

# **DistSense: Sistema distribuído de reconhecimento de atividades em ambientes inteligentes**

**Universidade Fernando Pessoa**



Luís Mota

Faculdade de Ciência e Tecnologia

Universidade Fernando Pessoa

Dissertação submetida para obtenção do grau de  
*Mestre em Engenharia Informática no ramo de Computação Móvel*

Outubro, 2023



## Resumo

Nos dias atuais, à medida que Portugal e o mundo enfrentam desafios demográficos e uma população em envelhecimento crescente, a área da *Ambient Assisted Living* (AAL) emerge como uma resposta crucial para melhorar a qualidade de vida e promover a autonomia dos utilizadores. A crescente aplicação de sensores audiovisuais em casas inteligentes, para funções como segurança, automação e monitorização de saúde, torna a proteção de dados uma preocupação urgente. Os utilizadores exigem garantias de que informações sensíveis capturadas nas suas habitações não serão comprometidas, acedidas por terceiros não autorizados ou utilizadas de forma inadequada.

Esta necessidade de segurança coloca uma pressão substancial sobre os sistemas de captura audiovisual, requerendo abordagens que garantam a privacidade e a salvaguarda dos dados do utilizador. Além disso, é essencial que esses sistemas sejam projetados tendo em mente a aceitação dos utilizadores, oferecendo transparência, controlo e, ao mesmo tempo, um grau adequado de precisão na deteção de atividades domésticas.

Neste contexto, o sistema *DistSense* surge como uma resposta inovadora a esses desafios. A adoção de uma rede distribuída *Peer-to-Peer* (P2P) de sensores domésticos inteligentes, juntamente com a utilização de várias tecnologias para priorizar a segurança dos dados do utilizador, garante um processamento eficiente e colaborativo de informações audiovisuais. Esta abordagem possibilita uma redução significativa de falsos positivos na deteção e reconhecimento de atividades domésticas, especialmente em situações que envolvem oclusão de ângulos, variações na iluminação e ruído acústico.

Para comprovar a eficácia do *DistSense*, foram realizados testes funcionais para cada módulo implementado e investigados dois casos de uso, um em ambiente real e outro em ambiente simulado. Os modelos de áudio e vídeo treinados demonstraram taxas de precisão de 88% e 80%, respetivamente. Os resultados obtidos durante a implementação dos casos de uso foram positivos, destacando a capacidade do sistema em atender de forma eficaz às necessidades dos utilizadores, tanto em termos de segurança e aceitação, quanto na redução de incertezas na deteção de atividades domésticas na presença de variações de ruído audiovisual.

***Palavras-chave:*** Sistema de sensores inteligentes distribuído; AAL; Privacidade de dados; Internet das Coisas; Aprendizagem Computacional;

## Abstract

In the present day, as Portugal and the world face demographic challenges and an increasingly aging population, the field of *Ambient Assisted Living* (AAL) emerges as a crucial response to enhance the quality of life and promote user autonomy. The growing use of audiovisual sensors in smart homes for functions such as security, automation, and health monitoring makes data protection an urgent concern. Users demand assurances that sensitive information captured in their residences will not be compromised, accessed by unauthorized third parties, or used improperly.

This need for security places substantial pressure on audiovisual capture systems, requiring approaches that ensure user privacy and data safeguarding. Additionally, it is essential that these systems are designed with user acceptance in mind, offering transparency, control, and, at the same time, an appropriate degree of accuracy in household activity detection.

In this context, the *DistSense* system emerges as an innovative response to these challenges. The adoption of a distributed Peer-to-Peer (P2P) network of intelligent household sensors, in conjunction with the use of a variety of technologies to prioritize user data security, ensures efficient and collaborative processing of audiovisual information. This approach enables a significant reduction in false positives in the detection and recognition of domestic activities, especially in situations involving angle occlusion, variations in lighting, and acoustic noise.

To validate the effectiveness of *DistSense*, functional tests were conducted for each implemented module, and two use cases were investigated, one in a real environment and another in a simulated environment. The trained audio and video models demonstrated accuracy rates of 88% and 80%, respectively. The results obtained during the implementation of the use cases were positive, highlighting the system's ability to effectively meet user needs in terms of security and acceptance, as well as reducing uncertainties in the detection of household activities in the presence of audiovisual noise variations.

**Keywords:** Distributed Intelligent Sensor System; Ambient Assisted Living; Data Privacy; Internet of things; Machine Learning;

## **Agradecimentos**

Gostaria de expressar a minha sincera gratidão aos meus orientadores de dissertação, o Prof. José Torres, Ph.D., e o Prof. Pedro Sobral, Ph.D. A sua orientação e apoio foram fundamentais para o sucesso deste trabalho.

Ao Prof. José Torres, agradeço pela sua dedicação incansável em fornecer orientações valiosas ao longo do processo de pesquisa e redação desta dissertação. A sua vasta experiência e profundo conhecimento na área foram essenciais para a minha compreensão dos tópicos abordados.

Ao Prof. Pedro Sobral, agradeço pela sua orientação perspicaz e pelo seu constante incentivo ao pensamento crítico. As suas sugestões e comentários construtivos desempenharam um papel crucial no desenvolvimento da minha investigação.

Ambos os orientadores demonstraram um compromisso exemplar com a excelência académica, partilhando generosamente o seu tempo e conhecimento. Agradeço-lhes por estarem sempre disponíveis para responder às minhas dúvidas e por me incentivarem a ultrapassar os obstáculos encontrados ao longo do caminho.

À minha família, em especial aos meus pais, agradeço todo o carinho transmitido, confiança e por me apoiarem no meu percurso académico que me permitiu chegar até aqui.

À minha namorada, pelo constante apoio, motivação e confiança que demonstrou sempre em todos os momentos.

Agradeço de uma forma geral a todos os que diretamente ou indiretamente me ajudaram e contribuíram para que eu alcançasse o meu objetivo.

# Tabela de Conteúdos

<b>Tabela de Conteúdos</b>	<b>vi</b>
<b>Lista de Figuras</b>	<b>viii</b>
<b>Lista de Tabelas</b>	<b>x</b>
<b>Definições e Acrónimos</b>	<b>xi</b>
<b>1 Introdução</b>	<b>1</b>
1.1 Enquadramento e motivação . . . . .	1
1.2 Objetivos . . . . .	3
1.3 Metodologia . . . . .	4
1.4 Contribuições . . . . .	5
1.5 Estrutura do trabalho . . . . .	6
<b>2 Trabalhos Relacionados em Ambientes Inteligentes</b>	<b>8</b>
2.1 Arquitetura de referência . . . . .	9
2.2 Ferramentas para simulação de ambientes inteligentes . . . . .	10
2.3 Sistemas Cliente-Servidor vs Sistemas <i>Peer-to-Peer</i> . . . . .	13
2.4 Sistemas de monitorização em casas inteligentes . . . . .	17
2.5 Análise comparativa . . . . .	28
<b>3 Especificação do Sistema <i>DistSense</i></b>	<b>32</b>
3.1 Cenário de aplicação: Sistema de monitorização distribuído para o reconhecimento de atividades domésticas . . . . .	32
3.2 Arquitetura genérica . . . . .	34
3.3 Lógica de funcionamento . . . . .	37
3.4 Módulo de descoberta na rede . . . . .	41
3.5 Módulo de comunicação . . . . .	42
3.6 Módulo de aprendizagem computacional . . . . .	43
3.7 Módulo de processamento e representação do conhecimento . . . . .	45

---

<b>4</b>	<b>Implementação do Sistema <i>DistSense</i></b>	<b>48</b>
4.1	Ambiente de virtualização do Sistema <i>DistSense</i> . . . . .	49
4.2	Inicialização do sistema <i>DistSense</i> . . . . .	52
4.2.1	Serviço de descoberta . . . . .	53
4.2.2	Processo de eleição do coordenador . . . . .	55
4.3	Comunicação entre os nós . . . . .	57
4.3.1	Mensagens, estrutura e procedimento . . . . .	59
4.4	Aprendizagem computacional . . . . .	61
4.4.1	Pré-processamento do conjunto de dados audiovisuais . . . . .	62
4.4.2	Treino dos modelos . . . . .	63
4.4.3	Conversão dos modelos . . . . .	66
4.5	Processamento e representação do conhecimento . . . . .	67
4.5.1	<i>Blockchain</i> . . . . .	68
4.5.2	<i>Home Assistant</i> . . . . .	71
<b>5</b>	<b>Testes e Avaliação</b>	<b>76</b>
5.1	Testes funcionais . . . . .	77
5.1.1	Módulo de descoberta na rede . . . . .	79
5.1.2	Módulo de comunicação . . . . .	81
5.1.3	Módulo de aprendizagem computacional . . . . .	84
5.1.4	Módulo de processamento e representação do conhecimento . . . . .	88
5.2	Caso de uso em ambiente simulado: Detecção de perigos domésticos . . . . .	92
5.3	Caso de uso em ambiente real: Detecção colaborativa de atividades domésticas com variações de ruído audiovisual . . . . .	94
5.4	Discussão . . . . .	98
<b>6</b>	<b>Conclusão</b>	<b>100</b>
	<b>Bibliografia</b>	<b>103</b>

# Lista de Figuras

2.1	Arquitetura de referência - Modelo em camadas . . . . .	9
2.2	Implementação da infraestrutura de um sistema exemplo no GNS3 (Official Website, 2023) . . . . .	12
2.3	Modelos Arquiteturais utilizados em Sistemas de Monitorização . . . . .	14
2.4	Parâmetros comuns a avaliar em casas inteligentes . . . . .	18
2.5	Arquitetura <i>edge-fog-cloud</i> apresentada no estudo de (Cao et al., 2019) . . . . .	19
2.6	Arquitetura centralizada de (Rupasinghe and Maduranga, 2022) . . . . .	24
3.1	Vista geral da arquitetura do sistema <i>DistSense</i> . . . . .	34
3.2	Módulos de funcionamento de um nó do sistema <i>DistSense</i> . . . . .	38
3.3	Fluxo de dados do sistema <i>DistSense</i> . . . . .	39
3.4	Funcionamento do protocolo mDNS (Al-Fuqaha et al., 2015b) . . . . .	41
3.5	Fluxo de dados no treino dos modelos especializados na deteção de eventos audiovisuais do sistema <i>DistSense</i> . . . . .	44
4.1	Processo de construção e registo de um contentor <i>docker</i> . . . . .	50
4.2	Configuração do contentor <i>docker</i> no GNS3 . . . . .	51
4.3	Registo de um serviço com auxílio da biblioteca <i>zeroconf</i> em <i>python</i> . . . . .	53
4.4	Descoberta de serviços com auxílio da biblioteca <i>zeroconf</i> em <i>python</i> . . . . .	54
4.5	Eleição do nó coordenador . . . . .	56
4.6	Captura de pacotes <i>keep alive</i> através da aplicação <i>wireshark</i> . . . . .	59
4.7	Mensagem padrão no formato JSON em <i>python</i> . . . . .	60
4.8	Fluxo do processo de pré-processamento do conjunto de dados audiovisuais . . . . .	63
4.9	Janela deslizante utilizada na implementação do modelo <i>YAMNet</i> . . . . .	64
4.10	Evolução da precisão no treino dos modelos <i>YAMNet</i> e <i>MoViNet</i> . . . . .	66
4.11	Pré-processamento dos dados para inferência do modelo <i>MoViNet</i> em <i>python</i> . . . . .	68
4.12	Estrutura de cada bloco da <i>blockchain</i> do sistema <i>DistSense</i> . . . . .	69
4.13	Fluxo de registo de transação na <i>blockchain</i> . . . . .	70
4.14	Interface da plataforma HA em vistas distintas . . . . .	73
4.15	Mensagem enviada pelo nó coordenador via MQTT para o HA . . . . .	74

---

4.16	Regra de automação no <i>Home Assistant</i> em <i>python</i> . . . . .	75
5.1	Interação entre módulos do sistema <i>DistSense</i> . . . . .	78
5.2	Resultado da adição de novos dispositivos na rede do sistema <i>DistSense</i> . . . . .	79
5.3	Envio do estado atual da <i>blockchain</i> no momento de adição de um novo nó na rede . . . . .	80
5.4	Comunicação entre os dispositivos do sistema <i>DistSense</i> . . . . .	82
5.5	Simulação de comportamento de falha de um nó na rede local . . . . .	83
5.6	Recuperação e reconexão da ligação do nó na rede local . . . . .	83
5.7	Sincronização da <i>blockchain</i> após a reconexão do nó na rede local . . . . .	84
5.8	Classificação de atividades domésticas em vídeo . . . . .	85
5.9	Matriz de confusão para os modelos de áudio e vídeo . . . . .	85
5.10	Métricas de desempenho para os modelos de áudio e vídeo . . . . .	86
5.11	Comparação de precisão do modelo retreinado com modelo <i>YAMNet</i> original através da classificação de áudios para as diferentes classes selecionadas . . . . .	88
5.12	Consulta à <i>blockchain</i> do último evento capturado por um nó . . . . .	90
5.13	Criação, receção e validação de transações na <i>blockchain</i> . . . . .	91
5.14	Representação de fugas de água de uma torneira mantida aberta pelo utilizador . . . . .	92
5.15	Consulta à <i>blockchain</i> do último evento capturado por um nó . . . . .	93
5.16	Alerta enviado ao utilizador através da plataforma HA após deteção de perigos no contexto doméstico . . . . .	94
5.17	Diferentes perspetivas de visualização do ambiente inteligente por dois nós distintos na rede para a atividade " <i>Lavar/Limpar louça</i> " . . . . .	96
5.18	Diferentes perspetivas de visualização do ambiente inteligente por dois nós distintos na rede para a atividade " <i>Ler um livro</i> " . . . . .	96
5.19	Deteção da atividade " <i>Ler um livro</i> " através do nó com um grau de certeza confiável . . . . .	97
5.20	Consulta à <i>blockchain</i> do último evento capturado . . . . .	97

# Lista de Tabelas

1.1	Cenários de aplicação no contexto de casas inteligentes . . . . .	3
2.1	Comparação entre arquiteturas adotadas em sistemas de monitorização . .	16
2.2	Comparação entre sistemas de monitorização em casas inteligentes . . . .	29
3.1	Requisitos funcionais do sistema <i>DistSense</i> . . . . .	35
3.2	Requisitos não funcionais do sistema <i>DistSense</i> . . . . .	36
3.3	Requisitos de sistema do sistema <i>DistSense</i> . . . . .	37
5.1	Especificações do dispositivo <i>Jetson Nano</i> . . . . .	95

# Definições e Acrónimos

**AAL** *Ambient Assisted Living*

**ADL** *Activities of Daily Living*

**AI** *Artificial Intelligence*

**ANN** *Artificial Neural Network*

**CBR** *Case-Based Reasoning*

**CNN** *Convolutional Neural Network*

**CV** *Computer Vision*

**DHCP** *Dynamic Host Configuration Protocol*

**DHT** *Distributed Hash Table*

**DL** *Deep learning*

**DNN** *Deep neural network*

**DNS-SD** *Domain Name System - Service Discovery*

**DT** *Decision Tree*

**edge AI** *Edge Artificial Intelligence*

**e-Health** *Electronic Health*

**FFNN** *Feedforward Neural Network*

**GDPR** *General Data Protection Regulation*

**GNS3** *Graphical Network Simulator 3*

**HA** *Home Assistant*

**IoT** *Internet of Things*

---

**IP** *Internet Protocol*

**JSON** *JavaScript object notation*

**LSTM** *Long Short Term Memory*

**mDNS** *Multicast DNS*

**ML** *Machine Learning*

**MQTT** *Message Queuing Telemetry Transport*

**WHO** *World Health Organization*

**PoW** *Proof of Work*

**P2P** *Peer-to-Peer*

**RGB** *Red, Green and Blue*

**RNN** *Recurrent Neural Network*

**R-CNN** *Region - Convolutional Neural Network*

**SBC** *Single Board Computer*

**SMAF** *Functional Autonomy Measurement System*

**SSL** *Secure Sockets Layer*

**SVM** *Support Vector Machine*

**TF** *TensorFlow*

**TFL** *TensorFlow Lite*

**TCP** *Transmission Control Protocol*

**TL** *Transfer learning*

**TLS** *Transport Security Layer*

**UDP** *User Datagram Protocol*

**UML** *Unified Modeling Language*

**UPnP** *Universal Plug and Play*

**UUID** *Universal Unique Identifier*

**VM** *Virtual Machine*

# Capítulo 1

## Introdução

### 1.1 Enquadramento e motivação

De acordo com a *World Health Organization* (WHO), prevê-se que, entre 2020 e 2030, cerca de 500 milhões de pessoas desenvolverão doenças cardíacas, obesidade, diabetes ou outras doenças não transmissíveis devido à inatividade física.

Este cenário gera a necessidade de criar uma solução que permita prevenir este tipo de problemas e que promova a saúde e a independência na população em geral, principalmente na população mais idosa.

Considerando que nos dias de hoje uma grande parte da população, acima de 65 anos, precisará de algum tipo de assistência a longo prazo para os seus próximos anos de vida, torna-se evidente que o planeamento de um sistema inteligente de cuidados prolongados, em termos financeiros, de gestão e de tecnologia, é mais urgente do que nunca.

Com base nessas razões, o foco deste estudo está voltado para o desenvolvimento de um sistema distribuído na vertente de casas inteligentes, com o objetivo de detetar atividades do quotidiano do utilizador, através da colaboração entre dispositivos para reduzir falsos positivos no reconhecimento de atividades.

Atualmente num contexto de *Internet of Things* (IoT), mais especificamente em *Ambient Assisted Living* (AAL), existem técnicas de deteção de atividades com recurso a sensores e dispositivos inteligentes, entre as demais, inclui a deteção através de câmaras de vídeo e microfones integrados em dispositivos inteligentes de deteção.

A utilização e integração dessas tecnologias através técnicas de *Computer Vision* (CV) em conjunto com técnicas de *Artificial Intelligence* (AI), permitem concentrar-se no reconhecimento de atividades domésticas, visando melhorar a segurança e qualidade de vida dos utilizadores.

Além disso, a colaboração em sistemas de monitorização emerge como um componente crucial. A colaboração distribuída, ao envolver múltiplos dispositivos, desempenha um papel fundamental na otimização da deteção de atividades complexas e na garantia da

---

segurança da informação sem comprometer a privacidade do utilizador.

Todavia, é necessário ter em consideração que cada utilizador é diferente e, por essa razão, podem existir vários cenários únicos com diversas atividades domésticas.

Um dos desafios em sistemas de AAL é a privacidade e confiabilidade, uma vez que, através da captação de informações audiovisuais, é necessário garantir ao utilizador que está protegido e não existem fugas de informação sensível para o exterior.

Outro desafio significativo nos sistemas de AAL é a deteção de atividades complexas. Uma possível solução para este problema reside na colaboração entre os dispositivos, a fim de processar e analisar as atividades em curso para reduzir falsos positivos. Esta abordagem é fundamental para aumentar o grau de certeza e, conseqüentemente, aprimorar a precisão na deteção das atividades realizadas pelo utilizador.

Considerando essas questões, o presente estudo tem como objetivo a implementação de uma solução de baixo custo que possa contribuir para resolver os desafios referidos na área de AAL utilizando câmaras de vídeo RGB e microfones integrados em dispositivos inteligentes.

Alguns dos cenários que os sistemas de deteção propõem solucionar encontram-se detalhados na tabela 1.1.

<b>Cenário de Aplicação</b>	<b>Descrição</b>
Deteção de quedas	A distribuição estratégica de sensores pela residência inteligente permite uma monitorização precisa de movimentos e acelerometria em diferentes divisões. Através de algoritmos avançados e colaboração entre os agentes, o sistema distingue de forma eficiente entre quedas reais e movimentos normais, reduzindo falsos alarmes. Ao detetar uma queda, aciona um alarme de emergência e envia notificações aos cuidadores ou serviços médicos, promovendo uma resposta rápida em situações críticas. A colaboração entre os agentes garante uma deteção precisa e confiável de quedas, minimizando falsos negativos e contribuindo para a segurança e bem-estar dos residentes.
Assistência pessoal	Mediante a integração de dispositivos e sensores inteligentes em toda a residência, o sistema distribuído almeja prover assistência pessoal num contexto de casas inteligentes. Desde a regulação da iluminação, temperatura e segurança, até a automação de tarefas domésticas, tais como o preparo de alimentos e a gestão de compromissos, o referido sistema viabiliza uma experiência personalizada e conveniente para os moradores, facilitando as suas atividades diárias. Como resultado, a vida dos utilizadores neste contexto é aprimorada, tornando-a mais cómoda e confortável.

Análise de hábitos de sono	Através da captação de dados recolhidos pela integração de dispositivos e sensores inteligentes, o sistema deve ser capaz de identificar padrões de sono e fornecer informação sobre a qualidade do sono de forma a otimizar os hábitos de descanso do utilizador. Este sistema contribui para uma melhor compreensão e promoção de um sono saudável e reparador, proporcionando benefícios significativos para o bem-estar e a qualidade de vida dos moradores.
Análise de padrões comportamentais	Com o intuito de identificar padrões comportamentais, como horários de sono, momentos de maior atividade física, uso de determinados dispositivos, entre outros. Através dos dados recolhidos pelos sensores inteligentes é possível retirar informações valiosas sobre o estilo de vida e bem-estar dos moradores, permitindo a personalização de serviços e a deteção de eventuais anomalias que possam indicar problemas de saúde ou situações de risco. Perante essas razões, o sistema contribui para o monitorização e a promoção de um ambiente residencial mais seguro, saudável e adaptado às necessidades individuais dos moradores.

Tabela 1.1: Cenários de aplicação no contexto de casas inteligentes

## 1.2 Objetivos

O objetivo principal desta pesquisa consiste no desenvolvimento de um sistema distribuído para deteção e classificação de atividades domésticas em habitações inteligentes, através da captura de imagens e áudio em tempo real, mantendo em consideração a privacidade e segurança como requisitos fundamentais do sistema.

Para alcançar este objetivo, será implementada uma arquitetura *Peer-to-Peer* (P2P) para a transmissão e processamento de dados capturados, com o auxílio de redes neuronais criadas com algoritmos de *Machine Learning* (ML) e AI.

Através da implementação destes algoritmos é possível detetar e processar localmente e de forma colaborativa as informações sobre as atividades domésticas audiovisuais capturadas, enviando apenas eventos relevantes para o utilizador, sem comprometer a sua privacidade.

