

Deteção de incêndios florestais com recurso a *Deep Learning* e Visão Computacional

Universidade Fernando Pessoa



João Miguel Ribeiro Alves
Faculdade de Ciência e Tecnologia
Universidade Fernando Pessoa

Dissertação apresentada à Universidade Fernando Pessoa como parte dos
requisitos para obtenção do grau de Mestre em Engenharia Informática,
ramo Computação Móvel

Orientadores: Prof Doutor José Torres e Prof. Doutor Pedro Sobral
Outubro de 2018

Resumo

Nos países mediterrânicos do sul da Europa, os incêndios têm tendência a agravar-se devido às alterações climáticas, resultado do aumento global da temperatura. Este trabalho apresenta um sistema de deteção automática de incêndios que procura minimizar este problema ao permitir a sua deteção precoce.

O sistema processa imagens de ambiente florestal e é capaz de detetar a presença de incêndio em fase inicial, através do fumo ou das chamas. Permite também estimar a área em ignição para que se possa avaliar a sua dimensão. Foi desenvolvido com a finalidade de poder ser aplicado em câmaras moveis, como em drones, e estáticas, como em torres de vigia. Foi utilizado um modelo de *Deep Learning* e um classificador de *Machine Learning* na tarefa de classificação das imagens, e técnicas de Visão Computacional no processo de deteção da área das chamas. Como modelo de *Deep Learning*, foi utilizada a *Deep Convolutional Neural Network Inception-V3* para extrair descritores de uma imagem que, de seguida, são utilizados para treinar um classificador, o *Logistic Regression*. Em relação à Visão Computacional, são aplicadas técnicas de processamento da imagem ao nível da cor.

De forma a perceber quais os tipos de situações que podem influenciar na tarefa de classificação, o *dataset* proposto é composto por imagens com metadados onde se encontram anotadas as características (e.g. chamas, fumo, nevoeiro, nuvens, elementos humanos,...) presentes em cada imagem.

O sistema obteve uma precisão de classificação de 94.1% em cenários diurnos e de 94.8% em cenários noturnos. Apresenta uma boa precisão na estimação da área das chamas em comparação com outras abordagens na bibliografia, reduzindo o número de falsos positivos.

Abstract

In southern Mediterranean countries, fires are likely to worsen as a result of global warming. This work presents an automatic fire detection system that seeks to minimize this problem by allowing its early detection.

The system processes images of the forest environment and is able to detect the presence of an early stage fire through smoke or flames. It also allows estimating the area under ignition so that its size can be evaluated. It was developed with the purpose of being able to be applied in mobile cameras, as in drones, and static, as in watchtowers. A Deep Learning model and a Machine Learning classifier were used in the image classification task, and Computer Vision techniques in the process of detecting the area of the flames. As a Deep Learning model, the Deep Convolutional Neural Network Inception-V3 was used to extract descriptors from an image that are then used to train a classifier, the Logistic Regression. Regarding Computer Vision, image processing techniques are applied at color level.

In order to understand the types of situations that may influence the classification task, the proposed dataset is composed of images with metadata where are recorded the characteristics (eg flames, smoke, fog, clouds, human elements, etc.) present in each image.

The system obtained a classification accuracy of 94.1% in daytime scenarios and 94.8 % in nighttime scenarios. It presents good accuracy in the estimation of the area of the flames compared to other approaches in the literature, reducing the number of false positives.

Agradecimentos

Aos Professores Doutores José Torres e Pedro Sobral, pela disponibilidade de orientação, pela partilha de conhecimento e pelas críticas manifestadas ao longo do trabalho. Aos restantes Professores do curso pelos conselhos.

Aos meus pais pelo suporte e por tornarem possível esta importante etapa da minha vida.

À minha namorada pela força e ajuda demonstrada desde o primeiro dia deste percurso.

Aos meus irmãos, por terem sido sempre os meus segundos pais, e aos meus sobrinhos.

Aos meus amigos, companheiros nesta etapa.

Conteúdo

Conteúdo	v
Lista de Figuras	viii
Lista de Tabelas	x
Lista de Abreviaturas	xi
1 Introdução	1
1.1 Enunciado do problema	2
1.2 Objetivos	3
1.3 Estrutura do documento	3
2 Estado da arte	5
2.1 Tecnologias usadas na detecção de incêndios florestais	5
2.1.1 Sensores óticos e câmaras digitais	5
2.1.2 Outras tecnologias de detecção	8
2.2 Sistemas de <i>Deep Learning</i> na detecção incêndios	9
2.2.1 Sistemas de detecção diurna e noturna	9
2.2.2 Análise comparativa dos sistemas de detecção	11
2.3 Sistema de visão computacional na detecção de incêndios	12
2.3.1 Sistemas de detecção de chamas	13
2.3.2 Sistemas de detecção de fumo	15
2.3.3 Análise comparativa dos sistemas de detecção	16
2.4 Conclusão	17
3 Especificação	18
3.1 Cenários de aplicação e Requisitos	18
3.1.1 Cenário de aplicação	18
3.1.2 Requisitos funcionais	19
3.1.3 Requisitos não funcionais	20
3.1.4 Requisitos de sistema (Software e Hardware)	20

3.2	Arquitetura do sistema	20
3.2.1	Análise de Dados Meteorológicos	23
3.2.2	Extração de Descritores	23
3.2.3	Classificação	24
3.2.4	Estimação da Área das Chamas	25
3.3	Conclusão	26
4	Implementação	27
4.1	Organização do <i>dataset</i>	28
4.2	Extração de Descritores	31
4.2.1	Fluxo de informação	31
4.2.2	Inception-V3	32
4.2.3	Descritores obtidos	33
4.3	Classificação	33
4.3.1	Fluxo de informação	33
4.3.2	<i>Logistic Regression</i>	34
4.3.3	Avaliação do modelo de aprendizagem	34
4.4	Estimação da Área das Chamas	35
4.4.1	Processo de detecção	35
4.4.2	Bloco <i>Piecewise-Linear Transformation (PLT)</i>	35
4.4.3	Bloco <i>Forest Fire Detetion Index (FFDI)</i>	38
4.5	Conclusão	39
5	Testes e avaliação	40
5.1	Análise do comportamento do sistema no cenário de aplicação	40
5.1.1	Situação nº1: Não é identificado incêndio	41
5.1.2	Situação nº2: É identificado incêndio mas não são detetadas chamas	41
5.1.3	Situação nº3: É identificado incêndio e são detetadas chamas	42
5.2	Seleção do modelo de Extração de Descritores	42
5.3	Classificação	43
5.3.1	Comparação dos modelos de classificação	43
5.3.2	Escolha das classes de classificação	44
5.3.3	Desempenho dos modelos treinados com todo o conjunto de imagens	46
5.3.4	Análise da influência das características das imagens no processo de classificação	47
5.4	Estimação da Área das Chamas	54
5.4.1	Cenários Diurnos	54
5.4.2	Cenários Noturnos	58
5.5	Conclusão	60

6 Conclusão	62
Referências	64

Lista de Figuras

3.1	Vista completa da arquitetura do sistema	21
3.2	Diagrama de fluxo do sistema	22
3.3	Detalhe da arquitetura do módulo de análise de dados meteorológicos	23
3.4	Detalhe da arquitetura do módulo de extração de descritores	24
3.5	Detalhe da arquitetura do módulo de classificação	25
3.6	Detalhe da arquitetura do módulo de estimação da área das chamas	26
4.1	Fluxo geral do sistema na ferramenta Orange	27
4.2	Ilustração das fases de um incêndio	30
4.3	Situações análogas ao fumo	30
4.4	Exemplos de vegetação com diferentes tons de cor	31
4.5	Fluxo de informação do módulo de extração de descritores	32
4.6	Exemplo dos n descritores obtidos para cada imagem	33
4.7	Fluxo de informação do módulo de classificação	33
4.8	Detalhe da arquitetura do módulo de análise de dados meteorológicos	35
4.9	Espaço de cor Lab	36
4.10	Histograma do canal a	36
4.11	Gráfico da transformação PLT no canal a	37
4.12	Antes da aplicação do PLT	38
4.13	Após aplicação do PLT	38
5.1	Fluxo da informação para o situação n ^o 1	41
5.2	Fluxo da informação para o situação n ^o 2	42
5.3	Fluxo da informação para a situação n ^o 3	42
5.4	Comparação entre vários modelos de classificação	43
5.5	Matriz de confusão do classificador diurno com duas classes	44
5.6	Matriz de confusão do classificador noturno com duas classes	44
5.7	Matriz de confusão do classificador diurno com três classes	45
5.8	Matriz de confusão do classificador com quatro classes	45
5.9	Desempenho do modelo em cenários diurnos	46
5.10	Matriz de confusão do modelo em cenários diurnos	46

5.11	Desempenho do modelo em cenários noturnos	46
5.12	Matriz de confusão do modelo em cenários noturnos	47
5.13	Matriz de confusão do teste realizado perante situações com nevoeiro . . .	48
5.14	Matriz de confusão do teste realizado perante situações com nuvens . . .	48
5.15	Matriz de confusão do teste realizado perante situações com elementos humanos	49
5.16	Matriz de confusão do teste realizado perante situações sem floresta . . .	49
5.17	Matriz de confusão do teste realizado perante vegetação com vários tons de cor	50
5.18	Matriz de confusão do teste realizado perante pequenas manchas de incêndio	51
5.19	Situações de TP da matriz de confusão 5.18	51
5.20	Situações de FN da matriz de confusão 5.18	51
5.21	Matriz de confusão do teste realizado perante grandes manchas de incêndio	52
5.22	Situações de TP da matriz de confusão 5.21	52
5.23	Situações de FN da matriz de confusão 5.21	52
5.24	Matriz de confusão do teste realizado perante situações noturnas com ele- mentos humanos	53
5.25	Situações de FP da matriz de confusão 5.24	53
5.26	Quantificação dos resultados obtidos	54
5.27	Variação de ρ no cenário C com FFDI	57
5.28	Variação de ρ no cenário C com <i>Color Algorithm for Flame Exposure</i> (CAFE)	57
5.29	Quantificação dos resultados obtidos em cenários noturnos	58

Lista de Tabelas

2.1	Propósitos e número de iniciativas da utilização de drones entre 2006 e 2013 (Colomina and Molina, 2014)	7
2.2	Comparação entre sistemas de deteção de incêndios baseados em <i>Deep Convolutional Neural Network</i> (DCNN)	12
2.3	Comparação entre sistemas de deteção de incêndios baseados em Visão Computacional (VC)	16
4.1	Composição do conjunto de imagens	28
4.2	Metadados do conjunto de imagens	29
5.1	Comparação entre modelos DCNN (Canziani et al., 2016)	43
5.2	Legenda das cores utilizadas na quantificação	54
5.3	Características dos cenários diurnos considerados	55
5.4	Resultados diurnos TP e FP das abordagens FFDI e CAFE	56
5.5	Características dos cenários noturnos considerados	59
5.6	Resultados noturnos TP e FP das abordagens FFDI e CAFE	60

Lista de Abreviaturas

ANN *Artificial Neural Network*

CAFE *Color Algorithm for Flame Exposure*

CNN *Convolutional Neural Network*

CV *Cross Validation*

DCNN *Deep Convolutional Neural Network*

DL *Deep Learning*

FFDI *Forest Fire Detetion Index*

FWI *Fire Weather Index*

ILSVRC *ImageNet Large Scale Visual Recognition Challenge*

LIDAR *Light Detection And Ranging*

LR *Logistic Regression*

ML *Machine Learning*

MODIS *Moderate-Resolution Imaging Spectroradiometer*

PLT *Piecewise-Linear Transformation*

SEVIRI *Spinning Enhanced Visible and Infrared Imager*

VIIRS *Visible Infrared Imaging Radiometer Suite*

VC *Visão Computacional*

Capítulo 1

Introdução

Na Europa do sul, e mais concretamente na bacia do mediterrâneo, a problemática dos incêndios florestais está no topo das preocupações das opiniões públicas sempre que se aproxima o Verão. Na realidade, o período de risco de incêndio florestal tem vindo a ser cada vez mais alargado, como em Portugal (Gabinete do Secretário de Estado das Florestas e do Desenvolvimento Rural, 2017), independentemente da estação do ano como resultado das alterações climáticas potenciadas pelo aquecimento global do planeta (de Rigo et al., 2017). As consequências dos incêndios florestais podem ser devastadoras se estes não forem detetados, combatidos e extintos na sua fase inicial (EUFOFINET). Mais particularmente Portugal, em 2017, apresentou o maior valor de área ardida desde 2007. Disto, estima-se que 442 mil hectares tenham ardido, o que equivale a mais 428% relativamente à média anual do período suprarreferido (ICNF, 2017). Em termos de fatalidades, foi o ano mais trágico nos últimos 17 anos, registando-se a perda 67 vidas humanas como um resultado direto dos incêndios florestais, para além das muitas pessoas feridas (Comissão Técnica Independente, 2017).

Segundo (de Rigo et al., 2017), a perspetiva de um aumento global da temperatura em 2°C acompanhado pela diminuição dos níveis de humidade irão causar maiores níveis de secura no meio ambiente. Em resultado disso, irá aumentar o risco de incêndios florestais provocados pelo clima em relação ao presente, em particular em torno do Mediterrâneo. Segundo os mesmos autores, os três países com maior risco são a Espanha, Portugal e Turquia. De seguida, com um alto risco de incêndio são referidos as regiões central e sul de Itália, o sul de França junto ao Mediterrâneo, a região costeira dos Balcãs e a Grécia.

Neste contexto, um sistema automático de deteção de incêndios florestais, preferencialmente na sua fase inicial, seria uma solução desejável para mitigar este problema. Ao invés da utilização de observadores humanos como forma de deteção de incêndios, o uso de tecnologias sob a forma de câmaras de vigilância é uma interessante opção, tendo em conta um significativo número de estudos apresentados em (Li et al., 2013). É também referido que a utilização de tecnologias de deteção de incêndio com base em imagens de vídeo possui algumas das seguintes vantagens:

-
- A velocidade de transmissão da luz e indução é muito maior do que o fumo e a temperatura e, com isso, oferecem uma detecção em tempo real.
 - O seu elevado alcance de detecção permite uma maior área abrangida.
 - A imagem possui a capacidade de obter mais informações, quer através da cor ou textura, o que permite uma maior variedade no método de detecção a aplicar.

Quando um incêndio florestal tem início, são duas as características principais que permitem identificá-lo visualmente: a chama e o fumo. Os sistemas de detecção automática de incêndios são desenhados para identificar estas características nas imagens recolhidas. Num contexto florestal, a propagação de fumo pelo ar é um dos primeiros indicadores visíveis da existência de um incêndio (Chunyu et al., 2010) e pode ser usada como um ponto de partida para uma detecção mais rápida. No entanto, em comparação com a chama, as características visuais do fumo, como a cor e o gradiente, são menos perceptíveis, o que torna mais difícil a diferenciação de situações semelhantes (Chunyu et al., 2010). Por outro lado, tem-se a presença de chamas que é outro indício confirmador da existência de um incêndio. A chama possui uma gama de cores mais perceptíveis em relação ao plano de fundo que vão desde o amarelo, laranja até ao vermelho (Li et al., 2013) e por isso a característica visual mais dominante da chama é a sua cor (Yuan et al., 2015a).

1.1 Enunciado do problema

No conjunto das várias técnicas de detecção existentes, encontra-se a detecção com recurso a câmaras de vídeo integradas em sistemas automáticos de detecção. O uso de sistemas óticos pode ser visto como se de um olho humano se tratasse na busca por indícios aparentes de um incêndio. Todavia, a floresta não é um cenário uniforme, em quase todos os casos, o que torna o processo de detecção um desafio ainda maior. Fenómenos dinâmicos como reflexões, sombras das nuvens e atividades humanas, ou mesmo situações análogas, traduzem-se em mais exigência e com isso a possibilidade de mais falsos alarmes (Alkhatib, 2014). Mais concretamente, um dos grandes desafios da detecção com base em sequências de vídeo, é que o sistema não detete erradamente objetos em movimento, nuvens e nevoeiro (Sedlak et al., 2017). Outras dos problemas, é a existência situações análogas em relação às chamas e que podem ser erradamente detetadas, como as luzes de iluminação durante a noite, reflexões solares, e objetos com cores avermelhadas (Yu et al., 2013). É com estes problemas em foco que o presente trabalho se realiza de forma a implementar uma solução de baixo custo capaz de contribuir na resolução dos desafios inerentes à detecção de um incêndio florestal com recurso a câmaras de vídeo.

1.2 Objetivos

O presente trabalho tem como objetivo desenvolver um sistema de baixo custo e portátil, capaz de detetar incêndios florestais através do uso de câmaras de vídeo. Pretende-se que as câmaras, possam ser aplicadas em plataformas estáticas, como em torres de vigia, e móveis, como em drones. Contudo, o grande foco deste trabalho é no processamento das imagens e não na parte de *hardware*.

O sistema proposto inicia-se pela utilização de dados meteorológicos numa vertente mais auxiliar pois não atuam diretamente no processo de deteção. Pretende-se que este módulo seja responsável pela obtenção do perigo de incêndio para um determinado local. Relativamente ao processo de deteção automática de incêndios, que é o foco deste trabalho, deve começar por identificar uma situação de incêndio. Para que possua essa habilidade, são necessárias duas etapas: a de extração de descritores e a de classificação, que juntos formariam um modelo de *Deep Learning* (DL). A extração de descritores tem como finalidade obter propriedades únicas que definem uma imagem por meio de um vetor numérico. Para atingir tal fim, é usada uma *Deep Convolutional Neural Network* (DCNN). Após obtidos os descritores, estes são utilizados para treinar um classificador de *Machine Learning* (ML). Objetiva-se treinar da melhor forma o modelo de classificação abordando diversas situações análogas e cenários variados, de forma a que o modelo esteja o mais preparado possível para detetar incêndios em situações reais. Por último, tem-se por objetivo detetar as zonas com chamas na imagem, anteriormente classificadas como incêndio, através da aplicação de técnicas de Visão Computacional (VC).

1.3 Estrutura do documento

O Capítulo 1 introduz o tema do trabalho onde são apresentadas as motivações presentes na elaboração do trabalho, os problemas que se pretendem resolver, os objetivos a cumprir e que darão origem ao desenvolvimento do sistema.

O Capítulo 2 começa por abordar as tecnologias usadas na deteção de incêndios florestais. Como no presente trabalho pretende-se trabalhar com imagens de câmaras de vídeo a cores, são apresentados alguns sistemas com o mesmo objetivo do presente trabalho. Encontram-se divididos em duas categorias, por um lado os que fazem uso de técnicas de DL e por outro os que utilizam técnicas de VC. No final de cada grupo de sistemas é feita uma análise comparativa.

No Capítulo 3 são apresentados três cenários de aplicação possíveis. Posteriormente, são identificados os requisitos do sistema. Finaliza-se com a proposta de arquitetura do sistema, composta por quatro módulos:

- Análise de dados meteorológicos;

-
- Extração de descritores;
 - Classificação;
 - Estimação da área das chamas.

No Capítulo 4 descreve-se a implementação de cada módulo da arquitetura do sistema. No módulo de extração de descritores, é apresentada uma DCNN e a sua capacidade de representar numericamente uma imagem para que a seguir, o vetor de descritores, possa ser utilizado num processo de treino. Sobre o módulo de classificação, é visto como treinar um classificador de ML tendo em conta o vetor de descritores obtido anteriormente, mais a classe, com incêndio ou sem incêndio, associada à imagem. Por fim, no módulo de estimação da área das chamas, são aplicadas técnicas de VC com a finalidade de detetar as chamas.

No Capítulo 5 são apresentados os testes realizados, justificadas as decisões tomadas e avaliados os resultados obtidos em cada módulo.

Finalmente no Capítulo 6 são discutidos os resultados obtidos, quer positivos e negativos, e os pontos que podem ser trabalhados no futuro de forma a tornar este sistema melhor e mais completo na tarefa para o qual está destinado.

Capítulo 2

Estado da arte

Neste capítulo são apresentadas diversas alternativas tecnológicas para a detecção de incêndios florestais. Em primeiro lugar, é analisado o uso de sensores óticos e câmaras digitais, e que levaram à escolha das câmaras de vídeo cores como meio de obtenção das imagens. Sendo os drones uma alternativa em crescente utilização, são apresentados os benefícios da sua aplicação na detecção de incêndios. Por fim, são apresentadas outras tecnologias, contudo não são o foco deste trabalho.

Posteriormente, é realizado um estudo mais vocacionado para artigos que propõem utilizar câmaras de vídeo na detecção de incêndios, através de plataformas estáticas ou móveis. Os sistemas apresentados dividem-se em dois campos de estudo: uns que utilizam técnicas de **VC** e outros técnicas de **DL**. Os sistemas de **VC** procuram, somente, detetar as chamas ou o fumo, enquanto que, nos sistemas de **DL** não existe essa restrição.

