Muldoon, M. F., & Bachen, E. A. (1991). Individual differences in cellular immune response to stress. *American Psychological Society*.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Maragos, P., & Sun, F. K. (1993). Measuring the Fractal Dimension of Signals: Morphological Covers and Iterative Optimization. *IEEE Transactions on Signal Processing*, 41(1), 108. <https://doi.org/10.1109/TSP.1993.193131>
- Markho, F. (2016). Major Influences in Households and Business Spaces – Wi-Fi , Telecommunication Masts Outputs and Electrical Pollution, (Epe), 20–22.
- Martin. (1000). Two-way ANOVA and ANCOVA. *None*, 1–6. <https://doi.org/10.1002/9781118491683>
- Martinez-Nicolas, A., Ortiz-Tudela, E., Rol, M. A., & Madrid, J. A. (2013a). Uncovering Different Masking Factors on Wrist Skin Temperature Rhythm in Free-Living Subjects. *PLoS ONE*, 8(4), e61142. <https://doi.org/10.1371/journal.pone.0061142>
- Martinez-Nicolas, A., Ortiz-Tudela, E., Rol, M. A., & Madrid, J. A. (2013b). Uncovering Different Masking Factors on Wrist Skin Temperature Rhythm in Free-Living Subjects. *PLoS ONE*, 8(4), e61142. <https://doi.org/10.1371/journal.pone.0061142>
- Mason, J. W. (1968). A review of psychoendocrine research on the sympathetic-adrenal medullary system. *Psychosomatic Medicine*, 30(5), Suppl:631-653. <https://doi.org/1968/09000>
- Matiko, J. W., Beeby, S. P., & Tudor, J. (2014). Fuzzy logic based emotion classification. In *2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 4389–4393). IEEE. <https://doi.org/10.1109/ICASSP.2014.6854431>
- Matlovic, T., Gaspar, P., Moro, R., Simko, J., & Bielikova, M. (2016). Emotions Detection Using Facial Expressions Recognition and EEG. *11th International Workshop on Semantic and Social Media Adaptation and Personalization (SMAP)*, 18–23. <https://doi.org/10.1109/SMAP.2016.7753378>
- Matsunaga, K. (1990). Psychology of the Pupil Movement. Nakanishiya publishing.
- Mayampurath, A., Volchenboum, S. L., & Sanchez-Pinto, L. N. (2018). Using photoplethysmography data to estimate heart rate variability and its association with organ dysfunction in pediatric oncology patients. *Npj Digital Medicine*, 1(1), 29. <https://doi.org/10.1038/s41746-018-0038-0>
- McCrae, R. R., & John, O. P. (1992). An Introduction to the Five-Factor Model and Its Applications. *Journal of Personality*, 60(2), 175–215. <https://doi.org/10.1111/j.1467-6494.1992.tb00970.x>
- McLeod, S. (2010). SRRS - Stressful Life Events and Daily Hassles | Simply Psychology. Retrieved June 22, 2017, from <https://www.simplypsychology.org/SRRS.html>
- McNair, D., Lorr, M., & Droppleman, L. (1989). Profile of Mood States (POMS).
- McNulty W, Gevirtz R, Berkoff G, H. D. (1994). Needle EMG Pevaluation of trigger point response to a psychological stressor. *Psychophysiol* 31,313-316, 1994.pdf. *Psychophysiology*, 31(3), 313–316.
- Medtronic. (2015). HxM | Zephyr™ Performance Systems. Retrieved June 16, 2017, from <https://www.zephyranywhere.com/resources/hxm>
- Mehta, S. K., Super, D. M., Salvator, A., Fradley, L. G., Connuck, D., & Kaufman, E. S. (2002). Heart rate variability by triangular index in infants exposed prenatally to cocaine. *Annals of Noninvasive Electrocardiology : The Official Journal of the International Society for*

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Holter and Noninvasive Electrocardiology, Inc*, 7(4), 374–378. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/12431317>
- Merens, W., Willem Van der Does, A. J., & Spinhoven, P. (2007). The effects of serotonin manipulations on emotional information processing and mood. *Journal of Affective Disorders*, 103(1–3), 43–62. <https://doi.org/10.1016/j.jad.2007.01.032>
- Microsoft. (2017a). Kinect – Desenvolvimento de aplicações do Windows. Retrieved June 30, 2017, from <https://developer.microsoft.com/pt-pt/windows/kinect>
- Microsoft. (2017b). Microsoft Cognitive Services - Emotion API. Retrieved December 31, 2016, from <https://www.microsoft.com/cognitive-services/en-us/emotion-api>
- Mietus, J., Peng, C.-K., Henry, I., Goldsmith, R., & AL, G. (2015). pNNx: Time Domain Heart Rate Variability Analysis. Retrieved October 15, 2017, from <https://physionet.org/physiotools/pNNx/>
- Mill, S., Road, R., Ardsley, P. O. B., & York, N. (n.d.). MicroMini-Motionlogger® Actigraph Interface/Connector with ACT Operational Software Micro Motionlogger Sleep Watch, 1–6. Retrieved from [www.ambulatory-monitoring.com](http://www.ambulatory-monitoring.com)
- Miller, G. A., Levin, D. N., Kozak, M. J., Edwin, E., McLean, A., & Lang, P. J. (1987). Individual Differences in Imagery and the Psychophysiology of Emotion. *Cognition and Emotion*, 1(4), 367–390. <https://doi.org/10.1080/02699938708408058>
- Miluzzo, E., Lane, N. D., Fodor, K., Peterson, R., Lu, H., Musolesi, M., ... Campbell, A. T. (2008). Sensing meets mobile social networks. *ACM Conference on Embedded Network Sensor Systems*, 337–350. <https://doi.org/10.1145/1460412.1460445>
- Mind Media. (n.d.). Biofeedback and neurofeedback systems | Oximetry Sensor. Retrieved August 15, 2017, from <http://www.mindmedia.info/CMS2014/en/products/sensors/oximetry-sensor>
- Mokhayeri, F., & Toosizadeh, S. (2011). Mental Stress Detection Using Physiological Signals Based on Soft Computing Techniques. *18th Iranian Conference on BioMedical Engineering*, (December), 232–237. <https://doi.org/10.1109/ICBME.2011.6168563>
- Monteiro, S., Tavares, J., Pereira, A., & Universidade de Aveiro, P. (2012). Adaptação portuguesa da escala de medida de manifestação de bem-estar psicológico com estudantes universitários – emmbep. *Psicologia, Saúde & Doenças*, 13(1), 66–77.
- Morris, T. L., & Miller, J. C. (1996). Electrooculographic and performance indices of fatigue during simulated flight. *Biological Psychology*, 42(3), 343–360. [https://doi.org/10.1016/0301-0511\(95\)05166-X](https://doi.org/10.1016/0301-0511(95)05166-X)
- Mosby's Medical Dictionary. (2009). peripheral vascular resistance. Retrieved April 18, 2017, from <http://medical-dictionary.thefreedictionary.com/peripheral+vascular+resistance>
- Moskowitz, D. S., Pinard, G., Zuroff, D. C., Annable, L., & Young, S. N. (2001). The effect of tryptophan on social interaction in everyday life: A placebo-controlled study. *Neuropsychopharmacology*, 25(2), 277–289. [https://doi.org/10.1016/S0893-133X\(01\)00219-6](https://doi.org/10.1016/S0893-133X(01)00219-6)
- Moturu, S. T., Khayal, I., Aharony, N., Pan, W., & Pentland, A. S. (2011). Using Social Sensing to Understand the Links Between Sleep, Mood, and Sociability. Retrieved from <http://hd.media.mit.edu/tech-reports/TR-670.pdf>