Acrescenta-se, ademais, a este estudo a integração de um componente essencial visando otimizar a precisão no processo de deteção de atividades no âmbito doméstico. Tal melhoria será alcançada através da colaboração entre os dispositivos presentes na rede, através da integração de uma tecnologia de registo distribuído. Além disso, no cenário em que o dispositivo encarregado de detetar uma atividade não consegue fazê-lo com precisão, existe a oportunidade de consultar os registos distribuídos, contribuindo para a tomada de decisões mais assertivas na classificação de atividades, possibilitando reduzir a ocorrência de falsos positivos e falsos negativos.

A colaboração entre dispositivos proporcionará a partilha de informações relevantes entre os dispositivos conectados na rede, sendo que quando um dispositivo capta a ocor-

---

rência de uma atividade específica, este será capaz de notificar outros dispositivos na mesma rede, possibilitando assim uma validação mútua dos eventos detetados.

Ao longo das últimas décadas, o paradigma de computação evoluiu e permitiu o desenvolvimento de várias aplicações. Neste estudo, mantém-se a discussão do paradigma de computação em relação à IoT. Desta forma, todos os aspetos descritos ao longo dos capítulos seguintes levam em consideração três restrições de projeto pré-estabelecidas:

- Privacidade e Segurança de dados: dados sensíveis devem ser sempre protegidos quando armazenados, transferidos ou processados, de acordo com as regras europeias de proteção de dados (Consulting, 2020).
- Custo: como a solução deve garantir escalabilidade para cenários distintos, o custo unitário deve ser considerado na escolha entre abordagens e tecnologias.
- Conexão de Rede: visto que a solução deve garantir comunicação entre todos os dispositivos, é necessário considerar o tipo de comunicação e protocolos que se devem abordar.

Posto isto, visando a concretização do sistema em ambiente real, propõe-se a utilização de um conjunto de sensores audiovisuais integrados em dispositivos inteligentes, para criar um sistema distribuído de monitorização inteligente de baixo custo, tendo em conta que os sensores e os dispositivos, como *Jetson Nano* ou *Raspberry Pi*, são recursos comuns e amplamente disponíveis no mercado atual.

## 1.3 Metodologia

A utilização de sistemas inteligentes tem crescido exponencialmente nas últimas décadas, e com ele a necessidade de avaliar e compreender o seu funcionamento e desempenho.

Uma metodologia científica amplamente utilizada para testar esses sistemas é o método experimental. Esse método permite testar hipóteses sobre como o sistema funciona e se o mesmo é capaz de realizar tarefas específicas de forma eficiente. Esse processo é dividido em várias etapas, incluindo planeamento, execução, análise e interpretação dos resultados.

Desta forma, a metodologia proposta para esta investigação é sustentada, num primeiro momento, por analisar e testar todo o sistema em ambiente controlado, a fim de colmatar possíveis lacunas. Posteriormente, o objetivo é testar e comparar o seu desempenho em ambiente real.

A combinação de metodologias experimentais e de estudo de caso permite uma avaliação mais completa e abrangente do sistema de inteligência artificial. Além disso, técnicas como a simulação em ambiente controlado podem ser utilizadas para testar o sistema em

---

diferentes cenários e condições, o que é crucial para avaliar a robustez e escalabilidade do sistema.

É importante destacar que a recolha e análise de dados devem ser realizadas de forma ética e segura, sendo importante ter em conta o impacto social e ético do uso do sistema.

O método de estudo de caso permite compreender como os sistemas inteligentes se comportam em situações reais e permite desenvolver soluções mais eficazes e adaptadas às necessidades dos utilizadores (Clausen et al., 2018).

Perante as razões mencionadas, torna-se possível compreender as vantagens inerentes à adoção deste método. No contexto específico deste estudo, procede-se a uma análise do comportamento do sistema, através de testes conduzidos em ambientes simulados e reais, com o propósito de o avaliar em toda a sua extensão. Esse processo viabiliza a avaliação de múltiplos aspetos do sistema, incluindo o seu desempenho, usabilidade e comportamento em situações da vida real. Além disso, é importante considerar o impacto social e ético do uso do sistema, garantindo que a recolha e análise de dados sejam realizadas de forma ética e segura.

## 1.4 Contribuições

Nos dias atuais e num contexto *Internet of Things*, o conceito *edge intelligence* ainda está sob forte discussão. O termo refere-se à capacidade de dispositivos e sistemas de computação processarem informações de forma autónoma e local, sem dependerem inteiramente de recursos de processamento centralizados (Cao, 2022).

No entanto, dado o estado de desenvolvimento crescente dessa abordagem de computação, poucas soluções representativas apresentam implementações reais de um paradigma de *edge intelligence*.

Desta forma, com o objetivo de fazer parte desse movimento de tarefas computacionais mais complexas para as camadas inferiores da rede e, com foco em *Edge Artificial Intelligence* (edge AI), apresenta-se uma arquitetura de rede cujo foco é assegurar a privacidade e segurança dos dados dos utilizadores. Cada módulo de rede e canal de comunicação é cuidadosamente definido e descrito, mantendo em consideração os requisitos estabelecidos. Complementando essa especificação, são analisados os cenários de aplicação e avaliados os méritos da arquitetura proposta. Nesse sentido, algumas das principais contribuições que podem ser destacadas são:

- Implementação de uma arquitetura P2P de sensores inteligentes audiovisuais em ambientes domésticos (Sistema *DistSense*);
- Colaboração, entre os sensores inteligentes, na deteção e análise das atividades domésticas visando desambiguar situações com informação incerta;

- 
- Desenvolvimento de uma solução com garantia da integridade, segurança e privacidade dos dados do utilizador através do processamento e armazenamento local das informações capturadas;
  - Especificação e implementação do sistema *DistSense* em ambiente de simulação e ambiente real através da utilização de contentores *docker*;

Estas contribuições visam impulsionar o desenvolvimento e a adoção de sistemas distribuídos inteligentes, que ofereçam benefícios significativos para a qualidade de vida e o bem-estar dos utilizadores, ao mesmo tempo em que asseguram a proteção e privacidade de informações pessoais.

## 1.5 Estrutura do trabalho

Este documento está organizado em seis capítulos distintos: Introdução, Trabalhos relacionados em ambientes inteligentes, Especificação do sistema *DistSense*, Implementação do sistema *DistSense*, Testes e Avaliação, e, por fim, a Conclusão.

No primeiro capítulo, é apresentado o contexto do problema e a solução proposta pelo sistema *DistSense*, sendo que o objetivo principal é introduzir a importância da monitorização em ambientes domésticos, destacando os potenciais benefícios de um sistema inteligente distribuído nesse contexto.

De seguida, no capítulo dois, é realizada uma revisão de literatura abrangente, com foco nos sistemas de monitorização em ambientes domésticos, com o intuito de explorar diferentes aspetos relacionados à monitorização em casas inteligentes, incluindo o uso de tecnologias de simulação para facilitar a avaliação do sistema, a arquitetura de referência em sistemas de monitorização e uma revisão da literatura existente sobre sistemas de monitorização em casas inteligentes já implementados. Essa revisão da literatura visa fornecer uma base sólida para a proposta de arquitetura do sistema denominado *DistSense*.

Posteriormente, no capítulo três, descreve-se detalhadamente a arquitetura proposta para o sistema *DistSense*, onde são apresentados os diferentes módulos e componentes que o compõem, incluindo sensores, inicialização na rede, captura e processamento dos dados e a representação do conhecimento ao utilizador. Além disso, são discutidos os requisitos específicos do sistema a serem implementados, para garantir a eficácia do sistema.

No quarto capítulo, é abordada a implementação dos vários módulos descritos no capítulo da especificação do sistema, sendo apresentados os detalhes técnicos e as decisões de projeto adotadas durante o desenvolvimento do sistema. A implementação considera aspetos como inicialização do sistema, comunicação entre os dispositivos, algoritmos de aprendizagem computacional, processamento de dados em tempo real e representação do informações para o utilizador.

---

O capítulo cinco é dedicado à avaliação criteriosa do desempenho do sistema *DistSense* num ambiente de simulação controlado e num ambiente real, a fim de validar a eficácia e a precisão do sistema na detecção de eventos em tempo real. Os resultados obtidos são analisados e processados em relação ao cenário de aplicação implementado.

No último capítulo, são apresentados os resultados obtidos através da implementação e avaliação do sistema *DistSense*. São discutidas as contribuições e as limitações do trabalho realizado, além de serem sugeridas melhorias e possíveis desenvolvimentos futuros. Para além disso, é realizado um balanço sobre o sistema proposto acerca do seu potencial como uma solução inteligente para monitorização de ambientes domésticos, oferecendo benefícios em termos de segurança, colaboração e escalabilidade.

## Capítulo 2

# Trabalhos Relacionados em Ambientes Inteligentes

No âmbito desta investigação, exploram-se os trabalhos relacionados em ambientes inteligentes. Este capítulo tem como objetivo proporcionar uma compreensão abrangente dos avanços recentes na área de AAL, onde a monitorização desempenha um papel crucial na melhoria da qualidade de vida e no aumento da autonomia do utilizador.

A organização deste capítulo foi concebida para possibilitar uma análise sistemática e aprofundada dos sistemas de monitorização em ambientes inteligentes. Começa-se por apresentar uma arquitetura de referência, na qual se detalha o modelo comum na área AAL e as estruturas conceituais fundamentais que sustentam os sistemas de monitorização em ambientes inteligentes.

Seguidamente, dedica-se uma secção à exploração das diversas ferramentas e técnicas disponíveis para simular e modelar o funcionamento desses ambientes. Essa análise permite uma visão mais aprofundada das capacidades de simulação que podem ser utilizadas para emular o funcionamento dos sistemas de monitorização em cenários do mundo real.

Adicionalmente, realiza-se uma análise comparativa que se centra nas abordagens cliente-servidor e P2P, destacando as vantagens e desvantagens de cada modelo arquitetural de implementação, fornecendo uma base sólida para a tomada de decisões ao longo desta investigação.

Por fim, apresenta-se uma revisão de literatura abrangente sobre sistemas de monitorização que fazem uso de conjuntos de sensores para detetar atividades domésticas em ambientes inteligentes. A crescente adoção de tecnologias de monitorização tem impulsionado a pesquisa e o desenvolvimento de soluções inovadoras nessa área, com o objetivo de aprimorar a compreensão e a gestão em diversos contextos.

A revisão de literatura visa proporcionar uma compreensão aprofundada dos avanços recentes na área de *Ambient Assisted Living*, destacando as características, benefícios e limitações de cada abordagem. Além disso, discutir-se-ão os desafios enfrentados pelos sistemas de monitorização e as possíveis direções futuras de investigação.

## 2.1 Arquitetura de referência

A arquitetura implementada nos sistemas de monitorização em casas inteligentes, desempenha um papel crucial na recolha, processamento e análise dos dados provenientes dos diferentes sensores e dispositivos presentes no ambiente inteligente. Esses sistemas são responsáveis por supervisionar e monitorizar o funcionamento dos dispositivos, bem como fornecer informações úteis para a tomada de decisões dos moradores.

Na figura 2.1, é apresentada uma arquitetura comumente implementada nos sistemas de monitorização em casas inteligentes, descrita como arquitetura de rede em camadas. Esta abordagem divide o sistema em diferentes camadas, cada uma com uma função específica, com o intuito de permitir uma melhor organização dos componentes e facilitar a escalabilidade e a manutenção do sistema.

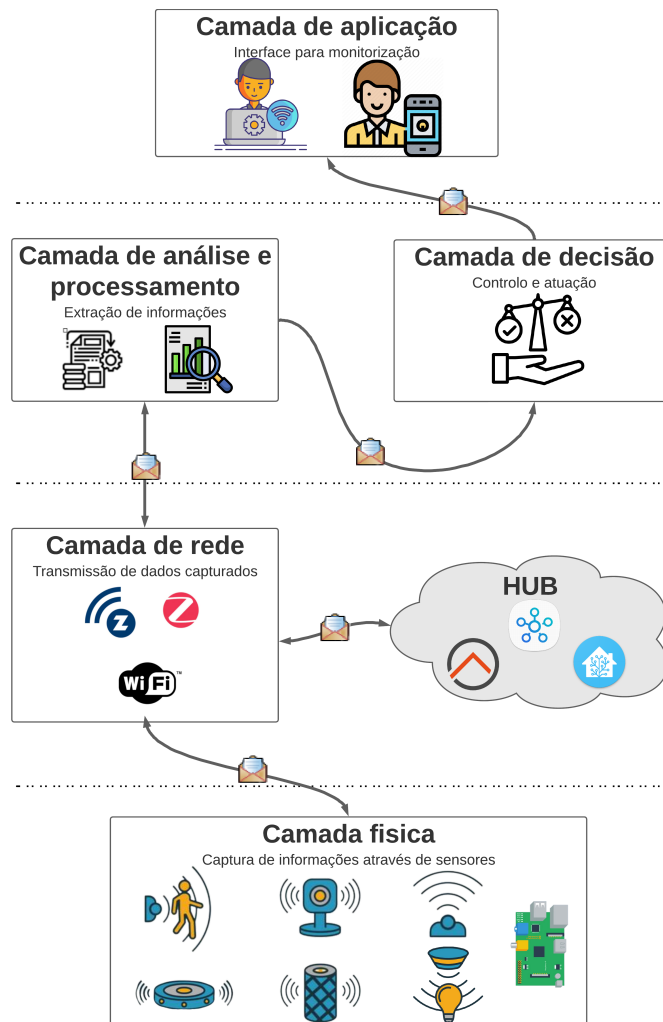


Figura 2.1: Arquitetura de referência - Modelo em camadas

Na camada inicial da arquitetura, denominada de camada física, estão presentes vários sensores com o propósito de realizar a captura de dados. Esses sensores são integrados em dispositivos de baixo custo, tais como a *Raspberry Pi* ou *Jetson Nano*, onde a função

---

primordial é adquirir informações provenientes do ambiente inteligente e encaminhá-las para a camada subsequente da arquitetura.

A segunda camada é a camada de rede, onde os dados recolhidos pelos sensores são enviados para um dispositivo central, como um *HUB* ou um controlador, por meio de tecnologias de comunicação, como *Wi-Fi*, *Bluetooth* ou *Zigbee*, garantindo a conectividade entre os dispositivos e o sistema central de monitorização.

A camada seguinte é referente à camada de análise e processamento, na qual os dados adquiridos pela camada anterior são processados e analisados para extrair informações relevantes. Algoritmos e técnicas de inteligência artificial podem ser aplicados nesta etapa para identificar padrões, realizar previsões e tomar decisões automatizadas com base nos dados recolhidos.

A quarta camada é a camada de decisão, onde as decisões tomadas com base na análise dos dados são convertidas em ações, por exemplo, se a temperatura ambiente estiver acima de um limite definido, o sistema pode acionar automaticamente o sistema de ar condicionado para controlar a temperatura ambiente. Essa camada permite a automação e o controlo remoto dos dispositivos presentes na casa inteligente.

Por fim, a quinta camada é a camada de aplicação para a qual são disponibilizadas interfaces intuitivas e amigáveis, como aplicações para telemóveis inteligentes, que permitem aos moradores interagir com o sistema de monitorização e controlar os dispositivos de forma fácil e conveniente.

Estudos que adotaram o modelo arquitetural descrito demonstram que esta implementação viabiliza a criação de residências inteligentes, que se destacam por serem eficientes, seguras e personalizadas, proporcionando aos seus moradores uma experiência confortável e inteligente.

## **2.2 Ferramentas para simulação de ambientes inteligentes**

A simulação de sistemas em ambiente inteligentes tem-se tornado uma abordagem cada vez mais relevante e promissora na área de monitorização. Em contraste com os testes realizados em ambiente real, a simulação oferece uma série de vantagens, permitindo a análise e avaliação de sistemas complexos, de forma mais conveniente, eficiente e económica.

A emulação de sistemas em ambiente inteligentes é um processo que envolve a criação de um modelo computacional que reproduz o comportamento de um sistema real, sendo que esse modelo pode ser desenvolvido ao utilizar-se uma variedade de técnicas, como a modelagem matemática, a física computacional e a computação gráfica.

Nesse contexto, um sistema de monitorização é um conjunto de dispositivos e sen-

---

sores que recolhem informações sobre o ambiente e os processos em tempo real, essas informações são analisadas e utilizadas para tomar decisões, identificar anomalias, prever comportamentos futuros e fornecer informações valiosas para a manutenção do sistema.

Uma das principais vantagens da simulação é a possibilidade de ter controle total sobre as condições de teste, cenários e parâmetros do sistema, isso permite a realização de testes em diferentes configurações, variando as cargas de trabalho e emulando condições extremas, as quais seriam difíceis ou arriscadas de se reproduzir num ambiente real, essa flexibilidade viabiliza uma análise aprofundada do comportamento do sistema e a otimização dos seus componentes antes da implementação em larga escala.

Além disso, a simulação é um processo rápido e eficiente para avaliar o desempenho e a eficácia de um sistema, ao contrário da implementação num contexto real, que necessita de tempo e recursos consideráveis, esta metodologia permite a execução ágil de experiências num ambiente virtual, acelerando o processo de desenvolvimento, possibilitando a identificação precoce de problemas e a realização de ajustes necessários para aprimorar o sistema.

Outra vantagem importante da simulação é a segurança e redução de riscos, uma vez que ao emular o sistema é possível mitigar riscos e garantir a proteção dos dados e recursos envolvidos.

Num ambiente virtual, os impactos de falhas e erros são controlados, permitindo a realização de testes em condições seguras, dessa forma, evita-se possíveis anomalias num ambiente real, enquanto se tem a oportunidade de avaliar a robustez e a resiliência do sistema, sem comprometer a integridade da infraestrutura ou a confidencialidade dos dados.

Adicionalmente, a simulação oferece a possibilidade de recolher dados detalhados sobre o desempenho, a eficiência e a escalabilidade do sistema distribuído inteligente, essas informações podem ser analisadas minuciosamente, identificando obstáculos, pontos de melhoria e oportunidades de otimização.

A utilização do *Graphical Network Simulator 3* (GNS3) e contentores *Docker* para realizar a simulação de sistemas em ambiente virtual é uma abordagem prática e eficiente, tendo em conta que essas ferramentas fornecem recursos poderosos para criar ambientes de rede virtualizados e executar aplicações em contentores, permitindo simular diferentes componentes de um sistema e testar todo o comportamento em condições controladas.

O *Graphical Network Simulator 3* (GNS3) é uma plataforma avançada e versátil de simulação de redes, que permite a criação de topologias complexas de rede por meio da virtualização de *routers*, *switches*, *firewalls* e outros dispositivos de rede.

Através do GNS3, é possível recriar a interconexão e o fluxo de dados entre esses dispositivos, proporcionando uma representação virtual que se assemelha de forma próxima a um ambiente de rede real (Neumann, 2015).

O GNS3 utiliza uma abordagem baseada em emulação e virtualização para reproduzir as funcionalidades dos dispositivos de rede no ambiente virtual, isso é alcançado por meio



---

nós de simulação.

Essas ferramentas fornecem recursos poderosos para simular sistemas complexos em condições controladas, permitindo uma análise e avaliação mais conveniente, eficiente e econômica.

A automação dos testes, por meio da utilização de *scripts*, proporciona a execução de testes coerentes, assegurando, assim, a qualidade do sistema de monitorização, sendo que estes *scripts* podem abranger testes unitários, de integração e até mesmo testes de carga, contribuindo para a validação do desempenho e estabilidade do sistema.

Adicionalmente, a adoção de contentores *docker* simplifica o processo de implantação do sistema num ambiente real, visto que, ao encapsular o sistema juntamente com as suas dependências num contentor isolado, é possível garantir a consistência entre os ambientes de desenvolvimento, teste e produção.

Neste sentido, os contentores *docker* fornecem uma abordagem padronizada e portátil para o encapsulamento do sistema, o que torna o processo de implantação mais rápido e fácil de ser realizado.

Ao combinar a utilização do GNS3 com os contentores *docker*, é possível criar simulações mais abrangentes e realistas de sistemas de monitorização, esta abordagem permite a simulação de uma infraestrutura de rede complexa no GNS3, utilizando dispositivos virtuais como *routers* e *switches*, onde posteriormente, dentro desses dispositivos, permite executar contentores *docker* que representam serviços e aplicações específicas do sistema de monitorização.

Perante estas razões, a integração entre o GNS3 e os contentores *docker* oferece várias vantagens, incluindo a possibilidade de testar o desempenho da rede, avaliar a interoperabilidade entre os componentes do sistema, simular tráfego de dados realista e explorar diferentes configurações e cenários sem impactar o ambiente de produção para a deteção precoce de problemas e para a entrega de um produto final de elevada qualidade aos utilizadores, ao mesmo tempo que se reduz os riscos e a complexidade associada à implantação em ambientes produtivos.

## 2.3 Sistemas Cliente-Servidor vs Sistemas *Peer-to-Peer*

A monitorização em ambientes inteligentes é uma área em crescimento que visa proporcionar soluções tecnológicas com o intuito de aprimorar a segurança, o conforto e a eficiência energética das habitações. O termo "Ambientes inteligentes" refere-se a espaços residenciais ou comerciais equipados com dispositivos conectados e integrados com sensores, que recolhem dados e permitem o controlo remoto para melhorar a experiência dos utilizadores (Solaimani et al., 2015). Neste contexto, surgem duas abordagens arquiteturais principais: sistemas centralizados e sistemas distribuídos.

Num sistema centralizado de monitorização de ambientes inteligentes, todas as infor-

mações e funcionalidades são concentradas e processadas num único ponto de controlo, como um servidor ou *HUB*, responsável por recolher dados provenientes de sensores espalhados pela casa e controlar os dispositivos conectados, permitindo que os utilizadores monitorizem e interajam remotamente com o ambiente inteligente (Oluwatosin, 2014). Os sistemas centralizados que adotam uma arquitetura cliente-servidor, ilustrada na figura 2.3a, têm sido amplamente adotados em espaços inteligentes, proporcionando uma abordagem tradicional para a monitorização e controlo de dispositivos e ambientes domésticos inteligentes.