2.1 Tecnologias usadas na detecção de incêndios florestais

2.1.1 Sensores óticos e câmaras digitais

Os avanços tecnológicos em sensores e câmaras digitais e o desenvolvimento de técnicas de processamento de imagem e vídeo permitiram a implementação de sistemas óticos capazes de detetar incêndios florestais (Alkhatib, 2014). Alguns dos sensores utilizados em sistemas de detecção de incêndios (EUFOFINET) são:

- Câmaras de vídeo

São câmaras sensíveis ao espectro visível do fumo durante o dia e ao da chama durante a noite (EUFOFINET). De acordo com (Yuan et al., 2017), as câmaras digitais, mais concretamente, câmaras com sensor de imagem *charge-coupled device* (CCD), são normalmente consideradas menos robustas e confiáveis em algumas aplicações ao ar livre. A possibilidade do fumo esconder as chamas, ou situações análogas ao incêndio, podem incrementar o número de falsos alarmes. Por outro

lado, estas câmaras podem fornecer medidas das chamas como o comprimento, a altura sobre o terreno e o ângulo da mesma (Martinez-de Dios et al., 2008). Outras das vantagens é que possuem um preço muito abaixo do que o necessário para obter uma câmara de infravermelhos ou outro tipo de sensores mais avançados (Yuan et al., 2016).

- Câmaras térmicas

São câmaras que detetam o fluxo de calor emitido pela chama durante o processo de combustão (EUFOFINET). As imagens podem ser obtidas em situações de fraca ou nenhuma luz ((Yuan et al., 2017)) e são geralmente capturadas em imagens monocromáticas. Porém, o fumo pode ser visto como transparente com este tipo de câmaras. As imagens infravermelhas podem ser usadas para fornecer estimativas da frente do incêndio como a sua posição, a taxa de propagação e a largura da base do incêndio (Martinez-de Dios et al., 2008).

- *Light Detection And Ranging* (LIDAR)

Neste tipo de sensores, o processo de funcionamento passa pelo envio de um pulso de laser sobre uma nuvem de fumo e posteriormente detetar a sua reflexão (Traiche et al., 2008). O seu uso permite identificar a localização com eficiência do fumo emitido por um incêndio, mesmo em pequenas proporções. Funciona de igual modo durante o dia e noite e o seu alcance ronda as dezenas de quilómetros (Utkin et al., 2003). Uma das desvantagens do uso deste sensor prende-se com o seu preço, podendo os sensores de maior alcance chegar a preços elevados.

Tendo em conta os vários tipos de câmaras e sensores especificados anteriormente, a sua escolha vai ter em conta o tipo de requisitos pretendidos, as condições em que vão ser aplicados e utilizados, bem como o orçamento disponível para a sua aquisição. No presente projeto, foram usadas imagens recolhidas por estes sensores, tendo em conta a sua maior acessibilidade, o seu preço mais reduzido e a possibilidade de aplicação de técnicas de VC e DL.

A inclusão dos drones na temática da deteção de incêndios florestais remonta-nos a 1961, onde estes eram usados pelo Serviço Florestal dos Estados Unidos para obter informações meteorológicas sobre um incêndio em curso (Wilson and Davis, 1988). Mais tarde em 1996, o drone de seu nome Firebird 2001, constituído por uma câmara visual, foi utilizado na recolha de imagens de incêndios florestais em Missoula, Montana (Ambrosia and Zajkowski, 2015). Como se pode comprovar, a descoberta do potencial resultante da sua utilização já é visionada desde algumas décadas. Com o passar dos anos, novos avanços tecnológicos nos drones foram surgindo e, com isso, a sua aplicação na deteção de incêndios florestais tornou-se cada vez mais uma opção notória (Yuan et al., 2015b).

Os benefícios da utilização de drones são os seguintes, como mencionado em (Yuan et al., 2015a):

- Cobrem áreas amplas, especialmente em tempo nublado;
- Funcionam em cenários diurnos e noturnos, com longa duração;
- São facilmente recuperáveis e relativamente baratos;
- No caso de drones elétricos, também é um benefício para o meio ambiente;
- Podem transportar diferentes cargas para diferentes missões e, o mais importante, as missões podem ser alcançadas de forma autónoma.

Os drones são então uma alternativa cada vez mais presente em vários propósitos, e o seu uso tem vindo a aumentar ao longo dos anos, factos esses se que podem comprovar através da tabela 2.1.

Propósitos	2006	2007	2008	2009	2010	2011	2012	2013
Civil/commercial	47	61	115	150	171	175	217	247
Military	413	491	578	683	631	674	548	564
Dual purpose	77	117	242	260	283	318	353	392
Research UAS	31	46	54	66	66	69	73	78
Developmental UAS	217	269	293	329	301	310	187	172

Tabela 2.1: Propósitos e número de iniciativas da utilização de drones entre 2006 e 2013 (Colomina and Molina, 2014)

Atualmente, os drones de pequenas dimensões e prontamente disponíveis carecem de uma longa duração de voo (Merino et al., 2012). Assim, estes sistemas não permitem missões de deteção ou monitorização de longo alcance a fim de fornecer uma contínua e ininterrupta operabilidade sobre uma área em vigilância (Allison et al., 2016). Com os novos desenvolvimentos na área dos drones de pequena dimensão, espera-se que esta limitação seja ultrapassada. Por outro lado, os drones de alta altitude não sofrem do problema anteriormente descrito. Estes, conseguem cobrir grandes áreas a fim de monitorizar e detetar um incêndio e para além disso dispõem, geralmente, de uma capacidade de carga relevante (Allison et al., 2016).

No entanto, existem técnicas de deteção de fumo e chamas baseadas em métodos convencionais de VC tais como, *Wavelets*, *Support Vector Machine* e *Fuzzy Finite Automata* entre outras, que requerem condições restritivas onde os vídeos devem ser obtidos por câmaras estáticas. Esta condição não é adequada para sistemas baseados em drones (Kim et al., 2016) e por isso a utilização de sistemas baseados em DL complementarão e aperfeiçoarão as limitações existentes.

2.1.2 Outras tecnologias de detecção

Os satélites em órbita terrestre têm sido utilizados para diversos fins, sendo um deles a detecção de incêndios ativos através da observação que é feita sobre a terra. Atualmente, imagens de satélite para fins de detecção de incêndios, têm sido obtidas por vários instrumentos chave, sendo eles o *Moderate-Resolution Imaging Spectroradiometer* (**MODIS**), o *Visible Infrared Imaging Radiometer Suite* (**VIIRS**) e o *Spinning Enhanced Visible and Infrared Imager* (**SEVIRI**). O processo de detecção passa pela identificação de zonas claramente mais quentes do que aquelas em seu redor. O **MODIS** encontra-se a bordo do satélite Terra e Aqua e possui uma resolução espacial de um quilómetro (Giglio, 2015). Por outro lado, o **VIIRS** encontra-se a bordo do satélite Suomi NPP e é visto como um complemento ao **MODIS**. A sua grande distinção traduz-se numa melhor resolução espacial, que neste caso é de 375 metros (Schroeder and Giglio, 2018). Com isso, obtém-se uma melhor resposta a incêndios de dimensões relativamente pequenas. Em ambos os casos, a resolução temporal é a grande desvantagem, pois não é efetuada quase em tempo real, o que torna estas duas soluções pouco viáveis para a detecção rápida de incêndios florestais. Relativamente ao **SEVIRI** (Amraoui et al., 2013), encontra-se a bordo do satélite Meteosat-8 que, ao contrário dos anteriormente referidos, possui uma boa resolução temporal, uma imagem a cada 15 minutos. Por outro lado, tem a desvantagem, em relação aos outros dois, de possuir uma resolução espacial de três quilómetros (Amraoui et al., 2013). Tendo em conta os três exemplos referidos, atualmente, pode-se concluir que o uso de satélites é mais útil na monitorização e acompanhamento da evolução de um incêndio, do que na sua detecção rápida.

É também possível efetuar a detecção de incêndios florestais recorrendo a redes de sensores sem fios (Alkhatib, 2014). Estas redes são compostas por nós sensores, posicionados estrategicamente no espaço a monitorizar. Estes nós são geralmente autónomos do ponto de vista energético, possuem capacidade sensora, de processamento e comunicação sem fios. Estão normalmente organizados como uma rede em malha de forma a permitir a comunicação entre todos os nós e com o exterior. Tudo isto, é consumido em termos energéticos através da mesma bateria, incluída em cada circuito que, por sua vez, não é recarregável. Assim, deve apresentar um baixo consumo energético de modo a obter-se uma maior longevidade dos sensores. Os sensores podem recolher parâmetros físicos como temperatura, pressão e humidade, e parâmetros químicos como monóxido de carbono, dióxido de carbono e dióxido de nitrogénio (Alkhatib, 2014). Os valores são enviados por uma determinada rota ao longo da rede, de nó em nó, até atingir o nó principal. Os dados são analisados e quando alguns destes parâmetros atingem valores pré configurados como indicadores da presença de um incêndio, um alarme é acionado. Em termos de aplicabilidade, podem ser espalhados em qualquer lugar, devido ao seu tamanho reduzido que

implica poucas ou nenhuma restrições (Alkhatib, 2014). O fornecimento da informação, pode ser feito rapidamente e com grande precisão (Liyang Yu et al., 2005). Tendo em conta a grande área ocupada pelas florestas, são necessários muitos nós para que a zona de interesse seja coberta na sua totalidade. Para além disso, é importante ter em conta que embora a duração das baterias seja longa, após totalmente gastas, é necessário a reposição dos nós em falta (Alkhatib, 2014).

Um exemplo do uso de redes de sensores sem fios, é demonstrado em (Neumann et al., 2018), onde é abordado o conceito de *Smart Forest*, que deriva da área de *Internet of Things*. É proposta uma infraestrutura de baixo custo composta por *Mobile Hubs*, *Sensor Tags*, atuadores e um servidor *Smart Forest*. Os dados recolhidos pelos *Sensor Tags*, são a temperatura e a humidade, e devem ser enviados para o *Mobile Hub*, que irá processar os dados à procura de eventos antes de notificar o servidor *Smart Forest*.

2.2 Sistemas de *Deep Learning* na deteção incêndios

O conceito de *Convolutional Neural Network* (CNN) foi introduzido em 1980 por Fukushima (Fukushima, 1980). As CNN são análogas às tradicionais *Artificial Neural Network* (ANN), pois são compostas por neurónios que se auto-otimizam por meio de técnicas de aprendizagem (O’Shea and Nash, 2015). Contudo, são maioritariamente aplicadas para reconhecer padrões em imagens e conseqüentemente usadas em tarefas de classificação. Desde 2010, o desafio anual *ImageNet Large Scale Visual Recognition Challenge* (ILSVRC) (Deng et al., 2009) baseia-se numa competição onde várias equipas submetem programas que classificam e detetam objetos em imagens. Em 2012, uma abordagem baseada em *Deep Convolutional Neural Network* (DCNN), de seu nome AlexNet (Krizhevsky et al., 2012), venceu o desafio ImageNet e, desde então, vários estudos têm sido realizados com vista a aprofundar a técnica, o que levou ao surgimento de novas soluções em cada edição do desafio. Modelos como VGGNet (Liu and Deng, 2015), GoogleNet (Szegedy et al., 2015) e Microsoft ResNet (He et al., 2016) são redes complexas e profundas, mais conhecidas como DCNN, que foram apresentadas no desafio e tem sido alvo de melhorias. As DCNN são mais difíceis de treinar em comparação com as CNN, porque possuem mais parâmetros (Sharma et al., 2017) e mais camadas, e por isso são consideradas redes profundas. As DCNN estão atualmente entre os modelos de classificação de imagem mais bem-sucedidos, o que os tornam ideais para tarefas como deteção de incêndios florestais em imagens (Sharma et al., 2017).

2.2.1 Sistemas de deteção diurna e noturna

Em (Huttner et al., 2017) é explorada a melhor escolha de otimizadores, funções de redução e taxas de aprendizagem para a DCNN Inception-V3. O conjunto de teste,

contém 13418 imagens sem fogo e 14259 imagens com fogo, proveniente de fontes de vídeo móveis. Por defeito, o Inception-V3 é implementado segundo determinados parâmetros, contudo foram analisadas as alternativas existentes. Conclui-se que a melhor combinação de parâmetros engloba o otimizador *Adam*, a função *reduce max* e uma taxa de aprendizagem de 0.1. Esta combinação obteve uma precisão de 99.7%, uma melhoria subtil de 0.5% em relação aos 99.2% obtidos com os parâmetros originais. Os resultados são elevados, porém o conjunto de imagens utilizado, não é proveniente de incêndios florestais, sendo a maioria deles, provenientes de incêndios em edifícios. Como a maioria dos vídeos foram gravados de perto, a chama é o principal sinal notório enquanto que num incêndio florestal inicial, a longas distâncias, o fumo é o sinal mais observável.

Como demonstrado em (Sharma et al., 2017), é proposto o uso de duas **DCNN** cujo o objetivo passa por melhorar a precisão de deteção através de um ajuste fino na camada *Fully Connected* de ambas. As duas **DCNN** envolvidas são a VGG16 e a Resnet50. O contributo passa por comparar as precisões de treino e teste, assim como os tempos de execução. O conjunto de treino consiste em 549 imagens enquanto que o de teste consiste em 102 imagens. Os resultados demonstram que ao adicionar camadas *Fully Connected* no final das redes, ocorre uma melhoria na precisão em apenas 1%, alcançando uma precisão de 91.18% e 92.15% respetivamente. Em comparação com uma simples **CNN**, verifica-se que as **DCNN** apresentam uma melhor precisão na deteção de incêndios, mesmo com um conjunto de treino não balanceado de forma a imitar o melhor possível os cenários reais. Contudo, o VGG16 possui vários parâmetros (Canziani et al., 2016), o que se traduz num maior número de operações necessárias.

Em (Wonjae Lee et al., 2017), é analisado a melhor **DCNN** para o problema da deteção de incêndios florestais. Como tal, são estudadas cinco **DCNN**: AlexNet, GoogLeNet, GoogLeNet modificada, VGG13 e VGG13 modificada. O número de imagens de incêndio é de 10985, e o número de imagens sem incêndio é de 12068, no entanto, não existe qualquer referência à fonte de aquisição nem à qualidade do conjunto de imagens utilizado. No processo de treino, de forma a reduzir o *overfitting* da **DCNN**, são aplicadas técnicas de recorte, inversão horizontal e vertical das imagens. Após treino, conclui-se que a GoogLeNet (versão anterior ao Inception-V3), apresenta o melhor resultado, com 99% de precisão, a seguir à VGG13 modificada. Por outro lado, a VGG13 original possui a pior precisão e o maior tempo de treino devido ao *overfitting* e à grande quantidade de parâmetros.

O sistema apresentado em (Zhang et al., 2016) propõe mais uma vez o uso de uma **DCNN**, neste caso a AlexNet de oito camadas. A abordagem passa por treinar a última camada da **DCNN**, responsável pelo processo de classificação e, de seguida, treinar um

classificador de blocos para que este consiga localizar precisamente as zonas da imagem com chamas. O número de imagens usadas é relativamente pequeno. Para o processo de treino foram utilizadas 178 imagens e, para avaliar a precisão alcançada, foram utilizadas 59 imagens. Os resultados obtidos após teste demonstram uma alta precisão na deteção correta dos blocos com chamas. Perante dois diferentes conjuntos de treino, foram alcançadas precisões de 97.3% e 90.1%. Como o sistema foi treinado para detetar apenas as chamas na imagem e não fumo, a longas distâncias, a sua utilização não é ideal pois, maioritariamente, só é visível o fumo.

Em (Kim et al., 2016), o sistema proposto passa pela criação de uma **CNN**, que utiliza imagens obtidas por drones, para decidir se uma determinada imagem apresenta um incêndio florestal. Mais concretamente, a arquitetura da **CNN** proposta consiste em três camadas *Convolutional*, três camadas *Pooling*, e duas camadas *Fully Connected*. O conjunto de imagens utilizado para treino é bastante extenso e, como tal, 950056 imagens com incêndio e 53656 imagens sem incêndio foram usadas. São definidos dois tipos de classificação, uma classificação binária, com ou sem incêndio, e outra classificação com seis classes, que engloba a distinção entre imagens de dia e de noite, com chamas, com fumo e entre outras mais. Os resultados demonstram que para a **CNN** proposta, a classificação com seis classes, possui uma maior precisão. Contudo, com um tempo de treino de cerca de seis horas, o valor mais alto não chega aos 90%, o que pode demonstrar uma menor competência da **CNN** para o problema em causa.

2.2.2 Análise comparativa dos sistemas de deteção

A tabela 2.2 representa o resumo da análise feita anteriormente, onde consta para cada sistema, o tipo de **DCNN** utilizada, se deteta as chamas e o fumo num incêndio, se aborda cenários noturnos, qual a precisão de deteção obtida tendo em conta o seu *dataset* e, por fim, a qualidade do *dataset* utilizado no processo de treino, numa escala de (+) até (+++). Procura-se perceber se o *dataset* é numeroso em termos de imagens, se está organizado e, se aborda situações análogas a um incêndio florestal e que podem induzir o sistema em erro.

Sistema	DCNN	Chama	Fumo	Noite	Precisão	Dataset
(Huttner et al., 2017)	Inception-V3	✓	✓	✗	99.7%	++
(Sharma et al., 2017)	Resnet50 modificada	✓	✓	✓	92.15%	++
(Sharma et al., 2017)	VGG16 modificada	✓	✓	✓	91.18%	++
(Wonjae Lee et al., 2017)	GoogLeNet	✓	✓	n/a	99%	++
(Wonjae Lee et al., 2017)	AlexNet	✓	✓	n/a	94.8%	++
(Wonjae Lee et al., 2017)	VGG13 modificada	✓	✓	n/a	96.2%	++
(Zhang et al., 2016)	AlexNet NN-Pool5	✓	✗	✗	97.3%	+
(Kim et al., 2016)	CNN simples	✓	✓	✓	88.54%	++

Tabela 2.2: Comparação entre sistemas de detecção de incêndios baseados em DCNN

A maioria dos sistemas fazem uso de uma DCNN previamente treinada, à exceção de (Kim et al., 2016) onde é desenvolvida e treinada uma CNN de raiz. A utilização de uma DCNN já treinada evita a construção de uma nova, o que pode levar semanas, dependendo do *dataset* de treino e da configuração da rede, sem mencionar o custo dos recursos. A grande maioria dos sistemas detecta tanto as chamadas do incêndio bem como o fumo, no entanto, alguns não abordam cenários noturnos, o que não é de descartar, pois um incêndio tanto ocorre de dia como de noite. Todos os sistemas apresentam precisões elevadas, sendo a maioria acima dos 90%, o que comprova a competência das DCNN na detecção de incêndios florestais. Constata-se que a grande parte dos sistemas, à exceção de (Zhang et al., 2016), apenas possuem um *dataset* numeroso. Em nenhum sistema é realizada qualquer análise do mesmo, a fim de averiguar quais os tipos de situações utilizadas e quais as que deveriam ser acrescentadas de forma a tornar o *dataset* o mais abrangente possível. Tendo em conta que os cinco sistemas apresentados utilizaram *datasets* diferentes, não é correto afirmar que um é melhor do que outro tendo em conta a precisão anunciada. Contudo, o melhor resultado obtido em termos de precisão é do sistema (Huttner et al., 2017), que tem por base a DCNN Inception-V3. No entanto, é de salientar que o *dataset* utilizado não aborda vários cenários florestais, fumo inicial e em pequenas dimensões, assim como cenários noturnos.

2.3 Sistema de visão computacional na detecção de incêndios

A VC (Bradski and Kaehler, 2016) pode ser definida como um processo de várias transformações sobre uma imagem até atingir um determinado objetivo. Todas essas transformações levam-nos a tomar uma decisão, ou obter uma nova representação com base na informação recolhida através de uma imagem. Tendo em conta o problema abordado neste projeto, os dados de entrada indicam informação contextual, como "a câmara está a vigiar uma floresta". Assim, a decisão poderá ser "existe um incêndio", e uma nova

representação poderá implicar a remoção do ruído presente na imagem ou a transformação da imagem a cores numa imagem em tons de cinzento. Como mencionado em (Szeliski, 2010), na **VC** tenta-se fazer o inverso do que se faz na computação gráfica. Enquanto na computação gráfica se pretende criar a ilusão da realidade, na **VC** tenta-se descrever o mundo que se vê nas imagens e reconstruir as suas propriedades como a forma, a iluminação e a cor. Na temática da deteção de incêndios florestais, a **VC** possui um grande número de estudos e, são prova disso, os artigos abordados em (Yuan et al., 2015b). Para além disso, as vantagens da utilização de técnicas baseadas em visão, como a obtenção de dados intuitivos, informativos e confiáveis quase em tempo real, deteção de longo alcance e entre outras mais, fazem da **VC** um importante tópico de pesquisa no campo da monitorização e deteção de incêndios florestais (Li et al., 2013).