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- movisens GmbH. (2018a). EdaMove 3. Retrieved June 24, 2018, from <https://www.movisens.com/en/products/edamove-3/>
- movisens GmbH. (2018b). EdaMove 3 – EDA and Activity Sensor. Retrieved November 3, 2018, from <https://www.movisens.com/en/products/eda-and-activity-sensor-move-3/>
- Mower, E., Matari, M. J., & Narayanan, S. (2011). A Framework for Automatic Human Emotion Classification Using Emotion Profiles. *Ieee Transactions on Audio, Speech, and Language Processing*, 19(5), 1057–1070. <https://doi.org/10.1109/TASL.2010.2076804>
- Muaremi, A., Arnrich, B., & Tröster, G. (2012). A Survey on Measuring Happiness with Smart Phones. *6th International Workshop on Ubiquitous Health and Wellness .UbiHealth*, (January). Retrieved from [http://www.researchgate.net/publication/235834264\\_A\\_Survey\\_on\\_Measuring\\_Happin\\_ess\\_with\\_Smart\\_Phones/file/9fcfd513f50c5229f9.pdf](http://www.researchgate.net/publication/235834264_A_Survey_on_Measuring_Happin_ess_with_Smart_Phones/file/9fcfd513f50c5229f9.pdf)
- Muaremi, A., Bexheti, A., Gravenhorst, F., Arnrich, B., & Tröster, G. (2014). Monitoring the Impact of Stress on the Sleep Patterns of Pilgrims using Wearable Sensors. *IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)*, 3–6. <https://doi.org/10.1109/BHI.2014.6864335>
- Müller, G., & Martin, G. (1992). [Quantitative measurement of peripheral vascular resistance with a cavernous sinus ultrasound instrument (Cavomat)]. *VASA. Supplementum*, 36, 25–28. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/1529421>
- Murad, U., & Malkawi, M. (2012). Artificial neuro fuzzy logic system for detecting human emotions. *IEEE CITS 2012 - 2012 International Conference on Computer, Information and Telecommunication Systems*, 1–13. <https://doi.org/10.1109/CITS.2012.6220388>
- Murai, M., Nakayama, M., & Shimizu, Y. (1998). A correlation of pupillary changes and subjective evaluation to television programs. *IEICE Technical Report. Education Technology*, 98(156), 7–14. <https://doi.org/10.3169/itej.52.1748>
- Murali, S., Rincon, F., & Atienza, D. (2015). A wearable device for physical and emotional health monitoring. *2015 Computing in Cardiology Conference (CinC)*, 121–124. <https://doi.org/10.1109/CIC.2015.7408601>
- Myers, & Briggs. (n.d.). The Myers and Briggs Personality Test | Online Personality Tests. Retrieved July 1, 2017, from <http://www.onlinepersonalitytests.org/mbti>
- Natus Medical Inc. (2017). Natus Medical Incorporated - Grass. Retrieved from [http://www.natus.com/index.cfm?page=company\\_1&crd=753](http://www.natus.com/index.cfm?page=company_1&crd=753)
- Nawasalkar, R. K., Lawange, H. R., Gupta, S. D., Butey, P. K., & Email, W. S. (2013). Study of comparison of human bio-signals for emotion detection using HCI. *International Journal of Emerging Trends & Technology in Computer Science*, 2(2), 449–452.
- Neurosky. (2017). EEG Headsets | NeuroSky Store. Retrieved June 16, 2017, from <http://neurosky.com/biosensors/eeg-sensor/biosensors/>
- NeuroSky. (2017). Development Tools for PC/Mac. Retrieved June 30, 2017, from <http://developer.neurosky.com/docs/doku.php?id=mdt2.5>
- Nichkova, M. I., Huisman, H., Wynveen, P. M., Marc, D. T., Olson, K. L., & Kellermann, G. H. (2012). Evaluation of a novel ELISA for serotonin: Urinary serotonin as a potential biomarker for depression. *Analytical and Bioanalytical Chemistry*, 402(4), 1593–1600. <https://doi.org/10.1007/s00216-011-5583-1>

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Nicolai, T., & Kenn, H. (2007). About the relationship between people and discoverable Bluetooth devices in urban environments. In *Proceedings of the 4th international conference on mobile technology, applications, and systems and the 1st international symposium on Computer human interaction in mobile technology - Mobility '07* (p. 72). New York, New York, USA: ACM Press. <https://doi.org/10.1145/1378063.1378076>
- Niedermeyer, E., & Silva, F. H. L. da. (2005). *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields* (Vol. 1). Retrieved from <https://books.google.fr/books?id=tndqYGPHQdEC>
- Niemic, C. P., Kirk, A., Brown, W., & Ph, D. (2002). Studies of Emotion: A Theoretical and Empirical Review of Psychophysiological Studies of Emotion. *Journal of Undergraduate Research*, 15–18.
- Noldus. (2017). Facial expression recognition software: FaceReader. Retrieved March 12, 2017, from <http://www.noldus.com/human-behavior-research/products/facereader>
- Norman, D. A. (2002). Emotion & Design: Attractive things work better - jnd.org, (October). <https://doi.org/10.1145/543434.543435>
- Nwe, L., Wei, S., Silva, D., Liyanage, C., Silva, D., Speech, L. C., ... Member, S. (2001). Speech based emotion classification.
- Omar, D. A. (2006). EMOÇÕES - Artigos.com. Retrieved April 9, 2017, from <http://www.artigos.com/artigos/13851-emocoos>
- OMS. (2016). WHO | Health. Retrieved from <http://www.who.int/about/mission/en/>
- OriginLab Corporation. (n.d.). Origin Data Analysis and Graphing Software Exercise. Retrieved July 2, 2017, from <http://www.originlab.com/Origin>
- Ornelas, J. (1996). Suporte social e doença mental. *Análise Psicológica*, 2-3 (XIV), 263–268.
- Oswald, A. J., & Wu, S. (2010). Objective Confirmation of Subjective Measures of Human Well-Being: Evidence from the U.S.A. *Science*, 327(5965), 576–579. <https://doi.org/10.1126/science.1180606>
- Oura Crew. (2017). How to Measure Heart Rate Variability? | OURA HRV Tracking. Retrieved September 9, 2018, from <https://blog.ouraring.com/blog/how-to-measure-heart-rate-variability/>
- Ouwerkerk, M., Pasveer, F., & Langereis, G. (2008). Unobtrusive sensing of psychophysiological parameters. *Probing Experience*, 163–193. [https://doi.org/10.1007/978-1-4020-6593-4\\_15](https://doi.org/10.1007/978-1-4020-6593-4_15)
- P. Ekman, R. W. Levenson, and W. V. F. (1983). Autonomic-Nervous-System-Activity-Distinguishes-Among-Emotio.pdf. *Science*, 221, 1208–1210.
- Padmanabhan, M., Murali, S., Rincon, F., & Atienza, D. (2015). Energy-aware embedded classifier design for real-time emotion analysis. In *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS* (Vol. 2015-Novem, pp. 2275–2278). IEEE. <https://doi.org/10.1109/EMBC.2015.7318846>
- Pagulayan, R. J., Keecker, K., Wixon, D., Romero, R., & Fuller, T. (2012). User-centered Design in Games. *The Human-Computer Interaction Handbook: Fundamentals, Evolving Technologies and Emerging Applications*, (January), 883–906. <https://doi.org/10.1088/1751-8113/44/8/085201>