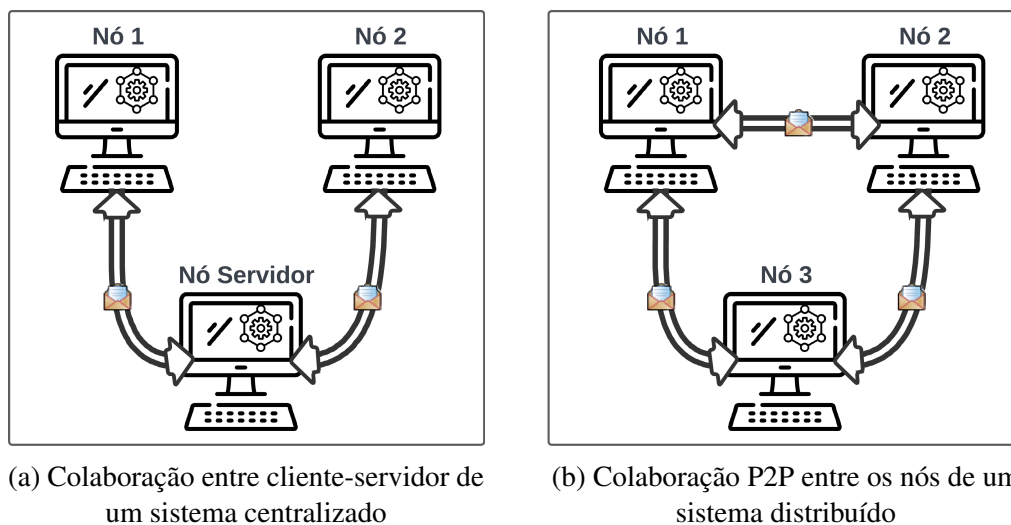


Figura 2.3: Modelos Arquiteturais utilizados em Sistemas de Monitorização

Nesta abordagem, o cliente representa qualquer dispositivo habilitado a interagir com o ambiente inteligente na rede doméstica, podendo assumir a forma de sensores, atuadores ou outras entidades inteligentes que recolhem informações acerca do ambiente e enviam os dados resultantes ao servidor central. Adicionalmente, os dispositivos clientes podem enviar solicitações ao servidor com o objetivo de obter informações ou aceder a serviços específicos.

O servidor central assume a responsabilidade de receber, armazenar e analisar os dados capturados por esses dispositivos e sensores. Essas informações são então utilizadas para fundamentar a tomada de decisões, que podem abranger uma variedade de ações e respostas, conforme necessidades ou requisitos específicos do utilizador.

Além disso, o servidor central assume a tarefa de enviar comandos de volta aos dispositivos clientes. Esses comandos são projetados para instruir os dispositivos a executarem as ações e tarefas solicitadas pelo utilizador ou em conformidade com as decisões tomadas com base nos dados analisados. Desse modo, o sistema de monitorização avançado torna-se capaz de proporcionar uma experiência mais eficiente e personalizada ao utilizador, além de contribuir para uma gestão inteligente e automatizada dos recursos e equipamen-

---

tos no ambiente doméstico ou em qualquer outro contexto em que a abordagem centralizada seja aplicada.

A comunicação entre o cliente e o servidor geralmente ocorre através da rede local. Neste contexto, o cliente pode fazer uso de um dispositivo central, conhecido como *HUB*, que pode ser fornecido pelo fabricante ou por terceiros. O *HUB* desempenha um papel fundamental ao conectar os dispositivos inteligentes, permitindo, assim, a interação com o ambiente inteligente.

Este serviço, permite estabelecer uma conexão direta com o servidor central, capacitando o utilizador a visualizar o estado do ambiente, receber alertas, definir preferências e enviar comandos de acordo com as suas necessidades e preferências (Blackstock and Lea, 2014).

Em comparação com a abordagem centralizada, os sistemas distribuídos emergem como uma alternativa que proporciona maior flexibilidade e escalabilidade. A implementação destes sistemas num ambiente residencial inteligente permite que cada dispositivo possa atuar como um nó autónomo, sendo capaz de recolher dados provenientes de sensores e executar ações com base nesse conhecimento. Adicionalmente, têm a capacidade de comunicar e colaborar entre si, partilhando informações e coordenando atividades para oferecer uma monitorização eficiente e equilibrada da habitação.

Nesse sentido, os sistemas distribuídos que implementam uma arquitetura P2P, apresentada na figura 2.3b, caracterizam-se por distribuir as funções de monitorização, processamento e controlo entre múltiplos dispositivos interconectados na rede doméstica, permitindo que todos os dispositivos inteligentes atuem tanto como clientes quanto como servidores (Milojicic et al., 2002). Esta abordagem oferece vantagens significativas, uma vez que a escalabilidade é um dos benefícios proeminentes, permitindo a adição de novos dispositivos à rede sem sobrecarregar um único ponto de controlo. Adicionalmente, a redundância dos recursos distribuídos aumenta a resiliência do sistema, garantindo uma maior disponibilidade e continuidade da monitorização, mesmo em caso de falhas, o que assegura a integridade das informações e do sistema.

Contudo, esta abordagem apresenta alguns desafios, como a coordenação e gestão dos dispositivos, o que requer algoritmos e protocolos adequados. Além disso, a comunicação entre os dispositivos pode ser afetada por atrasos e falhas na rede, exigindo mecanismos de tolerância a falhas e estratégias de recuperação eficazes.

Ambas as abordagens visam proporcionar ambientes residenciais mais seguros, eficientes e convenientes. Para interpretar melhor as características de cada uma, é realizada uma análise comparativa qualitativa entre ambas as arquiteturas, presente na tabela 2.1, na qual foram considerados critérios de avaliação, como a escalabilidade, interoperabilidade, eficiência, tolerância a falhas, segurança e integridade em sistemas de monitorização.

<b>Critério</b>	<b>Arquitetura Cliente-Servidor</b>	<b>Arquitetura <i>Peer-to-Peer</i></b>
Escalabilidade	-	++
Interoperabilidade	+-	++
Eficiência	++	++
Segurança	-	++
Integridade	+-	+
Tolerância a falhas	-	++

Tabela 2.1: Comparação entre arquiteturas adotadas em sistemas de monitorização

A arquitetura cliente-servidor, embora possa oferecer uma visão abrangente do ambiente doméstico, demonstra algumas limitações. Em termos de escalabilidade, esta abordagem enfrenta dificuldades à medida que o número de dispositivos monitorizados aumenta, pois todo o processamento e armazenamento de dados são centralizados numa única entidade. Por outro lado, a arquitetura P2P destaca-se pela sua alta escalabilidade, permitindo a distribuição de tarefas de monitorização em nós descentralizados e facilitando o aumento flexível da capacidade de monitorização à medida que novos dispositivos são adicionados.

No que diz respeito à interoperabilidade, a arquitetura cliente-servidor pode enfrentar desafios na gestão de diferentes protocolos de comunicação ou sistemas heterogêneos, onde a padronização dos dados e protocolos pode ser complexa.

Em contrapartida, a arquitetura P2P pode lidar melhor com a interoperabilidade, pois cada nó distribuído pode ser adaptado para interagir com dispositivos específicos, facilitando a troca de informações através de protocolos padronizados.

Em termos de eficiência, ambas as arquiteturas, cliente-servidor e P2P, apresentam pontos fortes. A arquitetura cliente-servidor pode consolidar todos os dados num único ponto, facilitando a análise e tomada de decisões. No entanto, isso pode levar a perdas de desempenho e atrasos na transferência de dados para o ponto central. A arquitetura P2P destaca-se em termos de latência e utilização de recursos, visto que cada nó distribuído pode processar localmente os dados capturados, reduzindo a carga do sistema e permitindo uma resposta mais rápida em tempo real.

Os sistemas que adotam uma arquitetura cliente-servidor, se o servidor falhar, todos os clientes são impactados, resultando em uma interrupção significativa dos serviços e comprometendo a integridade e o bom funcionamento do sistema.

Em contraste, nas redes P2P, a tolerância a falhas é uma característica intrínseca ao sistema, onde cada nó na rede é um ponto de acesso e contribuição de recursos, a falha

---

de um nó específico não compromete a funcionalidade global da rede. Em vez disso, outros nós podem compensar a perda de recursos, mantendo a integridade do sistema. No entanto, a complexidade da gestão de recursos e da comunicação entre pares pode criar desafios na detecção e recuperação de falhas, requerendo mecanismos robustos de coordenação e resiliência para garantir a continuidade dos serviços na rede P2P.

A segurança e a integridade dos dados são dois aspectos intrinsecamente ligados nos sistemas de monitorização em espaços inteligentes domésticos. Ao adotar uma arquitetura cliente-servidor, embora seja possível consolidar todas as informações num único ponto e estabelecer regras e políticas centralizadas, também existe o risco de criar um ponto único de falha que pode ser alvo de ataques cibernéticos.

No caso de ocorrer uma falha de segurança num sistema centralizado, todos os dados podem ser comprometidos, afetando tanto a confidencialidade como a integridade das informações.

Em compensação, a arquitetura P2P, ao dispersar os dados e as tarefas de monitorização em diversos nós, apresenta uma maior resiliência em termos de segurança, uma vez que se um nó distribuído for comprometido, apenas uma parte do sistema será afetada, preservando a confidencialidade e a integridade dos demais dados de monitorização.

Em última análise, a seleção da arquitetura dependerá dos objetivos de monitorização, das características do ambiente inteligente e da importância atribuída a cada critério de avaliação, visto que seja qual for a escolha, ambas as abordagens têm o potencial de contribuir para ambientes residenciais mais seguros, eficientes e convenientes, contribuindo para a evolução da tecnologia em benefício dos utilizadores.

## **2.4 Sistemas de monitorização em casas inteligentes**

Atualmente, o termo "casas inteligentes" está gradualmente a tornar-se parte integrante do nosso quotidiano. A *Internet of Things* (IoT) acrescenta uma nova dimensão a este conceito, não sendo surpreendente que existam mais dispositivos conectados à IoT do que seres humanos, demonstrando o seu impacto significativo no dia-a-dia do utilizador.

Com o avanço da tecnologia ao longo dos últimos anos, tornou-se viável a recolha de dados sobre as atividades do quotidiano do utilizador. No entanto, interpretar esses dados e reconhecer as ações correspondentes, de maneira eficiente, continua a ser um desafio.

Nesse sentido, diversos estudos abordam sistemas que implementam técnicas de *Machine Learning* (ML), as quais têm-se mostrado promissoras ao lidar com a complexidade e variabilidade dos dados obtidos.

Os sensores desempenham um papel fundamental nos sistemas de casas inteligentes, sendo componentes essenciais para a recolha de dados e monitorização de diversos parâmetros e atividades no ambiente residencial, fornecendo informações úteis ao utilizador.

A figura 2.4 ilustra alguns dos parâmetros a analisar em casas inteligentes. Os dados capturados pelos sensores abrangem desde sinais vitais, como frequência cardíaca e pressão arterial, até ao controlo do ambiente inteligente, como temperatura e luminosidade.

Adicionalmente, com a utilização de sensores inteligentes, é possível capturar atividades realizadas pelo utilizador ao longo do seu dia-a-dia, obtendo uma compreensão mais aprofundada dos padrões comportamentais e da interação com o ambiente residencial inteligente.




Figura 2.4: Parâmetros comuns a avaliar em casas inteligentes

À medida que os sensores recolhem informações sobre as atividades diárias dos utilizadores, como rotinas, preferências e comportamentos, surge a questão de como esses dados são utilizados e protegidos. Há receios de que terceiros possam ter acesso indevido a essas informações pessoais, o que possibilita violações de privacidade e até mesmo o uso indevido dos dados.

A segurança dos dados é uma preocupação crítica no contexto de casas inteligentes, visto que os dados recolhidos pelos sensores podem ser transferidos e armazenados em servidores remotos, criando potenciais vulnerabilidades para ataques cibernéticos e/ou violações de segurança. Os utilizadores estão preocupados com a possibilidade de que informações sensíveis, como dados biométricos ou padrões de comportamento, possam ser comprometidas e exploradas por agentes maliciosos.

Outra questão importante é a aceitabilidade dos sensores intrusivos por parte dos utilizadores. Embora esses sensores possam fornecer benefícios significativos, como automação conveniente e personalização das configurações domésticas, alguns utilizadores podem sentir-se desconfortáveis com a ideia de ter dispositivos que monitorizam constantemente as suas atividades e capturam dados pessoais sensíveis.

A invasão da privacidade e a sensação de vigilância constante podem gerar resistência e relutância em adotar essas tecnologias.

Assim, surgem duas abordagens principais em relação ao sensoriamento: sensores intrusivos e sensores não intrusivos. Estas abordagens distinguem-se pela forma como

são implementadas e pelo grau de invasão ou alteração exigido no ambiente residencial.

Diversos estudos têm explorado estas duas abordagens em sistemas para casas inteligentes, procurando encontrar soluções eficientes e adequadas às necessidades dos utilizadores.

Alguns destes trabalhos combinam a utilização de sensores intrusivos e não intrusivos, com o intuito de obter uma visão mais abrangente e precisa no contexto do ambiente inteligente. Estas abordagens híbridas podem, por exemplo, conjugar a instalação de sensores intrusivos em pontos estratégicos para monitorizar o ambiente de forma não intrusiva.

No âmbito da monitorização de casas inteligentes, surgem conceitos importantes, como *fog computing*, *edge computing* e *cloud computing*, ilustrados na figura 2.5, que desempenham papéis fundamentais no processamento e armazenamento de dados.

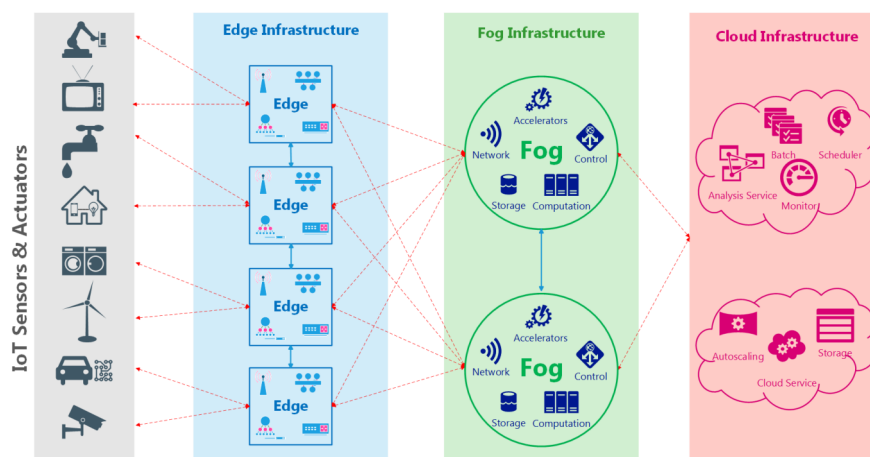


Figura 2.5: Arquitetura *edge-fog-cloud* apresentada no estudo de (Cao et al., 2019)

A *cloud computing* trata-se de um paradigma amplamente utilizado, que permite o armazenamento e processamento de dados em servidores remotos acessíveis pela *internet*. Deste modo, os dados capturados pelos dispositivos de monitorização numa casa inteligente podem ser enviados para a nuvem, onde são armazenados e processados, permitindo análises avançadas e o acesso remoto aos dados, facilitando a tomada de decisões informadas e fornecendo uma visão abrangente do estado da casa.

Embora essa abordagem ofereça benefícios em termos de capacidade de armazenamento, análises avançadas e acesso remoto aos dados, também suscita preocupações relacionadas à privacidade. Ao enviar os dados de monitorização para a nuvem, existe a possibilidade de que informações pessoais sensíveis sejam armazenadas em servidores de terceiros, aumentando o risco de violações de privacidade, especialmente se medidas de segurança adequadas não forem implementadas.

No entanto, em alguns casos, é imperativo realizar um processamento mais célere e eficiente dos dados recolhidos. Neste contexto, o paradigma de *edge computing* desem-

---

penha um papel crucial. Ao contrário da *cloud computing*, o *edge computing* envolve a realização de tarefas de processamento e análise de dados diretamente nos dispositivos de monitorização ou em servidores próximos a estes, permitindo reduzir significativamente a latência e a sobrecarga na rede, possibilitando respostas rápidas e ações imediatas com base nas informações obtidas.

Por exemplo, caso um sensor detete uma anomalia numa habitação inteligente, o dispositivo de *edge computing* pode agir instantaneamente para garantir a segurança do ambiente.

Adicionalmente, esta abordagem traduz-se numa redução da necessidade de transferir informações sensíveis para a nuvem, o que contribui para minimizar os riscos associados ao armazenamento de dados pessoais em servidores remotos, proporcionando maior controlo sobre a privacidade dos utilizadores.

Para otimizar ainda mais o processamento e a gestão de dados em ambientes residenciais inteligentes, entra em jogo o conceito de *fog computing*, desempenhando um papel essencial. Neste cenário, parte do processamento ocorre nos dispositivos de *edge computing*, enquanto outra parte é realizada em servidores localizados em pontos intermédios, denominados *fog gateways*.

Os *gateways* encontram-se estrategicamente mais próximos da nuvem do que os dispositivos de ponta, permitindo uma combinação eficiente de processamento local e acesso aos recursos da nuvem. Essa abordagem possibilita equilibrar a carga de trabalho entre os dispositivos de ponta e a nuvem, tirando proveito da capacidade de processamento local e da escalabilidade da nuvem, o que garante uma monitorização mais eficiente e contínua das habitações inteligentes.

Este enfoque controlado na distribuição de informações e no processamento fornece um ambiente mais seguro para os dados recolhidos, aumentando a resiliência do sistema, para que quando ocorram falhas, estas não comprometam a totalidade dos dados do utilizador.

É fundamental enfatizar que a capacidade de resposta em tempo real dos sistemas de *edge computing* constitui um dos principais pilares desta abordagem, uma vez que isso se traduz numa redução significativa da latência, permitindo respostas praticamente instantâneas em diversas situações.

Além disso, a redução da comunicação entre dispositivos periféricos e a nuvem contribui para a poupança de recursos de rede e energia consumida pelos nós, sendo esta característica especialmente relevante em ambientes de domótica inteligentes, onde a eficiência energética assume uma preocupação preponderante.

Diversos estudos têm sido conduzidos para explorar as capacidades e benefícios dos sistemas de monitorização em ambientes inteligentes, esses estudos abrangem várias áreas, incluindo saúde, eficiência energética e segurança.

Na área da *e-Health*, há uma ampla gama de estudos que investigam os sistemas

---

de monitorização em ambientes inteligentes, visando aprimorar o acompanhamento e cuidado dos pacientes, com o propósito de melhorar o bem-estar e qualidade de vida do utilizador.

Nesse contexto, os sistemas de monitorização em casas inteligentes são desenvolvidos para monitorizar sinais vitais, como pressão arterial, batimentos cardíacos, níveis de glicose, entre outros, permitindo um acompanhamento remoto contínuo do estado de saúde dos pacientes.

Na investigação de (Tewell et al., 2019), os autores descrevem o desenvolvimento de uma *framework* designada por *SCAMPI* (*Self-Care Advice, Monitoring, Planning, and Intervention*). Essa *framework* é composta por vários sensores inteligentes, com o objetivo de permitir que pessoas com demência e/ou doença de *parkinson* monitorizem atividades significativas e atividades do quotidiano de forma autónoma.

Para isso, os autores propuseram a utilização de sensores de baixo custo e facilmente disponíveis no mercado, a fim de garantir a aceitação por parte dos utilizadores. A informação recolhida pelos sensores é armazenada numa base de dados local e, posteriormente, é realizada uma análise crítica dos dados capturados, a qual permite fornecer uma visão da progressão da doença, uma vez que os padrões de atividade variam conforme o estado de saúde do utilizador se deteriora.

O sistema opera com uma variedade de protocolos de comunicação, como *Wi-Fi*, *Bluetooth*, *Zigbee* e *z-wave*, para permitir a integração dos diversos sensores. Um elemento essencial do sistema é a *Raspberry Pi*, que atua como um *HUB* central para a monitorização das atividades.

Nesse *HUB* central, os autores optaram por executar o *Home Assistant* (HA) na *Raspberry Pi*, possibilitando a integração dos diferentes protocolos de comunicação e a captura dos dados dos sensores, sendo que esta abordagem desempenha um papel central no processamento e armazenamento dos dados capturados, permitindo a realização de análises críticas para identificar padrões e tendências relevantes para a progressão da doença.

Os dados recolhidos pelos sensores são armazenados numa base de dados e posteriormente analisados localmente de forma crítica, a fim de fornecer informações valiosas sobre a progressão da doença e as mudanças nos padrões de atividade relacionados à saúde do utilizador.

Para testar essa abordagem, realizaram duas avaliações distintas à *framework* proposta: um estudo em laboratório para testar a instalação do sistema, incluindo a precisão e colocação dos sensores, e um estudo em ambiente real, no qual pessoas que não eram utilizadores-alvo, mas que se identificavam como entusiastas de tecnologia, avaliaram a viabilidade da *framework* para monitorizar atividades em e ao redor de residências inteligentes reais.

O público-alvo do estudo, em ambiente real, relatou obstruções mínimas durante a instalação e foi capaz de realizar e desfrutar de atividades do dia-a-dia sem ser preju-

---

dicado pelos sensores, revelando que atividades significativas podem ser monitorizadas remotamente utilizando sensores passivos e acessíveis.

No entanto, os autores afirmam que através do uso de sensores menos invasivos não é possível determinar, com algum grau de certeza, as atividades que o utilizador está a executar, como poderia ser feito através da utilização de sensores mais invasivos, em detrimento da privacidade, como por exemplo sensores audiovisuais.

No estudo conduzido por (Rajan Jeyaraj and Nadar, 2022), os autores propõem um sistema que aborda a questão de obter um serviço de saúde confiável por meio de previsões precisas do provedor de serviços. A arquitetura proposta neste sistema é composta por módulos, descritos da seguinte forma:

1. Módulo de monitorização: Este módulo é composto por um conjunto de sensores inteligentes vestíveis em conjunto com o processador *myRio*, uma vez que o mesmo atua como um dispositivo semelhante à *Raspberry Pi*, mas com capacidade limitada de realizar várias tarefas;
2. Módulo de processamento: Neste módulo, o processador *myRio* transmite os dados adquiridos pelos sensores utilizando o protocolo *Wi-Fi*;
3. Módulo de visualização e armazenamento de dados: Utilizam a plataforma *EVOTHINGS*, este módulo recebe os dados do módulo de processamento e permite a visualização e análise dos resultados, possibilitando a monitorização contínua dos sinais fisiológicos do paciente.