2.3.1 Sistemas de deteção de chamas

Em (Cruz et al., 2016) é proposto um método para deteção de chamas e fumo. É adequado para atuar em cenários diurnos e tem como finalidade ser aplicado em drones. O método consiste no uso de um novo índice de cor denominado de *Forest Fire Detetion Index (FFDI)* cujo algoritmo envolve apenas a manipulação do espaço de cor RGB através da aplicação de um conjunto de índices de cor. Embora pretenda detetar as chamas e o fumo num incêndio florestal, em cenários reais, nem sempre a chama é visível. Assim, o artigo não se encontra preparado para detetar somente o fumo pois requer que, primeiramente, seja detetado as chamas. Em resultado disso, no presente documento, é descrito na categoria de deteção de chamas, devido a sua maior aptidão para tal, mesmo na ausência de fumo. Em relação aos resultados, alcança uma precisão de 96.82% em imagens de tamanho 960x540 *pixels* num tempo de processamento de 0,0447 segundos. O resultado da sua rapidez traduz-se no facto de apenas envolver operações em espaços de cor.

É apresentado em (Vipin, 2012) um método de deteção de chamas baseado no processamento de imagens. Apesar de não declarar concretamente a sua aplicabilidade, em termos de obtenção das imagens e nem ao tipo de cenários, caracteriza-se pelo baixo custo computacional o que permite uma deteção rápida. Em termos algorítmicos, a deteção das chamas é feita através do manuseamento dos espaços de cor RGB e YCrCb. O algoritmo é composto por sete regras a aplicar sequencialmente. Em relação à sua avaliação, o autor afirma alcançar uma deteção da chama de 99% e uma taxa de falsos alarmes de 14% num conjunto de 200 imagens de teste. Devido à sua rapidez e simplicidade de implementação, as regras apresentadas são técnicas a ter em consideração, porém é necessário diminuir e averiguar as situações em que o sistema deteta zonas com chamas erradamente.

Uma solução na deteção de chamas, orientada para o uso de drones, é apresentada

em (Yuan et al., 2016). Primeiro, é aplicada uma regra de cor para extrair os *pixels* com cores idênticas ao das chamas e, em segundo, é utilizado um algoritmo para determinar a existência movimento. As imagens são obtidas em pleno voo, com uma resolução de 752x582, e o primeiro processamento a aplicar é a detecção com base nas características da cor. Para tal, o espaço de cor Lab é utilizado. De seguida, são detetadas as zonas com movimento, através do algoritmo *Horn and Shunk Optical Flow*. A utilização deste ultima técnica envolve um número elevado de cálculos e não pode garantir pontualidade nos resultados (Cai et al., 2016), para além do mais que, esta técnica é mais indicada para funcionar com câmaras estáticas. Apesar do artigo não especificar valores relativos à precisão e ao tempo de detecção do algoritmo, simplesmente é afirmado que pode ser alcançado um bom desempenho.

Em (Gomes et al., 2014), é proposto um método que procura melhorar a precisão na detecção das chamas através de câmaras fixas de vigilância. O sistema recorre a dois fluxos de imagens paralelos, um para a detecção da chama e outro para confirmação dos resultados. A análise dos espaços de cor HSI, YCbCr e RGB, de texturas dinâmicas e da frequência espacial-temporal são utilizadas no primeiro fluxo, enquanto que, no segundo fluxo é utilizado um algoritmo de *Background Subtraction* para detetar e rastrear objetos em movimento. Conseguir alcançar uma detecção de 93.1% num total de 12 vídeos com uma resolução de 300x250, o que demonstra o sucesso do uso dos dois *pipelines*. Apesar do bom resultado apresentado, possui algum grau de dificuldade na aplicação do método de detecção, devido ao uso de algumas técnicas de VC complexas, como a análise de frequência e detecção dinâmica de texturas.

A detecção de incêndios florestais em cenários noturnos é o objetivo de (Günay et al., 2009). Como o fumo não é visível durante a noite, apenas o brilho da chama é sinónimo da presença de um incêndio. Assim, a detecção proposta passa pela detecção de objetos com movimentos lentos, de regiões brilhantes, de regiões periódicas e, pela interpretação da deslocação das regiões em movimento. Os resultados, revelam que em nove vídeos de incêndios captados durante a noite, com uma resolução máxima de 704x576, o tempo de detecção variou entre 2 e 20 segundos após se tornarem visíveis, sendo que alguns dos vídeos ocorrem a uma distância considerável entre seis e sete quilómetros. Estes resultados são bastante bons, dado que o número de estudos sobre detecção noturna de incêndios ainda é escasso. No entanto, existem falsos alarmes emitidos num vídeo e que necessitam de ser analisados, embora no artigo não sejam descritas as situações em que acontecem.

2.3.2 Sistemas de detecção de fumo

Em (Vijayalakshmi, 2017) é proposta uma solução baseada na segmentação de regiões em movimento e no agrupamento de ambas, através das técnicas de *Background Subtraction* e *Fuzzy c-means* respetivamente. Tendo em conta os algoritmos utilizados, as imagens de vídeo terão de ser obtidas por uma câmara sem movimento. Relativamente aos resultados obtidos, os testes foram realizados com base em quatro vídeos, sendo que dois foram em cenários interiores, com 89.5% de precisão, e os restantes em cenários exteriores, com 85.5% de precisão. Os resultados demonstram que o método proposto é adequado para sistemas de detecção precoce, apesar dos poucos testes efetuados. Tendo em conta que os testes não foram focados somente em cenários exteriores, certas questões acerca da capacidade de detetar fumo a longas distâncias e sobre o comportamento perante outros objetos em movimento não foram aprofundadas suficientemente.

Um método para detecção de fumo com base na análise da cor e movimento é apresentado em (Sedlak et al., 2017). Este sistema proporciona uma detecção rápida, em cenários diurnos, e encontra-se desenvolvido para permitir o processamento de sinal de várias câmaras sem grandes complexidades computacionais. O processo de detecção passa pelo pré-processamento do sinal, extração de características e classificação das mesmas. A avaliação do método foi realizada em vídeos com uma baixa resolução de 292x240, sendo que o tempo médio máximo de detecção foi cerca de 10 segundos, o que é bastante bom. Foram utilizados 10 vídeos, cada um com uma característica diferente, o que culminou numa avaliação completa devido à utilização de situações análogas ao fumo. Em apenas um vídeo, que continha fumo e *smog* (nevoeiro mais fumo), o sistema não emitiu o alarme de fumo. Assim, os vários testes culminaram numa detecção correta do fumo em 90% dos casos, o que torna o método proposto, numa solução promissora a aprofundar.

Em (Cai et al., 2016) é proposto um método baseado na segmentação de zonas com movimento, extração de características do fumo e, por fim, um classificador. Para a segmentação das zonas com movimento é utilizado o método *Visual Background extractor*. De seguida, entra em ação a detecção de fumo com base em determinadas características, como a energia de alta frequência baseada na transformação de ondas, a consistência e a direção do movimento do fumo. Por fim, é utilizado o modelo de classificação *Support Vector Machine* que tem por base os dados anteriormente obtidos. A avaliação é caracterizada por uma taxa de detecção de 92.7%. O conjunto de teste resume-se a três vídeos estáticos de situações diferentes, sendo elas, fogo num jardim a longa distância, fogo num contentor do lixo e fogo atrás de uma vedação. Apesar de não ser um conjunto de teste exaustivo, ressalta a importância das características dinâmicas na detecção de fumo.

Como descrito em (Luu-Duc et al., 2016), é proposta uma abordagem para detectar fumo através de câmaras de vigilância estáticas. O método proposto resume-se a um pré-processamento para reduzir o ruído presente na imagem e dividir a imagem em pequenos blocos, determinar as regiões suspeitas de fumo com base na detecção de cor e de movimentos lentos e, por fim, analisar as regiões de fumo através de uma matriz de co-ocorrência. A matriz de co-ocorrências visa detectar três características representativas da presença de fumo, sendo elas o contraste, a energia e a correlação. A implementação desta última técnica aparenta alguma complexidade. A avaliação culminou uma precisão de 87%, no entanto a maioria das frames de fumo são detetadas nos vídeos usados como teste e, por isso, poderá ser uma questão de tempo até detetar o fumo. Foram usados 14 vídeos, a uma taxa de 10 frames por segundo e uma resolução média de 640x480 *pixels*. Para além disso, demonstra a capacidade de detetar fumo na presença de nevoeiro.

2.3.3 Análise comparativa dos sistemas de deteção

A tabela 2.3 resume a análise feita anteriormente, onde consta para cada sistema, se utiliza câmaras estáticas ou móveis, se deteta as chamas e o fumo num incêndio, se aborda cenários noturnos, o custo de implementação do algoritmo, qual a precisão de deteção obtida tendo em conta o seu *dataset* e, por fim, a qualidade do *dataset* utilizado na avaliação.

Sistema	Câmara	Chama	Fumo	Noite	Custo	Precisão	<i>Dataset</i>
(Cruz et al., 2016)	Móvel	✓	✗	✗	+	96.82%	+++
(Vipin, 2012)	Móvel	✓	✗	✗	+	99%	+
(Yuan et al., 2016)	Móvel	✓	✗	✗	++	n/a	+
(Gomes et al., 2014)	Fixa	✓	✗	✗	+++	91.1%	++
(Günay et al., 2009)	Fixa	✓	✗	✓	+++	n/a	+++
(Vijayalakshmi, 2017)	Fixa	✗	✓	✗	++	89.5%	+
(Sedlak et al., 2017)	Fixa	✗	✓	✗	++	90%	+++
(Cai et al., 2016)	Fixa	✗	✓	✗	+++	92.5%	+
(Luu-Duc et al., 2016)	Fixa	✗	✓	✗	++	87%	+++

Tabela 2.3: Comparação entre sistemas de deteção de incêndios baseados em VC

Como acima demonstrado, a deteção do fumo, recorre, na totalidade dos sistemas, a câmaras fixas, pois são aplicadas técnicas de deteção de movimento, o que requerem uma fonte de obtenção estável. Na deteção da chama, já existem sistemas ((Cruz et al., 2016), (Vipin, 2012), (Yuan et al., 2016)) vocacionados para a utilização de câmaras móveis. Por outro lado, a deteção noturna através de câmaras de vídeo, ainda carece de investigação,

já que apenas foi encontrado um sistema (Günay et al., 2009). São apresentados sistemas onde a precisão de detecção é muito boa, acima dos 95%, como é o caso de (Cruz et al., 2016) e (Vipin, 2012). Tendo em conta que cada sistema utiliza um *dataset* diferente, não é adequado afirmar que um é melhor que o outro, contudo permite avaliar o seu custo de implementação e a qualidade das técnicas aplicadas. Os sistemas de detecção diurno de chamadas, no seu geral, possuem um custo de implementação inferior aos que detetam o fumo. Isto porque, o processo de identificação das características do fumo, não se resume apenas a aplicar regras de cor, como em alguns sistemas ((Cruz et al., 2016) e (Vipin, 2012)) na detecção de chamadas. Contudo, não se privam da possibilidade de situações análogas, como luzes ou objetos da mesma cor. Relativamente à qualidade do *dataset* utilizado, isto é, se é vasto e variado em termos de situações, os sistemas (Cruz et al., 2016), (Günay et al., 2009), (Sedlak et al., 2017) e (Luu-Duc et al., 2016) são os que melhor cumprem estes requisitos.

2.4 Conclusão

Neste capítulo foram estudadas as tecnologias utilizadas na detecção de incêndios florestais e que levaram à escolha das câmaras de vídeo, as vantagens do uso de drones e os sistemas de detecção de incêndios, retratados em artigos, baseados em câmaras de vídeo.

Os sistemas baseados em técnicas de **VC** são, na sua maioria, vocacionados para operar em cenários diurnos, pois apenas foi encontrado um artigo que aborda cenários noturnos. A maioria das técnicas analisadas pelos artigos, inclusive as mais complexas de detecção, quer do fumo como da chama, são mais indicadas para funcionarem através de câmaras estáticas e não por câmaras em movimento, drones, que é um dos objetivos do presente trabalho. As técnicas de **DL** utilizadas nos artigos, são indiferentes ao facto da captura das imagens de vídeo ser realizada em movimento ou não e, por isso, não apresentam qualquer restrição no uso de drones como meio de obtenção das imagens. Constatou-se que a maioria dos artigos utilizou um volumoso número de imagens, no entanto, existe alguma fragilidade na sua estruturação, de forma a proporcionar ao leitor uma noção das situações em que o sistema se encontra apto e aquelas que podem induzir em erro.

Capítulo 3

Especificação

O sistema aqui proposto, procura atender aos seguintes grandes objetivos:

- Oferecer um mecanismo de treino para reconhecimento de incêndio florestal com base em informação visual.
- Detetar as chamas na imagem de incêndio para permitir avaliar a dimensão do mesmo.

Para a concretização do primeiro objetivo, é utilizado um modelo de **DL** e um classificador de **ML**. Para que o sistema consiga detetar incêndios iniciais, são utilizadas maioritariamente imagens de incêndio de pequenas dimensões. O segundo objetivo, é concretizado através de técnicas de **VC**, que permitirão encontrar as chamas presentes na imagem. Para além deste dois grandes objetivos, pretende-se avaliar, do ponto de vista meteorológico, o risco de incêndio para uma determinada região.

Neste capítulo são identificados os cenários de aplicação do sistema, que são sujeitos a avaliação no final do trabalho. Estes cenários de aplicação, dão origem aos requisitos apresentados posteriormente. Por último, é detalhada a arquitetura do sistema, mais pormenorizadamente cada módulo constituinte.

3.1 Cenários de aplicação e Requisitos

3.1.1 Cenário de aplicação

Pretende-se que, o sistema aqui proposto, seja aplicado em várias regiões florestais, caracterizadas por diferentes tipos e tons de vegetação. Independentemente do local onde é aplicado, deverá realizar uma deteção autónoma e eficaz, auxiliada por um drone que cobrirá o cenário florestal onde será aplicado.

Ao longo da observação do cenário, o sistema poderá deparar-se com três situações diferentes:

-
- Não é identificado incêndio;
 - É identificado um incêndio mas não são detetadas chamas;
 - É identificado um incêndio e são detetadas chamas.

A primeira situação diz respeito à não ocorrência de um incêndio. Assim, caso o sistema classifique corretamente uma imagem como não contendo incêndio, nada mais acontecerá no sistema com essa imagem e, por isso, ela é descartada e é dado início à captura e análise da próxima imagem.

Por outro lado, a segunda situação acontece quando o sistema está perante uma situação verdadeira de incêndio. O sistema deve começar por classificar a imagem como contendo incêndio e logo após, é passada para a fase de deteção das chamas. Caso não detete nenhuma chama na imagem de incêndio, então pode-se assumir que o incêndio foi reconhecido somente pela fumo libertado e visível na imagem. Tendo em conta que se trata de uma situação verdadeira de incêndio, poderá ser efetuada uma aproximação do incêndio, a nível espacial pelo drone ou através de *zoom* da imagem, e aí as chamas já poderão ser detetáveis.

Por fim, a terceira situação, ocorre, mais uma vez, quando o sistema está perante uma situação de incêndio e que é identificada corretamente. Ao contrário do que acontece na situação anterior, são detetadas zonas com chamas, sendo estas delimitadas na imagem para que se possa avaliar a dimensão do incêndio.

Todas estas informações devem ser comunicadas em tempo real para possibilitar uma intervenção rápida e consciente.

3.1.2 Requisitos funcionais

As funcionalidades que o sistema deve ser capaz de executar encontram-se detalhadas de seguida:

- **URF001:** Reconhecer uma situação de incêndio através das suas chamas.
- **URF002:** Reconhecer uma situação de incêndio através do seu fumo.
- **URF003:** Detetar um incêndio em fase inicial.
- **URF004:** Detetar as chamas, se presentes na imagem, para que possa ser estimada a área das mesmas.
- **URF005:** Obter várias informações meteorológicas, como o risco de incêndio, para um determinada região.

-
- **URF006:** Armazenar as imagens de incêndio, desde que se tenha a certeza que estão corretamente classificadas, para que no futuro possam ser utilizadas para re-treinar e melhorar o processo de classificação.
 - **URF007:** Armazenar os dados meteorológicos dos dias em que ocorreram incêndios para possibilitar uma análise dos mesmos no futuro.
 - **URF008:** Sempre que for detetado um incêndio, um alarme deve ser emitido.

3.1.3 Requisitos não funcionais

Os comportamentos e as características que o sistema deve possuir encontram-se discriminados de seguida:

- **URNF001:** Usar imagens fixas, extraídas de vídeos.
- **URNF002:** Detetar um incêndio em *near real time*.
- **URNF003:** Implementar um sistema de baixo custo através de aplicações e bibliotecas de software gratuitas.
- **URNF004:** As técnicas propostas devem funcionar perante câmaras móveis e estáticas.
- **URNF005:** Funcionar continuamente, de dia e noite.

3.1.4 Requisitos de sistema (Software e Hardware)

A seguir são estabelecidas as necessidades de software e hardware para que o sistema seja implementado:

- **URS001:** No desenvolvimento do sistema utilizar uma linguagem de alto nível.
- **URS002:** Uso de uma arquitetura **DCNN**, de um classificador de **ML** e de algoritmos de **VC**.
- **URS003:** Uso de uma câmara de vídeo a cores.

3.2 Arquitetura do sistema

A arquitetura do sistema é composta por quatro módulos (análise de dados meteorológicos, extração de descritores, classificação e estimação da área das chamas), como se pode visualizar na figura 3.1. Um módulo é auxiliar, o de análise de dados meteorológicos, e os restantes três são dedicados à deteção do incêndio. São consideradas fontes de entrada, as imagens obtidas pelas câmara e os dados meteorológicos obtidos

pela entidades responsáveis de cada país. De forma a armazenar, tanto as imagens como os dados meteorológicos, são utilizadas duas bases de dados.

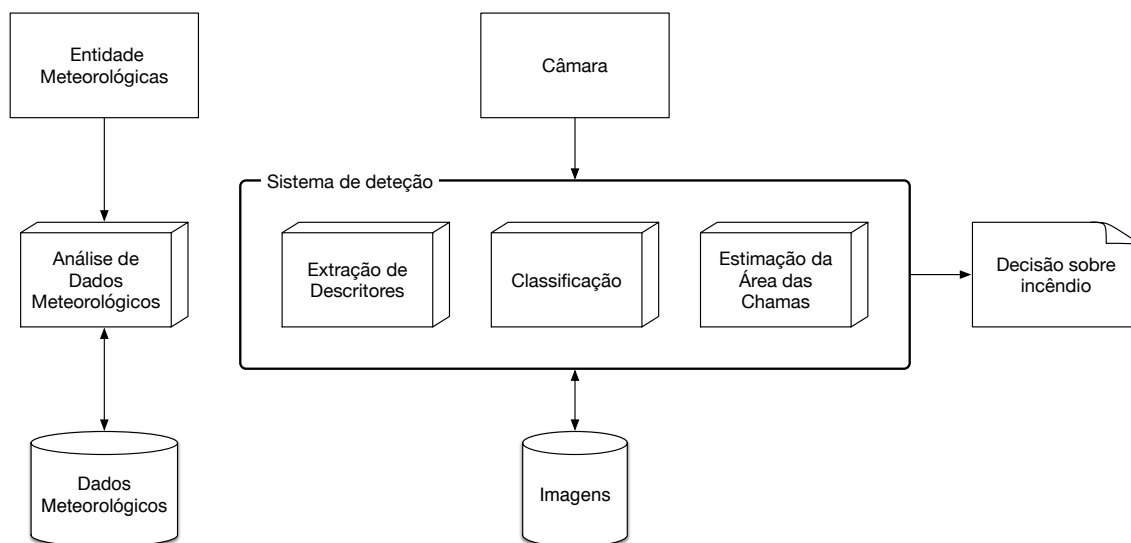


Figura 3.1: Vista completa da arquitetura do sistema

Para melhor entender toda a sequencialidade dos módulos apresentados na arquitetura do sistema, é apresentado na figura 3.2, o diagrama de fluxo do sistema.