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Pagulayan, R., Keeker, K., Fuller, T., Wixon, D., Romero, R., & Gunn, D. (2012). User-Centered Design in Games, (October), 795–822. <https://doi.org/10.1201/b11963-39>
- Pais-Ribeiro, J. L. (1999). Escala de satisfação com o suporte social (ESSS). *Análise Psicológica*, 3(17), 547–558. Retrieved from [http://www.scielo.oces.mctes.pt/scielo.php?pid=S0870-82311999000300010&script=sci\\_arttext%5Cnhttps://repositorio-aberto.up.pt/bitstream/10216/5544/2/80971.pdf](http://www.scielo.oces.mctes.pt/scielo.php?pid=S0870-82311999000300010&script=sci_arttext%5Cnhttps://repositorio-aberto.up.pt/bitstream/10216/5544/2/80971.pdf)
- Pais-Ribeiro, J., Silva, I., Ferreira, T., Martins, A., Meneses, R., & Baltar, M. (2007). Validation study of a Portuguese version of the Hospital Anxiety and Depression Scale. *Psychol Health Med*, 12(2), 225–227. <https://doi.org/10.1080/13548500500524088>
- Panthong, R., & Srivihok, A. (2015). Wrapper Feature Subset Selection for Dimension Reduction Based on Ensemble Learning Algorithm. *Procedia Computer Science*, 72, 162–169. <https://doi.org/10.1016/j.procs.2015.12.117>
- Pantic, M., Sebe, N., Cohn, J. F., & Huang, T. (2005). Affective multimodal human-computer interaction. *Proceedings of the 13th Annual ACM International Conference on Multimedia - MULTIMEDIA '05*, 669. <https://doi.org/10.1145/1101149.1101299>
- Papamatthaiakis, G., Polyzos, G. C., & Xylomenos, G. (2010). Monitoring and modeling simple everyday activities of the elderly at home. *2010 7th IEEE Consumer Communications and Networking Conference, CCNC 2010*. <https://doi.org/10.1109/CCNC.2010.5421717>
- Park, C., Ryu, J., Sohn, J., & Cho, H. (2007). An emotion expression system for the emotional robot. *Proceedings of the International Symposium on Consumer Electronics, ISCE*. <https://doi.org/10.1109/ISCE.2007.4382195>
- Partala, T., & Surakka, V. (2003). Pupil size variation as an indication of affective processing. *International Journal of Human Computer Studies*, 59(1–2), 185–198. [https://doi.org/10.1016/S1071-5819\(03\)00017-X](https://doi.org/10.1016/S1071-5819(03)00017-X)
- Partala, T., Surakka, V., & Vanhala, T. (2005). Person-independent estimation of emotional experiences from facial expressions. *Proceedings of the 10th International Conference on Intelligent User Interfaces - IUI '05*, 246. <https://doi.org/10.1145/1040830.1040883>
- Paschero, M., Del Vecovo, G., Benucci, L., Rizzi, A., Santello, M., Fabbri, G., & Mascioli, F. M. F. (2012). A real time classifier for emotion and stress recognition in a vehicle driver. *IEEE International Symposium on Industrial Electronics*, 1690–1695. <https://doi.org/10.1109/ISIE.2012.6237345>
- Pearson, K. (1901). Principal components analysis. *The London*. Retrieved from [http://www.botany.hawaii.edu/bot644/Manly\\_multivariate.pdf%5Cnpapers2://publication/uuid/8268B57E-298A-4D21-A76D-CE842083AA61](http://www.botany.hawaii.edu/bot644/Manly_multivariate.pdf%5Cnpapers2://publication/uuid/8268B57E-298A-4D21-A76D-CE842083AA61)
- Pechorro, P., Marôco, J., Póiares, C., & Vieira, R. X. (2011). Validação da Escala de Auto-estima de Rosenberg com adolescentes portugueses em contexto forense e escolar. *Arquivos de Medicina*, 25(5–6), 174–179.
- Peirce, R. S., Frone, M. R., Russell, M., Cooper, M. L., & Mudar, P. (2000). A longitudinal model of social contact, social support, depression, and alcohol use. *Health Psychol*, 19(1), 28–38. <https://doi.org/10.1037/0278-6133.19.1.28>
- Pentland, A. (2005). Socially aware computation and communication. *Computer*, 38(3), 33–40. <https://doi.org/10.1109/MC.2005.104>
- Penzel, T., Kantelhardt, J. W., Grote, L., Peter, J.-H., & Bunde, A. (2003). Comparison of

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

- detrended fluctuation analysis and spectral analysis for heart rate variability in sleep and sleep apnea. *IEEE Transactions on Bio-Medical Engineering*, 50(10), 1143–1151. <https://doi.org/10.1109/TBME.2003.817636>
- Peper, E., Harvey, R., Lin, I., Tylova, H., & Moss, D. (2007). Is There More to Blood Volume Pulse Than Heart Rate Variability, Respiratory Sinus Arrhythmia, and Cardiorespiratory Synchrony? *Biofeedback*, 35(2), 54–61.
- Perdiz, J., Pires, G., & Nunes, U. J. (2017). Emotional state detection based on EMG and EOG biosignals: A short survey. In *2017 IEEE 5th Portuguese Meeting on Bioengineering (ENBENG)* (pp. 1–4). IEEE. <https://doi.org/10.1109/ENBENG.2017.7889451>
- Pereira, M. G. (2003). Revised Dyadic Adjustment Scale - Versão de Investigação.
- Phinyomark, A., Phukpattaranont, P., & Limsakul, C. (2012). Feature reduction and selection for EMG signal classification. *Expert Systems with Applications*, 39(8), 7420–7431. <https://doi.org/10.1016/j.eswa.2012.01.102>
- Picard, R., & Klein, J. (2002). Computers that recognize and respond to user emotion: theoretical and practical implications. *Interacting with Computers*, 14(Spitz 1945), 141–169.
- Picard, R. W. (1995). *Affective computing. Social security bulletin* (Vol. 70). MIT press Cambridge. <https://doi.org/10.1007/BF01238028>
- Picard, R.W., Vyzas, E., & Healey, J. (2001). Toward machine emotional intelligence: analysis of affective\physiological state. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10), 1175–1191. <https://doi.org/10.1109/34.954607>
- Picard, Rosalind W. (2000). *Affective Computing*. MIT Press.
- Picard, Rosalind W., Vyzas, E., & Healey, J. (2001). Toward machine emotional intelligence: Analysis of affective physiological state. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 23(10), 1175–1191. <https://doi.org/10.1109/34.954607>
- Pleger, E., Wilke, A., Glaser, T., Müller, E., & Vogel, J. (1989). [Practical experiences with 2 oscillatory measuring procedures, Siregnost FD 5 and custo vit, in the assessment of chronic airway obstruction]. *Pneumologie (Stuttgart, Germany)*, 43(7), 353–357. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/2780527>
- plux. (n.d.). biosignalsplux | wearable body sensing platform. Retrieved August 18, 2017, from <http://biosignalsplux.com/index.php/en/>
- Plux. (2017). BVP Blood Volume Pulse. Retrieved April 17, 2017, from <http://biosignalsplux.com/index.php/en/bvp-blood-volume-pulse>
- Pocinho, M. (2009). Estatística: teoria e exercicios passo a passo. Volume I. *Ismt, I*, 1–82. Retrieved from [http://docentes.ismt.pt/~m\\_pocinho/Sebenta\\_estatistica I.pdf](http://docentes.ismt.pt/~m_pocinho/Sebenta_estatistica I.pdf)
- Poh, M.-Z., Swenson, N. C., & Picard, R. W. (2010). A wearable sensor for unobtrusive, long-term assesment of electrodermal activity. *IEEE Transactions on Biomedical Engineering*, 57(5), 1243–1252. <https://doi.org/10.1109/tbme.2009.2038487>
- Pollak, M. H., & Obrist, P. A. (1983). Aortic-Radial Pulse Transit Time and ECG Q-Wave to Radial Pulse Wave Interval as Indices of Beat-By-Beat Blood Pressure Change. *Psychophysiology*, 20(1), 21–28.
- Poole, A., & Ball, L. J. (2005). Eye Tracking in Human-Computer Interaction and Usability

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Research: Current Status and Future Prospects. *Encyclopedia of Human-Computer Interaction*, 211–219. <https://doi.org/10.4018/978-1-59140-562-7>
- Porges, S. W. (1995). Cardiac vagal tone: A physiological index of stress. *Neuroscience and Biobehavioral Reviews*, 19(2), 225–233. [https://doi.org/10.1016/0149-7634\(94\)00066-A](https://doi.org/10.1016/0149-7634(94)00066-A)
- Rachuri, K. K., Mascolo, C., Rentfrow, P. J., & Longworth, C. (2010). EmotionSense : A Mobile Phones based Adaptive Platform for Experimental Social Psychology Research. *International Studies*, 10, 281–290. <https://doi.org/10.1145/1864349.1864393>
- Radzyk, J. (2014). Validation of a New Social Well - Being Questionnaire.
- Ramirez, R., Ramirez, R., & Vamvakousis, Z. (2015). Detecting emotion from EEG signals using the emotive epoc device Detecting Emotion from EEG Signals Using the Emotive Epoc Device, (October), 175–184. <https://doi.org/10.1007/978-3-642-35139-6>
- Ramshur, J. T. (2010). Design, evaluation and application of heart rate variability analysis software (HRVAS). Retrieved from [https://scholar.google.ca/scholar?hl=en&q=DESIGN%2C+EVALUATION%2C+AND+APPLIC+ION+OF+HEART+RATE+VARIABILITY+ANALYSIS+SOFTWARE+%28HRVAS%29&btnG=&as\\_sdt=1%2C5&as\\_sdtp=](https://scholar.google.ca/scholar?hl=en&q=DESIGN%2C+EVALUATION%2C+AND+APPLIC+ION+OF+HEART+RATE+VARIABILITY+ANALYSIS+SOFTWARE+%28HRVAS%29&btnG=&as_sdt=1%2C5&as_sdtp=)
- Rani, P., Liu, C., Sarkar, N., & Vanman, E. (2006). An empirical study of machine learning techniques for affect recognition in human-robot interaction. *Pattern Analysis and Applications*, 9(1), 58–69. <https://doi.org/10.1007/s10044-006-0025-y>
- Rani, P., & Sarkar, N. (2006). A new approach to implicit human-robot interaction using affective cues. *Mobile Robots, Towards New Applications*, 3866113145(December), 233–252. <https://doi.org/10.5772/4693>
- Rani, P., Science, C., Sarkar, N., Smith, C. a, & Adams, J. a. (2003). Affective Communication for Implicit Human-. *Proceedings. ICRA'03. IEEE International Conference*, 2382–2387.
- Raschka, S. (2014). Linear Discriminant Analysis. Retrieved from [http://sebastianraschka.com/Articles/2014\\_python\\_lda.html](http://sebastianraschka.com/Articles/2014_python_lda.html)
- Raspberry Pi Foundation. (n.d.). Raspberry Pi. Retrieved November 18, 2018, from <https://www.raspberrypi.org/>
- Raudonis, V. (2013). Evaluation of Human Emotion from Eye Motions. *International Journal of Advanced Computer Science and Applications*, 4(8), 79–84. <https://doi.org/10.14569/IJACSA.2013.040812>
- Ravichandran, R., Saba, E., Chen, K. Y., Goel, M., Gupta, S., & Patel, S. N. (2015). WiBreathe: Estimating respiration rate using wireless signals in natural settings in the home. *2015 IEEE International Conference on Pervasive Computing and Communications, PerCom 2015*, 16, 131–139. <https://doi.org/10.1109/PERCOM.2015.7146519>
- Recognition, F. E. (2009). Facial Expression Recognition. *Analysis*, 77(6), 1507–1513. <https://doi.org/10.1016/j.anbehav.2009.02.024>
- Rehabilitation Institute of Chicago. (2014). WHO Quality of Life-BREF (WHOQOL-BREF). *Rehabmeasures.Org*. Retrieved from <http://www.rehabmeasures.org/Lists/RehabMeasures/PrintView.aspx?ID=937>
- Rehm, M., Bee, N., & André, E. (2008). Wave like an Egyptian: accelerometer based gesture recognition for culture specific interactions. *Proceedings of the 22nd British HCI Group*