Para extrair as características dos sinais fisiológicos recebidos pelo conjunto de sensores, os autores propuseram uma abordagem de *Deep neural network* (DNN), composta por três camadas, seguindo critérios como *linear separability* na primeira camada, conectividade total na segunda camada e construção do modelo de *Deep learning* na terceira camada, em que características como o tempo de aquisição do sinal fisiológico e a magnitude do sinal foram consideradas.

Como forma de validar o sistema, os autores realizaram uma comparação com outros trabalhos relacionados, utilizando diferentes modelos, onde concluíram que o sistema proposto apresenta uma precisão de, aproximadamente, 97,2%, o que indica que o sistema permite garantir a monitorização e a previsão precisa dos sinais fisiológicos monitorizados.

Além da importância na extração de informações sobre os sinais vitais dos utilizadores, os sistemas de monitorização também têm desempenhado um papel fundamental no acompanhamento e análise das atividades físicas do quotidiano do utilizador.

Esses sistemas são desenvolvidos com o propósito de adquirir e registar dados pertinentes referentes à atividade física, possibilitando uma avaliação mais precisa e minuciosa do desempenho e comportamento dos utilizadores.

---

Um exemplo interessante é o estudo de (Rupasinghe and Maduranga, 2022), que descreve o desenvolvimento de um sistema baseado em IoT para monitorização em tempo real das atividades físicas de pessoas idosas, utilizando acelerómetros.

O objetivo subjacente desta pesquisa consiste em superar a limitação da capacidade de monitorização das atividades físicas, particularmente devido ao crescimento do setor socioeconómico, o qual tem resultado num rápido aumento no número de idosos que vivem em áreas remotas, tais como casas de repouso.

Nessas circunstâncias, a saúde de pessoas idosas vulnerabiliza-se devido à diminuição das capacidades motoras e/ou cognitivas. O presente projeto de pesquisa pretende satisfazer a necessidade de um sistema capaz de recolher detalhes vitais dos utilizadores, através de um dispositivo de pulso de baixo custo capaz de capturar o movimento da mão em três eixos distintos.

Adicionalmente, os autores referem que foi necessário que o sensor escolhido fornecesse leituras precisas de forma consistente, além de ter uma taxa de deteção adequada e baixa latência para operar em tempo real.

No desenvolvimento desta investigação, foi identificada a necessidade de um nó principal, responsável por processar as leituras dos sensores e utilizar técnicas de ML supervisionado para reconhecer as atividades executadas pelo utilizador.

Um dos desafios encontrados durante o desenvolvimento desta investigação foi garantir a conectividade entre o dispositivo vestível IoT e o nó principal. Para solucionar essa questão, foi utilizado um *router Wi-Fi* compatível com o padrão *IEEE 802.11b/g/n*, permitindo a transmissão dos sinais detetados para o processamento e reconhecimento das atividades.

A escolha cuidadosa do *hardware* e a atenção à conectividade são elementos essenciais para o funcionamento adequado deste sistema. Essas considerações garantem que as leituras dos sensores sejam processadas de forma eficiente e precisa, possibilitando a deteção e classificação das atividades físicas dos utilizadores monitorizados.

Na figura 2.6, é ilustrada a vista geral da arquitetura desta investigação. O sistema é composto por um dispositivo vestível IoT, um nó principal, um servidor em nuvem e uma aplicação móvel.

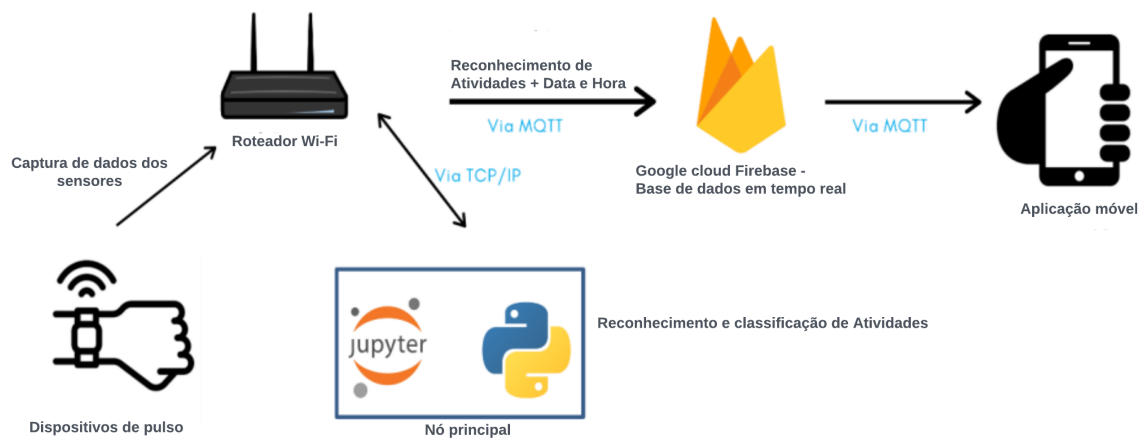


Figura 2.6: Arquitetura centralizada de (Rupasinghe and Maduranga, 2022)  
 [Figura adaptada para português de Portugal]

O dispositivo vestível IoT desenvolvido é responsável por medir as flutuações na aceleração do utilizador e transmitir essas informações em tempo real para o nó principal. A conexão entre o dispositivo vestível IoT e o nó principal é estabelecida por meio de um *router Wi-Fi*, onde utilizam o protocolo TCP/IP para a transmissão de dados.

O nó principal desempenha o papel central no sistema, processando os sinais recolhidos e fornecendo previsões ou resultados com base neles, sendo, posteriormente, transmitidas para um servidor em nuvem via *Message Queuing Telemetry Transport (MQTT)*.

Outro aspeto significativo deste estudo é a utilização de técnicas de aprendizagem computacional para reconhecer atividades simples como caminhar, sentar, dormir e ficar em pé. O uso destas técnicas é avaliado para superar as barreiras do reconhecimento de atividade em tempo real. O algoritmo de classificação implementado pelos autores foi o algoritmo de árvore de decisão, uma vez que possibilita obter uma precisão do modelo superior a 80%.

Além disso, outra área de interesse na monitorização de ambientes inteligentes é a eficiência energética, onde sistemas centralizados permitem a gestão e controlo inteligente do consumo de energia, otimizando a sua utilização e reduzindo custos.

No artigo de (Franco et al., 2021), os autores propõem uma abordagem intrusiva para a monitorização de consumos energéticos, através de um sistema de reconhecimento de atividades baseado numa arquitetura IoT que combina soluções avançadas nos seus diferentes módulos. A arquitetura referida é composta por cinco camadas: dispositivos, perceção, comunicação, *middleware* e aplicação. Através da implementação desta arquitetura, é garantida a escalabilidade geral do sistema, permitindo suportar diferentes aplicações domésticas, como a classificação das atividades diárias.

Na camada de dispositivo, é estabelecido um fluxo de dados que é posteriormente enviado para a camada superior, designada de camada de perceção, responsável pela aquisição dos dados.

---

Posteriormente, a camada de *middleware* atua como intermediário entre a interação dos dispositivos IoT e as aplicações de *software*, funcionando como uma camada de abstração entre a interface do utilizador e todos os dispositivos implantados. No topo da arquitetura encontra-se a camada de aplicação, que se refere aos serviços específicos dedicados aos utilizadores.

Os modelos de ML são aplicados no módulo de reconhecimento do dispositivo, para o qual foram testados três modelos diferentes utilizando o conjunto de dados denominado por *United Kingdom-Domestic Appliance Level Electricity (UK-DALE): Feedforward Neural Network (FFNN)*, *Long Short Term Memory (LSTM)* e *Support Vector Machine (SVM)*. Este conjunto de dados contém dados reais sobre dispositivos presentes em cinco casas distintas em Londres. Durante o processo de treino do modelo, os autores consideraram apenas informações da primeira residência, devido à variação no número de dispositivos presentes em cada habitação.

Adicionalmente, realizaram mais alguns testes para analisar o impacto do tamanho do grupo na precisão do classificador de ML. Esses grupos consistiam num número fixo de amostras a partir das quais os aparelhos inteligentes são identificados. Se o tamanho do grupo diminuir ou aumentar, espera-se o mesmo comportamento em relação à precisão, exceto para o modelo LSTM, que aumenta a precisão quando o tamanho do grupo é maior.

Uma crítica referente a esta abordagem é que o sistema proposto não funciona em tempo real, no entanto, é capaz de identificar atividades simultâneas ao analisar sequências de vetores de recursos, independentemente dos intervalos de tempo.

A precisão dos classificadores *FFNN* e *LSTM* ficou acima de 90%, enquanto a do *SVM* ficou em torno de 80%. Com base nos resultados obtidos, os autores concluíram que é preferível realizar um novo treino do classificador com dados atualizados antes de implantar o sistema em pleno funcionamento.

Com a crescente adoção de casas inteligentes e a utilização generalizada de dispositivos conectados, surgem preocupações significativas em relação à privacidade e segurança dos dados. À medida que as tecnologias avançam, sensores intrusivos são cada vez mais integrados nos ambientes domésticos, levantando questões sobre a aceitabilidade por parte dos utilizadores.

Para solucionar estas preocupações, o estudo de (Fleck and Straßer, 2010) propõe uma abordagem baseada em câmaras inteligentes distribuídas para a monitorização sensível à privacidade no cuidado de idosos. Os autores apresentam uma arquitetura de um sistema distribuído que inclui câmaras inteligentes e dispositivos de processamento de imagem para detetar eventos invulgares e rastrear a atividade dos indivíduos. O sistema foi concebido para preservar a privacidade do utilizador, incluindo medidas de segurança e anonimato.

Nesta investigação, são mencionadas algumas vantagens adicionais com a utilização de câmaras inteligentes em sistemas de monitorização para o cuidado de idosos, como

---

a capacidade de reconhecimento facial e de objetos, que podem ser usados para detetar eventos anormais de forma mais precisa e rastrear a atividade dos utilizadores de forma mais detalhada. Desta forma, o sistema pode ser expandido para incluir outros sensores, como sensores de movimento e de pressão, para melhorar ainda mais a precisão e a cobertura do sistema.

Em seguida, são discutidas as implicações éticas do uso de câmaras inteligentes no cuidado de idosos, como a questão da vigilância constante e a possibilidade de invasão da privacidade dos utilizadores. Os autores argumentam que esses problemas podem ser resolvidos por meio de medidas de segurança e anonimato, bem como por meio de diálogo e consentimento explícito dos pacientes e cuidadores. Além disso, salientam a importância de como o sistema pode ser projetado para evitar o uso indevido ou a exploração dos dados capturados.

Como forma de avaliar e validar o sistema proposto, foram realizados testes em ambientes controlados e ambientes reais com pacientes idosos. Através dos resultados obtidos, o sistema desenvolvido foi capaz de detetar eventos anormais e rastrear a atividade dos pacientes com precisão, e que o sistema foi bem recebido pelos pacientes e cuidadores, onde a privacidade foi adequadamente protegida.

No estudo (Facchini et al., 2020), os autores procuram detetar comportamentos maliciosos numa rede IoT através da colaboração entre os dispositivos. Para isso, é utilizado um sistema de deteção de Intrusão Distribuído (IDS) que implementa um classificador binário baseado em ML para analisar recursos extraídos de dados do *kernel*, da rede e da *Distributed Hash Table* (DHT).

Os autores propõem uma arquitetura P2P composta por dispositivos inteligentes, como televisões inteligentes, colunas inteligentes e frigoríficos inteligentes, que são responsáveis por um conjunto de dispositivos não tão inteligentes, como sensores de temperatura espalhados pela casa, usados pelo sistema de aquecimento inteligente. Estes dispositivos inteligentes são interconectados por meio de uma rede doméstica comum e compartilham dados de aplicativos numa DHT, em que colocam periodicamente dados relacionados com o seu comportamento, num determinado período de tempo. Cada nó inteligente contém um agente do sistema de deteção de intrusão que examina o comportamento dos outros nós em três níveis diferentes: *kernel*, rede e DHT.

Para detetar comportamentos maliciosos, é utilizado um mecanismo de reputação distribuído, para o qual o nó que deteta um comportamento malicioso de outro nó, coloca um "recurso" na DHT contendo essa informação para convidar outros nós a excluí-lo da rede. De maneira a evitar que nós maliciosos declarem indevidamente nós benignos como maliciosos, os autores sugerem a utilização de um mecanismo de reputação distribuído para atribuir uma pontuação de reputação de forma colaborativa.

Para facilitar a operabilidade do sistema, os autores utilizam um algoritmo popular de DHT denominado de *Kademlia*, que reduz as mensagens de introdução entre os nós,

---

configura automaticamente os nós de rede e direciona as consultas por caminhos de baixa latência. Essa abordagem contribui significativamente para a eficiência e agilidade do sistema como um todo.

Com o aumento da utilização de câmaras inteligentes em ambientes domésticos, o desenvolvimento de algoritmos para redes distribuídas tem despertado bastante interesse.

O reconhecimento de ações humanas em múltiplos pontos de vista enfrenta desafios como invariância de visualização, nível de iluminação e oclusão. No entanto, devido à enorme quantidade de dados processados e comunicados em aplicações do mundo real, adaptar esses algoritmos para redes de câmaras inteligentes é uma tarefa complexa.

Nesse sentido, a investigação de (Mosabbeh et al., 2013) apresenta uma ferramenta de classificação de atividades distribuída. Neste estudo, várias câmaras observam uma cena e cada uma processa as suas próprias observações, chegando a um acordo sobre a atividade que ocorre por meio da comunicação com outras câmaras.

Esse método baseia-se em completude de matriz por consenso, utilizando otimização convexa para realizar a completude de matriz distribuída.

O foco deste estudo é o reconhecimento de atividades humanas, e o desempenho é testado nos conjuntos de dados *IXMAS* e *MuHAVi* para demonstrar sua viabilidade.

Os resultados obtidos com o algoritmo demonstram a eficácia nos conjuntos de dados utilizados, alcançando uma precisão de 85,9%. A completude de matriz mostra-se como uma ferramenta valiosa para lidar com dados ruidosos e variações nas atividades humanas.

Como perspectivas futuras, sugerem realizar os procedimentos de treino e teste incrementalmente, para resumir grandes volumes de dados em matrizes menores, o que poderá proporcionar maior eficiência computacional e menor tempo de processamento. Além disso, explorar outras abordagens de otimização e técnicas de aprendizagem computacional pode contribuir para aprimorar o desempenho desta ferramenta em ambientes distribuídos complexos.

Outra área que tem emergido como um tópico de pesquisa em evidência em ambientes inteligentes é a aplicação de tele-assistência e monitorização. Estes serviços têm como objetivo inferir o estado dos pacientes através de arquiteturas centralizadas que recolhem dados de um conjunto de sensores instalados no ambiente residencial. No entanto, quando o cenário aumenta em tamanho e o número de pacientes a monitorizar aumenta, esses sistemas normalmente enfrentam dificuldades ao processar todos os dados associados e fornecer resultados razoáveis em tempo real.

Nesse sentido, o artigo de (Navarro et al., 2018) apresenta o conceito de uma plataforma distribuída de AAL que visa acionar alarmes com base na detecção acústica de eventos específicos em diversos ambientes residenciais, como áreas residenciais, residências particulares e lares. A arquitetura proposta é inspirada no paradigma de *fog computing* e é projetada para dividir as camadas de detecção, processamento e acionamento de alarmes, atendendo às necessidades crescentes em termos de cobertura de área e tempo

---

de resposta dos sistemas modernos de AAL.

A plataforma é capaz de lidar com cenários de grande escala e foi adaptada para atender aos requisitos da organização sem fins lucrativos *Fundación Ave Maria*. Além disso, foi implementado um sistema de classificação automática de eventos acústicos sobre essa arquitetura distribuída. O processo de classificação é dividido em duas etapas. A primeira etapa baseia-se numa *Artificial Neural Network* (ANN) e realiza uma detecção de eventos acústicos em tempo real, com uma precisão geral de 85,4% e uma pontuação F1 de 71%. A segunda etapa de classificação considera a evolução temporal dos eventos detectados em um intervalo de 10 segundos, utilizando um algoritmo de *Case-Based Reasoning* (CBR) e um conjunto de heurísticas, o que permite aumentar a precisão geral do sistema para 94,6% e a pontuação F1 para 90,58%, quando duas transmissões de dados acústicos simultâneas são consideradas.

Apesar do conjunto de dados de treino limitado, o protótipo apresenta uma precisão razoável na detecção dos eventos de interesse em cenários amplos de AAL, com uma sobrecarga computacional aceitável e custos arquitetônicos limitados. Ainda há espaço para melhorias no sistema, como a aplicação de técnicas mais sofisticadas de *data mining*, *Transfer learning* ou incrementar o conjunto de dados, o que permitiria melhorar a precisão do sistema. Além disso, ajustes no modelo da ANN e do CBR após a implantação do sistema de acordo com as características do ambiente podem contribuir para otimizar o desempenho.

Como trabalho futuro, os pesquisadores planeiam criar um novo conjunto de dados num ambiente real com múltiplos sensores, visando maximizar o desempenho do protótipo proposto. Além disso, procuram aprimorar a detecção de eventos acústicos, considerando todos os sensores da rede como um todo. Com esse aprofundamento, o sistema tem o potencial de se tornar uma base sólida para o desenvolvimento de serviços de AAL cada vez mais eficientes e confiáveis, promovendo uma maior qualidade de vida para idosos e pessoas dependentes no seu cotidiano.

## 2.5 Análise comparativa

A monitorização de ambientes inteligentes tem ganhado reconhecimento substancial como uma abordagem altamente promissora para aprimorar significativamente a eficiência e a segurança em contextos domésticos, ao permitir a transformação de residências convencionais em espaços altamente adaptativos e automatizados, oferecendo uma ampla gama de vantagens.

Os estudos explorados destacam o potencial dos sistemas centralizados e/ou distribuídos de monitorização em ambientes inteligentes para melhorar a saúde, a eficiência energética e o conforto dos utilizadores, permitindo uma monitorização mais eficaz e uma interação aprimorada com o espaço inteligente.

Na tabela 2.2 é realizada uma análise crítica com objetivo de examinar e contrastar os principais sistemas de monitorização investigados na literatura, considerando critérios fundamentais como o modelo arquitetural, modelo de ML, modelo de computação, sensores e *HUBs* utilizados. Além disso, é dada especial atenção às abordagens adotadas em relação à segurança e privacidade dos dados, considerando o cenário cada vez mais sensível e regulamentado no contexto da proteção de informações pessoais do utilizador.

Sistema	Modelo Arquitetural	Modelos ML	Modelo Computação	Sensores	Privacidade	HUB
(Fleck and Straßer, 2010)	Distribuído	SVM	<i>Edge</i>	Vídeo	Sim	-
(Mosabbeh et al., 2013)	Distribuído	-	<i>Fog</i>	Vídeo	Sim	-
(Navarro et al., 2018)	Distribuído	ANN & CBR	<i>Fog</i>	Vídeo	Sim	-
(Tewell et al., 2019)	Centralizado	-	<i>Cloud</i>	Ambiente	Não	Home Assistant
(Facchini et al., 2020)	Distribuído	Múltiplas Abordagens	<i>Edge</i>	Ambiente	Sim	-
(Franco et al., 2021)	Centralizado	Múltiplas Abordagens	<i>Fog</i>	Ambiente	Não	-
(Rupasinghe and Maduranga, 2022)	Centralizado	Árvore de decisão	<i>Cloud</i>	Vestível	Não	Google Firebase
(Rajan Jeyaraj and Nadar, 2022)	Centralizado	DCNN	<i>Cloud</i>	Vestível	Não	EVOTINGS

Tabela 2.2: Comparação entre sistemas de monitorização em casas inteligentes

No que concerne aos modelos arquiteturais explorados, constata-se que os sistemas que fazem uso de sensores intrusivos, tais como áudio e/ou vídeo, tendem a adotar uma abordagem distribuída. Esta escolha pode ser atribuída às vantagens inerentes à descentralização do processamento, à salvaguarda da privacidade dos dados e à minimização dos pontos críticos de falha. Os sistemas de natureza distribuída apresentam uma maior redundância, o que contribui para uma maior fiabilidade do sistema como um todo. No entanto, é importante notar que os sistemas centralizados examinados na presente análise podem oferecer uma gestão e controlo mais simplificados, embora possam demonstrar menor escalabilidade em cenários de elevada procura. Esta limitação é particularmente evidente nos sistemas centralizados em que um *HUB* central desempenha o papel de coordenador na comunicação entre dispositivos, resultando numa redução de tolerância a eventuais falhas que possam ocorrer, corroborando o que foi apresentado na secção 2.3.

Os modelos de ML desempenham um papel fundamental na análise de dados e na tomada de decisões nos sistemas de monitorização em casas inteligentes. A análise com-

---

parativa revela que, embora os estudos investigados apliquem algoritmos de ML para detecção de atividades e otimização de processos, ainda existe uma falta de padronização na escolha de algoritmos específicos. Esta falta de uniformidade sugere uma oportunidade para futuras investigações que possam identificar os modelos de ML mais eficazes para aplicações específicas.

No que diz respeito ao modelo de computação, os sistemas de monitorização distribuídos explorados adotam um modelo *fog computing* ou *edge computing*, caracterizados pela descentralização do processamento e armazenamento dos dados. Em vez de enviar todos os dados para um centro de processamento remoto, os dados são processados e armazenados em nós próximos aos dispositivos e sensores que os produzem. Nessa abordagem, os dispositivos inteligentes possuem capacidade computacional para realizar tarefas de processamento básico e filtragem dos dados antes de enviá-los para um ponto central de agregação ou para a nuvem, permitindo reduzir a latência e aliviar a sobrecarga da rede, tornando a monitorização mais eficiente e em tempo real.

Por sua vez, o modelo de computação *cloud computing* adotado pelos sistemas de monitorização centralizados baseia-se na concentração de recursos e dados numa infraestrutura remota. Neste modelo, os dados são enviados pelos dispositivos locais para servidores remotos, onde são processados e armazenados. A partir destas infraestruturas, as análises mais complexas são executadas, e os resultados são enviados de volta para os dispositivos locais ou para um centro de controlo central, proporcionando grande escalabilidade e capacidade de armazenamento, além de possibilitar a execução de algoritmos mais avançados.