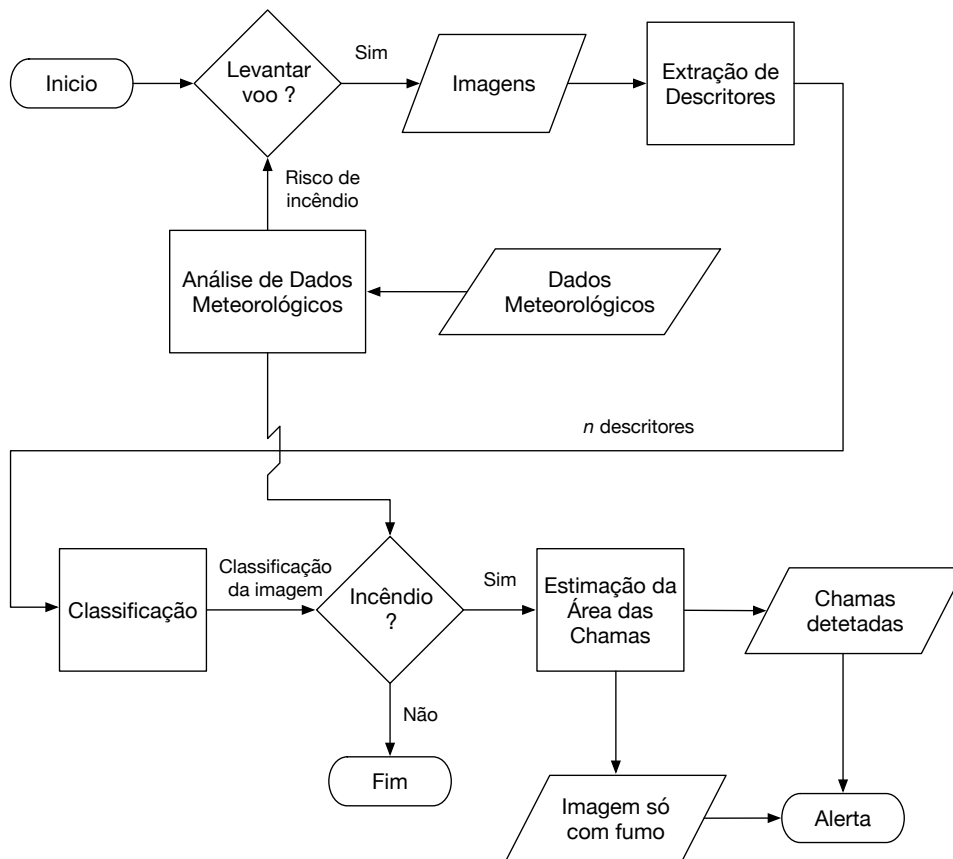


Figura 3.2: Diagrama de fluxo do sistema

O sistema deve seguir o princípio de que se justifica sempre levantar voo e dar início à procura de incêndios. Excepcionalmente, caso as condições climáticas sejam de extrema humidade ou precipitação, o risco de incêndio é muito baixo e só aí não se justifica o levantamento do drone.

É dado início à obtenção das imagens que de seguida são analisadas pelos módulos de extração de características e de classificação. Neste ponto, espera-se uma decisão correta sobre a presença de incêndio. Contudo, podem existir algumas incertezas e o módulo de análise de dados meteorológicos pode auxiliar na tomada de decisão final. Por exemplo, caso uma imagem seja classificada como incêndio com uma probabilidade 50% e as condições climáticas sejam de elevada temperatura ou forte vento, a imagem deve continuar a ser classificada como incêndio. Esta parte pode ser vista como um sistema de regras.

No último módulo, todas as imagens classificadas como incêndio, são submetidas à deteção das chamas. Porém, nem sempre as chamas são visíveis e detetáveis, o que leva a concluir que o incêndio foi detetado pela presença de fumo.

3.2.1 Análise de Dados Meteorológicos

A utilização de outros dados para além das imagens, permitem aplicar novas funcionalidades no sistema e, por isso, o objetivo deste módulo é utilizar dados meteorológicos, nomeadamente o risco de incêndio para uma determinada zona. O cálculo do risco de incêndio pode ser efetuado tendo em conta o Sistema Canadano *Fire Weather Index (FWI)*. Foi originalmente concebido para calcular possíveis condições de incêndio nas florestas do Canadá (Van Wagner, 1987), no entanto, atualmente é utilizado noutras regiões como Europa, China, Estados Unidos da América e entre outras (Wang, 2015). Contudo, é necessário uma calibração do sistema tendo em conta as propriedades específicas do clima do próprio país (Viegas et al., 2004). Por isso, as entidades responsáveis de cada país, são geralmente as mais indicadas para fornecer tal informação tendo em conta o seu maior conhecimento, ao invés de estar a implementar o sistema de cálculo no presente trabalho e adaptá-lo para cada região.

A arquitetura deste módulo é detalhada na figura 3.3.




Figura 3.3: Detalhe da arquitetura do módulo de análise de dados meteorológicos

O sistema *FWI* tem em conta os seguintes parâmetros meteorológicos (Viegas et al., 2004):

- A temperatura do ar;
- A humidade relativa do ar;
- A velocidade do vento, medida a 10m de altura;
- A precipitação ocorrida nas últimas 24 horas.

O cálculo do risco de incêndio é baseado nas equações e metodologias descritas por (Van Wagner, 1987).

3.2.2 Extração de Descritores

A extração de descritores de uma imagem pode ser realizada através de vários exemplos de *DCNN*. A *DCNN* escolhida para o presente módulo foi o Inception-V3. Este

módulo serve de base para o módulo seguinte, o módulo de classificação. Todas as [DCNN](#) possuem uma camada de extração de descritores e uma de classificação no final da sua rede. Contudo, é possível desassociar a camada de classificação a fim de testar vários algoritmos de aprendizagem com o propósito de encontrar a melhor solução. A escolha do algoritmo de classificação irá ser abordada no próximo módulo do sistema. Resumidamente, este módulo extrai de cada imagem, um vetor numérico, sendo que duas imagens diferentes, irão obter dois vetores diferentes.

A arquitetura deste módulo é detalhada na figura 3.4.




Figura 3.4: Detalhe da arquitetura do módulo de extração de descritores

Para adquirir uma representação numérica das imagens, estas, são enviadas para a [DCNN](#) Inception-V3, que neste caso concreto, irá descartar a camada de classificação e considerar apenas a penúltima camada da sua rede. Esta penúltima camada irá retornar um vetor com 2048 valores descritivos de cada imagem.

3.2.3 Classificação

Em seguimento do módulo de extração de descritores, este módulo, tem como entrada, os 2048 descritores de cada imagem. Aqui, pretende-se que o módulo seja capaz de, dado o conjunto de entrada, obter uma resposta binária, se existe, ou não, incêndio. Para que isso seja possível, é necessário que o classificador tenha conhecimento e, para tal, é necessário treiná-lo. A aprendizagem do classificador é baseada no conjunto de imagens de entrada e na classe a que essas mesmas imagens pertencem. Isto é, se o modelo for treinado com três classes de imagens, este deve apenas ser capaz de classificar uma dada imagem numa dessas três classes. Assim, e após ensaios com vários modelos de aprendizagem supervisionada, como é apresentado no Capítulo 5, conclui-se que o modelo *Logistic Regression* (LR), possui o melhor desempenho para o problema em questão. Como o conjunto de imagens possui situações diurnas e noturnas, e tendo em conta que as diferenças entre cada cenário são bastante significativas, procedeu-se à divisão do mesmo o que levou à utilização de dois classificadores.

A arquitetura deste módulo é detalhada na figura 3.5.

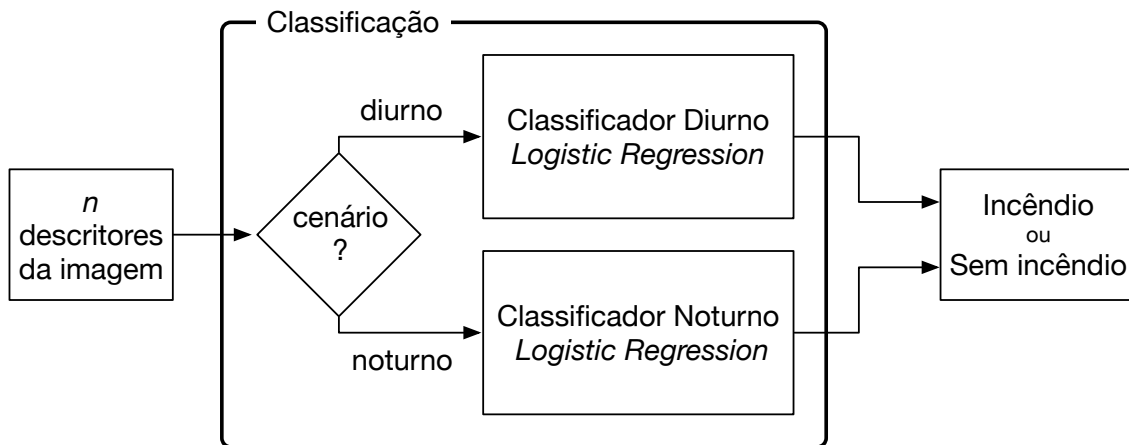


Figura 3.5: Detalhe da arquitetura do módulo de classificação

A distinção entre cenário diurno e noturno pode ser realizada tendo em conta o horário solar.

Quanto ao classificador diurno *Logistic Regression*, este utiliza uma técnica de [ML](#) usada para aprendizagem supervisionada. Como tal, recebe dados de entrada de imagens categorizados tendo em conta a classe a que pertence, e treina o seu próprio modelo de aprendizagem. Após o treino e dado uma imagem sem classe, este deve ser capaz de a classificar corretamente, entre imagem com "Incêndio" ou "Sem Incêndio", tendo em conta que este modelo foi treinado com imagens de situações diurnas.

No classificador noturno *Logistic Regression*, este componente utiliza o mesmo modelo de aprendizagem que o componente referido anteriormente. O que difere são apenas os dados de entrada, neste caso, imagens de situações noturnas.

3.2.4 Estimação da Área das Chamas

A fim de se alcançar uma deteção mais eficiente e ao mesmo tempo reduzir o número de situações de falsos positivos, apenas com a utilização do índice [FFDI](#), é proposto uma abordagem denominada de *Color Algorithm for Flame Exposure (CAFE)* (Alves et al., 2018), que introduz um módulo de pré-processamento, no espaço de cor Lab. Este módulo, no seu geral, pretende estimar a área das chamas visíveis numa imagem. Visto que o módulo de classificação não especifica se detetou incêndio com fumo, com chamas ou com ambos, através deste módulo pode-se resolver essa omissão através das seguintes conclusões: se forem detetadas chamas na imagem, então a imagem é composta por fumo e chamas; se não forem detetadas chamas, então pode-se afirmar que o módulo está perante uma imagem onde o sinal de incêndio é apenas o fumo.

A arquitetura deste módulo é detalhada na figura [3.6](#).




Figura 3.6: Detalhe da arquitetura do módulo de estimativa da área das chamas

Sendo a tonalidade verde a que predomina numa paisagem florestal e os vermelhos num incêndio, decidiu-se aplicar a seguinte regra no componente *Piecewise-Linear Transformation* (PLT): as regiões da imagem que não apresentarem cores entre o laranja e o vermelho, passarão a verde. Deste modo potencia-se a separação entre o grupo de *pixels* relativos à chama dos restantes, como será apresentado em mais detalhe no capítulo seguinte. O componente FFDI envolve a normalização do espaço de cor RGB, o cálculo do índice FFDI e a determinação do valor de *threshold* para aplicar a segmentação (Cruz et al., 2016).

3.3 Conclusão

Neste capítulo foram propostos os cenários de aplicação, os requisitos funcionais, não funcionais e de software, e a arquitetura modular do sistema. A arquitetura do sistema é composta por quatro módulos, um de análise de dados meteorológicos, um de extração de descritores das imagens, outro de classificação e, por fim, um de estimativa da área das chamas.

O módulo de análise de dados meteorológicos, possui a função de obter o risco de incêndio florestal e, com isso, determinar se justifica, ou não, o levantamento do drone. Para além disso, poderá auxiliar na confirmação de um incêndio duvidoso por parte do módulo de classificação.

O módulo de extração de descritores utiliza uma DCNN, enquanto o módulo de classificação de uma imagem, treina um classificador de ML.

No último módulo, o de estimativa da área das chamas, é proposta uma abordagem de deteção das chamas, baseada em técnicas de VC.

Estes últimos três módulos são dependentes em relação ao seu antecessor, ou seja, o resultado (*output*) de um módulo é a entrada (*input*) do módulo seguinte.

Capítulo 4

Implementação

O atual capítulo apresenta detalhadamente o *dataset* criado e descreve a implementação dos módulos constituintes da arquitetura do sistema de forma a atingir os objetivos pretendidos.

O módulo de extração de descritores é responsável pela obtenção das representações numéricas de cada imagem, através de uma [DCNN](#).

De seguida, é retratado o módulo de classificação das imagens, que tem como entrada, os resultados do módulo anterior, e utiliza-os para treinar um classificador de [ML](#).

O último módulo, o de estimação da área das chamas, tem por objetivo aplicar técnicas de [VC](#), com o auxílio da biblioteca OpenCV (Kaehler and Bradski, 2016), versão 3.1.0, de forma a detetar as chamas na imagem e avaliar a dimensão do incêndio.

Todo o sistema é desenvolvido na ferramenta Orange (Demsar et al., 2013), versão 3.13. Esta, é uma ferramenta de código aberto, visualização de dados, [ML](#) e *data mining*. Através dos blocos, designados por *widgets*, com técnicas já implementadas, pode-se combinar e desenhar o fluxo pretendido de forma rápida.

O fluxo geral do sistema é o demonstrado pela figura 4.1.

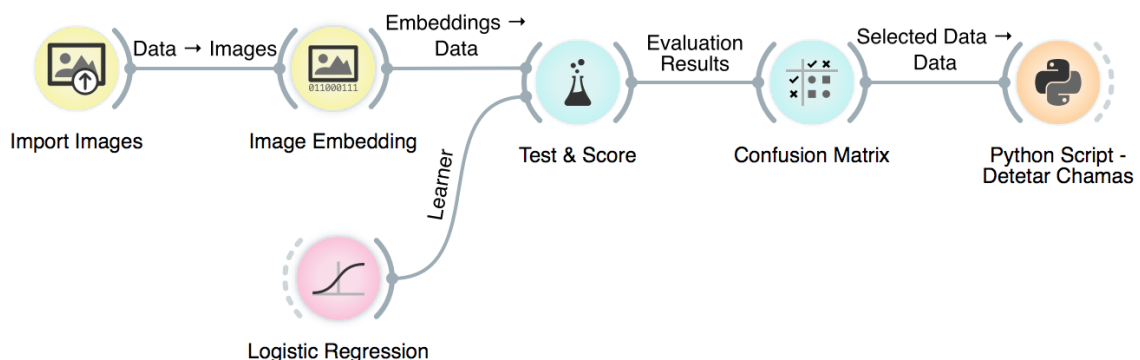


Figura 4.1: Fluxo geral do sistema na ferramenta Orange

4.1 Organização do *dataset*

Antes da implementação do sistema de detecção, é importante do ponto de vista deste trabalho, a obtenção de um conjunto de imagens variadas de forma a retratar da melhor maneira o mundo real, e, com isso, tornar o sistema apto quando colocado perante ambientes reais e em diferentes regiões. Assim, procedeu-se à recolha de imagens na Internet obtendo-se um total de 882 imagens divididas em quatro classes, como mencionado e discriminado na tabela 4.1.

Classes	Nº Imagens
Incêndio	247
Sem Incêndio	448
Incêndio Noturno	101
Sem Incêndio Noturno	86
	882

Tabela 4.1: Composição do conjunto de imagens

Na construção do conjunto de imagens, foram tidos em atenção determinados aspetos de forma a torná-lo o abrangente possível e, com isso, diminuir o número de falsos alarmes por parte do sistema. As imagens são compostas por vários tipos de zonas florestais, cenários diurnos e noturnos, situações análogas, incêndios com várias dimensões e entre outras. De forma a manter rastreio de todas essas variantes, foi criada uma tabela de metadados, que possui todas as características associadas a cada imagem tendo em conta as variáveis da tabela 4.2. A vantagem da utilização destes metadados, é possibilidade de realização de vários testes consoante as características desejadas. Com isto, pode-se verificar, até que ponto, uma determinada característica influencia negativamente no desempenho do classificador.

Variáveis	Valores
Modo	Diurno ; Noturno
Chamas	0 ; 1
Fumo	0 ; 1
Nuvens	0 ; 1
Nevoeiro	0 ; 1
Elementos Humanos	0 ; 1
Superfície Terrestre	0 (outros) ; 1 (floresta)
Cor da Vegetação	0 (outras) ; 1 (verde)
Fases do Incêndio	Sem ; Inicial ; Avançado

Tabela 4.2: Metadados do conjunto de imagens

As imagens possuem maioritariamente, mas não exclusivamente, uma perspectiva aérea e afastada do cenário de interesse. Devido à adoção deste critério de pesquisa, as imagens disponíveis para recolha foram mais restritas. Para além disso, teve-se a preocupação de recolher o maior número possível de imagens com incêndio inicial, tanto para de dia como para de noite, pois o grande propósito é que o sistema seja capaz de detetar pequenas manchas de incêndio, indo de encontro ao requisito URF003. Contudo, a recolha foi um pouco limitada em termo de números, pois a maioria das imagens disponíveis são de incêndios em fase avançada. Assim, teve que se proceder à utilização de imagens com uma área de incêndio maior, dando a origem a três fases de incêndio, como demonstrado pela figura 4.2. Como para já não se tem controlo da aquisição das imagens, não é possível retirar conclusões sobre o relacionamento entre pequeno e grande incêndio. No entanto, quando aplicado numa situação real onde se tem um conhecimento do meio em redor, já é possível obter a dimensão do incêndio tendo em conta a distância entre a câmara e o local em foco. No total, foram obtidas 96 imagens de incêndios com pequenas dimensões e 194 incêndios de grandes dimensões, para cenários diurnos. Relativamente aos cenários noturnos, o número de imagens é mais reduzido em comparação com os cenários diurnos, devido à sua menor disponibilidade na Internet. Em virtude disso, só existem cinco imagens de incêndios com uma área de chama muito reduzida.



Figura 4.2: Ilustração das fases de um incêndio

Muitas das vezes o fumo pode ser visível em conjunto com as chamas, porém nem sempre isso pode acontecer, sendo apenas o fumo o único sinal visível e, por isso, é fulcral possuir um conjunto de imagens que abranja essas variantes. Assim, as variáveis *chamas* e *fumo*, foram usadas na tabela de metadados.

Por outro lado, também é obrigatório treinar o modelo para que este saiba o que não deve classificar como incêndio. Portanto, é importante possuir um bom conjunto de imagens sem incêndio. Para além das características anteriormente referidas, foram consideradas outras duas que não tendo relação com a presença de um incêndio, são semelhantes em termos de aparência, sendo elas o nevoeiro e as nuvens, como comprovado pela figura 4.3. Assim, utilizaram-se imagens sem incêndio, mas com nevoeiro ou com nuvens, no treino do classificador para que estas duas características não se tornem numa fonte de falsos alarmes aquando da sua manifestação.




Figura 4.3: Situações análogas ao fumo

Como os cenários florestais não são exclusivamente constituídos por vegetação, mas também por habitações, fontes de iluminação, veículos, pontes, estradas, e entre outros mais, teve-se a preocupação de recolher imagens com vários elementos humanos com a finalidade de preparar o sistema para o mundo real e perceber até que ponto a sua presença

influencia na tarefa de classificação.

Não sendo a floresta igual em todas as regiões nem em todas as alturas do ano, uma das principais diferenças visuais, é a sua cor. Algumas regiões são caracterizadas por uma vegetação mais esverdeada, enquanto que outras possuem tons mais amarelados, alaranjados ou até avermelhados, como comprovado através da figura 4.4. Por isso, o conjunto de imagens atual, não se restringe apenas a imagens de floresta verde, mas sim nas suas mais variadas cores, de forma a não tornar o sistema operacionalmente limitado a determinadas regiões ou só a uma época do ano.



Figura 4.4: Exemplos de vegetação com diferentes tons de cor

Para além disso, não importa só obter imagens de zonas florestais onde predomina uma grande densidade de árvores, mas também, como por exemplo, campos cultivados caracterizados por uma vegetação menos densa e mais rasteira. Assim, teve-se a preocupação de incluir imagens com diferentes tipos de superfície terrestre.

Nenhuma das imagens utilizadas foi submetida a qualquer pré-processamento, e por isso possuem diversas resoluções.

4.2 Extração de Descritores

4.2.1 Fluxo de informação

Para a implementação do módulo de extração de descritores da imagem, o *pipeline* de fluxo e processamento de dados é o seguinte, como demonstrado pela figura 4.5. É composto por três *widgets*, sendo que o primeiro diz respeito à importação das imagens, o segundo é responsável pela escolha da *DCNN* e por fim, um *widget* auxiliar que permite visualizar os dados recebidos pela *DCNN*. O fluxo apresentado, é igual tanto para cenários diurnos como para cenários noturnos, sendo que a única alteração a realizar é na importação do conjunto de imagens, no primeiro *widget*.