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Annual Conference on People and Computers: Culture, Creativity, Interaction*, 13–22. Retrieved from <http://dl.acm.org/citation.cfm?id=1531514.1531517>
- Reis, C. (2016). MBTI – Myers Briggs Test - Faça o Teste Online! - E-Konomista. Retrieved July 1, 2017, from <http://www.e-konomista.pt/artigo/myers-briggs-test/>
- Reis, H. T., Gable, S. L., Keyes, C. L. M., & Haidt, J. (2003). Toward a positive psychology of relationships. In *Flourishing: Positive psychology and the life well-lived*. (pp. 129–159). Washington: American Psychological Association. <https://doi.org/10.1037/10594-006>
- Rigamonti, R., Brown, M. A., & Lepetit, V. (2011). Are sparse representations really relevant for image classification? *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 1545–1552. <https://doi.org/10.1109/CVPR.2011.5995313>
- Rigas, G. (2007). User Modeling 2007, *4511*(June 2014), 1–6. <https://doi.org/10.1007/978-3-540-73078-1>
- Rissanen, J. (2013). Cisbio Bioassays and Orion Diagnostica Oy sign an agreement for steroid radioimmunoassays - [www.oriondiagnostica.com](http://www.oriondiagnostica.com). Retrieved June 11, 2017, from <http://www.oriondiagnostica.com/News-and-events/Cisbio-Bioassays-and-Orion-Diagnostica-Oy-sign-an-agreement-for-steroid-radioimmunoassays/>
- Ritz, T., Steptoe, A., DeWilde, S., & Costa, M. (2000). Emotions and Stress Increase Respiratory Resistance in Asthma. *Psychosomatic Medicine*, *62*(3), 401–412. <https://doi.org/10.1097/00006842-200005000-00014>
- Robbins, B. D., & Parlavecchio, H. (2006). The Unwanted Exposure of the Self: A Phenomenological Study of Embarrassment. *The Humanistic Psychologist*, *34*(4), 321–345. [https://doi.org/10.1207/s15473333thp3404\\_3](https://doi.org/10.1207/s15473333thp3404_3)
- Robins, R. W., & Tracy, J. L. (2004). Putting the Self Into Self-Conscious Emotions: A Theoretical Model. *Psychological Inquiry*, *15*, 103–125.
- Rodin, J., & Salovey, P. (1989). Health Psychology. *Annual Review of Psychology*, *40*(1), 533–579. <https://doi.org/10.1146/annurev.ps.40.020189.002533>
- Rosenberg, M. (1965). Society and the Adolescent Self-Image. 1965. <https://doi.org/10.1515/9781400876136>
- Rosmalen, J. G. M., Bos, E. H., & de Jonge, P. (2012). Validation of the Long-term Difficulties Inventory (LDI) and the List of Threatening Experiences (LTE) as measures of stress in epidemiological population-based cohort studies. *Psychological Medicine*, *42*(12), 2599–2608. <https://doi.org/10.1017/S0033291712000608>
- Rudolph, H., & Pnt, R. (2004). HANS RUDOLPH, inc.
- Russell, J. A. (1980). A circumplex model of affect. *Journal of Personality and Social Psychology*, *39*(6), 1161–1178. <https://doi.org/10.1037/h0077714>
- Russell, J. A., Weiss, A., & Mendelsohn, G. A. (1989). Affect Grid: A single-item scale of pleasure and arousal. *Journal of Personality and Social Psychology*, *57*(3), 493–502. <https://doi.org/10.1037/0022-3514.57.3.493>
- Saha, S., Datta, S., Konar, A., & Janarthanan, R. (2014). A study on emotion recognition from body gestures using Kinect sensor. *Communications and Signal Processing (ICCSP), 2014 International Conference On*, 56–60. <https://doi.org/10.1109/ICCSP.2014.6949798>
- Salimetrics. (n.d.). Melatonin Testing in Saliva & Salivary Melatonin Research. Retrieved

## RELATÓRIO TÉCNICO

Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

April 22, 2017, from <https://www.salimetrics.com/biomarker/melatonin>

- Sander, B., Markvart, J., Kessel, L., Argyraki, A., & Johnsen, K. (2015). Can sleep quality and wellbeing be improved by changing the indoor lighting in the homes of healthy, elderly citizens? *Chronobiology International*, 0528(December), 1–12. <https://doi.org/10.3109/07420528.2015.1056304>
- Sanders, J. L., & Brizzolara, M. S. (1982). Relationships between Weather and Mood. *The Journal of General Psychology*, 107(1), 155–156. <https://doi.org/10.1080/00221309.1982.9709917>
- Sano, A., & Eng, B. (2016). Measuring College Students' Sleep, Stress, Mental Health and Wellbeing with Wearable Sensors and Mobile Phones, (2003), 182.
- Sano, A., & Picard, R. W. (2013a). Recognition of sleep dependent memory consolidation with multi-modal sensor data. *2013 IEEE International Conference on Body Sensor Networks, BSN 2013*. <https://doi.org/10.1109/BSN.2013.6575479>
- Sano, A., & Picard, R. W. (2013b). Stress Recognition using Wearable Sensors and Mobile Phones. *Humaine Association Conference on Affective Computing and Intelligent Interaction Stress*, 671–676. <https://doi.org/10.1109/ACII.2013.117>
- Sano, A., & Picard, R. W. (2014). Comparison of sleep-wake classification using electroencephalogram and wrist-worn multi-modal sensor data. *Conference Proceedings : ... Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE Engineering in Medicine and Biology Society. Annual Conference, 2014*, 930–933. <https://doi.org/10.1109/EMBC.2014.6943744>
- Santos, P. J., & Maia, J. (2003). Análise factorial confirmatória e validação preliminar de uma versão portuguesa da escala de auto-estima de Rosenberg. *Psicologia: Teoria, Investigação e Prática*. Porto: Faculdade de Letras, Secção autónoma de Educação, Universidade do Porto.
- Sarabia, J. A., Rol, M. A., Mendiola, P., & Madrid, J. A. (2008). Circadian rhythm of wrist temperature in normal-living subjects. A candidate of new index of the circadian system. *Physiology and Behavior*, 95(4), 570–580. <https://doi.org/10.1016/j.physbeh.2008.08.005>
- Sarason, I. G., Sarason, B. R., Potter, E. H., & Antoni, M. H. (1985). Life events, social support, and illness. *Psychosomatic Medicine*, 47(2), 156–163. Retrieved from <http://www.ncbi.nlm.nih.gov/pubmed/17992965>
- Sarason, I. G., Sarason, B. R., Shearin, E. N., & Pierce, G. R. (1987). Assessing social support: The Social Support Questionnaire. *Journal of Social and Personal Relationships*, 4(1), 497–510.
- Sarstedt. (n.d.). *Cortisol-Salivette: Evaluation Report*.
- Sato, N.; Obuchi, Y. . (2007). Emotion Recognition using Mel- Frequency Cepstral Coefficients. *Journal of Natural Language Processing*, 83–96.
- Schachter, J. (1957). Pain, Fear, and Anger in Hypertensives and Normotensives: A Psychophysiological Study. *Psychosomatic Medicine*, 19(1), 17–29. Retrieved from <http://www.psychosomaticmedicine.org/cgi/content/abstract/19/1/17>
- Schapiro, R. E. (2013). Explaining adaboost. *Empirical Inference: Festschrift in Honor of Vladimir N. Vapnik*, 37–52. [https://doi.org/10.1007/978-3-642-41136-6\\_5](https://doi.org/10.1007/978-3-642-41136-6_5)
- Scheer, F., van Doornen, L., & Buijs, R. (1999). Light and diurnal cycle affect human heart rate:

## RELATÓRIO TÉCNICO

### *Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Possible role for the circadian pacemaker. *Journal of Biological Rhythms*, 14(3), 202–212. <https://doi.org/10.1177/074873099129000614>
- Scherer, K. R., & Ekman, P. (1984). On the nature and function of emotion: A component process approach. In Press Psychology (Ed.), *Approaches To Emotion* (pp. 294–317). New Jersey: Taylor & Francis. Retrieved from <https://books.google.com/books?hl=fr&lr=&id=k0mhAwAAQBAJ&pgis=1>
- Schiele, B. C., Baker, A. B., & Hathaway, S. R. (1943). The Minnesota multiphasic personality inventory. *Journal-Lancet*, 63, 292–297. Retrieved from <http://search.ebscohost.com/login.aspx?direct=true&db=psyh&AN=1944-03192-001&site=ehost-live>
- Schulze, L., Renneberg, B., & Lobmaier, J. S. (2013). Gaze perception in social anxiety and social anxiety disorder. *Frontiers in Human Neuroscience*, 7. <https://doi.org/10.3389/fnhum.2013.00872>
- Schumm, J., & Arnrich, B. (2012). ecG Monitoring in an airplane Seat:, 28–34.
- Schumm, J., B??chlin, M., Setz, C., Arnrich, B., Roggen, D., & Tr??ster, G. (2008). Effect of movements on the electrodermal response after a startle event. *Proceedings of the 2nd International Conference on Pervasive Computing Technologies for Healthcare 2008, PervasiveHealth*, (June 2017), 315–318. <https://doi.org/10.1109/PCTHEALTH.2008.4571101>
- Schumm, J., Setz, C., B??chlin, M., B??chler, M., Arnrich, B., & Tr??ster, G. (2010). Unobtrusive physiological monitoring in an airplane seat. *Personal and Ubiquitous Computing*, 14(6), 541–550. <https://doi.org/10.1007/s00779-009-0272-1>
- Schwartz, G. E., Weinberger, D. a, & Singer, J. a. (1981). Cardiovascular differentiation of happiness, sadness, anger, and fear following imagery and exercise. *Psychosomatic Medicine*, 43(4), 343–364. <https://doi.org/10.1097/00006842-198108000-00007>
- Sebe, N., Cohen, I., Gevers, T., & Huang, T. S. (2006). Emotion recognition based on joint visual and audio cues. *Proceedings - International Conference on Pattern Recognition*, 1, 1136–1139. <https://doi.org/10.1109/ICPR.2006.489>
- Sela, I., Shinar, Z., & Tavakolian, K. (2016). Measuring Left Ventricular Ejection Time Using Under-the-Mattress Sensor. *Computing in Cardiology*, (Figure 1), 665–668.
- Seligman, M. E. (2011). *Flourish: A visionary vew understanding of happiness and well-being*. Sydney: Nicholas Brealey Publishing.
- Setz, C., Arnrich, B., Schumm, J., Marca, R. La, Tr, G., & Ehlert, U. (2010). Using a Wearable EDA Device. *Technology*, 14(2), 410–417.
- Shan, C., Gong, S., & McOwan, P. W. (2009). Facial expression recognition based on Local Binary Patterns: A comprehensive study. *Image and Vision Computing*, 27(6), 803–816. <https://doi.org/10.1016/j.imavis.2008.08.005>
- Sheehan, P. W. (1967). A shortened form of Betts' questionnaire upon mental imagery. *Journal of Clinical Psychology*, 23(3), 386–389. [https://doi.org/10.1002/1097-4679\(196707\)23:3<386::AID-JCLP2270230328>3.0.CO;2-S](https://doi.org/10.1002/1097-4679(196707)23:3<386::AID-JCLP2270230328>3.0.CO;2-S)
- Shegokar, P., & Sircar, P. (2016). Continuous Wavelet Transform based Speech Emotion Recognition, (720).

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Shen, L. L., Bai, L., & Fairhurst, M. (2007). Gabor wavelets and General Discriminant Analysis for face identification and verification. *Image and Vision Computing*, 25(5), 553–563. <https://doi.org/10.1016/j.imavis.2006.05.002>
- Shimmer Discovery in Motion. (2017). Shimmer | All products. Retrieved August 16, 2017, from <http://www.shimmersensing.com/products/all-products/>
- Siegrist, J., Starke, D., Chandola, T., Godin, I., Marmot, M., Niedhammer, I., & Peter, R. (2004). The measurement of effort-reward imbalance at work: European comparisons. *Social Science and Medicine*, 58(8), 1483–1499. [https://doi.org/10.1016/S0277-9536\(03\)00351-4](https://doi.org/10.1016/S0277-9536(03)00351-4)
- Sigma. (2016). Statistical Analysis 2 : Pearson Correlation. *Centre for Excellence in Mathematics & Statistic Support*, 1–4. Retrieved from <http://www.statstutor.ac.uk/resources/uploaded/coventrycorrelation.pdf>
- Silmee, P. (n.d.). Silmee Bar type.
- Silva, M. L. (2014). A PELE , O MAIOR ÓRGÃO Sumário, 3730.
- Sim, K., Jang, I., & Park, C. (2007). The Development of Interactive Feature Selection and GA Feature Selection Method for Emotion Recognition. In B. Apolloni, R. J. Howlett, & L. Jain (Eds.), *Database* (pp. 73–81). Berlin, Heidelberg: Springer Berlin Heidelberg. [https://doi.org/10.1007/978-3-540-74829-8\\_10](https://doi.org/10.1007/978-3-540-74829-8_10)
- Simões, A. (1992). Ulterior validação de uma Escala de Satisfação com a Vida (SWLS). *Revista Portuguesa de Pedagogia*, 26(3), 503–515.
- Singh, S., Sharma, V., Jain, K., & Bhall, R. (2015). EDBL-algorithm for detection and analysis of emotion using body language. *Next Generation Computing Technologies (NGCT), 2015 1st International Conference On*, (September), 820–823.
- Sinha, R, Lovallo, W. R., & Parsons, O. a. (1992). Cardiovascular differentiation of emotions. *Psychosomatic Medicine*, 54(4), 422–435. <https://doi.org/10.1097/00006842-199207000-00005>
- Sinha, Rajita. (1996). Multivariate Response Patterning of Fear and Anger. *Cognition & Emotion*, 10(2), 173–198. <https://doi.org/10.1080/026999396380321>
- Sloan, D. M. (2004). Emotion regulation in action: Emotional reactivity in experiential avoidance. *Behaviour Research and Therapy*, 42(11), 1257–1270. <https://doi.org/10.1016/j.brat.2003.08.006>
- Smeets, T., Dziobek, I., & Wolf, O. T. (2009). Social cognition under stress: Differential effects of stress-induced cortisol elevations in healthy young men and women. *Hormones and Behavior*, 55(4), 507–513. <https://doi.org/10.1016/j.yhbeh.2009.01.011>
- Smith, R. P., Argod, J., Pépin, J. L., & Lévy, P. A. (1999). Pulse transit time: an appraisal of potential clinical applications. *Thorax*, 54(5), 452–457. <https://doi.org/10.1136/thx.54.5.452>
- Smith, S. W. (1997). The z-Transform. *The Scientist and Engineer's Guide to Digital Signal Processing*, 605–630. <https://doi.org/http://dx.doi.org/10.1016/B978-0-7506-7444-7/50070-4>
- Smith, S. W. (2003). The Complex Fourier Transform. In *Digital Signal Processing* (pp. 567–580). <https://doi.org/10.1016/B978-0-7506-7444-7/50068-6>