Além disso, a privacidade é um aspeto crítico quando se trata da monitorização de ambientes inteligentes domésticos. Nesse contexto, é possível constatar que a maioria dos sistemas distribuídos demonstra preocupação com a proteção da privacidade dos utilizadores, utilizando mecanismos de segurança ou pedindo acesso de utilização aos utilizadores.

Através da análise comparativa dos sistemas investigados, é enfatizado dois aspetos fundamentais que são considerados essenciais no desenvolvimento do sistema *DistSense*: a privacidade dos utilizadores e a adoção de uma abordagem de uma colaboração entre os dispositivos inteligentes através da implementação de uma arquitetura distribuída. A privacidade é um ponto crítico para garantir a confiança e segurança dos utilizadores, onde a importância de proteger os seus dados sensíveis é reconhecida, assegurando que apenas informações de alto nível sejam armazenadas após o processamento local.

Posto isto, é possível afirmar que o modelo de arquitetura distribuído é o mais apropriado para a implementação do sistema *DistSense*, visto que a colaboração entre os dispositivos inteligentes traz vantagens significativas, corroborando o que foi apresentado na tabela 2.1.

Mediante a utilização de sensores intrusivos, uma abordagem distribuída é especial-

---

mente importante, visto que, com a combinação de informações provenientes de múltiplas fontes, o sistema é capaz de obter uma visão mais abrangente e precisa do ambiente.

## Capítulo 3

# Especificação do Sistema *DistSense*

Este capítulo tem como objetivo fornecer uma descrição detalhada da arquitetura implementada, destacando os diferentes módulos que viabilizam a colaboração entre os vários nós na rede local, a fim de assegurar um desempenho adequado e a segurança abrangente de todo o sistema.

A arquitetura do sistema é composta por diversos componentes interligados, que cooperam para permitir a comunicação e a troca de informações entre os nós. Esses componentes incluem o módulo de inicialização e descoberta na rede, módulo de comunicação, módulo de aprendizagem computacional e o módulo de processamento e representação do conhecimento.

No que diz respeito aos requisitos na implementação do sistema, considerando os cenários de aplicação apresentados, foram estabelecidos requisitos funcionais e não funcionais que desempenham um papel fundamental na garantia do seu sucesso.

Os requisitos funcionais definem as funcionalidades específicas que o sistema deve oferecer, como a partilha de informações, a comunicação em tempo real e a colaboração na detecção de atividades domésticas no quotidiano do utilizador. Já os requisitos não funcionais abrangem aspetos como o desempenho, a segurança, a escalabilidade e a usabilidade do sistema, estabelecendo padrões e objetivos a serem alcançados em cada um desses aspetos.

### **3.1 Cenário de aplicação: Sistema de monitorização distribuído para o reconhecimento de atividades domésticas**

A evolução tecnológica tem impulsionado avanços significativos em várias áreas, incluindo a forma como os dados são monitorizados e geridos. Um dos cenários de aplicação mais promissores é a implementação de sistemas de monitorização em espaços

---

inteligentes a longo prazo, que combinam dispositivos conectados, sensores avançados e algoritmos de análise de dados para recolher informações em tempo real.

Essa abordagem oferece benefícios em diversas situações, incluindo a promoção da saúde e bem-estar num contexto residencial inteligente.

Nesse sentido, é exemplificado o cenário da Dona Rosa, uma mulher idosa que reside numa pacata vila costeira de Portugal, na qual desfruta dos confortos de uma casa inteligente, onde sensores e dispositivos são utilizados para monitorizar as suas atividades diárias, através da recolha de dados relevantes para sua saúde e qualidade de vida. No entanto, a privacidade dos seus dados pessoais é uma preocupação primordial para Dona Rosa, o que a leva a procurar uma solução segura e confidencial para a gestão dos seus dados.

Como forma de garantir os requisitos da Dona Rosa, o sistema implementado na sua habitação adota uma abordagem distribuída, pelo que, em vez de enviar os dados para um serviço exterior, as informações são processadas localmente, dentro dos limites da sua própria residência. Essa configuração permite que a Dona Rosa mantenha o controlo exclusivo sobre os seus dados pessoais, decidindo quando e com quem deseja compartilhá-los.

Esta abordagem distribuída de monitorização oferece à Dona Rosa um nível aprimorado de deteção e privacidade, para que os seus dados permaneçam na sua casa, protegidos de olhares indiscretos e acessos indesejados. Desta forma, pode desfrutar dos benefícios da tecnologia inteligente, sabendo que a confidencialidade dos seus dados está preservada e que possui total controlo sobre a forma como os mesmos estão a ser tratados.

Ao longo de um período de monitorização contínua, o sistema inteligente compila e analisa os dados recolhidos, onde é possível fornecer um diagnóstico personalizado para Dona Rosa com base nessas informações. Por exemplo, caso a análise revele uma semana com pouca atividade física, o sistema pode sugerir opções de exercícios adequados à sua condição física, incentivando-a a tornar-se mais ativa.

É importante salientar que, durante todo o processo, a privacidade da Dona Rosa é rigorosamente respeitada, sendo que os dados são utilizados exclusivamente para fins de monitorização e melhoria da sua saúde, para os quais mantém o total controlo sobre o acesso e a utilização dos seus dados pessoais.

A Dona Rosa tem a capacidade de definir as suas preferências de privacidade e pode optar por partilhar os seus dados com profissionais de saúde, apenas em situações específicas e autorizadas.

Desta forma, a Dona Rosa beneficia da monitorização a curto e longo prazo, recebendo um diagnóstico personalizado e recomendações para melhorar a sua saúde, enquanto mantém a privacidade dos seus dados como uma prioridade absoluta. A aceitabilidade e confiança no sistema são garantidas, permitindo-lhe desfrutar dos benefícios de um ambiente inteligente, sem comprometer a sua privacidade.

## 3.2 Arquitetura genérica

Os avanços na área de monitorização têm proporcionado melhorias significativas na recolha e análise de dados sobre as atividades dos utilizadores. No entanto, através da revisão de literatura descrita no capítulo 2, é possível observar que sistemas que adotam uma arquitetura centralizada podem apresentar determinadas desvantagens, tais como a falta de privacidade, a segurança dos dados e a tolerância a falhas.




Figura 3.1: Vista geral da arquitetura do sistema *DistSense*

Neste contexto, propõe-se uma abordagem distribuída que visa fornecer um sistema seguro e confiável para a comunicação e monitorização de dados sensíveis do utilizador. Na figura 3.1, é apresentada uma visão geral da arquitetura proposta nesta investigação, na qual o sistema é composto por nós independentes, designados por *peers*, que estabelecem conexões uns com os outros para formar uma rede do tipo *Peer-to-Peer* (P2P).

Essa arquitetura distribuída permite uma interação descentralizada entre os dispositivos, promovendo maior resiliência e escalabilidade na gestão dos dados sensíveis e favorecendo a segurança e confiança no tratamento dessas informações.

Nesse sentido, é essencial identificar e compreender os requisitos necessários para o correto funcionamento de um sistema distribuído para a monitorização de ambientes inteligentes.

Desta forma, os requisitos funcionais do sistema *DistSense* são especificados na tabela 3.1, onde são descritas as funcionalidades e capacidades específicas que o sistema proposto deve possuir, a fim de responder às necessidades e objetivos do ambiente em que

está inserido.

ID	Descrição dos requisitos funcionais
RF001	O sistema deve ser capaz de identificar automaticamente novos dispositivos quando estes se conectam à rede doméstica, permitindo uma integração fácil de novos dispositivos na rede existente, sem intervenção manual por parte do utilizador
RF002	O sistema deve proporcionar a comunicação eficaz entre todos os dispositivos disponíveis na rede, utilizando protocolos e tecnologias apropriados de acordo com as características da rede e dos dispositivos envolvidos, possibilitando uma interconexão sem problemas entre os dispositivos na rede doméstica
RF003	O sistema deve ser capaz de reconectar automaticamente um dispositivo à rede, caso ocorra uma desconexão não planeada, assegurando uma experiência contínua para o utilizador, mesmo em caso de falhas temporárias na conectividade
RF004	O sistema deve monitorizar a atividade dos dispositivos na rede para determinar se estão ativos ou inativos, isso é importante para a gestão da rede e a segurança, permitindo ao utilizador saber quais dispositivos estão atualmente em funcionamento
RF005	O sistema deve ser capaz de identificar e reconhecer automaticamente atividades rotineiras do quotidiano do utilizador, de acordo com os casos de uso definidos
RF006	O sistema deve ser capaz de comunicar com o utilizador, enviando alertas e informações relevantes através de uma plataforma de automação residencial de código aberto, permitindo que o utilizador esteja ciente de eventos importantes ou situações específicas na sua habitação
RF007	O sistema deve manter um registo histórico detalhado das informações relevantes relacionadas com a deteção de atividades domésticas através dos sensores audiovisuais. Esses dados são armazenados de acordo com uma linha temporal, permitindo aos nós colaborativos consultar eventos passados quando necessário

Tabela 3.1: Requisitos funcionais do sistema *DistSense*

Os requisitos não funcionais estão intrinsecamente ligados aos critérios de qualidade que validam os requisitos funcionais. Esses critérios podem abranger diversos aspetos, tais como desempenho, usabilidade, confiabilidade e robustez (Tockey, 2019).

A tabela 3.2 apresenta uma descrição pormenorizada dos requisitos não funcionais, os quais englobam características como a capacidade de processamento em tempo real de grandes volumes de dados, bem como a necessidade de alta confiabilidade, a fim de evitar a perda de dados ou falhas significativas. Além disso, é fundamental que o sistema seja suficientemente robusto para enfrentar adversidades, como falhas de rede.

ID	Descrição dos requisitos não funcionais
RNF001	O sistema deve ser capaz de processar sequências de áudio e imagens em tempo real, o que significa que deve garantir a capacidade de captar, analisar e responder a dados audiovisuais com latência mínima.

RNF002	O sistema deve ser concebido de forma a ser escalável, ou seja, deve ter a capacidade de se expandir e lidar com um aumento no número de dispositivos sem comprometer o desempenho. Além disso, deve garantir a privacidade dos dados, assegurando que as informações pessoais dos utilizadores sejam protegidas de acessos não autorizados. A segurança deve ser uma prioridade, protegendo o sistema contra ameaças cibernéticas e garantindo a integridade dos dados.
RNF003	O sistema deve ser desenvolvido de forma a minimizar os custos, utilizando aplicações e bibliotecas de software gratuitas sempre que possível.
RNF004	O sistema deve ser capaz de lidar com falhas de rede de forma robusta e continuar a funcionar mesmo em condições adversas, incluindo a capacidade de recuperar automaticamente de interrupções de conectividade e manter a operação normal do sistema sempre que possível.

Tabela 3.2: Requisitos não funcionais do sistema *DistSense*

Na tabela 3.3 estão estabelecidas as necessidades de *software* e *hardware* essenciais para a implementação bem-sucedida do sistema de monitorização proposto.

No desenvolvimento do sistema, é requerido o uso de uma linguagem de programação de alto nível. Essa escolha visa aproveitar as vantagens oferecidas por linguagens modernas e robustas, que facilitam o desenvolvimento, a manutenção e a escalabilidade do sistema. Além disso, linguagens de alto nível proporcionam maior produtividade e flexibilidade no desenvolvimento de algoritmos e na integração com outros componentes do sistema.

Adicionalmente, são adotados algoritmos de inteligência artificial e técnicas de visão computacional. A aplicação dessas técnicas permite a análise e interpretação inteligente dos dados audiovisuais capturados pelas câmaras e microfones, possibilitando o reconhecimento de padrões no quotidiano do utilizador através da identificação de eventos relevantes. A sua utilização contribui para uma melhor compreensão do ambiente monitorizado e auxilia na tomada de decisões.

Em termos de *hardware*, o sistema requer o uso de câmaras de vídeo e microfones integrados num microcomputador do tipo *Jetson Nano* ou *Raspberry Pi*, sendo este de placa única (*Single Board Computer* (SBC)) que oferece uma solução compacta, de baixo custo e com baixo consumo de energia. A capacidade de processamento e recursos de conectividade destes dispositivos tornam-nos adequados para aplicações de monitorização.

A utilização de microfones e câmaras de vídeo integradas em cada dispositivo inteligente permite a captura direta das imagens e áudio, onde posteriormente é realizado o processamento local das informações capturadas, simplificando a implementação e melhorando a eficiência do sistema.

ID	Descrição dos requisitos de sistema
RS001	O sistema deve ser desenvolvido utilizando uma linguagem de programação de alto nível, como por exemplo <i>Python</i>
RS002	O sistema deve incorporar algoritmos de aprendizagem computacional e técnicas de visão computacional
RS003	O sistema deve integrar microfones e câmaras de vídeo integradas num dispositivo inteligente de baixo custo e acessível no mercado, como o <i>Jetson Nano</i> ou <i>Raspberry Pi</i>

Tabela 3.3: Requisitos de sistema do sistema *DistSense*

Mediante os requisitos de *software* e *hardware*, é possível desenvolver e implantar um sistema de monitorização que utilize linguagens de programação modernas, algoritmos de aprendizagem computacional, bem como câmaras e microfones integrados num dispositivo inteligente. Essa combinação proporciona uma solução capaz de processar e analisar dados audiovisuais de maneira distribuída e eficiente, contribuindo para uma monitorização precisa e efetiva.

### 3.3 Lógica de funcionamento

O sistema *DistSense* tem como finalidade a aquisição contínua e a análise de dados audiovisuais pertinentes, com o propósito de monitorizar o ambiente inteligente. Através da obtenção destas informações relevantes e representativas, possui a capacidade de detetar tendências, anomalias e padrões, fornecendo dados valiosos para sustentar decisões fundamentadas.

Além disso, o sistema opera de forma distribuída, onde os nós presentes na rede colaboram de forma coordenada, sincronizando esforços para assegurar um maior grau de certeza na determinação de eventos capturados.

Nesse sentido, cada dispositivo no sistema *DistSense* é composto por quatro módulos principais, representados na figura 3.2, onde desempenham funções específicas, atuando em perfeita sinergia para uma monitorização eficiente do ambiente inteligente.

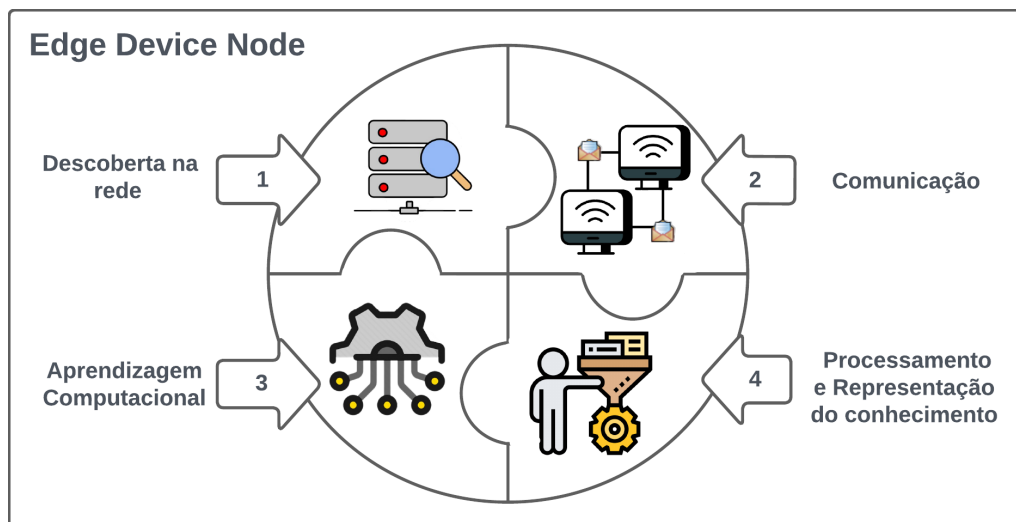


Figura 3.2: Módulos de funcionamento de um nó do sistema *DistSense*

Num primeiro momento, quando um *peer* é inicializado, é realizado o processo de descoberta de *peers* para encontrar nós vizinhos disponíveis na rede local, esse processo, pode ser realizado por meio de diferentes mecanismos, como protocolos de rede ou mecanismos baseados em consultas, o que permite que os *peers* se encontrem e estabeleçam conexões entre si.

Assim que tenham sido descobertos e conectados, é realizado o processo de eleição para determinar o nó coordenador, que tem como objetivo desempenhar um papel específico no sistema distribuído.

Os algoritmos de eleição são projetados para eleger um nó designado por coordenador entre o conjunto de nós em execução, de forma que em qualquer instante de tempo haja um único líder. A eleição pode ser baseada em diferentes critérios, como capacidade de processamento, disponibilidade ou até mesmo algoritmos de consenso distribuído (Mamun et al., 2004).

Dessa forma, é possível garantir a presença de um coordenador confiável, facilitando a coordenação e a gestão adequada das tarefas a executar.

Após realizado o processo de eleição, ou quando há nós suficientes na rede, os *peers* podem começar a comunicar uns com os outros. A comunicação entre os nós é realizada por meio de canais seguros e encriptados, para garantir a confidencialidade e integridade dos dados transmitidos. Essa abordagem garante que apenas os *peers* autorizados possam acessar e interpretar as informações enviadas por outros *peers*.

Posteriormente à configuração inicial da rede, cada nó tem como objetivo capturar e processar informações audiovisuais de forma eficiente, permitindo uma análise inteligente em tempo real dos eventos ocorridos no espaço monitorizado

A figura 3.3 ilustra o fluxo de dados de cada dispositivo presente no sistema *DistSense*, sendo que a fase primordial consiste na captação dos dados audiovisuais. Nesta etapa, são utilizados sensores e dispositivos cuidadosamente projetados para recolher informações

relevantes do ambiente sob observação.

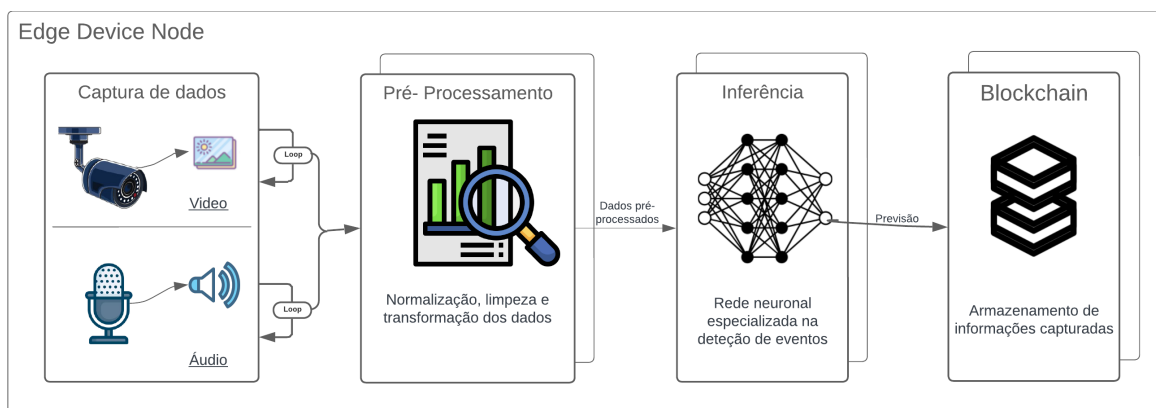


Figura 3.3: Fluxo de dados do sistema *DistSense*

Numa etapa subsequente, os dados capturados são sujeitos a um procedimento de pré-processamento. Esta fase assume um papel crucial na garantia da qualidade e fiabilidade dos dados antes da sua submissão à análise. Durante o pré-processamento, os dados são normalizados, limpos e transformados. A normalização visa a padronização dos dados, garantindo que estes assumam um formato consistente e adequado para análises posteriores. Por sua vez, a limpeza tem como objetivo identificar e corrigir possíveis imperfeições e ruídos presentes nos dados, de modo a assegurar a precisão dos resultados obtidos. Em seguida, a transformação dos dados visa otimizar a sua representação, permitindo a extração eficiente de informações relevantes.

Uma vez concluído o pré-processamento local, os dados são enviados ao modelo de análise e inferência. Este modelo é desenvolvido com base em técnicas avançadas de ML, concedendo-lhe a capacidade de efetuar uma análise profunda dos dados audiovisuais. Através deste processo, o modelo consegue extrair padrões, identificar eventos e fornecer previsões acerca dos acontecimentos no espaço monitorizado, assumindo, deste modo, um papel de elevada importância na tomada de decisões e monitorização de situações críticas.

Adicionalmente, os dados capturados sobre as atividades realizadas no quotidiano pelo utilizador são armazenados de forma distribuída e descentralizada através da utilização da tecnologia *blockchain*, como é demonstrado na figura 3.5.

Além disso, com a implementação de uma arquitetura P2P, é possível identificar algumas vantagens referidas na secção 2.3. Em primeiro lugar, elimina pontos únicos de falha, já que não depende de um servidor central para a operação do sistema. De seguida, a descentralização permite escalabilidade, uma vez que novos *peers* podem ser adicionados à rede sem afetar significativamente o desempenho global do sistema.

Neste contexto, considerando as preocupações relevantes acerca da aceitação e privacidade dos dados relativas à presença de sensores mais intrusivos, como câmaras e

---

microfones, a implementação da tecnologia *blockchain* pode fornecer vantagens significativas, como a segurança e transparência dos dados.

Neste sistema, a *blockchain* funciona como um armazenamento cronológico dos dados recolhidos, sendo que estes ao serem recolhidos pelos sensores, são registados em blocos imutáveis, garantindo a integridade e segurança por meio de técnicas de criptografia avançadas. Esses blocos são distribuídos na rede P2P implementada, o que elimina a necessidade de confiar numa autoridade central única, tornando o sistema mais resiliente a ataques e violações de segurança.

A confidencialidade dos dados é uma preocupação alarmante, especialmente quando sensores audiovisuais são utilizados como principais métodos de recolha de informação. Por meio da tecnologia *blockchain*, é possível estabelecer mecanismos que garantem o acesso restrito aos dados sensíveis apenas por utilizadores autorizados. Este comportamento é alcançado por meio de chaves criptográficas e contratos inteligentes, permitindo que os proprietários controlem os privilégios de visualização, modificação e acesso aos seus dados pessoais (Dorri et al., 2017).