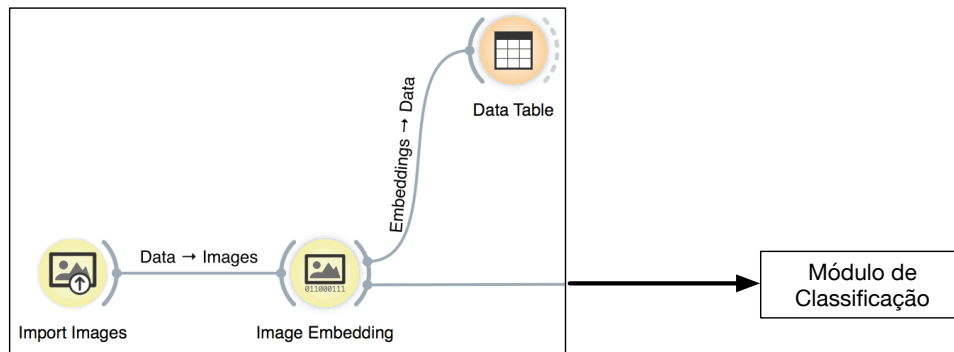


Figura 4.5: Fluxo de informação do módulo de extração de descritores

4.2.2 Inception-V3

A arquitetura do Inception-V3 pode ser dividida em duas partes. A primeira parte é responsável pela extração de descritores, enquanto que a segunda parte é responsável pela classificação desses mesmo descritores. Originalmente, o Inception-V3 foi desenvolvido para classificar 1000 classes de imagens (Szegedy et al., 2016), e por isso a sua arquitetura original já possui integrado um classificador na ultima camada. Contudo, como no atual projeto pretende-se classificar um novo conjunto de imagens em classes para as quais o Inception-V3 não se encontra devidamente treinado, recorreu-se à técnica de *Transfer Learning* (Goodfellow et al., 2016). Ou seja, foi reutilizada a parte de extração de descritores e efetuou-se o treino de um classificador para o novo conjunto de imagens. Visto não ser necessário treinar a parte de extração de descritores (que é a parte mais complexa), conseguiu-se executar a parte de classificação com menos recursos computacionais e tempo de treino. Como não é pretendido utilizar a parte de classificação já embutida e proposta no final Inception-V3, foram testados outros classificadores, no entanto esse tema será abordado na próximo módulo. Por isso, neste módulo apenas interessa a capacidade do Inception-V3 extrair representações numéricas de uma dada imagem. Para obter tais representações, a ferramenta Orange, possui algumas [DCNN](#) que se encontram disponíveis através do *widget Image Embedding*, sendo que a escolhido foi o Inception-V3. As imagens recebidas no *widget Image Embedding* são enviadas para um servidor remoto que já possui o Inception-V3. Na entrada, as imagens são automaticamente redimensionadas para 299x299 (Szegedy et al., 2016), pois o Inception-V3 foi treinado e desenvolvido com imagens dessa resolução. Após isso, são efetuados vários cálculos ao longo da rede até ao momento final em que são obtidos e devolvidos os vetores numéricos representativos de cada imagem. Todo o conjunto de imagens aqui utilizado, de treino e teste, desde imagens diurnas e noturnas, com e sem incêndio, passam por este processo antes de seguirem rumo ao módulo de classificação.

4.2.3 Descritores obtidos

Quando os cálculos estiverem concluídos, o servidor remoto devolve os 2048 descritores ($n_0, n_1, n_2, \dots, n_{2047}$) de cada imagem, juntamente com a categoria e alguns meta atributos. Todas estas informações podem ser visualizadas numa tabela através do *widget Data Table*, como demonstrado pela figura 4.6. Terminado esta parte, pode-se continuar com qualquer método de classificação de ML que o Orange oferece e que será o assunto do próximo módulo.

	category	image name	n0	n1	n2	n3	n4	n5	n6	n7
1	FIRE_NIGHT	FIRE_NIGHT_1	0.662	0.108	0.243	0.095	0.082	0.460	0.150	0.171
2	FIRE_NIGHT	FIRE_NIGHT_10	0.265	0.658	0.225	0.192	0.165	0.247	0.241	0.614
3	FIRE_NIGHT	FIRE_NIGHT_100	0.589	1.752	0.033	0.175	0.660	0.155	0.079	0.639
4	FIRE_NIGHT	FIRE_NIGHT_101	0.165	0.646	0.115	0.426	0.822	0.681	0.093	0.661
5	FIRE_NIGHT	FIRE_NIGHT_102	0.153	0.358	0.049	0.192	0.162	0.129	0.207	0.459
6	FIRE_NIGHT	FIRE_NIGHT_103	0.420	0.693	0.097	0.178	0.297	0.091	0.197	0.859
7	FIRE_NIGHT	FIRE_NIGHT_104	0.321	0.991	0.103	0.246	0.625	0.127	0.027	0.659
8	FIRE_NIGHT	FIRE_NIGHT_105	0.301	0.727	0.182	0.148	0.090	0.162	0.018	0.518
9	FIRE_NIGHT	FIRE_NIGHT_11	0.425	0.583	0.025	0.134	0.143	0.340	0.067	1.027
10	FIRE_NIGHT	FIRE_NIGHT_12	0.486	0.497	0.035	0.107	0.334	0.033	0.098	0.511

Figura 4.6: Exemplo dos n descritores obtidos para cada imagem

4.3 Classificação

4.3.1 Fluxo de informação

Tendo em conta que este módulo é contínuo ao módulo anterior, é igualmente utilizado a ferramenta Orange, neste caso, com *widgets* de ML a fim de treinar um modelo de classificação, um para cenários diurnos e outro para cenários noturnos, indo de encontro ao requisito URNF005. O *pipeline* utilizado é demonstrado pela figura 4.7. É composto por três *widgets*. O *widget Logistic Regression* é o modelo de classificação escolhido, e os restantes dois são referentes ao desempenho do modelo treinado, *Test & Score* e *Confusion Matrix*.

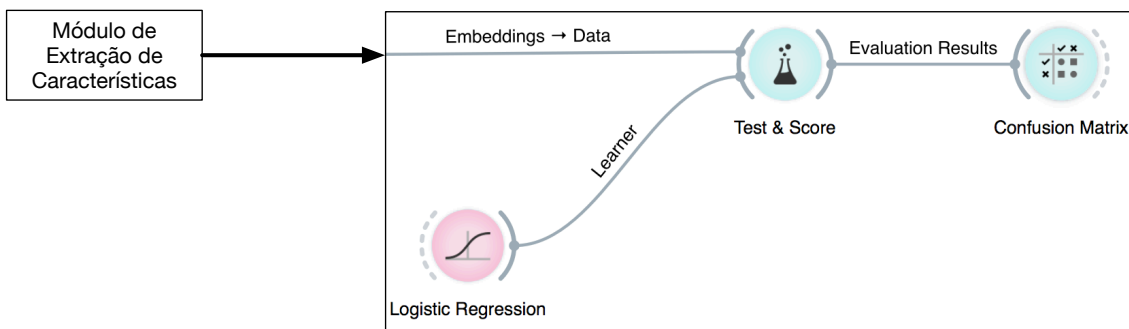


Figura 4.7: Fluxo de informação do módulo de classificação

4.3.2 *Logistic Regression*

Como modelo de **ML** usado para classificação das imagens de incêndio, utilizou-se o **LR**, que se encontra disponível, entre outras tantas, no Orange. Esta parte da implementação do trabalho visa cumprir os requisitos URF001 e URF002. O *widget Logistic Regression* aprende um modelo **LR** a partir dos dados, neste caso, os enviados pelo *widget Image Embedding*. Este *widget* possui dois parâmetros que podem ser alterados pelo utilizador, sendo eles o tipo de regularização e a força da regularização. A regularização pode ser entendida como uma penalização contra a complexidade do modelo e uma forma de combater o *overfitting* dos dados por parte do modelo. Se aumentar a força da regularização, penaliza-se os coeficientes mais pesados. Assim, pretende-se que o modelo não tome demasiada atenção a determinadas peculiaridades e ruídos, *overfitting*, que podem prejudicar a generalização do modelo quando enfrentado por um conjunto de teste. Existem vários tipos de regularização, no entanto são referidos apenas os dois que o Orange disponibiliza. São eles o *Lasso* (função de penalização L1) e *Ridge* (função de penalização L2). De forma a controlar a força da regularização destes dois tipos, existe o parâmetro ajustável *C*. Quanto menor é o valor deste parâmetro, maior é a regularização sobre o modelo. Após vários testes, foi decidido avançar com uma regularização do tipo *Ridge* e uma força de regularização igual a 1.

4.3.3 *Avaliação do modelo de aprendizagem*

Um passo importante ao trabalhar com técnicas de **ML** é verificar o desempenho do modelo de aprendizagem. Através do *widget Test & Score* podem-se encontrar vários procedimentos de avaliação. Um deles é o *Cross Validation (CV)*, mais utilizado quando o conjunto de dados é limitado. Para além disso, é mais uma das boas formas de estar atento e combater o *overfitting* do modelo em relação aos dados (Chicco, 2017).

O modo (Kohavi, 1995) como este método opera é através da divisão dos dados num determinado número de *k folds*. Iterativamente, o algoritmo é treinado em *k-1 folds* enquanto que o restante *fold* é utilizado para teste. No final, o cálculo da precisão é o número de classificações corretas dividido pelo número de instâncias no conjunto de dados. Um *k* baixo é mais barato, possui mais variação e diminui o *bias*, enquanto que um *k* maior é mais caro, possui menos variação e aumenta o *bias* (Kohavi, 1995). Com o método **CV**, pode-se ajustar os parâmetros do modelo e melhorar o seu desempenho usando todo o conjunto de imagens disponível. Assim, para o treino e avaliação dos dois modelos, um para dia e outro para noite, decidiu-se que o número *folds* será igual a 10, ativando a opção *Stratified*, que assegura que os *folds* são *stratified*, ou seja, contêm aproximadamente as mesmas proporções de classes que o conjunto de imagens original (Kohavi, 1995).

4.4 Estimação da Área das Chamas

4.4.1 Processo de detecção

A fim de se alcançar uma detecção mais eficiente e reduzir o número de situações análogas detetadas como possíveis regiões de incêndio apenas com a utilização do índice **FFDI**, é proposta uma abordagem, denominada de **CAFE**, que introduz um módulo de pré-processamento. Com isto, pretende-se que seja possível estimar a áreas das chamas, como declarado no requisito URF004.

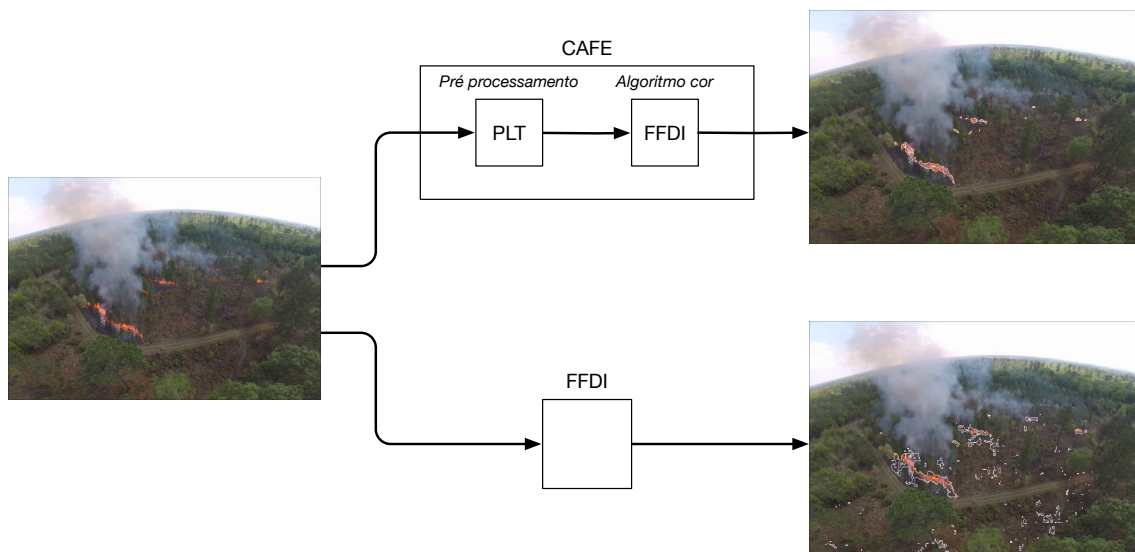


Figura 4.8: Detalhe da arquitetura do módulo de análise de dados meteorológicos

4.4.2 Bloco **PLT**

Sendo a tonalidade verde a que predomina em paisagem de floresta e os vermelhos num incêndio, decidiu-se aplicar a seguinte regra: as regiões da imagem que não possuírem uma cor que pertença às cores do laranja ao vermelho, passarão a verde. Deste modo potencia-se a separação entre o grupo de *pixels* das chamas dos restantes *pixels*. No componente de pré-processamento, o processo de transformação pode ser descrito nos seguintes passos:

1. Aquisição (frame de vídeos ou imagem fixa).
2. Converter a imagem de RGB para Lab.
3. Aplicar-lhe uma transformação *piecewise-linear* no canal *a* do espaço de cor Lab.
4. Converter a imagem de Lab para RGB.

Como acima mencionado, foi utilizado o espaço de cor Lab com a finalidade de aplicar a transformação **PLT**. O Lab é composto por três canais sendo eles o canal L , a e b , como demonstrado pela figura 4.9. O canal L representa a luminosidade, que varia entre o preto (0) e o branco (100). O canal a representa a gama de cores desde o verde até ao vermelho (-128 até ao 128). Por fim, o canal b , representa cores desde o azul até ao amarelo (-128 até ao 128). Por vezes os valores de a e b são representados como *unsigned* 8 bits, sendo somado 128 à gama apresentada. O espaço de cor Lab pode ser observado a seguir, através da figura 4.9.




Figura 4.9: Espaço de cor Lab

Tendo em conta a transformação proposta, o canal a é o mais indicado para a aplicar devido à representação num só canal da gama que vai do verde ao vermelho.

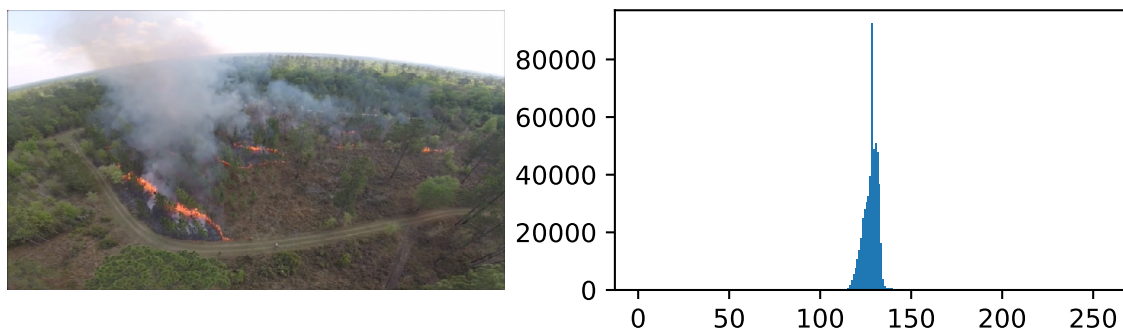


Figura 4.10: Histograma do canal a

Tipicamente, em cenários mistos envolvendo floresta, a distribuição das duas cores

no canal a não é claramente bimodal como seria desejável. A gama dos vermelhos não se encontra distintamente separada da gama dos verdes, como se pode comprovar pela figura 4.10. O histograma varia entre 0 e 255, sendo o 128 a fronteira entre o verde e o vermelho.




Figura 4.11: Gráfico da transformação **PLT** no canal a

Assim, empiricamente, determinou-se um limite de $\delta = 16$, que permite separar as cores representativas de um incêndio (laranja e vermelho) daquelas que não o representam. Com isto, todos os *pixels* cujo o valor de a pertence ao intervalo de $[-\delta, +\delta]$ passarão agora a ter um $a = -\delta$ (gama de verdes), enquanto os restantes permanecerão inalterados. Para cada *pixel* no canal a , aplica-se a seguinte regra de transformação que se encontra representada, graficamente, na figura 4.11:

$$\mathbf{if } a \subseteq [-\delta, +\delta] \mathbf{ then } a = -\delta$$

Nas figuras 4.12 e 4.12 pode-se observar o efeito da transformação descrita num cenário de incêndio com vastas regiões da imagem compostas por solo com pouca ou nenhuma vegetação. Após a transformação, essas regiões da imagem tornam-se esverdeadas.



Figura 4.12: Antes da aplicação do [PLT](#)



Figura 4.13: Após aplicação do [PLT](#)

Tendo em conta que a próxima etapa é a aplicação do índice [FFDI](#), e visto que o seu objetivo é a subtração do verde da floresta em relação vermelho da chama, a inclusão deste pré-processamento é um contributo determinante na obtenção de um melhor resultado no final.

4.4.3 Bloco [FFDI](#)

Perante cenários diurnos, o bloco final, [FFDI](#), envolve a normalização do espaço de cor RGB, o cálculo do índice [FFDI](#) e a determinação do valor de *threshold* para aplicar a segmentação, como descrito em (Cruz et al., 2016). Relativamente aos cenários noturnos, foram efetuadas algumas alterações de forma a adequar este bloco para funcionar perante tal cenário. Assim, decidiu-se não aplicar a normalização do espaço de cor RGB, tendo em conta que de noite não existe a necessidade de obter uma maior robustez das cores. Outra alteração aplicada, foi a utilização da operação morfológica *opening*, com

um *kernel* de 3x3 de forma a eliminar pequenos ruídos detetados na imagem. O valor do parâmetro ρ , usado no cálculo do índice **FFDI**, tem um papel importante na deteção. Ele irá condicionar se irá ser detetada apenas a chama ou, a chama em conjunto com o fumo. Como neste trabalho o objetivo é detetar a chama, o valor de ρ usado, é limitado à gama de valores entre 0 e 1. Para $\rho = 0$, não existe ênfase das cores vermelhas e azuis, apenas o verde é subtraído. Para $0 < \rho \leq 1$, à medida que se aumenta o valor de ρ , existe uma ênfase cada vez maior das cores vermelhas e das tonalidades alaranjadas em seu redor.

4.5 Conclusão

No presente capítulo foi esclarecido ao pormenor o conjunto de imagens utilizado assim como os seus metadados. Para os cenários diurnos, o número de imagens recolhidas foi maior do que para os cenários noturnos, limitações incontornáveis nesta fase inicial do desenvolvimento do sistema. Contudo, após colocado em prática no mundo real, visiona-se utilizar as imagens recolhidas para melhorar o treino dos modelos **LR**, como pretendido no requisito URF006. Quanto às características associadas a cada imagem, constata-se que, em cenários diurnos, existem diversas situações a ter em atenção, como casas, carros, cor da vegetação, nevoeiro, nuvens e entre outros. Por outro lado, em cenários noturnos, não se sente tanto esse problema pois a ausência de luz solar omite muitas das situações anteriormente identificadas. Assim, apenas os objetos que possuam iluminação própria ou sejam incididos por tal, são considerados possíveis fontes de falso alarme e, por isso, é necessário ter consideração tais situações.

Relativamente à implementação do sistema, foi descrito detalhadamente como cada módulo é implementado na ferramenta Orange. As técnicas implementadas no sistema, não apresentaram restrições à utilização de câmaras móveis e estáticas na obtenção das imagens, como pretendido no requisito URNF004.

Capítulo 5

Testes e avaliação

No seguinte capítulo é, primeiramente, analisado o comportamento do sistema para cada situação que poderá deparar-se no seu cenário de aplicação. De seguida, é analisado cada módulo individualmente.

Para o módulo de extração de características, a questão pertinente é justificar a escolha da [DCNN](#) a utilizar.

No que diz respeito ao módulo de classificação, são apresentados testes que justificam as escolhas tomadas, o modelo de classificação e quais as classes de classificação. Para além disso, são efetuadas duas avaliações distintas. Por um lado pretende-se analisar o desempenho do modelo de classificação quando treinado com todo o conjunto de imagens. Por outro, como um dos contributos deste trabalho é a construção de um *dataset* organizado e constituído por características pertinentes, é realizada uma segunda avaliação acerca da influência de cada característica na tarefa de classificação.

Por último, o módulo de estimação da área das chamadas é sujeito a testes diurnos e noturnos, perante situações diferentes, com a finalidade de avaliar a sua capacidade de detetar chamadas, mesmo perante eventuais situações análogas.

5.1 Análise do comportamento do sistema no cenário de aplicação

Tendo em conta o cenário de aplicação e as três diferentes situações identificadas, ambas descritas no Capítulo 2, é feita uma análise para cada situação. Pretende-se averiguar, como o sistema se comporta, e dar a entender melhor, os resultados obtidos ao longo dos módulos para cada uma das três situações. Para tal, é realizado um teste por cada situação.