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Solà i Carós, J. M. (2011). Continuous non-invasive blood pressure estimation, (20093).  
<https://doi.org/10.3929/ethz-a-007273889>
- Soleymani, M., Asghari-esfeden, S., Pantic, M., & Fu, Y. (2013). Continuous emotion detection using EEG signals and facial expressions. *IEEE Conference on Multimedia and Expo (ICME), 231287(231287)*, 3–8. <https://doi.org/10.1109/ICME.2014.6890301>
- Sony Inc. (2010). Sony Product Detail Page - XCDSX90. Retrieved July 9, 2017, from  
<https://pro.sony.com/bbsc/ssr/cat-camerasindustrial/cat-ciindustrial/product-XCEI30/>
- Sorvoja, H., & Myllylä, R. (2006). Noninvasive Blood Pressure Measurement Methods. *Molecular and Quantum Acoustics*, 27, 239–264.
- Spacelabs Healthcare. (2008). 90207 / 90217 Ambulatory Blood Pressure Systems. *Spacelabshealthcare.Com*.
- Spanier, G. B. (1976). Measuring dyadic adjustment: New scales for assessing the quality of marriage and similar dyads. *Journal of Marriage and the Family*, 38(1), 15–28.  
<https://doi.org/10.2307/350547>
- Spielberger, C. D. (2010a). State-Trait Anger Expression Inventory. *The Corsini Encyclopedia of Psychology*. <https://doi.org/10.1002/9780470479216.corpsy0942>
- Spielberger, C. D. (2010b). State-Trait Anger Expression Inventory. In *The Corsini Encyclopedia of Psychology*. Hoboken, NJ, USA: John Wiley & Sons, Inc.  
<https://doi.org/10.1002/9780470479216.corpsy0942>
- Spielberger, CD. (1983). Manual for the State-Trait Anxiety Inventory (STAI). *Consulting Psychologists Press*, 4–26.
- Spielberger, Cd, Gorsuch, R., Lushene, R., & Vagg, P. (1983). *State-Trait Anxiety Inventory (STAI)*. *BiB 2010*. Retrieved from [http://www.pol.gu.se/digitalAssets/1307/1307827\\_bib-2010.pdf#page=182](http://www.pol.gu.se/digitalAssets/1307/1307827_bib-2010.pdf#page=182)
- Špulák, D., Čmejla, R., & Fabián, V. (n.d.). Experiments With Blood Pressure Monitoring, 2–6.
- SR Research. (2017). The EyeLink 1000 Plus. Retrieved April 22, 2017, from <http://www.sr-research.com/eyelink1000plus.html>
- SR Research Ltd. (2013). SR Research - EyeLink II. Retrieved June 12, 2017, from <http://www.sr-research.com/eyelinkII.html>
- Sroykham, W., Promraksa, T., Wongsathikun, J., & Wongsawat, Y. (2015). The red and blue rooms affect to brain activity, cardiovascular activity, emotion and saliva hormone in women. *BMEiCON 2014 - 7th Biomedical Engineering International Conference*.  
<https://doi.org/10.1109/BMEiCON.2014.7017432>
- Sroykham, W., & Wongsawat, Y. (2013). Effects of LED-backlit computer screen and emotional selfregulation on human melatonin production. *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 1704–1707.  
<https://doi.org/10.1109/EMBC.2013.6609847>
- Steffen, M., & Leonhardt, S. (2008). Non-Contact Monitoring of Heart and Lung Activity by Magnetic Induction Measurement. *Acta Polytechnica*, 48(3), 71–78.  
<https://doi.org/10.1109/TBCAS.2008.915633>
- Stephens, C. L., Christie, I. C., & Friedman, B. H. (2010). Autonomic specificity of basic emotions: Evidence from pattern classification and cluster analysis. *Biological Psychology*,

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- 84(3), 463–473. <https://doi.org/10.1016/j.biopsycho.2010.03.014>
- Sthle, L., & Wold, S. (1989). Analysis of variance (ANOVA). *Chemometrics and Intelligent Laboratory Systems*. [https://doi.org/10.1016/0169-7439\(89\)80095-4](https://doi.org/10.1016/0169-7439(89)80095-4)
- Sugiura, A., Eto, T., Takada, H., & Kinoshita, F. (2016). Cerebral Blood Flow in the Prefrontal Cortex while Reading a Novel on a Tablet Computer and its Effect on Sleep Temporary and remaining changes. *2016 11Th International Conference on Computer Science & Education (Iccse)*, (Iccse), 35–40.
- Suryadevara, N. K., Member, S., & Mukhopadhyay, S. C. (2012). Wireless Sensor Network Based Home Monitoring System for Wellness Determination of Elderly. *IEEE Sensor Journal*, 12(6), 1965–1972. <https://doi.org/10.1109/JSEN.2011.2182341>
- Suzuki, S., Matsui, T., Imuta, H., Uenoyama, M., Yura, H., Ishihara, M., & Kawakami, M. (2008). A novel autonomic activation measurement method for stress monitoring: Non-contact measurement of heart rate variability using a compact microwave radar. *Medical and Biological Engineering and Computing*, 46(7), 709–714. <https://doi.org/10.1007/s11517-007-0298-3>
- Sztajzel, J. (2004). Heart rate variability: A noninvasive electrocardiographic method to measure the autonomic nervous system. *Swiss Medical Weekly*. <https://doi.org/2004/35/smw-10321>
- Tan, A. (2016). Hilbert-Huang Transform. Retrieved November 4, 2017, from <https://www.mathworks.com/matlabcentral/fileexchange/19681-hilbert-huang-transform?requestedDomain=www.mathworks.com>
- Tarvainen, M. P., Niskanen, J.-P., Lipponen, J. A., Ranta-aho, P. O., & Karjalainen, P. A. (2014). Kubios HRV ? Heart rate variability analysis software. *Computer Methods and Programs in Biomedicine*, 113(1), 210–220. <https://doi.org/10.1016/j.cmpb.2013.07.024>
- Taylor, G. J., Ryan, D., & Bagby, M. (1985). Toward the Development of a New Self-Report Alexithymia Scale. *Psychotherapy and Psychosomatics*, 44(4), 191–199. <https://doi.org/10.1159/000287912>
- Taylor, S., Jaques, N., Chen, W., Fedor, S., Sano, A., & Picard, R. (2015). Automatic Identification of Artifacts in Electrodermal Activity Data. *Engineering in Medicine and Biology Society (EMBC), 2015 37th Annual International Conference of the IEEE*, 1934–1937. <https://doi.org/10.1109/EMBC.2015.7318762>
- TEA. (2016). Captiv - Skilful and adptable software. Retrieved June 30, 2017, from <http://teaergo.com/site/en/products/manufacturers/tea/captiv-software>
- TEA. (2017). Wireless sensor - GSR.
- Terburg, D., Morgan, B., & van Honk, J. (2009). The testosterone-cortisol ratio: A hormonal marker for proneness to social aggression. *International Journal of Law and Psychiatry*, 32(4), 216–223. <https://doi.org/10.1016/j.ijlp.2009.04.008>
- The Mathworks Inc. (2016). MATLAB - MathWorks. <https://doi.org/2016-11-26>
- Theiler, J. (1990). Estimating fractal dimension. *Journal of the Optical Society of America A*, 7(6), 1055. <https://doi.org/10.1364/JOSAA.7.001055>
- Thielbar, K. O., Triandafilou, K. M., Fischer, H. C., O'Toole, J. M., Listenberger, M. L., Ochoa, J. M., ... Kamper, D. G. (2016). Benefits of using a voice and EMG-driven actuated glove to