O armazenamento descentralizado proporcionado por esta tecnologia permite um maior controlo, privacidade e segurança dos dados. Assim, a *blockchain* pode ser utilizada para registar eventos que ocorrem num determinado período temporal, possibilitando mais tarde serem processados para detetar padrões comportamentais do utilizador e, como resultado, fornecer diagnósticos personalizados, contribuindo para a melhoria da saúde e do bem-estar do utilizador.

Após a deteção de padrões comportamentais do utilizador, através do processamento dos dados, essas informações são enviadas pelo nó eleito como coordenador para o *HUB*. A utilização de um IoT *HUB* é uma abordagem que facilita a comunicação entre o sistema e o utilizador.

Um dos *HUBs* mais populares na área de IoT é o *Home Assistant* (HA), tratando-se de um *software* de automação residencial de código aberto, desenvolvido para controlar dispositivos inteligentes em ambientes domésticos.

O HA oferece uma plataforma centralizada para integração e controlo de dispositivos de diferentes fabricantes, permitindo a criação de regras personalizadas, automação de tarefas e interação com assistentes virtuais.

De acordo com o estudo de (Akhmetzhanov et al., 2022), a utilização do *software* HA demonstrou ser uma solução economicamente mais vantajosa, devido à sua natureza de código aberto e à facilidade de implementação de diferentes funcionalidades que se adaptam ao contexto do utilizador.

Essa abordagem permite a criação de um sistema de monitorização eficiente e personalizável, que combina a deteção de padrões comportamentais com recursos de automação e controlo fornecidos pelo HA.

Com a utilização de dispositivos de baixo custo e a integração com o HA, é possível

obter um sistema de monitorização acessível, flexível e de fácil implementação para ambientes residenciais inteligentes.

Através dos módulos definidos na figura 3.2, a abordagem colaborativa entre os dispositivos na rede amplia significativamente a precisão e fiabilidade do sistema, conferindo-lhe capacidades poderosas para a monitorização em tempo real de ambientes complexos e em constante mudança.

### 3.4 Módulo de descoberta na rede

A inicialização do sistema é um processo fundamental no estabelecimento e configuração de um sistema numa rede local, sendo que este processo abrange várias etapas, incluindo a identificação de dispositivos disponíveis na rede e a descoberta de vizinhos próximos para estabelecer conexões e compartilhar recursos e/ou informações. Uma abordagem comum para a descoberta de vizinhos é a utilização do protocolo *Multicast DNS* (mDNS).

O mDNS é um protocolo de descoberta de serviços utilizado em redes locais para permitir que dispositivos descubram e se comuniquem entre si sem a necessidade de um servidor *DNS* centralizado, utilizando o *multicast* para propagar pacotes *DNS* para todos os dispositivos na rede, permitindo a resolução de nomes de domínio localmente.

Essa tecnologia é amplamente utilizada em redes domésticas e em ambientes de IoT, onde a comunicação e a descoberta de serviços são essenciais. Para além disso, é um protocolo de descoberta de serviços semelhante ao *Domain Name System - Service Discovery* (DNS-SD) e *Universal Plug and Play* (UPnP). No entanto, o mDNS é mais simples e prático de configurar comparativamente ao DNS-SD e o UPnP. Além disso, é mais eficiente do que o DNS-SD e o UPnP porque utiliza menos largura de banda da rede (Cheshire and Krochmal, 2013).

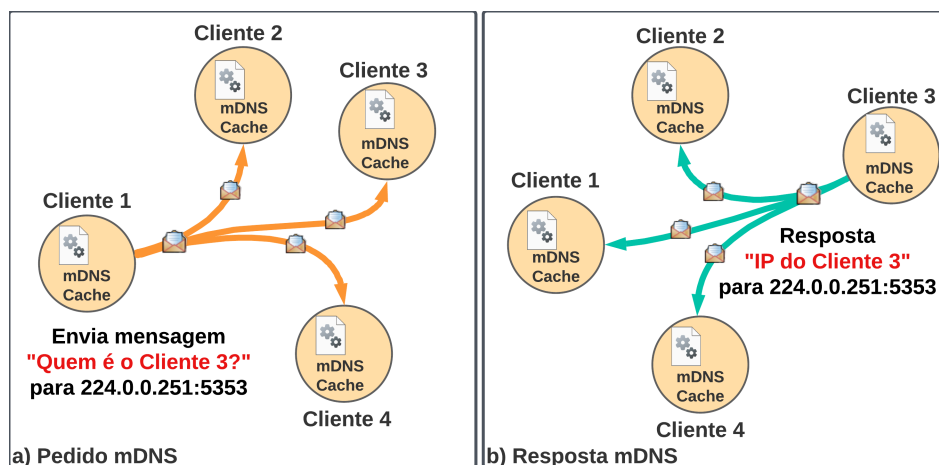


Figura 3.4: Funcionamento do protocolo mDNS (Al-Fuqaha et al., 2015b)

A *Internet of Things* (IoT) requer uma arquitetura que seja independente de um mecan-

---

ismo de configuração, permitindo que os dispositivos inteligentes se conectem ou desconectem da plataforma sem impactar o comportamento global do sistema. A utilização dos protocolos mDNS e DNS-SD pode viabilizar esse desenvolvimento.

Essa abordagem de *zero configuration* é particularmente útil em ambientes de rede domésticos, onde a configuração manual de serviços pode ser complicada e demorada, através do DNS-SD/mDNS, os dispositivos podem ser integrados facilmente à rede local e tornar os serviços prontamente acessíveis para outros dispositivos, simplificando a experiência do utilizador e promovendo a interoperabilidade entre os dispositivos numa rede local.

No entanto, uma limitação significativa desses protocolos reside na necessidade de armazenar em cache as entradas *DNS*, especialmente quando se trata de dispositivos com recursos limitados. Contudo, essa questão pode ser solucionada através da gestão de cache para um intervalo específico, seguido da sua limpeza. As implementações conhecidas como *Bonjour* e *Avahi* englobam tanto a utilização do protocolo mDNS quanto o DNS-SD.(Al-Fuqaha et al., 2015a)

### 3.5 Módulo de comunicação

Num ambiente distribuído, os nós estão espalhados em diferentes locais físicos e podem não ter uma conexão direta entre si. O protocolo de comunicação permite que os nós estabeleçam conexões e se comuniquem uns com os outros, independentemente da sua localização geográfica.

A arquitetura de comunicação adotada neste sistema é baseada num modelo P2P, onde cada nó atua simultaneamente como cliente e servidor. Essa abordagem descentralizada permite que os nós estabeleçam comunicação direta entre si, eliminando a necessidade de um servidor central.

A comunicação entre os nós é estabelecida por meio de uma rede sobreposta, na qual cada nó mantém conexões diretas com outros nós na rede, essas conexões podem ser estabelecidas utilizando uma variedade de protocolos, como UDP(*User Datagram Protocol*) ou TCP/IP, permitindo que os nós troquem mensagens e dados entre si, independentemente da topologia física da rede.

O protocolo TCP/IP é amplamente conhecido pela sua robustez e garantia de entrega confiável dos dados, devido aos mecanismos sofisticados de controlo de fluxo, confiabilidade e retransmissão de pacotes (Xylomenos and Polyzos, 1999). Essas características tornam o TCP/IP mais adequado para aplicações críticas, como sistemas de monitorização, em que a perda de dados é inaceitável e a integridade das informações é primordial. No entanto, é importante ressaltar que o TCP/IP pode impor uma sobrecarga adicional no tráfego de dados devido à necessidade de estabelecer e manter conexões persistentes.

Por outro lado, o protocolo UDP, é uma alternativa mais leve e de menor complexi-

---

dade em comparação ao TCP/IP, contudo não oferece garantias de entrega confiável dos dados, o que pode resultar em pacotes perdidos ou fora de ordem. A simplicidade torna o UDP mais adequado para aplicações em que a latência é um fator crítico e a perda ocasional de pacotes pode ser tolerada, sem comprometer significativamente a eficácia do sistema de monitorização.

Para garantir a segurança na comunicação P2P, é importante adotar medidas de proteção adequadas. Uma das abordagens possíveis é utilizar o protocolo SSL/TLS para garantir a confidencialidade, integridade e autenticidade dos dados transmitidos. Este protocolo fornece uma camada de segurança adicional, encriptando os dados antes de serem enviados pela rede (Satapathy et al., 2016).

Adicionalmente, pode ser aplicada encriptação ponta-a-ponta nas comunicações entre os nós, essa encriptação pode ser baseada em algoritmos assimétricos, garantindo que somente os nós legítimos possam decifrar e verificar a integridade dos dados transmitidos.

A comunicação entre os nós é realizada por meio do envio e receção de mensagens, sendo que as mesmas são estruturadas num formato adequado, como JSON(*JavaScript object notation*), para facilitar a serialização e desserialização dos dados, isso permite que os nós troquem informações de forma eficiente e compreensível.

A arquitetura P2P oferece vantagens em termos de escalabilidade e resiliência, uma vez que não depende de um único ponto de falha, como apresentado na tabela 2.1. No entanto, a segurança na comunicação entre os nós deve ser cuidadosamente planeada e implementada, levando em consideração as ameaças e requisitos específicos do sistema proposto.

Nesse sentido, a utilização de um protocolo de comunicação eficiente é essencial para viabilizar a comunicação direta entre os nós, permitir a troca de informações, coordenar as ações dos nós, garantir a confiabilidade e integridade da comunicação, além de prover segurança e escalabilidade ao sistema.

## **3.6 Módulo de aprendizagem computacional**

A identificação e classificação de áudio e vídeo representam desafios significativos no campo da computação. Para abordar essas tarefas complexas, uma solução viável é o uso de redes neuronais artificiais, que são sistemas computacionais inspirados nas redes neuronais biológicas presentes no cérebro de animais, sendo que são capazes de aprender a executar tarefas por meio do processamento de exemplos.

No contexto da construção de redes neuronais, são utilizados algoritmos de ML para criar modelos e ajustar os pesos dessas redes com base nos dados de treino disponíveis. Uma plataforma frequentemente utilizada para esse propósito é o *TensorFlow* (TF), que oferece ferramentas e recursos para a construção e execução desses modelos (Pang et al., 2020).

Dois componentes cruciais na construção de um modelo são o conjunto de dados e o próprio modelo em si. A coleção de dados é utilizada para treinar e validar o modelo. Nesse sentido, esses dados são geralmente divididos em categorias ou classes, permitindo que o modelo aprenda a reconhecer padrões e realizar classificações. Por exemplo, um conjunto de dados para treinar um modelo de identificação de sons de gatos e cães conteria amostras de áudio separadas em categorias correspondentes a esses dois animais.

O modelo, por sua vez, é a estrutura da rede neuronal composto por neurónios artificiais interconectados que processam e transmitem informações entre si. Cada neurónio possui um peso específico, que é ajustado durante o processo de aprendizagem, esses pesos são atualizados iterativamente para que o modelo seja capaz de realizar previsões cada vez mais precisas.

Modelos simples podem envolver funções lineares, enquanto modelos mais complexos, como aqueles utilizados para o reconhecimento de áudio e vídeo, requerem arquiteturas mais sofisticadas, treinadas em conjunto de dados extensos.

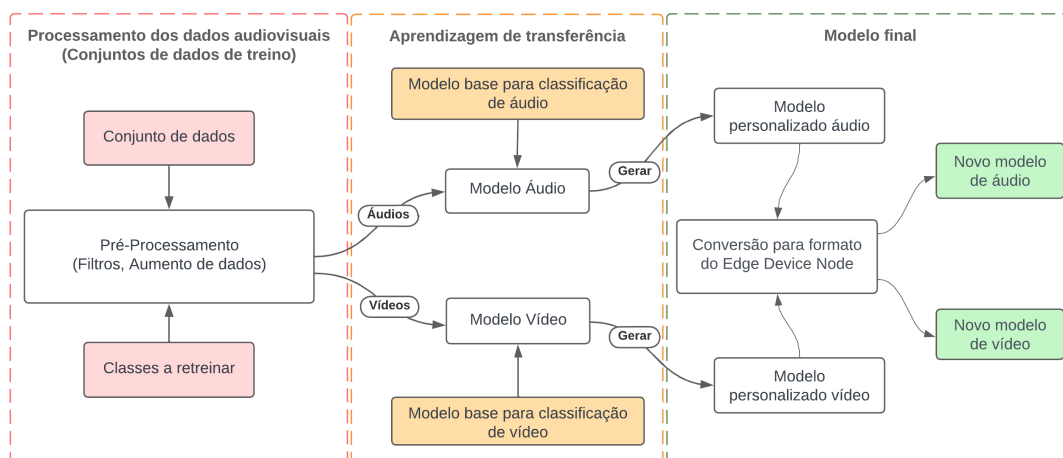


Figura 3.5: Fluxo de dados no treino dos modelos especializados na detecção de eventos audiovisuais do sistema *DistSense*

A figura 3.5 ilustra o fluxo de dados envolvido no processo de criação de modelos especializados para a detecção de eventos em ambientes residenciais. Este sistema visa capturar, em tempo real, dados audiovisuais utilizando dispositivos equipados com sensores apropriados, tais como câmaras e/ou microfones.

No entanto, antes da fase de inferência dos dados em tempo real, o modelo passa por um processo de treino que utiliza conjuntos de dados disponíveis online.

Esses conjuntos de dados são divididos em dois campos sensoriais: vídeo e áudio. Para o campo de vídeo, podem ser utilizados conjuntos de dados como o *Charades* (Sigurdsson et al., 2016), *UCF50* (Reddy and Shah, 2013), *UCF101* (Soomro et al., 2012) e *Toyota Smart Home* (Das et al., 2019), entre outros. Relativamente ao domínio do áudio, existem diversos conjuntos de dados conjuntos de dados como o *FSD50k* (Fonseca et al.,

---

2022), *UrbanSound8k* (Salamon et al., 2014) e o *ESC-50* (Piczak, 2015), que englobam uma diversidade de sons característicos do ambiente doméstico e urbano.

Tais conjuntos de dados são criteriosamente selecionados como base para o treino do modelo, dada a sua submissão prévia a etapas de filtragem, limpeza e pré-processamento. Essa preparação visa assegurar a qualidade e relevância das informações fornecidas ao modelo. Adicionalmente, a utilização de múltiplos conjuntos de dados em simultâneo proporciona exemplos e contextos diversos, conferindo ao modelo a capacidade de generalizar e reconhecer uma vasta gama de eventos e situações, sobretudo no contexto de um ambiente doméstico.

Após o treino do modelo com esses conjuntos de dados, o sistema está pronto para a fase de captura de dados em tempo real, onde durante essa fase os dispositivos capturam dados audiovisuais, que são então submetidos a um processo de pré-processamento.

Uma vez pré-processados, os dados são analisados utilizando uma rede neuronal previamente treinada e estruturada, essa arquitetura especializada permite que o modelo capture relações de longo prazo em sequências temporais, possibilitando o reconhecimento de padrões complexos e a previsão de eventos futuros com base nas informações audiovisuais recolhidas.

Por fim, os resultados obtidos a partir da execução do modelo são armazenados localmente na *blockchain*. Essa tecnologia descentralizada garante a imutabilidade e a transparência das informações, fornecendo uma linha temporal de registo confiável dos eventos capturados. Esse armazenamento em *blockchain* é particularmente relevante para aplicações em áreas como segurança, análise de vídeo e automação residencial, onde a integridade e a rastreabilidade dos eventos são essenciais (Ozdayi et al., 2020).

### **3.7 Módulo de processamento e representação do conhecimento**

Através da disseminação de novas tecnologias, surge uma preocupação crescente sobre quais dados sensíveis são recolhidos e como estes são utilizados (Miltgen and Peyrat-Guillard, 2014). A segurança e privacidade dos dados são desafios importantes enfrentados pelos dispositivos IoT em casas inteligentes.

De acordo com a investigação conduzida por (Psychoula et al., 2018), sobre a utilização de dispositivos inteligentes no quotidiano do utilizador, conclui-se que as pessoas idosas mostram uma maior predisposição para partilhar dados e têm menos preocupações acerca de questões de privacidade, quando comparadas com as gerações mais jovens. Os autores explicam este resultado através da tendência dos jovens em estarem mais familiarizados com a tecnologia e serem mais conscientes dos riscos que as tecnologias de IoT representam.

---

A natureza distribuída e a grande escala das redes IoT tornam difícil garantir a confidencialidade, integridade e autenticação dos dados. Uma abordagem promissora para resolver esses desafios é a implementação de um sistema distribuído, este tipo de sistemas oferecem várias vantagens em termos de escalabilidade, latência e privacidade (Singh et al., 2018).

Além disso, a recolha de dados local permite que os sistemas distribuídos respondam rapidamente a mudanças nas atividades, sem depender da transmissão de dados para um sistema central, dessa forma a privacidade dos utilizadores é protegida, visto que os dados não precisam ser transmitidos para um sistema central e permanecem livres de falhas.

Nesse sentido, a tecnologia de *blockchain* emerge como uma solução relevante para abordar as questões de segurança dos dados, tratando-se de uma abordagem promissora para o processamento de dados em sistemas distribuídos, onde é estabelecido um registo distribuído e imutável de transações, mantido por uma rede de nós (Ozdayi et al., 2020). Cada bloco na *blockchain* contém um registo de múltiplas transações e é encriptado e conectado ao bloco anterior por meio de criptografia, formando assim uma cadeia de blocos. A integridade dos dados é garantida, uma vez que qualquer tentativa de alteração ou falsificação seria detetada e rejeitada pelos nós da rede local.

Ao funcionar como um registo de eventos numa linha cronológica, a *blockchain* permite que todas as transações sejam rastreáveis e verificáveis, onde cada bloco contém um registo encriptado de todas as transações anteriores, formando uma sequência imutável de eventos. Essa característica torna a *blockchain* extremamente útil em diversas áreas, desde transações financeiras até ao registo de ações para deteção de padrões no quotidiano do utilizador.

Uma das principais vantagens desta tecnologia é sua imutabilidade, uma vez que após os dados serem registados na *blockchain*, eles não podem ser alterados ou excluídos, garantindo a integridade dos dados e aumentando a confiança no sistema. Com a natureza descentralizada da *blockchain* significa que não há uma única entidade a controlar os dados, o que aumenta a resiliência do sistema contra ataques e falhas (Tariq et al., 2019).

Adicionalmente oferece várias vantagens em termos de segurança, para a qual a criptografia é usada para garantir a confidencialidade dos dados e para verificar a autenticidade das transações (Tariq et al., 2019). Do mesmo modo que os mecanismos de consenso utilizados na *blockchain* garantem que todos os nós na rede concordem com o estado atual da *blockchain*, o que ajuda a prevenir fraudes e adulteração de dados.

No entanto, a *blockchain* apresenta desafios em termos de implementação como demonstrado no estudo de (Dorri et al., 2017). Alguns desses desafios são referentes à latência e baixa escalabilidade, resultante da necessidade de transmitir transações e blocos para toda a rede.

É importante realçar que o sistema proposto atribui primordial importância à segurança dos dados sensíveis, tais como imagens e áudio, capturados pelos sensores. Estes

---

dados não são armazenados nem local nem externamente; em vez disso, são apenas processados e convertidos em informações de elevada relevância, como eventos ocorridos dentro de um determinado período temporal. Estes eventos são subsequentemente registados em formato JSON na *blockchain* e enviados pelo nó coordenador à plataforma de automação residencial adotada, para efeitos de representação do conhecimento. Esta abordagem reforça a segurança, minimizando assim os riscos de acesso não autorizado ou de fuga de informações pessoais sensíveis.

Além disso, possibilita ao sistema a capacidade de consultar eventos ao longo da linha temporal, contribuindo assim para a redução de falsos positivos na deteção de atividades quotidianas por parte do utilizador, o que, por sua vez, simplifica o processo de reconhecimento de atividades complexas.

## Capítulo 4

# Implementação do Sistema *DistSense*

O presente capítulo descreve a implementação dos módulos apresentados no capítulo 3 do sistema *DistSense*. O objetivo principal é a detecção e classificação de atividades domésticas do utilizador, alcançado por meio da colaboração na captura em tempo real de imagens e áudio, mantendo a privacidade e segurança como elementos fundamentais do sistema.

Neste capítulo, serão apresentados em detalhe os procedimentos técnicos adotados para a implementação do sistema *DistSense*, onde serão abordadas as estratégias utilizadas para a captura de imagens e áudio, bem como as etapas envolvidas no processamento e análise desses dados.

No âmbito da privacidade, foram adotadas medidas rigorosas para garantir que os dados recolhidos sejam tratados de forma confidencial, respeitando os direitos do utilizador. A implementação foi realizada com base em princípios científicos estabelecidos na área de pesquisa, utilizando estudos e metodologias mencionadas no capítulo 2.

Num primeiro momento, será detalhado o processo de inicialização do sistema e a forma como a comunicação entre os nós é estabelecida de maneira descentralizada, e em seguida, será abordada em profundidade a integração da tecnologia *blockchain* no sistema, explorando o seu funcionamento e destacando os benefícios da sua utilização como um mecanismo de armazenamento de registos em ordem cronológica.

Por fim, os eventos são processados localmente com o intuito de fornecer informações relevantes, possibilitando identificar padrões comportamentais do utilizador ao longo de um período de tempo específico, definido pelo utilizador. Essas informações são disponibilizadas ao utilizador através de um *software* de automação residencial gratuito e de código aberto, desenvolvido como um sistema de controlo central para dispositivos domésticos inteligentes, com ênfase no controlo local e na privacidade residencial designado por *Home Assistant* (HA).

---

## 4.1 Ambiente de virtualização do Sistema *DistSense*

A simulação desempenha um papel fundamental no desenvolvimento e implementação dos cenários de aplicação escolhidos, proporcionando uma série de vantagens, mencionadas na secção 2.2, que justificam a sua aplicação preliminar antes da implementação num contexto real.

Ao evitar a necessidade de *hardware* dedicado e outras infraestruturas, a simulação oferece uma opção acessível e económica para o desenvolvimento e teste do sistema *DistSense*, resultando numa redução significativa de custos em comparação com a implementação direta num contexto real.

A escolha do GNS3 em comparação com outras tecnologias, como o *containerlab*, pode ser justificada com base em vários critérios, incluindo a presença de uma interface gráfica amigável.

A interface gráfica disponibilizada pelo GNS3 é caracterizada pela intuitividade e facilidade de utilização, permitindo aos utilizadores criar e configurar topologias de rede de forma visual, visto que a sua interface gráfica permite simplificar a criação, configuração e gestão de dispositivos de rede virtualizados.