5.1.1 Situação nº1: Não é identificado incêndio

Na maioria das vezes, o sistema irá deparar-se com este tipo de situação, onde não existe qualquer incêndio. Assim, ao sistema chegará uma imagem, como por exemplo, uma situação de floresta com algumas casas inseridas no seu meio. O primeiro módulo a tratar desta imagem, é o de extração de descritores, onde o Inception-V3, para a dada imagem, cria um vetor de números, representativos das características dessa mesma imagem. Os valores obtidos, são passados ao módulo de classificação, já previamente treinado, onde o modelo LR classifica-os como provenientes de uma imagem sem incêndio. Como o sistema está perante uma situação sem incêndio, o fluxo desta imagem no sistema termina aqui, e é obtida uma nova imagem para análise. O fluxo para este exemplo de imagem, sem incêndio, anteriormente descrito, é apresentado na figura 5.1.




Figura 5.1: Fluxo da informação para o situação nº1

5.1.2 Situação nº2: É identificado incêndio mas não são detetadas chamas

Tendo como exemplo, uma situação de fumo inicial, o módulo de extração de descritores produz um vetor de números tendo em conta a imagem recebida. O módulo de classificação recebe o vetor e classifica-o como pertencente a uma imagem com incêndio. Como o classificador não revela informações acerca da presença de fumo ou chamas na imagem, esta, é enviada para o próximo e último módulo. A imagem em questão, só possui fumo e, por isso, a abordagem CAFE no módulo de estimação da área das chamas, não deteta chamas. Assim, pode-se assumir que o incêndio foi detetado somente devido à presença de fumo inicial. As próximas imagens, muito provavelmente, continuarão a ser classificadas como incêndio, caso o foco da câmara se mantenha no incêndio em questão. O fluxo para este exemplo de imagem, com incêndio inicial, anteriormente descrito, é apresentado na figura 5.2.

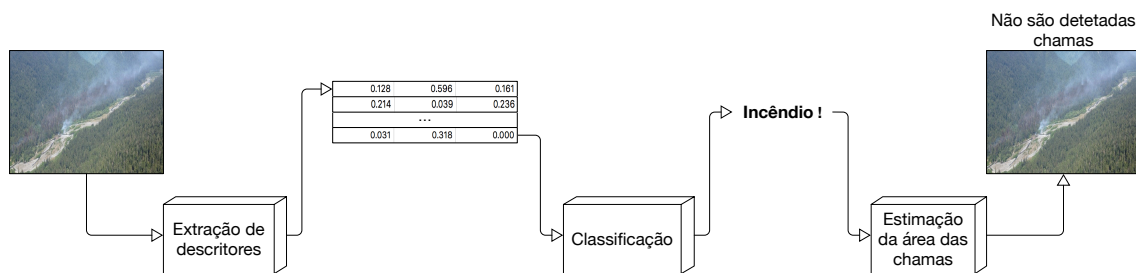


Figura 5.2: Fluxo da informação para o situação nº2

5.1.3 Situação nº3: É identificado incêndio e são detetadas chamas

Para esta última situação, tem-se como exemplo, um caso de incêndio já com algum desenvolvimento, dado que as chamas são bastante evidentes assim como o seu fumo. A imagem é analisada pelo Inception-V3, onde daí resulta um vetor de números que é enviado para o módulo de classificação. A imagem, como aconteceu na situação nº2, é classificada como contendo incêndio. Tendo em conta que possui características de incêndio facilmente reconhecíveis, o modelo de classificação não tem qualquer problema em a classificar corretamente. Por último, a imagem é passada ao próximo módulo, onde são detetadas e assinaladas as regiões das chamas na imagem. O fluxo para este exemplo de imagem, com chamas e fumo, anteriormente descrito, é apresentado na figura 5.3.

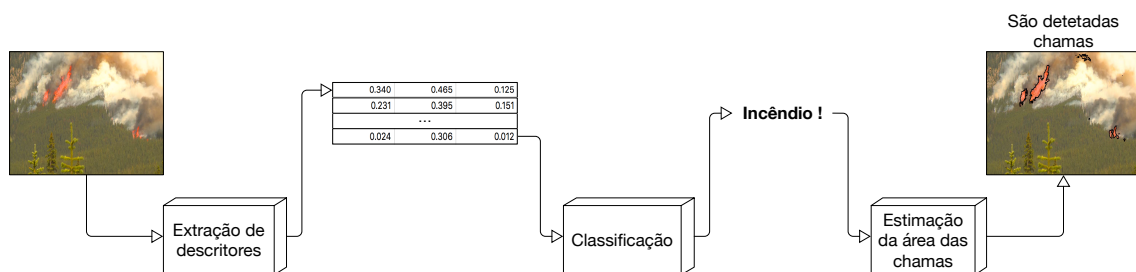


Figura 5.3: Fluxo da informação para a situação nº3

5.2 Seleção do modelo de Extração de Descritores

De forma a auxiliar na escolha de uma **DCNN**, são apresentadas na tabela 5.1, as características da **DCNN** Inception-V3 (Szegedy et al., 2016), Resnet50 (He et al., 2016), VGG16 (Liu and Deng, 2015), GoogLeNet (Szegedy et al., 2015) e AlexNet (Krizhevsky et al., 2012).

DCNN	<i>Top-1 accuracy</i>	<i>Top-5 error</i>	Parâmetros
Inception-V3	78%	3.5%	24M
Resnet50	76%	6.71%	25M
VGG16	71%	7.3%	138M
GoogLeNet	68%	6.67%	5M
AlexNet	54%	15.3%	60M

Tabela 5.1: Comparação entre modelos DCNN (Canziani et al., 2016)

Os resultados da tabela 5.1 entram em concordância com os obtidos na tabela 2.2, confirmando o modelo Inception-V3 como o melhor em termos de *Top-1 accuracy* e *Top-5 error*, em comparação com os outros modelos abordados. Relativamente ao número de parâmetros de cada DCNN, o melhor resultado vai para a GoogLeNet, a versão inicial e anterior ao InceptionV3. Tendo em conta os ótimos resultados obtidos pelo Inception-V3, este, é utilizado como modelo DCNN no atual projeto.

5.3 Classificação

5.3.1 Comparação dos modelos de classificação

O Orange oferece variadas técnicas de aprendizagem supervisionadas. De forma a perceber qual o melhor modelo de classificação para o problema da detecção de incêndios florestais, tendo em conta o conjunto de imagens para cenários diurnos, foi analisado o desempenho de vários classificadores através do método CV. Todos os algoritmos testados possuíam as configurações por defeito oferecidas no Orange.

Method	AUC	CA	F1	Precision ▼	Recall
Logistic Regression	0.980	0.941	0.941	0.941	0.941
SVM	0.970	0.922	0.921	0.924	0.922
kNN	0.963	0.921	0.921	0.922	0.921
Neural Network	0.969	0.908	0.908	0.907	0.908
Random Forest	0.938	0.906	0.906	0.906	0.906
Naive Bayes	0.912	0.904	0.904	0.904	0.904
Tree	0.808	0.865	0.864	0.864	0.865

Figura 5.4: Comparação entre vários modelos de classificação

Como demonstrado pela figura 5.4, o modelo com maior precisão de treino, tendo em conta o conjunto de imagens utilizado, é o LR, sendo esta a razão para a sua escolha no atual projeto.

5.3.2 Escolha das classes de classificação

O conjunto de imagens foi inicialmente recolhido e desenvolvido tendo em conta quatro classes, como demonstrado pela tabela 4.1. No entanto, foi necessário averiguar quantos classificadores se deveria utilizar e quais as classes associadas no processo de treino do conjunto de imagens. Assim, identificaram-se quatro exemplos de classificação e procedeu-se ao treino dos mesmos tendo em conta o conjunto de treino. O treino e posterior avaliação do desempenho do modelo são realizados através do método CV.

- Um classificador diurno com duas classes: Com Incêndio; Sem Incêndio.

Os resultados demonstraram uma precisão de 94.1%.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	221	26	247
	Sem Incêndio	15	433	448
Σ		236	459	695

Figura 5.5: Matriz de confusão do classificador diurno com duas classes

- Um classificador noturno com duas classes: Com Incêndio; Sem Incêndio.

Os resultados demonstraram uma precisão de 94.8%.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	94	7	101
	Sem Incêndio	3	83	86
Σ		97	90	187

Figura 5.6: Matriz de confusão do classificador noturno com duas classes

- Um classificador diurno com três classes: Sem Incêndio; Incêndio Inicial; Incêndio Avançado.

Com auxílio dos metadados, juntamente com algumas funcionalidades do Orange, procedeu-se à divisão do conjunto de imagens diurno em três novas classes, tendo em conta a variável *Fases do Incêndio*. Os resultados demonstraram uma precisão de 83.6%.

		Predicted			Σ
		Avançado	Inicial	Sem	
Actual	Avançado	126	20	10	156
	Inicial	29	32	30	91
	Sem	5	9	434	448
Σ		160	61	474	695

Figura 5.7: Matriz de confusão do classificador diurno com três classes

- Um classificador com quatro classes: Com Incêndio Diurno; Sem Incêndio Diurno; Com Incêndio Noturno; Sem Incêndio Noturno

Os resultados demonstraram uma precisão de 91.8%.

		Predicted				Σ
		1-Incêndio	1-Sem Incêndio	2-Incêndio Noite	2-Sem Incêndio Noite	
Actual	1-Incêndio	216	26	4	1	247
	1-Sem Incêndio	16	429	0	3	448
	2-Incêndio Noite	5	3	90	3	101
	2-Sem Incêndio Noite	0	7	4	75	86
Σ		237	465	98	82	882

Figura 5.8: Matriz de confusão do classificador com quatro classes

Tendo em conta os quatro treinos efetuados, comprova-se que a melhor forma de organizar e treinar o conjunto de imagens, é através do uso de dois classificadores binários, um para cenários diurnos e outro para cenários noturnos.

5.3.3 Desempenho dos modelos treinados com todo o conjunto de imagens

Com a finalidade de avaliar os modelos de classificação, diurno e noturno, quando treinado todo o conjunto de imagens, recorreu-se ao método CV. Através das figuras 5.9 e 5.11 é possível verificar o desempenho do modelo treinado para cenários diurnos e noturnos. As respetivas matrizes de custo podem ser visualizadas através das figuras 5.10 e 5.12.

Method	AUC	CA	F1	Precision	Recall
Logistic Regression	0.980	0.941	0.941	0.941	0.941

Cross validation
 Number of folds: 10
 Stratified

Figura 5.9: Desempenho do modelo em cenários diurnos

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	221	26	247
	Sem Incêndio	15	433	448
Σ		236	459	695

Figura 5.10: Matriz de confusão do modelo em cenários diurnos

Method	AUC	CA	F1	Precision	Recall
Logistic Regression	0.991	0.947	0.947	0.948	0.947

Cross validation
 Number of folds: 10
 Stratified

Figura 5.11: Desempenho do modelo em cenários noturnos

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	94	7	101
	Sem Incêndio	3	83	86
Σ		97	90	187

Figura 5.12: Matriz de confusão do modelo em cenários noturnos

Em ambos os modelos, diurno e noturno, o treino resultou numa precisão a rondar os 94%. Tendo em conta a dimensão do conjunto de imagens, os resultados obtidos são promissores e já demonstram a capacidade de o modelo conseguir distinguir situações de incêndio.

5.3.4 Análise da influência das características das imagens no processo de classificação

A próxima sub-secção tem por objetivo analisar as características presentes nas imagens e verificar, quais delas, criam maior dificuldade no processo de classificação do modelo. Como tal, é realizado um teste para cada um dos metadados representados na tabela 4.2. O processo passa por separar em 70/30 as imagens constituídas por uma determinada característica. Por exemplo, 70% das imagens com nevoeiro, são separadas para treino enquanto que os restantes 30% são para fins de teste. Assim, 70% dessas imagens mais as restantes do *dataset* são utilizadas no treino do modelo. No final, os 30% das imagens colocados de parte, são usados para testar o desempenho do modelo perante essa característica.

- Nevoeiro

Alguns fenómenos naturais podem-se confundir como fumo e por isso podem induzir o modelo de classificação em erro. Um desses casos, é o nevoeiro pois possui algum grau de semelhança tanto em termos de cor como de forma. No atual conjunto de imagens, as imagens com nevoeiro encontram-se todas na categoria de imagens sem incêndio, visto que dificilmente se encontram imagens com incêndio juntamente com nevoeiro. Verifica-se através matriz de confusão 5.13, que a presença de nevoeiro é um fator de indecisão para o modelo, levando a caracterizar sete imagens com nevoeiro como sendo incêndio. Perante os resultados obtido, é necessário um treino mais aprofundado através da utilização de mais imagens com nevoeiro a fim de este não cair no erro de detetar nevoeiro como sendo fumo.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	0	0	0
	Sem Incêndio	7	28	35
Σ		7	28	35

Figura 5.13: Matriz de confusão do teste realizado perante situações com nevoeiro

- Nuvens

A existência de nuvens é outro fenómeno natural caracterizado pela semelhança com o fumo, tanto a nível de cor como de forma. Constata-se através da matriz de confusão 5.14, que a maioria das imagens de teste foram detetadas corretamente. Apenas existem duas situações de *False Positive* e apenas uma de *False Negative*. Estes resultados veem demonstrar que a presença de nuvens não cria grandes problemas na tarefa de classificação do modelo e, por isso, não necessita de um conjunto de treino muito extenso a nível de imagens com nuvens.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	14	1	15
	Sem Incêndio	2	34	36
Σ		16	35	51

Figura 5.14: Matriz de confusão do teste realizado perante situações com nuvens

- Elementos humanos

Em muitas situações, o sistema não se irá deparar apenas com cenários naturais, mas sim com casas, com estradas, com veículos e entre outros mais, e portanto é necessário ter uma noção da influência da presença destes elementos humanos no desempenho do modelo. Tendo em conta a matriz de confusão 5.15, verifica-se que a grande maioria das imagens de teste foram detetadas corretamente, à exceção de três, dando origem a duas situações de *False Negative* e uma de *False Positive*. Com este bom desempenho, verifica-se que a presença de elementos humanos não é um fator de muita indecisão. É de salientar que o conjunto de treino não envolve todas

as situações com elementos humanos, no entanto já permite ter a noção da pouca influência destes elementos na tarefa de classificação.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	23	2	25
	Sem Incêndio	1	58	59
Σ		24	60	84

Figura 5.15: Matriz de confusão do teste realizado perante situações com elementos humanos

- Zonas de campo

Como neste trabalho não se procura ter em atenção apenas zonas florestais, também foi criada uma variável na tabela dos metadados denominada de superfície terrestre, cujo objetivo é permitir a distinção entre situações constituídas por pura floresta e situações sem muita densidade de árvores, nomeadamente terrenos de cultivo, zonas de pasto, zonas de relva e por aí além. A matriz de confusão 5.16, demonstra que as 64 imagens usadas como teste foram classificadas corretamente na sua maioria, com maior expressão nas 43 situações de *True Negative*. Somente duas imagens foram detetadas erradamente, sendo um *False Positive* e um *False Negative*. Assim, verifica-se presença de zonas sem floresta não demonstra uma grande influência negativa no desempenho do modelo.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	19	1	20
	Sem Incêndio	1	43	44
Σ		20	44	64

Figura 5.16: Matriz de confusão do teste realizado perante situações sem floresta

- Vegetação com tons variados

Como não se pretende que o modelo se limite apenas a reconhecer vegetação com tons verdes, também são utilizadas zonas de vegetação com vários tons. Portanto, é

importante verificar o desempenho do modelo, perante situações de vegetação com vários tons, com especial atenção para aquelas mais avermelhadas ou alaranjadas, devido à semelhança com as cores das chamas. Verifica-se através da matriz de confusão 5.17, que existe um bom desempenho do modelo ao só detetar erradamente uma imagem. Tendo em conta que as 32 imagens classificadas corretamente como sem incêndio, são bastante variadas em termos de cor e situações, pode-se assumir que existe já um grande desempenho do modelo perante este tipo de situações.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	27	1	28
	Sem Incêndio	0	32	32
Σ		27	33	60

Figura 5.17: Matriz de confusão do teste realizado perante vegetação com vários tons de cor

- Incêndio inicial

Por fim, procura-se perceber a importância do uso de imagens com incêndio inicial e avançado no treino do modelo. O primeiro teste diz respeito a incêndios com uma área reduzida na imagem. Através da matriz de confusão 5.18, constata-se que o modelo não conseguiu detetar corretamente nove imagens de incêndio inicial, algumas demonstradas na figura 5.20. A maioria destas imagens são bastantes desafiadores, devido às dimensões reduzidas que o fumo apresenta na imagem. Por outro lado, é importante valorizar o facto de o modelo conseguir detetar corretamente casos de incêndio inicial, como se pode verificar através da figura 5.19. Os resultados obtidos veem justificar uma maior necessidade do uso de mais situações de incêndio inicial no processo de treino, a fim de o modelo conseguir classificar tais situações corretamente.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	19	9	28
	Sem Incêndio	0	0	0
Σ		19	9	28

Figura 5.18: Matriz de confusão do teste realizado perante pequenas manchas de incêndio



Figura 5.19: Situações de TP da matriz de confusão 5.18



Figura 5.20: Situações de FN da matriz de confusão 5.18

- Incêndio avançado

O próximo teste passa pela análise do desempenho do modelo perante incêndios em grande plano na imagem. A matriz de confusão 5.21, revela que 45 das situações de incêndio, foram detetadas corretamente. Na figura 5.22, podem-se visualizar algumas das situações de *True Positive*. Os dois casos de *False Negative* encontram-se ilustrados na figura 5.23. O resultado obtido, comprova a melhor aptidão do modelo para classificações tais situações, em comparação com incêndios iniciais. Tal facto, deve-se às características bastante notórias e facilmente reconhecíveis.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	45	2	47
	Sem Incêndio	0	0	0
Σ		45	2	47

Figura 5.21: Matriz de confusão do teste realizado perante grandes manchas de incêndio



Figura 5.22: Situações de TP da matriz de confusão 5.21



Figura 5.23: Situações de FN da matriz de confusão 5.21

- Elementos humanos (cenários noturnos)

Nos cenários noturnos não foram utilizadas tantas variáveis como nos cenários diurnos, já que o grande problema é, maioritariamente, a presença de luzes artificiais, pois tudo o que não possui luz ou é incidido por tal, não é visível através

das câmaras de vídeo. Através da análise da matriz de confusão 5.24, verifica-se que das 15 imagens com incêndio, apenas uma não foi detetada corretamente. Embora o conjunto de treino e de teste sejam pequenos, pode-se concluir que as luzes artificiais, nomeadamente aquelas com tons alaranjados, são a grande fonte de falsos alarmes. Tal afirmação, é justificada pelo facto de as luzes artificiais serem a única causa das quatro situações de *False Positive*, como demonstrado pela figura 5.25. Assim, é necessário possuir um maior conjunto de imagens constituído por situações com luzes artificiais, com a finalidade de treinar melhor o modelo para não classificar tais situações como incêndio.