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

- support occupational therapy for stroke survivors. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 25(3), 1–1. <https://doi.org/10.1109/TNSRE.2016.2569070>
- Thomas, P. B. M., Baltrušaitis, T., Robinson, P., & Vivian, A. J. (2016). The Cambridge Face Tracker: Accurate, Low Cost Measurement of Head Posture Using Computer Vision and Face Recognition Software. *Translational Vision Science & Technology*, 5(5). <https://doi.org/10.1167/tvst.5.5.8>
- Thomé, S., Härenstam, A., & Hagberg, M. (2011). Mobile phone use and stress, sleep disturbances, and symptoms of depression among young adults - a prospective cohort study. *BMC Public Health*, 11(1), 66. <https://doi.org/10.1186/1471-2458-11-66>
- Thought Technology Ltd. (n.d.). BioGraph Infiniti Software Upgrade - T7900UP. Retrieved from <http://thoughttechnology.com/index.php/biograph-infiniti-software-upgrade.html>
- Thought Technology Ltd. (2016a). FlexComp System with/ BioGraph Infiniti Software - T7555M. Retrieved July 22, 2017, from <http://thoughttechnology.com/index.php/flexcomp-system-with-biograph-infiniti-software-t7555m.html>
- Thought Technology Ltd. (2016b). *Getting Started with BioGraph*. [thoughttechnology.com](http://thoughttechnology.com).
- Tobii AB. (2015). Tobii Pro TX300 screen-based eye tracker. Retrieved July 9, 2017, from <https://www.tobii.com/product-listing/tobii-pro-tx300/>
- Tobii Technology AB. (2015). tobii pro studio. Retrieved June 30, 2017, from <https://www.tobii.com/product-listing/tobii-pro-studio/>
- Toruzyme, L. (2001). MP150 Product Sheet. *Biopac Systems*.
- Toshiba. (2015). Toshiba Silmee™ W20/W21. Retrieved May 28, 2017, from [https://www.toshiba.co.jp/about/press/2015\\_08/pr\\_j1701.htm](https://www.toshiba.co.jp/about/press/2015_08/pr_j1701.htm)
- Tran, T. Q., Boring, R. L., Dudenhoefter, D. D., Hallbert, B. P., Keller, M. D., & Anderson, T. M. (2007). Advantages and disadvantages of physiological assessment for next generation control room design. *IEEE Conference on Human Factors and Power Plants*, (1), 259–263. <https://doi.org/10.1109/HFPP.2007.4413216>
- Trans Cranial Technologies Ltd. (2012). 10 / 20 System Positioning Manual. *Technologies Trans Cranial*, (1), 20. Retrieved from [http://www.trans-cranial.com/local/manuals/10\\_20\\_pos\\_man\\_v1\\_0\\_pdf.pdf%5Cnwww.trans-cranial.com](http://www.trans-cranial.com/local/manuals/10_20_pos_man_v1_0_pdf.pdf%5Cnwww.trans-cranial.com)
- Turan, C., Lam, K., & He, X. (2015). Facial Expression Recognition with Emotion-Based Feature Fusion, (December), 1–6.
- Ugoni, A., & Walker, B. F. (1995). THE t TEST. *COMSIG Review*, 4(2), 37–40.
- Universidade de Coimbra. (n.d.). *WHOQOL-BREF (versão portuguesa)*.
- Van Der Vloed, G., & Berentsen, J. (2009). Measuring emotional wellbeing with a non-intrusive bed sensor. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 5727 LNCS(PART 2), 908–911. [https://doi.org/10.1007/978-3-642-03658-3\\_108](https://doi.org/10.1007/978-3-642-03658-3_108)
- van Eck, M., Berkhof, H., Nicolson, N., & Sulon, J. (2005). The effects of perceived stress, traits, mood states, and stressful daily events on salivary cortisol. *Psychosomatic Medicine*, 58(5), 447–458. <https://doi.org/10.1097/00006842-199609000-00007>
- Varghees, V. N., & Ramachandran, K. I. (2016). Two-Channel Heart Sound Segmentation

## RELATÓRIO TÉCNICO

### Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções

- Framework Using Phonocardiogram and Pulsatile Signals, 305–310.
- Vaz Serra, A., Cristina Canavarro, M., Simões, M., Pereira, M., Gameiro, S., João Quartilho, M., ... Paredes, T. (2006). Estudos Psicométricos do Instrumento de Avaliação da Qualidade de Vida da Organização Mundial de Saúde (WHOQOL-Bref) para Português de Portugal. *Psiquiatria Clínica, 27*(271), 41–49.
- Vermun, K., Senapaty, M., Sankhla, A., Patnaik, P., & Routray, A. (2013). Gesture-based affective and cognitive states recognition using kinect for effective feedback during E-learning. *Proceedings - 2013 IEEE 5th International Conference on Technology for Education, T4E 2013*, 107–110. <https://doi.org/10.1109/T4E.2013.34>
- Viola, P., & Jones, M. M. J. (2004). Robust Real-Time Face Detection. *International Journal of Computer Vision, 57*(2), 137–154. <https://doi.org/10.1023/B:VISI.0000013087.49260.fb>
- Virkkunen, M. (1994). CSF Biochemistries, Glucose Metabolism, and Diurnal Activity Rhythms in Alcoholic, Violent Offenders, Fire Setters, and Healthy Volunteers. *Archives of General Psychiatry, 51*(1), 20. <https://doi.org/10.1001/archpsyc.1994.03950010020003>
- Visser, A. K. D., van Waarde, A., Willemsen, A. T. M., Bosker, F. J., Luiten, P. G. M., den Boer, J. A., ... Dierckx, R. A. J. O. (2011). Measuring serotonin synthesis: from conventional methods to PET tracers and their (pre)clinical implications. *European Journal of Nuclear Medicine and Molecular Imaging, 38*(3), 576–591. <https://doi.org/10.1007/s00259-010-1663-2>
- von Zerssen, D., Strian, F., & Schwarz, D. (1974). Evaluation of Depressive States, Especially in Longitudinal Studies. In *Pichit P (ed). Psychological Measurements in Psychopharmacology* (pp. 189–202). <https://doi.org/10.1159/000395076>
- Vrana, S R, Cuthbert, B. N., & Lang, P. J. (1986). Fear imagery and text processing. *Psychophysiology*. <https://doi.org/10.1111/j.1469-8986.1986.tb00626.x>
- Vrana, Scott R. (1993). The psychophysiology of disgust: Differentiating negative emotional contexts with facial EMG. *Psychophysiology, 30*(3), 279–286. <https://doi.org/10.1111/j.1469-8986.1993.tb03354.x>
- Vrije Universiteit. (n.d.). Ambulatory Monitoring System. Retrieved July 23, 2017, from <http://www.vu-ams.nl/>
- Vrijkotte, T. G., van Doornen, L. J., & de Geus, E. J. (2000). Effects of work stress on ambulatory blood pressure, heart rate, and heart rate variability. *Hypertension (Dallas, Tex. : 1979), 35*(4), 880–886.
- W. H. Press, B. P. Flannery, S. A. T. and W. T. V. (n.d.). Linear Correlation. Retrieved October 29, 2017, from <https://www.statlect.com/fundamentals-of-probability/linear-correlation>
- Wagner, J. (2006). AuBT - Augsburg Biosignal Toolbox website. Retrieved July 9, 2017, from <https://www.informatik.uni-augsburg.de/lehrstuehle/hcm/projects/tools/aubt/>
- Wahoo Fitness. (2018). Wahoofitness TICKR heart rate monitors. Retrieved January 28, 2018, from <https://eu.wahoofitness.com/devices/heart-rate-monitors>
- Wakamura, T., & Tokura, H. (2002). Circadian rhythm of rectal temperature in humans under different ambient temperature cycles. *Journal of Thermal Biology, 27*(5), 439–447. [https://doi.org/10.1016/S0306-4565\(02\)00014-1](https://doi.org/10.1016/S0306-4565(02)00014-1)
- Wallston, B. S., Devellis, B. M., & Devellis, R. F. (1983). Social Support and Physical Health.

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Health Psychology*, 2(4), 367–391.  
<https://doi.org/10.12987/yale/9780300102185.001.0001>
- Wang, H., Zhou, L. B., & Ying, Y. (2010). A novel approach for real time eye state detection in fatigue awareness system. *2010 IEEE Conference on Robotics, Automation and Mechatronics, RAM 2010*, 528–532. <https://doi.org/10.1109/RAMECH.2010.5513139>
- Wang, R., Wenyan Jia, Zhi-Hong Mao, Sciabassi, R. J., & Mingui Sun. (2014). Cuff-free Blood Pressure Estimation using Pulse Transit Time and Heart Rate. *12th International Conference on Signal Processing (ICSP)*, 115–118.  
<https://doi.org/10.1109/ICOSP.2014.7014980.Cuff-Free>
- Ware, J. J., Kosinski, M. M., & Keller, S. S. D. (1996). A 12-Item Short-Form Health Survey: construction of scales and preliminary tests of reliability and validity. *Medical Care*, 34(3), 220–233. <https://doi.org/10.2307/3766749>
- Wassink, P. (2013). Delft Institute of Positive Design | PrEmo (Product Emotion Measurement Instrument). Retrieved June 2, 2017, from <http://studiolab.ide.tudelft.nl/diopd/library/tools/premo-product-emotion-measurement-instrument/>
- Watson, D, Clark, L. a, & Tellegen, A. (1988). Development and validation of brief measures of positive and negative affect: the PANAS scales. *Journal of Personality and Social Psychology*, 54(6), 1063–1070. <https://doi.org/10.1037/0022-3514.54.6.1063>
- Watson, David, & Clark, L. A. (1999). The PANAS-X: Manual for the Positive and Negative Affect Schedule - Expanded Form. *Department of Psychological & Brain Sciences Publications*. Retrieved from [http://ir.uiowa.edu/psychology\\_pubs/11](http://ir.uiowa.edu/psychology_pubs/11)
- WebMD Drugs & Medications. (2017a). Citalopram HBR. Retrieved July 23, 2017, from <http://www.webmd.com/drugs/2/drug-1701/citalopram-oral/details>
- WebMD Drugs & Medications. (2017b). Hydrocortisone Cream With Perineal Applicator. Retrieved July 23, 2017, from <http://www.webmd.com/drugs/2/drug-10402-3245/hydrocortisone-topical/hydrocortisone-cream-ointment-rectal/details>
- Weinfurt, K. P., Bryant, F. B., & Yarnold, P. R. (1994). The factor structure of the Affect Intensity Measure: In search of a measurement model. *Journal of Research in Personality*, 28(3), 314–331. <https://doi.org/10.1006/jrpe.1994.1023>
- Weiser, M. (1991). The computer for the 21st century. *Scientific American*, 94–100.
- Weiser, M., & Brown, J. S. (1996). Designing Calm Technology. *PowerGrid Journal*. <https://doi.org/10.1.1.135.9788>
- Weiss, R. (1974). *The Provisions of Social Relationships. Doing Unto Others*. New Jersey: Englewood Cliffs.
- Weissler, A. M., Harris, W. S., & Schoenfeld, C. D. (1969). Bedside technics for the evaluation of ventricular function in man. *The American Journal of Cardiology*, 23(April), 577–583. [https://doi.org/10.1016/0002-9149\(69\)90012-5](https://doi.org/10.1016/0002-9149(69)90012-5)
- Weisstein, E. W. (2017). Root-Mean-Square. Retrieved from <http://mathworld.wolfram.com/Root-Mean-Square.html>
- Wen, D., Jia, P., Lian, Q., Zhou, Y., & Lu, C. (2016). Review of Sparse Representation-Based Classification Methods on EEG Signal Processing for Epilepsy Detection, Brain-Computer