Adicionalmente, o GNS3 oferece um amplo suporte a dispositivos de rede virtualizados, como *routers*, *switches* e *firewalls* de diferentes fornecedores. Além disso, suporta recursos avançados, como emulação de protocolos de roteamento, inspeção de pacotes e análise de tráfego, possibilitando aos utilizadores realizar testes e simulações detalhadas em redes virtuais.

O GNS3 conta com uma comunidade ativa e uma vasta gama de recursos disponíveis. Existem fóruns, tutoriais e documentação detalhada que auxiliam os utilizadores a aproveitar ao máximo o *software*, onde a comunidade contribui com modelos e imagens prontas para uso, facilitando a configuração rápida de dispositivos de rede virtualizados.

Outra vantagem do GNS3 é sua capacidade de integração com equipamentos de rede físicos, permitindo a interação entre dispositivos físicos e virtuais, numa única topologia, o que possibilita a criação de ambientes de teste mais realistas.

A integração das tecnologias *docker* e GNS3 permite a criação de cenários de rede complexos, nos quais é possível implementar e testar o sistema num ambiente virtual controlado. Através da sua utilização, é possível criar contentores que contêm todos os componentes e dependências necessárias para a execução do sistema distribuído, como bibliotecas, ferramentas e serviços específicos. Estes contentores podem ser implantados nos nós virtuais do GNS3, representando os diferentes elementos do sistema distribuído.

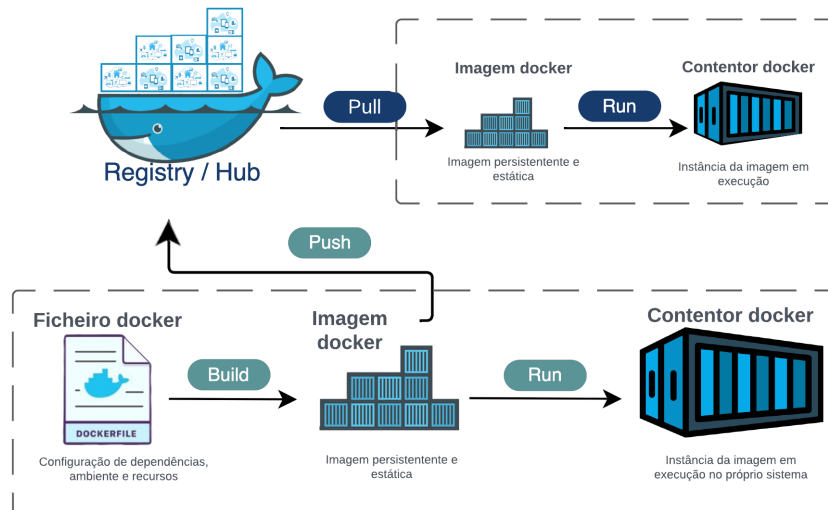


Figura 4.1: Processo de construção e registo de um contentor *docker*

Ao utilizar a tecnologia *docker*, é possível definir um ficheiro, designado de *dockerfile*, que especifica de forma precisa os requisitos e configurações necessários para a construção e execução dos contentores, incluindo a instalação de dependências, a configuração do ambiente, a exposição de portas e a transferência de ficheiros relevantes para a imagem *docker*.

Após a criação do *dockerfile*, o próximo passo é a construção da imagem *docker*, ilustrado na figura 4.1. Este processo é realizado utilizando o comando "*docker build*" no terminal, indicando o diretório onde o *dockerfile* está localizado. O *docker* analisa o ficheiro construído e executa as instruções nele contidas, gerando assim a imagem *docker*. Durante este processo, cada instrução é executada em camadas distintas, permitindo uma construção incremental e eficiente.

Com a imagem *docker* devidamente construída, torna-se apto a executar o contentor, usando o comando "*docker run*". Esta instrução cria uma instância em execução do contentor com base na imagem especificada. Além disso, é possível fornecer diversas opções durante a sua execução, tais como mapeamento de portas, montagem de volumes e definição de variáveis de ambiente. Deste modo, o contentor é inicializado e torna-se acessível através das portas que foram expostas.

Posteriormente à construção da imagem, realiza-se o envio da mesma para um registo *docker* utilizando o comando "*docker push*". Este é um repositório centralizado que armazena as imagens *docker*, permitindo assim o acesso remoto a elas. Deste modo, a imagem fica disponível para os dispositivos que necessitam de a executar.

O registo ou *Hub* desempenha um papel crucial no armazenamento e partilha de imagens *docker*. O *Docker Hub*<sup>1</sup> é um exemplo popular de registo, contudo existem outras

<sup>1</sup><https://hub.docker.com/>

opções, como o *Amazon Elastic Container Registry*<sup>1</sup> e o *Google Container Registry*<sup>2</sup>. É altamente recomendado registar a imagem *docker* no *hub* antes de a partilhar ou implementar, pois isso permite que outras pessoas a acessem e utilizem de forma simples e conveniente.

No GNS3, a integração de imagens *docker* é realizada através da utilização da GNS3 *Virtual Machine* (GNS3 VM). Num primeiro momento, é necessário efetuar o *download* e a instalação da GNS3 VM, tratando-se de uma máquina virtual pré-configurada para executar o GNS3 e suportar a integração com o *docker*.

Após configurar a GNS3 VM e inicializar o ambiente, o próximo passo envolve a realização do comando "*docker pull*", para obter a imagem desejada a partir do *docker Hub*.

Este procedimento é efetuado através do terminal da GNS3 VM, onde se executa o comando "*docker pull [nome da imagem]*" para fazer o *download* da imagem específica do *docker Hub* para a VM. É importante salientar que é fundamental ter uma conexão de rede ativa para aceder ao registo e efetuar o *download* da imagem desejada.

Após realizar o *download* da imagem *docker* do registo, é possível executar o contentor localmente utilizando o comando "*docker run*", conforme mencionado anteriormente. Deste modo, o *docker* verifica se a imagem está presente localmente e, caso não esteja, realiza automaticamente o *download* do registo antes de executar o contentor.

Uma vez que a imagem *docker* esteja disponível na GNS3 VM, é possível prosseguir com a criação de instâncias do contentor *docker* dentro do GNS3.

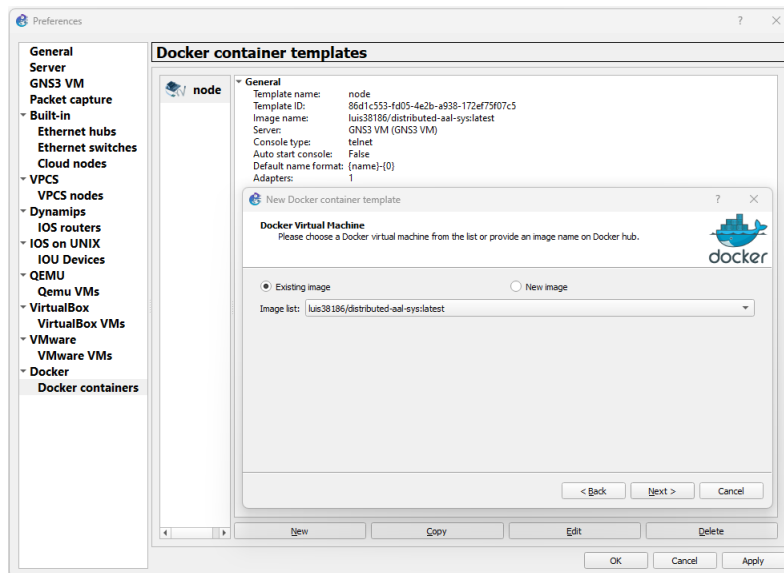


Figura 4.2: Configuração do contentor *docker* no GNS3

Para tal, ao aceder às preferências do GNS3 na secção "*Docker container templates*",

<sup>1</sup><https://aws.amazon.com/pt/ecr/>

<sup>2</sup><https://cloud.google.com/artifact-registry>

---

como apresentado na figura 4.2, é possível adicionar modelos personalizados de contentores, onde são especificados detalhes como nome, descrição, comandos de inicialização, portas expostas e parâmetros adicionais.

Posteriormente, é possível utilizar esses modelos na construção da topologia no GNS3. Ao adicionar um dispositivo *docker* à topologia, é selecionado o modelo de contentor previamente definido. Durante a execução da simulação, o GNS3 criará e iniciará instâncias do contentor *docker* com base nas configurações fornecidas no modelo.

Através da integração do *docker* com o GNS3, é possível criar e interligar dispositivos virtuais baseados em contentores *docker* com outros dispositivos da topologia, como *routers switches* virtuais, esta integração possibilita testar e simular cenários de rede complexos, aproveitando as funcionalidades e a flexibilidade oferecidas pelos contentores *docker*.

## 4.2 Inicialização do sistema *DistSense*

A inicialização de um sistema em ambientes distribuídos é uma etapa crítica que desempenha um papel fundamental na estabilização da rede, garantindo a conexão e a ativação adequada dos nós. É importante garantir que esta inicialização ocorra de forma apropriada, uma vez que é essencial para assegurar a escalabilidade e a fiabilidade do sistema, possibilitando a adição e a ligação transparente de novos nós à rede.

Antes de prosseguir com a implementação do módulo de descoberta, torna-se imperativo realizar algumas etapas de configuração inicial. Durante essas etapas, cada dispositivo obtém o seu endereço IP através do protocolo *Dynamic Host Configuration Protocol* (DHCP). Este procedimento garante uma configuração correta e coerente na rede local, evitando conflitos de endereçamento e permitindo que os dispositivos comuniquem eficientemente.

A inicialização do sistema *DistSense* divide-se em duas etapas fundamentais:

1. **Descoberta de dispositivos na rede:** Nesta etapa, o sistema realiza uma descoberta ativa dos dispositivos presentes na rede, possibilitando a identificação e o reconhecimento de cada nó pelos demais. Para tal, é implementado um módulo de descoberta específico que rastreia e identifica os dispositivos ativos na rede local. Este processo é crucial para estabelecer um ambiente coeso e apto a integrar sem problemas novos nós à medida que são acrescentados à rede.
2. **Implementação do algoritmo de eleição:** Uma vez concluída a etapa de descoberta, o sistema dá início à implementação de um algoritmo de eleição entre os nós participantes. Este algoritmo tem como objetivo selecionar um nó específico para assumir uma posição ou função especial dentro da rede. O nó eleito será responsável por coordenar operações, recolher informações agregadas ou desempenhar outras tarefas

---

importantes para o funcionamento do sistema. A escolha criteriosa deste nó líder é crucial para otimizar a eficiência do sistema distribuído e garantir um funcionamento harmonioso.

### 4.2.1 Serviço de descoberta

Os sistemas distribuídos são compostos por diversos dispositivos interconectados que colaboram para realizar tarefas de forma conjunta. No entanto, para que os dispositivos possam comunicar entre si, é necessário estabelecer um mecanismo eficiente de descoberta de dispositivos disponíveis na rede local.

A implementação de um módulo de descoberta adequado desempenha um papel crucial nesse contexto, possibilitando a conexão e comunicação entre os nós na rede local de forma transparente e segura.

Com o objetivo de atender a um requisito fundamental de não exigir interação direta do utilizador para o funcionamento do sistema, optou-se por utilizar a biblioteca *zeroconf* em *python*. Esta escolha baseia-se no facto de que a biblioteca oferece uma solução que permite a descoberta e a conexão automática entre os nós numa rede local.

A biblioteca *zeroconf* utiliza o protocolo mDNS, que possibilita que os dispositivos presentes na rede local se descubram mutuamente, sem a necessidade de configurações prévias ou de um servidor centralizado. Além disso, não exige tarefas adicionais ou intervenções ativas por parte do utilizador, contribuindo para a simplicidade e praticabilidade do sistema, garantindo que todos os nós sejam automaticamente integrados à rede sem complicações adicionais.

Através da utilização da biblioteca *zeroconf* em *python*, é possível registar e navegar pelos serviços disponíveis na rede local de forma simples e eficiente. O registo de serviços envolve a criação de um objeto de serviço, no qual são especificados o nome, o tipo e a porta do serviço a ser oferecido. Este objeto é, em seguida, registado na rede local.

```
1 from zeroconf import ServiceInfo, Zeroconf
2
3 service_info = ServiceInfo(
4     type="_node._tcp.local.",
5     name=f"{NODE_NAME}._node._tcp.local.",
6     addresses=[socket.inet_aton(NODE_IP)],
7     port=NODE_PORT,
8     weight=0,
9     priority=0,
10    properties={'IP': NODE_IP, 'ID': NODE_ID, 'LOCAL': NODE_LOCAL})
11
12 zeroconf = Zeroconf()
13 zeroconf.register_service(service_info)
```

Figura 4.3: Registo de um serviço com auxílio da biblioteca *zeroconf* em *python*

Na implementação do anúncio de serviços, é utilizada a classe *"ServiceInfo"* para encapsular as informações relevantes do serviço, como o tipo, nome, endereço IP, porta, peso, prioridade e propriedades do serviço.

Ao anunciar um serviço, essas informações são divulgadas na rede local, permitindo que outros dispositivos obtenham conhecimento da existência e das características desse serviço.

Este procedimento é essencial em ambientes de rede doméstica, onde a configuração automatizada é preferida, evitando que os utilizadores tenham que configurar manualmente cada dispositivo para estabelecer comunicação com os restantes nós.

```
1 service_type = "_node._tcp.local."
2 zeroconf = Zeroconf()
3 servicicos = ServiceBrowser(zeroconf, service_type, [update_service])
4
5 def add_service(zeroconf, service_type, name):
6     info = zeroconf.get_service_info(service_type, name)
7     if info:
8         ip_list = info.parsed_addresses()
9         for ip in ip_list:
10            if ip != NODE_IP:
11                connect_to_peer(ip, info.port, info.properties.get(b'ID'), info.
12                    properties.get(b'LOCAL'))
13
14 def update_service(zeroconf: Zeroconf, service_type: str, name: str, state_change:
15     ServiceStateChange):
16     if state_change is ServiceStateChange.Added:
17         info = zeroconf.get_service_info(service_type, name)
18         if info:
19             add_service(zeroconf, service_type, name)
```

Figura 4.4: Descoberta de serviços com auxílio da biblioteca *zeroconf* em *python*

A descoberta de serviços assume um papel fundamental na implementação do módulo de descoberta, permitindo que outros dispositivos presentes na rede tenham a capacidade de encontrar e conectar-se ao serviço de forma adequada.

Após o registo de um serviço numa rede local, torna-se essencial que outros dispositivos presentes nessa mesma rede possam descobrir tal serviço. Para alcançar esse objetivo, utiliza-se a classe *"ServiceBrowser"*, a qual possibilita a exploração dos serviços disponíveis na rede, aplicando filtros para encontrar um tipo específico de serviço.

Assim, ao recorrer à classe *"ServiceBrowser"*, os dispositivos têm a capacidade de explorar os serviços que foram anunciados na rede local, facilitando a identificação dos serviços e a obtenção das informações relevantes associadas a cada um deles.

Através da aplicação de filtros, é possível realizar uma busca apenas dos serviços que correspondem a critérios específicos, como um tipo de serviço particular ou outras características relevantes, essa capacidade é particularmente relevante em ambientes nos quais a interconexão dinâmica e automática de dispositivos é essencial, sem a necessidade

---

de configurações manuais complexas.

Além disso, o código utiliza a função *"update\_service()"*, que permanece à escuta de ocorrências de adição, atualização ou remoção de serviços na rede. Cada vez que um serviço é adicionado ou atualizado, o método *"update\_service()"* é invocado pelo objeto *zeroconf*. No caso em que o nó atual possui o mesmo nome do tipo de serviço, o método *"add\_service()"* é ativado para incluir o serviço na lista de *peers* conhecidos pelo nó.

Um aspecto de grande importância na implementação de um módulo de descoberta é o tratamento de falhas, tornando-se crucial que o módulo seja capaz de lidar com situações em que um serviço registado não esteja disponível ou quando um nó perde a conectividade com a rede.

## 4.2.2 Processo de eleição do coordenador

A eleição de um líder ou coordenador desempenha um papel fundamental na garantia da eficiência, cooperação e ordem na comunicação entre os nós participantes de sistemas distribuídos. Através da implementação de um algoritmo de eleição, torna-se possível selecionar um nó específico entre os demais, conferindo-lhe a responsabilidade de liderança para coordenar as atividades e decisões no sistema.

A implementação de um algoritmo de eleição requer rigor e precisão, uma vez que qualquer imprecisão ou falha no processo pode acarretar consequências graves para a estabilidade e confiabilidade do sistema distribuído. Nesse sentido, é imperativo explorar abordagens algorítmicas eficientes e robustas que garantam uma eleição justa e coerente, mesmo em cenários adversos ou em condições variáveis na rede.

No contexto dos sistemas distribuídos, a aplicação de algoritmos de eleição tem como objetivo designar um nó específico para desempenhar funções especializadas, como a coordenação de atividades, em determinado momento. No sistema *"DistSense"*, onde múltiplos nós independentes colaboram na detecção de atividades domésticas, a seleção de um nó responsável por tomar decisões e coordenar algumas tarefas torna-se essencial.

O algoritmo *"Bully"* é uma das abordagens clássicas para a eleição do coordenador em sistemas distribuídos, proporcionando uma abordagem hierárquica baseada nos UUIDs dos nós, sendo que este garante que haja sempre um único coordenador para gerir as atividades dos nós vizinhos ativos.

O funcionamento do algoritmo em questão pode ser compreendido através de uma série de passos bem definidos. Quando um nó identifica que o coordenador atual está inacessível, inicia-se o processo de eleição. O nó iniciante envia mensagens eleitorais para todos os outros nós com identificadores maiores, comunicando o desejo de tornar-se o novo coordenador. Os nós que recebem a mensagem eleitoral têm duas opções: reconhecer o pedido do nó iniciante e retirar-se da eleição, aceitando-o como coordenador, ou iniciar uma nova eleição enviando mensagens eleitorais para os nós com identificadores

maiores.

Através deste mecanismo de hierarquia de eleição, o nó com o maior UUID é eleito como o novo coordenador após receber todas as confirmações dos outros nós. O novo coordenador anuncia a sua vitória através do envio de uma mensagem para todos os nós na rede, concluindo assim o processo de eleição, conforme ilustrado na figura 4.5.

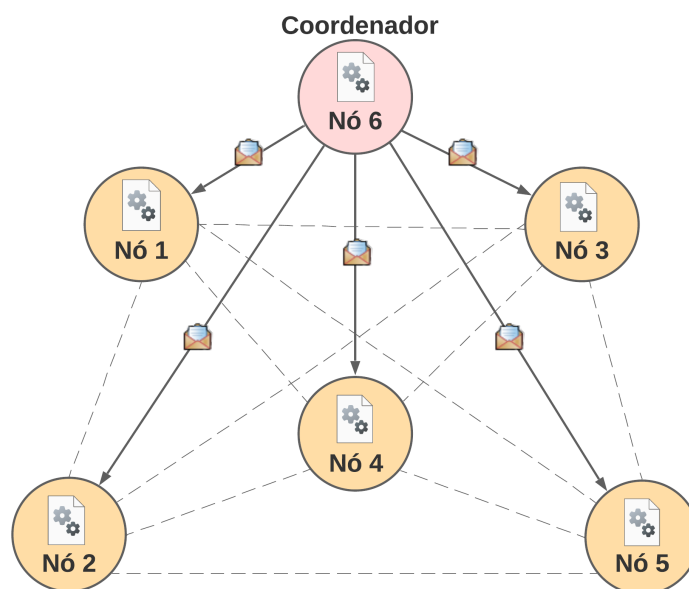


Figura 4.5: Eleição do nó coordenador

Assim, a escolha do algoritmo "*Bully*" apresenta justificativas sólidas quando comparado com outras alternativas disponíveis, sendo que uma das suas principais vantagens reside na eficiência em situações de falhas e recuperação. No caso de ocorrer uma falha no nó coordenador, os nós presentes na rede conseguem prontamente identificar esse evento e, através do algoritmo mencionado, proceder a uma eleição do novo coordenador de forma ágil e direta, neste sentido esta rápida transição reduz significativamente o tempo em que o sistema poderia operar sem um coordenador funcional, garantindo maior continuidade nas atividades e minimizando possíveis impactos negativos (Coulouris et al., 2005).

Além disso, o algoritmo "*Bully*" destaca-se por uma abordagem robusta na eleição do líder, visto que ao utilizar mensagens diretas e explícitas para comunicar as intenções dos nós candidatos, o algoritmo minimiza ambiguidades e conflitos que poderiam surgir em metodologias mais complexas.

A simplicidade e clareza desta abordagem favorecem uma implementação concisa e de fácil compreensão, tornando-o uma opção preferencial no contexto de ambientes domésticos inteligentes, onde características como a confiabilidade e transparência são essenciais.

Outro aspeto relevante é a capacidade deste algoritmo em lidar eficientemente com

---

sistemas distribuídos de grande escala e à medida que o número de nós aumenta, a complexidade de outros algoritmos pode crescer exponencialmente, tornando a escalabilidade um fator crítico. No entanto, o algoritmo "*Bully*" demonstra um desempenho satisfatório mesmo em ambientes com um grande número de nós, o que o torna uma solução viável e prática para o sistema *DistSense*.

Neste sentido, a implementação cuidadosa deste algoritmo de eleição, proporciona o estabelecimento de uma estrutura de coordenação sólida e eficiente, garantindo a adequada gestão de eventos entre os nós participantes.

Através de uma seleção justa e confiável do coordenador, o sistema assegura a estabilidade e a ordem necessárias para o correto funcionamento do mesmo, face aos desafios e variações nas condições da rede.

O coordenador desempenha um papel crucial na gestão de eventos da *blockchain*, assumindo a responsabilidade de validar e adicionar novos blocos à *blockchain*, essa função garante a integridade e segurança das transações, contribuindo para a manutenção da imutabilidade dos dados e para a consistência do sistema distribuído.

Adicionalmente, o coordenador assume o importante papel de estabelecer uma comunicação bidirecional com o HA, através do protocolo *Message Queuing Telemetry Transport* (MQTT), dado que a interação permite que o sistema *DistSense* envie eventos de alto nível, processados localmente, para o utilizador como representação do conhecimento.

Através desta funcionalidade, o HA atua como uma interface valiosa para o utilizador, proporcionando-lhe informações relevantes e permitindo a interação com o sistema desenvolvido de forma simplificada e eficiente.