		Predicted		Σ
		Incêndio	Sem Incêndio	
Actual	Incêndio	14	1	15
	Sem Incêndio	4	14	18
Σ		18	15	33

Figura 5.24: Matriz de confusão do teste realizado perante situações noturnas com elementos humanos




Figura 5.25: Situações de FP da matriz de confusão 5.24

5.4 Estimação da Área das Chamas

5.4.1 Cenários Diurnos

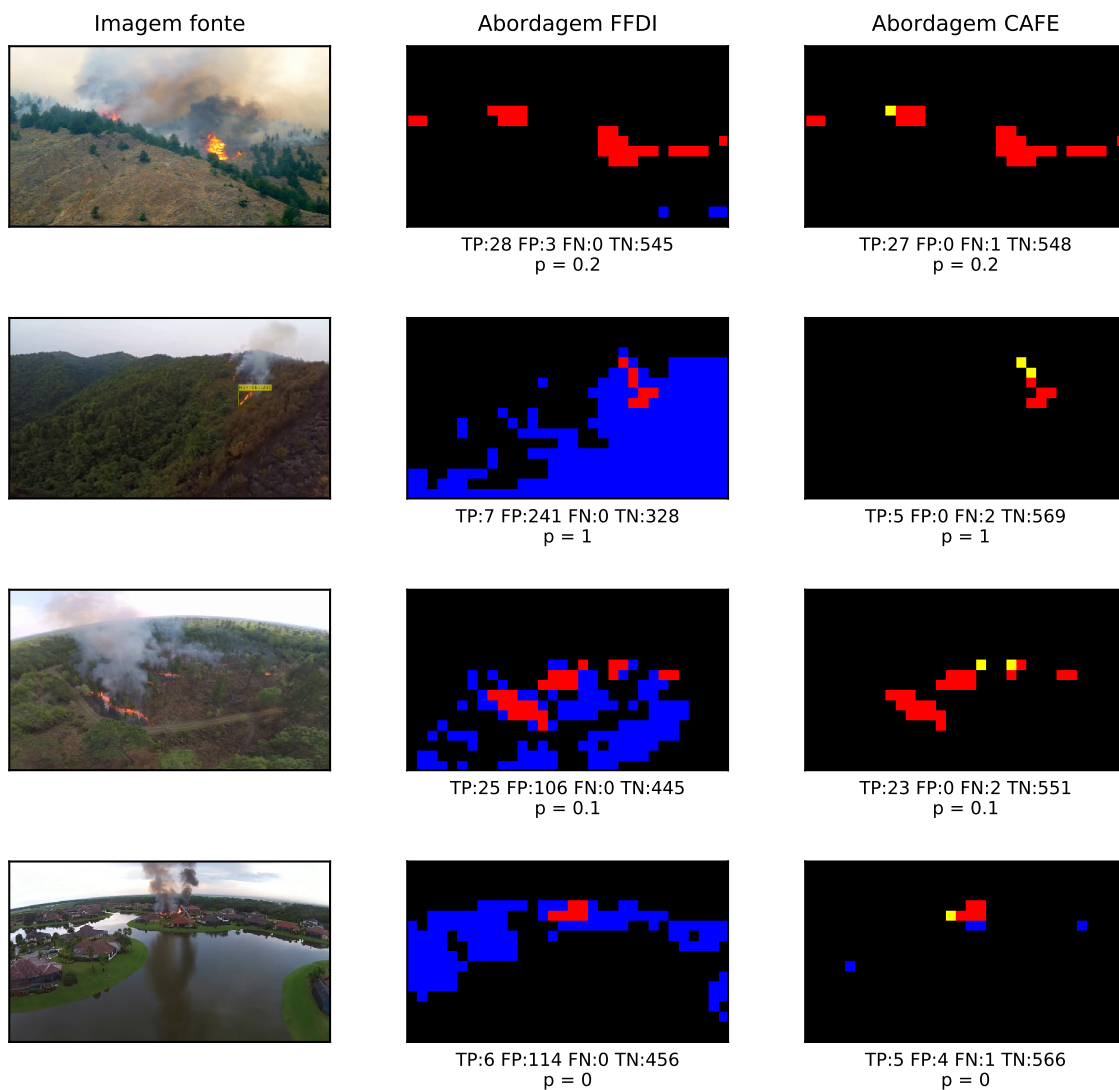


Figura 5.26: Quantificação dos resultados obtidos





	TP - <i>True Positive</i>
	FP - <i>False Positive</i>
	FN - <i>False Negative</i>
	TN - <i>True Negative</i>

Tabela 5.2: Legenda das cores utilizadas na quantificação

Os testes realizados pretendem comparar a solução **CAFE**, isto é, do componente **PLT**, seguida da aplicação bloco **FFDI** (abordagem **CAFE**), versus a utilização apenas de **FFDI** (abordagem **FFDI**), conforme atesta a figura 4.8. Foram utilizadas apenas imagens aéreas de incêndios em cenários com características distintas. As imagens obtidas, todas com resolução de 960x540, são provenientes de quatro cenários com características diferentes o que permite avaliar a abordagem **CAFE** perante diferentes situações.

A tabela 5.3 demonstra as quatro características próprias de cada cenário.

A	Pouca vegetação, zona rochosa
B	Vegetação ardida
C	Superfície seca e acastanhado
D	Zona habitacional

Tabela 5.3: Características dos cenários diurnos considerados

A metodologia de avaliação adotada, repetida para cada imagem de teste i , consiste nos seguintes passos:

1. Aplicar a grelha de blocos 30x30 e obter três imagens:
 - 1.1. Imagem original: Fonte[i].
 - 1.2. Imagem com a abordagem **FFDI**[i].
 - 1.3. Imagem com a abordagem **CAFE**[i].
2. Para cada bloco da imagem original, Fonte[i], anotar manualmente se o bloco contém incêndio (positivo) ou não (negativo). Este *ground truth* será a referência tida como verdadeira na avaliação.
3. Considerar uma matriz de confusão, 2x2, com as seguintes células: TP, FP, FN, TN.
4. Preencher a matriz de confusão respeitante a:
 - 4.1. Imagem com abordagem **FFDI**[i]. Contabilizar TP, FP, FN, TN com base em Fonte[i].
 - 4.2. Imagem com abordagem **CAFE**[i]. Contabilizar TP, FP, FN, TN com base em Fonte[i].

Os resultados obtidos e comprovados através da figura 5.26, demonstram que a utilização da abordagem **CAFE** reduz o número de *False Positive* detetados em cada cenário.

O cenário A é caracterizado por uma superfície com pouca ou nenhuma vegetação em certas zonas (observadas em primeiro plano). Ambas as abordagens possuem excelentes

resultados no que se refere a detetar a zona de incêndio. Comparativamente com a abordagem **FFDI**, a abordagem **CAFE** não detetou um dos blocos *True Positive*, mas superou esta não tendo nenhum *False Positive*.

No cenário B, encontra-se uma floresta dividida em duas zonas distintas. Uma zona anteriormente queimada que se encontra no canto inferior direito e uma outra zona, não queimada, com vegetação verde. A abordagem **FFDI**, deteta a zona queimada como uma possível zona de incêndio. Com a abordagem **CAFE**, essa mesma zona já não é detetada, limitando-se assim a detetar apenas a zona de chama. A abordagem **CAFE** possui dois blocos de incêndio não detetados, localizados nas extremidades da região com chama. Porém, estas zonas de incêndio seriam detetadas utilizando futuras imagens, quando a região da chama atingisse uma maior dimensão nesses blocos.

O cenário C é uma zona da floresta com alguma vegetação o que leva a observar a superfície do terreno seca e acastanhada que se encontra na zona central da imagem. Este tom acastanhado do terreno leva a abordagem **FFDI** a detetar algumas partes do terreno como zonas de incêndio. Porém, consegue detetar com eficácia toda a zona de incêndio. A abordagem **CAFE** deteta apenas as zonas com chamas, no entanto, não consegue detetar dois blocos que contêm chamas quase impercetíveis.

Como uma floresta não é só constituída por vegetação, mas também por aldeias embutidas no meio de florestas, o cenário D tem o propósito de avaliar as abordagens acerca da existência de casas devido ao facto de os seus telhados poderem possuir cores alaranjadas ou avermelhadas. A abordagem **FFDI** deteta toda a área de chama mais todos os telhados das casas o que não é desejável. Por outro lado, a abordagem **CAFE** reduz substancialmente o número de telhados detetados confinando-se apenas à deteção de três telhados de casas. Consegue detetar todos os blocos com chamas exceto um bloco cujo a chama possui dimensões muito pequenas e a sua cor possui tons de amarelo muito claro.

	Área chama IMG fonte	TP FFDI	TP CAFE	FP FFDI	FP CAFE
A	28	28	27	3	0
B	7	7	5	241	0
C	25	25	23	106	0
D	6	6	5	114	4

Tabela 5.4: Resultados diurnos TP e FP das abordagens **FFDI** e **CAFE**

Na tabela 5.4, verifica-se que, nos cenários apresentados, obtiveram-se resultados semelhantes quantos aos *True Positive* identificados, contudo regista-se uma diferença notória no número de *False Positive* detetados. Deste modo conseguiu-se melhorar o mecanismo de deteção e as respetivas regiões afetadas pelo incêndio.

O parâmetro ρ utilizado variou de modo a melhor se adaptar à abordagem **FFDI**, como se pode comprovar através da figura 5.27 e 5.28.

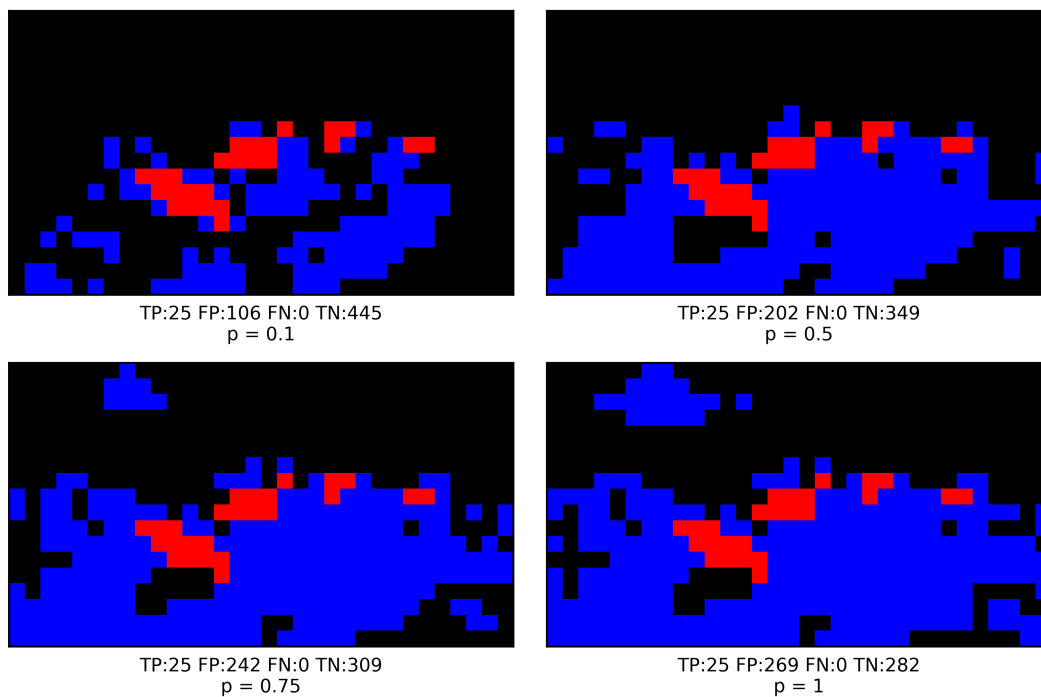


Figura 5.27: Variação de ρ no cenário C com **FFDI**

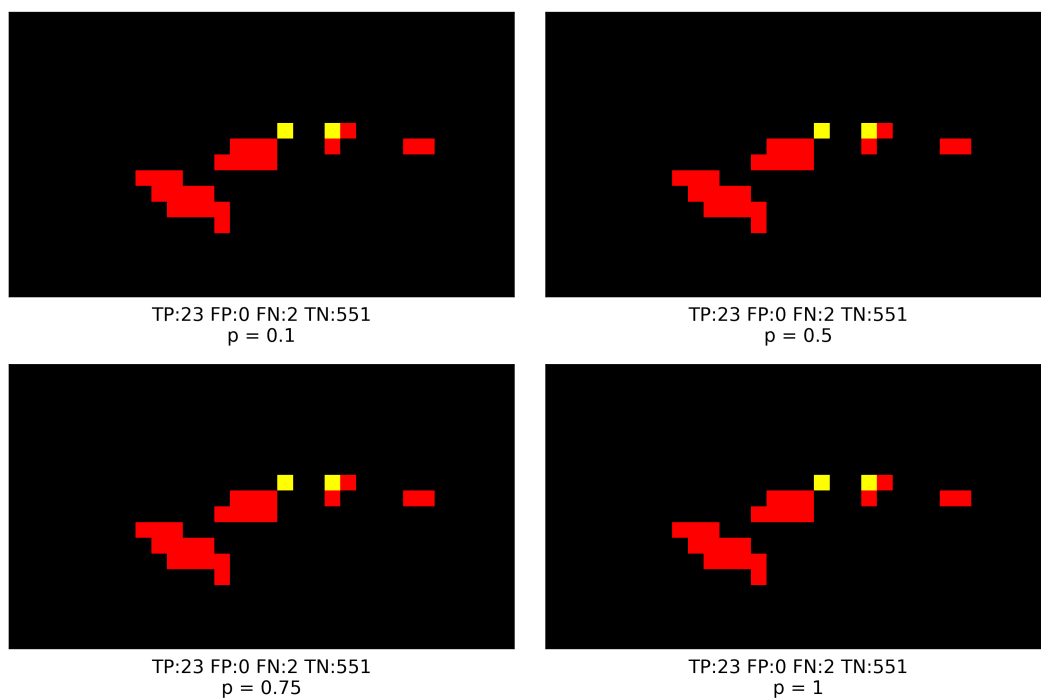


Figura 5.28: Variação de ρ no cenário C com **CAFE**

Para o cenário C, foi escolhido um $\rho = 0.1$ pois é o que apresenta melhores resultados na abordagem **FFDI**. No entanto, na abordagem **CAFE**, a variação do valor de ρ , entre 0 e 1, não apresenta grandes alterações significativas na detecção da chama, chegando ao ponto de manter os valores de *True Positive* e *False Positive*.

5.4.2 Cenários Noturnos




Figura 5.29: Quantificação dos resultados obtidos em cenários noturnos

Embora a abordagem **FFDI** tenha sido apresentada, por parte dos próprios autores, para atuar apenas em cenários diurnos, nesta secção, é comparado a abordagem **CAFE** com a **FFDI** em cenários noturnos. Como descrito no Capítulo 4, na abordagem **CAFE**, efetuaram-se algumas alterações no seu módulo **FFDI**, com a finalidade de se obter um

melhor desempenho em cenários noturnos. Para fins de teste, foram escolhidos quatro cenários com características diferentes de forma a avaliar o desempenho da abordagem aqui proposta.

A tabela 5.5 demonstra as quatro características próprias de cada cenário.

A	Floresta sem elementos humanos
B	Luzes artificiais brancas e vermelhas
C	Luzes artificiais variadas
D	Luzes artificiais amarelas

Tabela 5.5: Características dos cenários noturnos considerados

Os resultados obtidos e comprovados pela figura 5.29, demonstram que a utilização da abordagem CAFE consegue detetar, nos quatro cenários, as zonas com chamas assim como o seu reflexo que se faz incidir no fumo. Contudo, certas zonas da imagem que não pertencem à zona de incêndio são detetadas erradamente, muito devido a determinadas luzes artificiais. Em comparação com a abordagem FFDI, mais uma vez, obteve-se uma redução significativa no número de *False Positive*, no entanto, ainda não é o suficiente para os eliminar na sua totalidade.

Mais concretamente, o cenário A é caracterizado por ser uma zona de pura floresta, sem a presença de casas, veículos ou luzes artificiais. Somente é visível a zona de incêndio, e sem qualquer problema, a abordagem CAFE deteta toda a zona de incêndio. Apenas foram considerados como *True Positive* as zonas das chamas, no entanto, o reflexo da chama faz-se deslumbrar no fumo libertado e por isso também é detetado como chamas pelo algoritmo, contudo não é considerado um problema, já que faz parte da zona de incêndio. Perante este tipo de cenários, sem a presença de elementos humanos, pode-se prever que a abordagem CAFE comportar-se-á eficazmente.

O cenário B é composto por zona habitacional e com isso é natural que existam luzes artificiais. Mais concretamente, destacam-se dois tipos de luzes, uma com cor avermelhada e outras brancas. A solução CAFE deteta mais uma vez eficazmente a zona de chama mais o reflexo deste no fumo libertado. Porém existem alguns *False Positive* que em nada tem haver com a zona de incêndio, sendo eles referentes a luzes vermelhas emitidas por um poste de luz.

No cenário C, encontra-se uma zona habitacional caracterizada pela presença de luzes de iluminação com várias cores, nomeadamente brancas, roxas, vermelhas e amarelas. Eficazmente, toda a zona da chama é detetada pelo CAFE, assim como a zona circundante do fumo. Erradamente são detetadas pequenas luzes, de cor roxa e vermelha. Tendo em conta que as zonas habitacionais são maioritariamente compostas por luzes de iluminação das ruas e casas brancas ou amarelas, o aparecimento deste tipo de luzes com cores vermelhas e roxas é menos provável de acontecer, contudo é sempre importante estar preparado.

Por fim, o cenário D é composto no seu todo por uma zona habitacional com luzes amarelas, provenientes das casas e das ruas. Para este tipo de situações, a abordagem **CAFE** comporta-se bem ao não detetar tais luzes artificiais como sendo chamas. Relativamente à zona de incêndio, a chama é detetada com todo o sucesso, mesmo as zonas de chama mais reduzidas, como a que se encontra no bloco isolado mais à esquerda na imagem. Igualmente como em todos os anteriores cenários, a zona de fumo incidida pela luz da chama é detetada.

A abordagem **FFDI**, em todos os quatro cenários, demonstrou um desempenho substancialmente pior ao detetar imensos blocos considerados como *False Positive*. Este resultado vem demonstrar que a abordagem **FFDI** não está preparada para atuar em cenários noturnos, da forma como foi originalmente desenvolvida. As alterações efetuadas no bloco **FFDI** da abordagem **CAFE**, culminaram em melhores resultados, ao não detetar tantas situações de *False Positive*, como demonstra a tabela 5.6.

	Área chama IMG fonte	TP FFDI	TP CAFE	FP FFDI	FP CAFE
A	5	5	5	269	78
B	8	8	8	262	42
C	12	12	12	340	81
D	19	19	19	557	43

Tabela 5.6: Resultados noturnos TP e FP das abordagens **FFDI** e **CAFE**

5.5 Conclusão

Neste capítulo foram realizados diversos testes de forma a comprovar as decisões tomadas e o potencial do sistema apresentado neste trabalho. Inicialmente, foi realizado um teste para cada umas das três situações identificadas no cenário de aplicação, com a finalidade de demonstrar os resultados obtidos módulo após módulo. Posteriormente, foi analisado cada módulo em particular, através de testes realizados.

Para o módulo de extração de características, foi apresentada uma breve justificação da escolha do Inception-V3 como modelo **DCNN** no presente trabalho.

Nos testes efetuados no módulo de classificação, concluiu-se que o modelo **LR** é o que apresenta um melhor desempenho perante o conjunto de imagens aqui utilizado. A existência de dois modelos de classificação, um para utilizar de dia e outro durante a noite, são a melhor combinação. Ambos são classificadores binários, pois apenas dão como resposta final se existe, ou não, incêndio. Através da técnica **CV**, verificou-se uma precisão de deteção acima dos 90% em ambos os modelos, diurno e noturno. Contudo, é

imperativo utilizar um conjunto de imagens maior a fim de treinar novamente os modelos para se alcançar uma melhor detecção. Através de testes efetuados com as variáveis dos metadados, verificou-se que, de dia, as situações de *False Positive* são especialmente devido à presença de nevoeiro. Já as situações de *False Negative*, acontecem perante incêndios iniciais com dimensões muito reduzidas. Durante a noite, foi comprovado que as situações de iluminação artificial contribuem para o aumento do número de casos de *False Positive*.

No último módulo, o de estimação da área das chamas, apenas devem chegar situações verdadeiras de incêndio. Após realizados testes com cenários distintos, verificou-se, tanto de dia como de noite, a existência de blocos da imagem detetados erradamente, mais durante a noite. Contudo, nunca deixa de detetar corretamente as zonas das chamas, para além de reduzir o número de situações de *False Positive*.

Capítulo 6

Conclusão

Este trabalho, apresenta um estudo completo sobre um sistema de detecção automática de incêndios florestais. Foi treinado para funcionar continuamente, dia e noite, em diferentes cenários florestais. O seu desenvolvimento teve em conta a possibilidade de ser aplicado em câmaras moveis, como em drones, e estáticas, como em torres de vigia.

Pretende-se também que o sistema proposto atue de forma autónoma. Porém em situações de baixo risco de incêndio, poderá não entrar em funcionamento devido às condições climáticas menos favoráveis, como extrema humidade ou precipitação. Assim, o objetivo do módulo de análise dos dados meteorológicos passa pela obtenção do risco de incêndio para uma determinada zona, a fim de justificar a atuação do sistema.

Um dos contributos deste trabalho passou pela criação e organização de um *dataset*, maioritariamente constituído por imagens com uma perspetiva aérea. Foi dividido tendo em conta duas classes, imagens com e sem incêndio, e é constituído por situações diurnas e noturnas. Complementou-se o *dataset* através da utilização de metadados, ou seja, para cada imagem, foram identificadas e apontadas quais as características presentes. As características escolhidas permitem averiguar se uma dada imagem é constituída por chamas, fumo, nuvens, nevoeiro ou até elementos humanos. Para além disso também foi apontado qual o tipo de superfície, a cor da vegetação e qual o tamanho do incêndio na imagem.

A arquitetura do sistema de detecção inicia-se pela extração de descritores de uma imagem. A escolha da [DCNN](#) Inception-V3 baseou-se no facto de ser uma melhores em termos de precisão quando comparada com outras. No processo de classificação, o modelo de aprendizagem supervisionada [LR](#) demonstrou, quando treinado com todo o conjunto de imagens, uma elevada precisão de detecção tanto nos cenários diurno (94.1%) como noturno (94.8%). No entanto, existem casos de falsos negativos que devem ser evitados pois não podem ocorrer aquando da sua utilização real.

Os resultados obtidos após testes com os metadados, esclarecem que, a presença de nevoeiro durante o dia, e de luzes de iluminação durante a noite, são as características com maior responsabilidade pela ocorrência de falsos positivos por parte do modelo de

classificação. Esclarecem ainda que, a deteção de pequenas manchas de incêndio numa imagem, é uma tarefa desafiante e é necessário um treino mais volumoso.

A estimação da área das chamas é a última etapa a aplicar neste processo da deteção de incêndios florestais. A proposta apresentada, o **CAFE**, é uma melhoria de um índice utilizado na deteção de chamas, sendo que a grande diferença se traduz num menor número de falsos positivos detetados.