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

- Interface and Cognitive Impairment. *Frontiers in Aging Neuroscience*, 8. <https://doi.org/10.3389/fnagi.2016.00172>
- Weppner, J., & Lukowicz, P. (2011). Collaborative crowd density estimation with mobile phones. *ACM Conference on Embedded Network Sensor Systems*.
- Wickert, M. (n.d.). Chap7: Z-Transform.
- Wikia. (n.d.). Observer effect | Psychology Wiki | Fandom powered by Wikia. Retrieved November 5, 2016, from [http://psychology.wikia.com/wiki/Observer\\_effect](http://psychology.wikia.com/wiki/Observer_effect)
- Wikipédia. (n.d.). Valor eficaz. Retrieved November 26, 2017, from [https://pt.wikipedia.org/wiki/Valor\\_eficaz](https://pt.wikipedia.org/wiki/Valor_eficaz)
- Willemsen, G. H. M., De Geus, E. J. C., Klaver, C. H. A. M., Van Doornen, L. J. P., & Carroll, D. (1996). Ambulatory monitoring of the impedance cardiogram. *Psychophysiology*, 33(2), 184–193. <https://doi.org/10.1111/j.1469-8986.1996.tb02122.x>
- Wilson, G. F. (2002). An Analysis of Mental Workload in Pilots During Flight Using Multiple Psychophysiological Measures. *The International Journal of Aviation Psychology*, 12(1), 3–18. [https://doi.org/10.1207/S15327108IJAP1201\\_2](https://doi.org/10.1207/S15327108IJAP1201_2)
- Winton, W. M., Putnam, L. E., & Krauss, R. M. (1984). Facial and autonomic manifestations of the dimensional structure of emotion. *Journal of Experimental Social Psychology*, 20(3), 195–216. [https://doi.org/10.1016/0022-1031\(84\)90047-7](https://doi.org/10.1016/0022-1031(84)90047-7)
- Wolfram Alpha. (2013). Wolfram|Alpha: Computational Knowledge Engine. Retrieved July 8, 2017, from <http://www.wolframalpha.com/>
- Wright, J., Yang, A. Y. a. Y., Ganesh, A., Sastry, S. S., & Ma, Y. (2009). Robust face recognition via sparse representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 31(2), 210–227. <https://doi.org/10.1109/TPAMI.2008.79>
- Wu, W. H., Batalin, M. A., Au, L. K., Bui, A. A. T., & Kaiser, W. J. (2007). Context-aware sensing of physiological signals. *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*, 5271–5275. <https://doi.org/10.1109/IEMBS.2007.4353531>
- Wu, W. H., Bui, A. A. T., Batalin, M. A., Au, L. K., Binney, J. D., & Kaiser, W. J. (2008). MEDIC: Medical embedded device for individualized care. *Artificial Intelligence in Medicine*, 42(2), 137–152. <https://doi.org/10.1016/j.artmed.2007.11.006>
- XiaoMi. (n.d.). Mi Band 2 - Mi Global Home. Retrieved September 9, 2018, from <https://www.mi.com/en/miband2/>
- xsens. (n.d.). IMU Inertial Measurement Unit - Xsens 3D motion tracking. Retrieved September 10, 2017, from <https://www.xsens.com/tags/imu/>
- Yang, A. C. C. (2006). Poincare Plots: A Mini-Review. *PhysioNet Heart Rate Variability. Techniques, Applications and Futute Directions*.
- Yang, S., & Bhanu, B. (2011). Facial expression recognition using emotion avatar image. *2011 IEEE International Conference on Automatic Face and Gesture Recognition and Workshops, FG 2011*, 866–871. <https://doi.org/10.1109/FG.2011.5771364>
- Zakrzewski, M., Kolinummi, A., & Vanhala, J. (2006). Contactless and unobtrusive measurement of heart rate in home environment. In *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings* (pp. 2060–2063).

## RELATÓRIO TÉCNICO

*Revisão de contribuições para um pipeline de reconhecimento e consciência de emoções*

<https://doi.org/10.1109/IEMBS.2006.260714>

Zenonos, A., Khan, A., Kalogridis, G., Vatsikas, S., Lewis, T., & Sooriyabandara, M. (2016). HealthyOffice: Mood recognition at work using smartphones and wearable sensors. 2016 IEEE International Conference on Pervasive Computing and Communication Workshops, PerCom Workshops 2016. <https://doi.org/10.1109/PERCOMW.2016.7457166>

Zephyr Technology. (2012). BioHarness 3.0 User Manual. *Zephyranywhere.Com*.

Zhai, J., & Barreto, A. (2006). Stress detection in computer users based on digital signal processing of noninvasive physiological variables. *Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE, (lc)*, 1355–1358.

Zhang, J., Guo, F., Hong, J., & Zhang, Y. (2013). Human-robot shared control of articulated manipulator. *Proceedings - 2013 IEEE International Symposium on Assembly and Manufacturing, ISAM 2013*, 81–84. <https://doi.org/10.1109/ISAM.2013.6643493>

Zhang, L., Zhou, W.-D., Chang, P.-C., Liu, J., Yan, Z., Wang, T., & Li, F.-Z. (2012). Kernel Sparse Representation-Based Classifier. *IEEE Transactions on Signal Processing*, 60(4), 1684–1695. <https://doi.org/10.1109/TSP.2011.2179539>

Zhang, S., Zhang, C., & Yang, Q. (2010). Data preparation for data mining. *Applied Artificial Intelligence*, 17, 2003. <https://doi.org/10.1080/08839510390219264>

Zhang, Z., Girard, J. M., Wu, Y., Zhang, X., Liu, P., Ciftci, U., ... Yin, L. (2016). Multimodal Spontaneous Emotion Corpus for Human Behavior Analysis. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 3438–3446. <https://doi.org/10.1109/CVPR.2016.374>

Zhao, M., Adib, F., & Katabi, D. (2016). Emotion recognition using wireless signals. *22nd Annual International Conference on Mobile Computing and Netwfile:///Home/Jelena/Downloads/Fneng-07-00021.Pdf Orking, MobiCom 2016, (CONFCODENUMBER)*, 95–108. <https://doi.org/10.1145/2973750.2973762>

Zheng, Z., Yang, F., Tan, W., Jia, J., & Yang, J. (2007). Gabor feature-based face recognition using supervised locality preserving projection. *Signal Processing*, 87(10), 2473–2483. <https://doi.org/10.1016/j.sigpro.2007.03.006>

Zucco, C., Calabrese, B., & Cannataro, M. (2017). Sentiment analysis and affective computing for depression monitoring. *Proceedings - 2017 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2017, 2017-Janua*, 1988–1995. <https://doi.org/10.1109/BIBM.2017.8217966>

ZUNG, W. W. K. (1965). A Self-Rating Depression Scale. *Archives of General Psychiatry*, 12(1), 63. <https://doi.org/10.1001/archpsyc.1965.01720310065008>