O sistema proposto demonstra a boa capacidade de deteção de incêndios florestais através do uso de técnicas de **DL** e de **VC**. Contudo, em cada módulo constituinte do sistema, existem melhorias a efetuar e novas implementações possíveis a acrescentar, de modo a tornar o sistema, numa solução mais eficaz e completa. Com o uso de dados meteorológicos no sistema, objetivam-se novas funcionalidades, para além da obtenção do risco de incêndio. Uma solução possível seria a recolha periódica de dados meteorológicos ao longo do percurso do drone, de forma a manter o sistema atualizado.

Na construção do *dataset*, uma das grandes limitações encontradas foi a disponibilidade de mais imagens com perspetiva aérea o que não levou à obtenção de melhores e mais resultados conclusivos. Por isso, uma das melhorias a efetuar, seria recolher mais imagens, de forma a re-treinar o modelo. Esta recolha deverá recair em mais imagens com incêndio em fase inicial, com nevoeiro e com fontes de iluminação noturna.

A abordagem proposta no módulo de estimação da área das chamas, devido ao facto de utilizar apenas a cor como fator de distinção dos *pixels* das chamas dos restantes, apresenta algumas limitações. É bastante precisa ao detetar as zonas das chamas, contudo, numa imagem com incêndio, outros objetos nas imediações com tons de cor iguais aos das chamas, podem ser erradamente detetados. Para ultrapassar este problema, a deteção com base em características dinâmicas, como o movimento, é uma solução futura, porém a utilização de drones, cria algumas restrições na aplicação de tais técnicas. De forma a contornar essas restrições, sempre que uma imagem fosse classificada como incêndio, o drone poderia pairar durante breves instantes, e aplicar a deteção de zonas com movimento, auxiliando a deteção já existente com base nas propriedades da cor.

Referências

- Ahmad A. A. Alkhatib. A Review on Forest Fire Detection Techniques. *International Journal of Distributed Sensor Networks*, 10(3):597368, mar 2014. ISSN 1550-1477. doi: 10.1155/2014/597368. URL <http://journals.sagepub.com/doi/10.1155/2014/597368>.
- Robert Allison, Joshua Johnston, Gregory Craig, and Sion Jennings. Airborne Optical and Thermal Remote Sensing for Wildfire Detection and Monitoring. *Sensors*, 16(8):1310, aug 2016. ISSN 1424-8220. doi: 10.3390/s16081310. URL <http://www.mdpi.com/1424-8220/16/8/1310>.
- Joao Alves, Christophe Soares, Jose Torres, Pedro Sobral, and Rui S. Moreira. Color algorithm for flame exposure (CAFE). In *2018 13th Iberian Conference on Information Systems and Technologies (CISTI)*, pages 1–7. IEEE, jun 2018. ISBN 978-989-98434-8-6. doi: 10.23919/CISTI.2018.8399412. URL <https://ieeexplore.ieee.org/document/8399412/>.
- Vincent G. Ambrosia and Thomas Zajkowski. Selection of Appropriate Class UAS/Sensors to Support Fire Monitoring: Experiences in the United States. In *Handbook of Unmanned Aerial Vehicles*, pages 2723–2754. Springer Netherlands, Dordrecht, 2015. doi: 10.1007/978-90-481-9707-1_73. URL http://link.springer.com/10.1007/978-90-481-9707-1_{_}73.
- Malik Amraoui, Margarida L.R. Liberato, Teresa J. Calado, Carlos C. DaCamara, Luís Pinto Coelho, Ricardo M. Trigo, and Célia M. Gouveia. Fire activity over Mediterranean Europe based on information from Meteosat-8. *Forest Ecology and Management*, 294:62–75, 2013. ISSN 03781127. doi: 10.1016/j.foreco.2012.08.032. URL <http://dx.doi.org/10.1016/j.foreco.2012.08.032>.
- Gary Bradski and Adrian Kaehler. *Learning OpenCV 3: Computer Vision in C++ with the OpenCV Library*. O’Reilly Media, 2016. ISBN 9781491937983.
- Min Cai, Xiaobo Lu, Xuehui Wu, and Yifei Feng. Intelligent video analysis-based forest fires smoke detection algorithms. In *2016 12th International Conference on Natural*

- Computation, Fuzzy Systems and Knowledge Discovery (ICNC-FSKD)*, pages 1504–1508. IEEE, aug 2016. ISBN 978-1-5090-4093-3. doi: 10.1109/FSKD.2016.7603399. URL <http://ieeexplore.ieee.org/document/7603399/>.
- Alfredo Canziani, Adam Paszke, and Eugenio Culurciello. An Analysis of Deep Neural Network Models for Practical Applications. *CoRR*, abs/1605.0:1–7, 2016. URL <http://arxiv.org/abs/1605.07678>.
- Davide Chicco. Ten quick tips for machine learning in computational biology. *BioData Mining*, 10(1):35, dec 2017. ISSN 1756-0381. doi: 10.1186/s13040-017-0155-3. URL <https://biodatamining.biomedcentral.com/articles/10.1186/s13040-017-0155-3>.
- Yu Chunyu, Fang Jun, Wang Jinjun, and Zhang Yongming. Video Fire Smoke Detection Using Motion and Color Features. *Fire Technology*, 46(3):651–663, jul 2010. ISSN 0015-2684. doi: 10.1007/s10694-009-0110-z. URL <http://link.springer.com/10.1007/s10694-009-0110-z>.
- I. Colomina and P. Molina. Unmanned aerial systems for photogrammetry and remote sensing: A review. *ISPRS Journal of Photogrammetry and Remote Sensing*, 92:79–97, 2014. ISSN 09242716. doi: 10.1016/j.isprsjprs.2014.02.013. URL <http://dx.doi.org/10.1016/j.isprsjprs.2014.02.013>.
- Comissão Técnica Independente. Análise e apuramento dos factos relativos aos incêndios que ocorreram em Pedrógão Grande, Castanheira de Pera, Ansião, Alvaiázere, Figueiró dos Vinhos, Arganil, Góis, Penela, Pampilhosa da Serra, Oleiros e Sertã, entre 17 e 24 de junho de 2017. Technical report, Lisboa, 2017.
- Henry Cruz, Martina Eckert, Juan Meneses, and José-Fernán Martínez. Efficient Forest Fire Detection Index for Application in Unmanned Aerial Systems (UASs). *Sensors*, 16(6):893, jun 2016. ISSN 1424-8220. doi: 10.3390/s16060893. URL <http://www.mdpi.com/1424-8220/16/6/893>.
- Daniele de Rigo, Giorgio Libertà, Tracy Houston Durrant, Tomas Artés Vivancos, and Jesus San-Miguel-Ayanz. Forest fire danger extremes in Europe under climate change: variability and uncertainty. Technical report, Joint Research Centre, Luxembourg, 2017.
- Janez Demsar, Tomaz Curk, Ales Erjavec, Crt Gorup, Tomaz Hocevar, Mitar Milutinovic, Martin Mozina, Matija Polajnar, Marko Toplak, Anze Staric, Miha Stajdohar, Lan Umek, Lan Zagar, Jure Zbontar, Marinka Zitnik, and Blaz Zupan. Orange: Data Mining Toolbox in Python. *Journal of Machine Learning Research*, 14:2349–2353, 2013. URL <http://jmlr.org/papers/v14/demsar13a.html>.

- Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. ImageNet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255. IEEE, jun 2009. ISBN 978-1-4244-3992-8. doi: 10.1109/CVPR.2009.5206848. URL <http://ieeexplore.ieee.org/document/5206848/>.
- EUFOFINET. Project Detection Synthesis of Good Practices. Technical Report 5, Zvolen.
- Kunihiko Fukushima. Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 36(4):193–202, apr 1980. ISSN 0340-1200. doi: 10.1007/BF00344251. URL <http://link.springer.com/10.1007/BF00344251>.
- Gabinete do Secretário de Estado das Florestas e do Desenvolvimento Rural. Despacho n.º 9081-E/2017 de 13 de Outubro, 2017. URL www.dre.pt.
- Louis Giglio. MODIS Collection 6 Active Fire Product User’s Guide, Revision A. Technical report, University of Maryland, 2015.
- Pedro Gomes, Pedro Santana, and José Barata. A vision-based approach to fire detection. *International Journal of Advanced Robotic Systems*, 11:1–12, 2014. ISSN 17298814. doi: 10.5772/58821.
- Ian Goodfellow, Yoshua Bengio, and Aaron Courville. Representation Learning. In *Deep Learning*, chapter 15. MIT Press, 2016. URL <http://www.deeplearningbook.org>.
- Osman Günay, Kasim Taşdemir, B. Uğur Töreyn, and A. Enis Çetin. Video based wildfire detection at night. *Fire Safety Journal*, 44(6):860–868, 2009. ISSN 03797112. doi: 10.1016/j.firesaf.2009.04.003.
- Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. Deep Residual Learning for Image Recognition. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, volume 77, pages 770–778. IEEE, jun 2016. ISBN 978-1-4673-8851-1. doi: 10.1109/CVPR.2016.90. URL <http://link.springer.com/10.1007/s11042-017-4440-4><http://ieeexplore.ieee.org/document/7780459/>.
- Valquiria Huttner, Cristiano Rafael Steffens, and Silvia Silva da Costa Botelho. First response fire combat: Deep learning based visible fire detection. In *2017 Latin American Robotics Symposium (LARS) and 2017 Brazilian Symposium on Robotics (SBR)*, pages 1–6. IEEE, nov 2017. ISBN 978-1-5386-0956-9. doi: 10.1109/SBR-LARS-R.2017.8215312. URL <http://ieeexplore.ieee.org/document/8215312/>.

- ICNF. 10.º Relatório Provisório de Incêndios Florestais 2017, 01 de Janeiro a 31 de Outubro. Technical report, 2017. URL <http://www2.icnf.pt/portal/florestas/dfci/Resource/doc/rel/2017/10-rel-prov-1jan-31out-2017.pdf>.
- Adrian Kaehler and Gary Bradski. *Learning OpenCV 3: Computer Vision in C++ with the OpenCV Library*. O'Reilly Media, Inc., 1st edition, 2016. ISBN 1491937998 9781491937990.
- Seonghyun Kim, Wonjae Lee, Young-su Park, Hyun-Woo Lee, and Yong-Tae Lee. Forest fire monitoring system based on aerial image. In *2016 3rd International Conference on Information and Communication Technologies for Disaster Management (ICT-DM)*, pages 1–6. IEEE, dec 2016. ISBN 978-1-5090-5234-9. doi: 10.1109/ICT-DM.2016.7857214. URL <http://ieeexplore.ieee.org/document/7857214/>.
- Ron Kohavi. A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection. *Appears in the International Joint Conference on Artificial Intelligence (IJCAI)*, 5:1–7, 1995. ISSN 10450823. doi: 10.1067/mod.2000.109031. URL <http://robotics.stanford.edu/~ronnyk>.
- Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. ImageNet Classification with Deep Convolutional Neural Networks. *Advances In Neural Information Processing Systems*, pages 1–9, 2012. ISSN 10495258. doi: <http://dx.doi.org/10.1016/j.protcy.2014.09.007>.
- Mengxin Li, Weijing Xu, K E Xu, Jingjing Fan, and Dingding Hou. REVIEW OF FIRE DETECTION TECHNOLOGIES BASED ON VIDEO IMAGE. *Journal of Theoretical and Applied Information Technology*, 49(2):700–707, 2013.
- Shuying Liu and Weihong Deng. Very deep convolutional neural network based image classification using small training sample size. In *2015 3rd IAPR Asian Conference on Pattern Recognition (ACPR)*, pages 730–734. IEEE, nov 2015. ISBN 978-1-4799-6100-9. doi: 10.1109/ACPR.2015.7486599. URL <http://arxiv.org/abs/1409.1556><http://ieeexplore.ieee.org/document/7486599/>.
- Liyang Yu, Neng Wang, and Xiaoqiao Meng. Real-time forest fire detection with wireless sensor networks. In *Proceedings. 2005 International Conference on Wireless Communications, Networking and Mobile Computing, 2005.*, volume 2, pages 1214–1217. IEEE, 2005. ISBN 0-7803-9335-X. doi: 10.1109/WCNM.2005.1544272. URL <http://ieeexplore.ieee.org/ielx5/10362/32965/01544272.pdf?tp={&}arnumber=1544272{&}isnumber=32965>.
- Hoai Luu-Duc, Dung Trung Vo, and Tuan Do-Hong. Wildfire smoke detection based on co-occurrence matrix and dynamic feature. In *2016 International Confe-*

- rence on *Advanced Technologies for Communications (ATC)*, pages 277–281. IEEE, oct 2016. ISBN 978-1-5090-2711-8. doi: 10.1109/ATC.2016.7764789. URL <http://ieeexplore.ieee.org/document/7764789/>.
- J. R. Martinez-de Dios, B. C. Arrue, A. Ollero, L. Merino, and F. Gomez-Rodriguez. Computer vision techniques for forest fire perception. *Image and Vision Computing*, 26(4):550–562, 2008. ISSN 02628856. doi: 10.1016/j.imavis.2007.07.002.
- Luis Merino, Fernando Caballero, J. Ramiro Martínez-De-Dios, Iván Maza, and Anibal Ollero. An unmanned aircraft system for automatic forest fire monitoring and measurement. *Journal of Intelligent and Robotic Systems: Theory and Applications*, 65(1-4): 533–548, 2012. ISSN 09210296. doi: 10.1007/s10846-011-9560-x.
- Guilherme Borba Neumann, Vitor Pinheiro De Almeida, and Markus Endler. Smart Forests : fire detection service. pages 1–4, 2018.
- Keiron O’Shea and Ryan Nash. An Introduction to Convolutional Neural Networks. *CoRR*, abs/1511.0, 2015. URL <http://arxiv.org/abs/1511.08458>.
- Wilfrid Schroeder and Louis Giglio. NASA VIIRS Land Science Investigator Processing System (SIPS) Visible Infrared Imaging Radiometer Suite (VIIRS) 375 m & 750 m Active Fire Products. Technical Report July, 2018.
- Vladimir Sedlak, Viera Stopjakova, and Juraj Brenkus. A real-time method for smoke detection in monitored forest areas. In *2017 International Conference on Applied Electronics (AE)*, pages 1–6. IEEE, sep 2017. ISBN 978-8-0261-0642-5. doi: 10.23919/AE.2017.8053615. URL <http://ieeexplore.ieee.org/document/8053615/>.
- Jivitesh Sharma, Ole-christoffer Granmo, Morten Goodwin, and Jahn Thomas Fidje. Deep Convolutional Neural Networks for Fire Detection in Images. In *Engineering Applications of Neural Networks*, volume 744, pages 183–193. Springer International Publishing, 2017. doi: 10.1007/978-3-319-65172-9_16. URL http://link.springer.com/10.1007/978-3-319-65172-9_{_}16.
- Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew Rabinovich. Going deeper with convolutions. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, volume 07-12-June, pages 1–9. IEEE, jun 2015. ISBN 978-1-4673-6964-0. doi: 10.1109/CVPR.2015.7298594. URL <http://ieeexplore.ieee.org/document/7298594/>.
- Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens, and Zbigniew Wojna. Rethinking the Inception Architecture for Computer Vision. In *2016*

- IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 2818–2826. IEEE, jun 2016. ISBN 978-1-4673-8851-1. doi: 10.1109/CVPR.2016.308. URL <http://arxiv.org/abs/1512.00567><http://ieeexplore.ieee.org/document/7780677/>.
- Richard Szeliski. *Computer Vision : Algorithms and Applications*, volume 5. Springer, 2010. ISBN 1848829345. doi: 10.1007/978-1-84882-935-0.
- M. Traiche, K. Bourai, N. Moussaoui, R. Beggar, F. Almabouada, D. Louhibi, El-Hachemi Amara, Said Boudjemai, and Djamila Doumaz. Lidar Technique for Early Forest Fire Detection: Design and Development Aspects. In *AIP Conference Proceedings*, volume 1047, pages 50–58. AIP, 2008. ISBN 9780735405752. doi: 10.1063/1.2999968. URL <http://aip.scitation.org/doi/abs/10.1063/1.2999968>.
- Andrei B. Utkin, Armando Fernandes, Fernando Simões, Alexander Lavrov, and Rui Vi-lar. Feasibility of forest-fire smoke detection using lidar. *International Journal of Wildland Fire*, 12(2):159, 2003. ISSN 1049-8001. doi: 10.1071/WF02048. URL <http://www.publish.csiro.au/?paper=WF02048>.
- C. E. Van Wagner. Development and Structure of the Canadian Forest Fire Weather Index System. Technical report, Canadian Forest Service, Ottawa, 1987.
- Domingos X Viegas, Raul M Reis, Miguel G Cruz, Maria T Viegas, Bolseiro De Dou-toramento, Engenheira Silvicultora, Universidade De Coimbra, Departamento De En-genharia, and Pinhal De. Calibração do Sistema Canadiao de Perigo de Incêndio para Aplicação em Portugal. *Silva Lusitana*, 12(1):77 – 93, 2004. URL <http://www.scielo.oces.mctes.pt/pdf/slu/v12n1/12n1a07.pdf>.
- S. R. Vijayalakshmi. Smoke detection in video images using background subtraction method for early fire alarm system. In *2017 2nd International Conference on Communication and Electronics Systems (ICCES)*, number Icces, pages 167–171. IEEE, oct 2017. ISBN 978-1-5090-5013-0. doi: 10.1109/CESYS.2017.8321258. URL <http://ieeexplore.ieee.org/document/8321258/>.
- V Vipin. Image Processing Based Forest Fire Detection. *International Journal of Emer-ging Technology and Advanced Engineering*, 2(2):87–95, 2012. doi: 10.1109/ICCPCT.2014.7054883.
- Yonghe Wang. Updated source code for calculating fire danger indices in the Canadian Forest Fire Weather Index System. Technical report, 2015.
- C C Wilson and J B Davis. Forest Fire Laboratory at Riverside and fire re-search in California: past, present, and future. *USDA Forest Service Gene-*

- ral Technical Report*, PSW-105, 1988. URL papers2://publication/uuid/7F546D8C-736F-479D-A5AF-BA81F4FCAE71.
- Wonjae Lee, Seonghyun Kim, Yong-Tae Lee, Hyun-Woo Lee, and Min Choi. Deep neural networks for wild fire detection with unmanned aerial vehicle. In *2017 IEEE International Conference on Consumer Electronics (ICCE)*, volume 10132 LNCS, pages 252–253. IEEE, 2017. ISBN 978-1-5090-5544-9. doi: 10.1109/ICCE.2017.7889305. URL <http://ieeexplore.ieee.org/document/7889305/>.
- Chunyu Yu, Zhibin Mei, and Xi Zhang. A real-time video fire flame and smoke detection algorithm. *Procedia Engineering*, 62:891–898, 2013. ISSN 18777058. doi: 10.1016/j.proeng.2013.08.140. URL <http://dx.doi.org/10.1016/j.proeng.2013.08.140>.
- Chi Yuan, Zhixiang Liu, and Youmin Zhang. UAV-based forest fire detection and tracking using image processing techniques. *2015 International Conference on Unmanned Aircraft Systems (ICUAS)*, pages 639–643, 2015a. doi: 10.1109/ICUAS.2015.7152345. URL <http://ieeexplore.ieee.org/lpdocs/epic03/wrapper.htm?arnumber=7152345>.
- Chi Yuan, Youmin Zhang, and Zhixiang Liu. A survey on technologies for automatic forest fire monitoring, detection, and fighting using unmanned aerial vehicles and remote sensing techniques. *Canadian Journal of Forest Research*, 45(7): 783–792, jul 2015b. ISSN 0045-5067. doi: 10.1139/cjfr-2014-0347. URL <http://www.nrcresearchpress.com/doi/10.1139/cjfr-2014-0347>.
- Chi Yuan, Zhixiang Liu, and Youmin Zhang. Vision-based forest fire detection in aerial images for firefighting using UAVs. *2016 International Conference on Unmanned Aircraft Systems, ICUAS 2016*, pages 1200–1205, 2016. doi: 10.1109/ICUAS.2016.7502546.
- Chi Yuan, Zhixiang Liu, and Youmin Zhang. Fire Detection Using Infrared Images for UAV-based Forest Fire Surveillance. *2017 International Conference on Unmanned Aircraft Systems (ICUAS)*, 2017.
- Qingjie Zhang, Jiaolong Xu, Liang Xu, and Haifeng Guo. Deep Convolutional Neural Networks for Forest Fire Detection. In *Proceedings of the 2016 International Forum on Management, Education and Information Technology Application*, number Ifmeita, pages 568–575, Paris, France, 2016. Atlantis Press. ISBN 978-94-6252-166-7. doi: 10.2991/ifmeita-16.2016.105. URL <http://www.atlantis-press.com/php/paper-details.php?id=25850411>.