A eficiência, abordagem robusta e escalabilidade do algoritmo "*Bully*" tornam-o numa escolha perspicaz e segura para sistemas distribuídos, a sua aplicação no sistema, aliada ao papel ativo do coordenador na gestão de eventos da *blockchain* e na comunicação com o HA via MQTT, contribuindo significativamente para a otimização da comunicação e cooperação entre os nós, consequentemente, esses esforços contribuem para o sucesso do sistema como um todo, garantindo a confiabilidade e a eficácia de suas operações.

### **4.3 Comunicação entre os nós**

No sistema *DistSense*, a comunicação entre os nós desempenha um papel crítico na viabilização de uma rede colaborativa e descentralizada, nesse paradigma cada nó atua como um servidor e um cliente simultaneamente, permitindo a troca direta de informações e recursos entre os *peers*, sem a necessidade de uma entidade central intermediária, visto que a comunicação estabelecida é o responsável para facilitar a cooperação e a partilha de dados, tornando possível a construção de redes escaláveis e resilientes.

A estrutura de comunicação num sistema P2P é constituída por diversos elementos inter-relacionados que possibilitam a interação entre os nós. Posto isto, os protocolos de

---

comunicação, como o TCP/IP e UDP, são amplamente utilizados para facilitar a envio e recepção de dados entre os *peers*, através dos mesmos, a comunicação efetua-se recorrendo à transferência de pacotes de dados entre os nós, garantindo a integridade e confiabilidade da informação.

Para estabelecer as conexões e permitir a troca de dados, as bibliotecas de comunicação, como o *socket*, desempenham um papel fundamental, para possibilitar a troca de informações entre os *peers*, garantindo uma comunicação eficiente e flexível.

No contexto da comunicação P2P, a segurança dos dados transmitidos é uma preocupação vital, especialmente em ambientes onde os dados são capturados por sensores intrusivos, como áudio e vídeo. A privacidade e integridade das informações trocadas entre os nós devem ser salvaguardadas para evitar potenciais vulnerabilidades e ataques maliciosos.

Neste sentido, é crucial aplicar protocolos seguros, como o TLS, cujo objetivo é proporcionar uma camada adicional de segurança em comunicações através de redes, esta tecnologia opera através da criptografia dos dados transmitidos entre os *peers*, protegendo-os contra a ação de terceiros mal-intencionados que possam tentar interceptar ou modificar as informações durante a comunicação.

Ao implementar o protocolo TLS no sistema *DistSense*, pode-se assegurar a confidencialidade e integridade dos dados transmitidos, através do processo de criptografia, que torna os dados ilegíveis para qualquer pessoa não autorizada a aceder à informação, contribuindo para a proteção dos dados sensíveis do utilizador, contra eventuais ataques cibernéticos.

Da mesma forma, a integridade dos dados é salvaguardada através do uso de mecanismos de verificação de integridade de mensagens durante a transmissão, significando que qualquer tentativa de modificar os dados durante a sua transmissão seria detetada, assegurando que os dados permanecem autênticos e não foram adulterados.

Desta forma, ao utilizar o protocolo TLS, o sistema *DistSense* promove uma comunicação segura e protegida, o que é fundamental em ambientes domésticos, onde a privacidade e a segurança da informação são essenciais.

Adicionalmente, ao destacar a implementação deste protocolo específico, reforça-se a preocupação na concretização do sistema *DistSense* em adotar práticas de segurança de última geração para proteger os dados dos utilizadores, de forma eficaz e confiável.

Uma abordagem comum para garantir a continuidade das conexões e a resiliência da comunicação entre os nós, é a utilização do mecanismo de reconexão baseado em mensagens de *keep alive*. Este mecanismo consiste em enviar periodicamente pacotes de sondagem para verificar se a conexão TCP ainda está ativa.

No caso de não existir resposta aos pacotes de sondagem dentro de um intervalo previamente definido, a conexão é considerada inválida, permitindo que a aplicação tome ações apropriadas.

Para implementar o TCP *keep alive* é adotada a biblioteca *socket*, que fornece as funcionalidades necessárias para habilitar o mecanismo no *socket* de comunicação, através do ajuste de opções específicas do *socket*.

Ao criar o *socket* TCP cliente, é essencial habilitar o TCP *keep alive*, definindo os parâmetros de intervalo entre os pacotes de sondagem, número de tentativas de envio sem resposta e tempo máximo de espera para resposta.

Uma vez habilitado o TCP *keep alive* no *socket*, a aplicação pode prosseguir com a comunicação normal entre os nós. Durante períodos de inatividade, serão automaticamente enviados pacotes de sondagem, como ilustrado na figura 4.6, verificando a validade da conexão, permitindo que a aplicação detete e reaja a desconexões inesperadas, garantindo a continuidade da comunicação, mesmo em ambientes com instabilidades de rede.

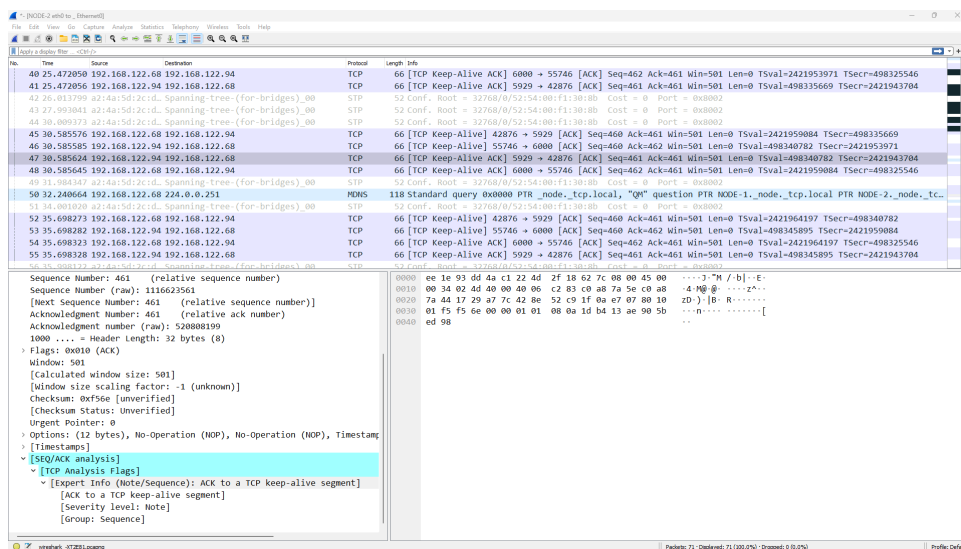


Figura 4.6: Captura de pacotes *keep alive* através da aplicação *wireshark*

Num ambiente inteligente distribuído, onde falhas na rede podem ocorrer, a implementação de tais mecanismos é essencial para garantir a continuidade das conexões e a resiliência da comunicação entre os nós.

Assim, ao verificar a atividade dos nós e reorganizar dinamicamente a rede, os mecanismos de reconexão asseguram uma comunicação contínua e eficiente entre os *peers*, reforçando a colaboração e a confiabilidade da arquitetura distribuída. Desse modo, a utilização desses mecanismos torna a rede P2P mais robusta e preparada para lidar com possíveis desafios e falhas na rede, garantindo o sucesso do sistema *DistSense* como uma equipe colaborativa.

### 4.3.1 Mensagens, estrutura e procedimento

Um sistema distribuído consiste num conjunto de processos independentes que executam em diferentes máquinas e comunicam entre si por meio de troca de mensagens, permitindo

a criação de redes descentralizadas, onde os nós podem coordenar e compartilhar informações de maneira eficiente.

Assim, é essencial que haja mecanismos para lidar com as mensagens entre os dispositivos. O sistema *DistSense* é projetado para ser executado por nós que atuam como *peers*, ou seja, entidades autónomas que se comunicam entre si para realizar operações como transações e atualizações na *Blockchain*.

As mensagens trocadas entre os nós são representadas em formato JSON, que é uma notação de dados leve e amplamente suportada. Esse formato torna a serialização e deserialização das mensagens mais simples, facilitando a interoperabilidade do sistema.

Cada mensagem é estruturada como um dicionário JSON contendo campos relevantes, como o tipo de mensagem, o conteúdo da mensagem, e outras informações necessárias para o processamento adequado, como representado na figura 4.7.

```
1  {
2    "META": {
3      "CLIENT": "0.0.1",
4      "FROM_ADDRESS": {
5        "UUID": "07b4ab99-504a-40d9-ad2a-69e4c47e21c8",
6        "IP": "192.168.122.94",
7        "PORT": 5929
8      },
9      "TO_ADDRESS": {
10       "UUID": "d8544564-ec92-421a-94c4-27ff2bd003d4",
11       "IP": "192.168.122.68",
12       "PORT": 6000
13     }
14   },
15   "TYPE": "PING",
16   "PAYLOAD": {
17     "LAST_TIME_ALIVE": 1689886629.4676633,
18     "COORDINATOR": "07b4ab99-504a-40d9-ad2a-69e4c47e21c8"
19   }
20 }
```

Figura 4.7: Mensagem padrão no formato JSON em *python*

O mecanismo para lidar com as mensagens num sistema distribuído, como o *DistSense*, é implementado por meio de um conjunto de métodos e estruturas que possibilitam a receção, processamento e envio adequado das mensagens entre os nós da rede.

Nesse sentido, o sistema mantém uma conexão de rede ativa entre os nós, permitindo a troca de mensagens, sendo que cada nó possui um socket que fica a aguardar a chegada de mensagens, após a chegada de uma nova mensagem, esta é armazenada num *buffer* de entrada, aguardando o processamento com base no tipo de mensagem para tomar as ações apropriadas. Em seguida, é enviada a mensagem de resposta ao nó remetente através do socket de conexão.

Através destes mecanismos implementados, o sistema *DistSense* é capaz de lidar efi-

---

cientemente com as mensagens entre os nós da rede. A estruturação dos dados em formato JSON, a definição clara dos tipos de mensagem e a atribuição de métodos específicos para o processamento de cada tipo permitem que os nós coordenem as suas atividades, realizem transações, atualizem informações na *blockchain* e garantam a integridade e segurança das operações num ambiente distribuído. A robustez do mecanismo de tratamento de exceções contribui para a confiabilidade do sistema, garantindo que possíveis erros ou falhas sejam tratados de forma adequada e que a rede continue a funcionar de maneira resiliente.

## 4.4 Aprendizagem computacional

A monitorização e análise de dados em tempo real são elementos cruciais em diversos domínios, como segurança, saúde, transporte e meio ambiente. Com os avanços nas tecnologias de sensores e captura de dados, surgiram sistemas de monitorização sofisticados, capazes de capturar informações detalhadas a partir de múltiplas fontes.

Neste contexto, verifica-se que tais sistemas têm vindo progressivamente a incorporar métodos provenientes da aprendizagem computacional, destacando-se, em particular, o recurso recorrente a redes neuronais artificiais, tendo sido amplamente adotadas na interpretação e extração de informações relevantes a partir dos dados capturados.

As redes neuronais, por sua vez, apresentam-se como uma abordagem de elevado potencial no que concerne à identificação de padrões com algum grau de complexidade presentes em conjuntos de dados extensos, o que permite efetuar uma análise automatizada de desempenho substancial.

A aprendizagem computacional corresponde ao sub-campo da inteligência artificial que se concentra no desenvolvimento de algoritmos capazes de melhorar o seu desempenho numa tarefa específica por meio da experiência adquirida com a prática (El Naqa and Murphy, 2015). Diferentes técnicas de aprendizagem computacional são aplicadas dependendo da natureza dos dados e da complexidade da tarefa em questão.

No sistema *DistSense*, são utilizadas técnicas de aprendizagem computacional aplicadas à monitorização de áudio e vídeo, que visam detetar atividades do quotidiano do utilizador em tempo real. Nesse sentido, são adotados dois modelos amplamente reconhecidos na comunidade científica: o modelo *YAMNet* para processamento de áudio e o modelo *Movinet* para análise de vídeo.

O *YAMNet* é um modelo de DL pré-treinado para classificação de áudio em várias categorias sonoras. Ele foi desenvolvido com base numa arquitetura de rede neuronal convolucional e já foi treinado num extenso conjunto de dados para capturar informações sonoras relevantes.

Por sua vez, o *Movinet* é um modelo de DL especialmente concebido para tarefas de processamento de vídeo, como deteção de objetos e reconhecimento de atividades. A ar-

---

quitetura deste modelo baseada em transformadores permite capturar contextos temporais e espaciais complexos, tornando-o adequado para análise de vídeo.

O modelo *Movinet* foi treinado utilizando o conjunto de dados *Kinetics-600* (Carreira et al., 2018). Este conjunto de dados abrange a anotação de vídeos que representam classes de ações humanas, incluindo interações humano-objeto e humano-humano.

A escolha dos modelos *YAMNet* e *Movinet* pré-treinados deve-se à sua eficácia em tarefas específicas de processamento de áudio e vídeo em tempo real. Essa eficácia decorre, em grande parte, da transferência de aprendizagem, uma estratégia poderosa que permite aproveitar o conhecimento prévio desses modelos, adquirido em conjuntos de dados extensos. Essa abordagem não só acelera o treino, mas também melhora significativamente o desempenho em tarefas relacionadas, pois beneficia da especialização desses modelos nas suas áreas específicas de atuação.

A implementação dos modelos *YAMNet* e *Movinet* foi realizada utilizando a plataforma *TensorFlow* (TF), uma biblioteca de código aberto para aprendizagem computacional e desenvolvimento de redes neurais, visto que oferece uma variedade de ferramentas e recursos para construir, treinar e avaliar modelos de ML, tornando o processo de implementação mais eficiente e acessível.

A utilização de aprendizagem computacional na monitorização de áudio e vídeo tem o potencial de fornecer informações valiosas para diversas aplicações práticas. Os modelos implementados neste sistema contribuem para a deteção e classificação de eventos sonoros e padrões visuais em tempo real, aprimorando a capacidade de tomada de decisão e fornecendo uma visão mais abrangente dos dados monitorizados.

#### **4.4.1 Pré-processamento do conjunto de dados audiovisuais**

Antes de iniciar o treino dos modelos, é necessário realizar o pré-processamento dos conjuntos de dados de entrada, tanto de áudio como de vídeo. No que se refere ao conjunto de dados de áudio, foram escolhidos dois conjuntos principais: o *FSD50k* (Fonseca et al., 2022) e o *ESC-50* (Piczak, 2015). No que concerne ao conjunto de dados de vídeo, optou-se por utilizar o *Toyota Smart Home* (Das et al., 2019) e pelo *Charades* (Sigurdsson et al., 2016). Estes conjuntos foram selecionados para a tarefa específica de identificação e classificação de sons e vídeos relevantes no contexto doméstico.

Um passo crucial nesse procedimento é a seleção das classes mais pertinentes para cada conjunto de dados, sendo necessária a análise de cada áudio e vídeo individualmente, para avaliar a sua qualidade e relevância em relação ao objetivo em questão. Durante esse processo, é importante eliminar os sons e/ou vídeos que contenham várias classes misturadas, uma vez que a presença de várias classes num único ficheiro pode dificultar a correta classificação.

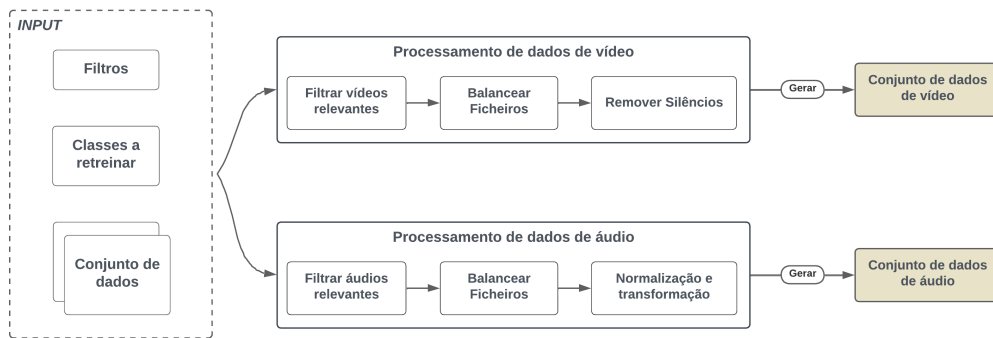


Figura 4.8: Fluxo do processo de pré-processamento do conjunto de dados audiovisuais

Apesar de ser um trabalho minucioso, especialmente num conjunto de dados com milhares de sons e vídeos, esta etapa é essencial para garantir a qualidade dos modelos. A seleção cuidadosa das classes contribui para a eficiência de cada modelo e a precisão das classificações realizadas.

Outro procedimento realizado durante o processamento do conjunto de dados é o balanceamento das classes, sendo que é uma etapa importante para evitar que o modelo se torne tendencioso em relação a classes com mais exemplos e, assim, garantir que a aprendizagem seja equilibrada em todas as classes.

Além disso, no domínio do áudio, é realizada a remoção dos segmentos de silêncio presentes nos sons, o que consiste em eliminar partes dos ficheiros que possuam níveis baixos de decibéis, geralmente localizados no início, meio ou fim de cada som. A remoção destes segmentos de silêncio é relevante para eliminar ruídos indesejados e garantir que apenas informações relevantes sejam consideradas durante o treino do modelo.

Estas etapas de pré-processamento do conjunto de dados são fundamentais para aprimorar a qualidade dos dados utilizados no treino de cada modelo. A eliminação de segmentos indesejados e a construção de um conjunto de dados consistente e limpo garantem que o modelo seja alimentado com informações precisas e relevantes, permitindo que o mesmo aprenda padrões significativos para a tarefa em questão.

A seguir a esta fase de pré-processamento, o conjunto de dados tratado está pronto para ser utilizado no treino do modelo. Através da utilização do modelo *YAMNet* para processamento de áudio, e do modelo *Movinet* para análise de vídeo, é possível obter resultados de qualidade na identificação e classificação de sons e vídeos, contribuindo para aplicações práticas em sistemas de monitorização de casas inteligentes e diversos outros domínios.

#### 4.4.2 Treino dos modelos

A estratégia de transferência de aprendizagem tem revelado ser altamente eficaz na otimização do desempenho de modelos de redes neuronais, como é o caso dos modelos adotados, *MoViNet* e *YAMNet*, para tarefas específicas.

No âmbito da monitorização de áudio, depara-se com desafios consideráveis na extração de informações relevantes a partir de sinais acústicos, neste sentido, a criação de modelos especializados voltados para a análise de áudio assume uma importância fundamental.

Assim, preparar adequadamente os dados de áudio, previamente pré-processados, para o treino destes modelos é uma etapa crucial, englobando a redefinição de variáveis críticas, como o número de canais e a taxa de amostragem, sendo que estes fatores desempenham um papel determinante na asseguarção da qualidade do modelo resultante.

A extração de *embeddings* provenientes do modelo original desempenha um papel central na construção de uma nova abordagem simplificada. Os *embeddings*, enquanto representações vetoriais contínuas de variáveis discretas, facultam a aprendizagem de características relevantes para o contexto do sistema de monitorização. A conversão das variáveis categóricas em espaços vetoriais de dimensão reduzida permite não só a redução da complexidade dos dados, como também a representação significativa das diversas classes selecionadas.




Figura 4.9: Janela deslizante utilizada na implementação do modelo *YAMNet*

No caso particular do modelo *YAMNet*, o mesmo faz uso de *features* com uma dimensão de 1024, as quais caracterizam cada *frame* de áudio, correspondente a um intervalo de tempo de 0.96 segundos. No processo de treino, é imperativo garantir que a sequência de áudio de entrada possua uma frequência de amostragem de 16 kHz e esteja configurada para um único canal. Para explorar aspetos temporais, o áudio é particionado em janelas de 0.96 segundos, com um passo de 0.48 segundos entre cada uma, originando, deste modo, uma abordagem de janela deslizante demonstrada na figura 4.9.

No âmbito da análise visual, com o intuito de solidificar o procedimento de treino

---

do modelo *MoViNet*, são incorporadas abordagens fundamentadas em transferência de aprendizagem, após submeter conjuntos de dados audiovisuais a um processo de pré-processamento, onde se procede a uma curadoria e equilíbrio dos dados audiovisuais. Este processo visa adequadamente preparar os conjuntos de dados para o propósito de classificação de atividades em tempo real.

O modelo *MoViNet* evidencia-se como um robusto classificador de vídeo, encontrando aplicações em cenários de *streaming* de vídeo e inferência em tempo real, no âmbito do reconhecimento de ações. Por outro lado, os modelos assentes em *frames* 2D, apesar da sua eficiência na análise de vídeos completos ou *frames* individuais em regime de *streaming*, revelam limitações na consideração do contexto temporal, culminando numa precisão limitada e resultados inconsistentes entre *frames* sucessivos.

Uma abordagem mais sofisticada engloba a utilização de redes convolucionais 3D, as quais incorporam contexto temporal bidirecional, contribuindo assim para um incremento da precisão e consistência temporal. No entanto, estas redes podem exigir mais recursos computacionais e não são ideais para o processamento de fluxos contínuos de dados, dado o requisito de considerar informações futuras.

Posto isto, o traço arquitetónico distintivo do modelo *MoViNet* reside na adoção de convoluções 3D causais ao longo do eixo temporal, assemelhando-se à operação "*layers.Conv1D*" com o parâmetro "*padding='causal'*". Este design conjuga as vantagens das abordagens anteriores, possibilitando uma análise eficaz em *streaming*.

Adicionalmente, é crucial compreender que o modelo *MoViNet* implementado requer um tensor de vídeo 5D RGB como entrada, apresentando uma estrutura específica: [BATCH\_SIZE, NUM\_FRAMES, HEIGHT\_PIXELS, WIDTH\_PIXELS, 3]. Esta configuração permite que o modelo analise cada *frame* dentro de um contexto mais alargado, garantindo, desse modo, a apreensão mais precisa das relações temporais e espaciais presentes na captura de vídeo.

A convolução causal garante que a saída no tempo "*x*" seja calculada apenas com base em entradas até o tempo "*y*". Esta eficiência em regime de *streaming* pode ser ilustrada por meio de uma analogia com as RNN, nas quais o estado é transmitido ao longo do tempo. No contexto do *MoViNet*, esse estado é designado por "*Stream Buffer*".

O treino do modelo *MoViNet* através da transferência de aprendizagem baseia-se num conjunto de dados previamente tratado e equilibrado, onde implica a utilização de pesos pré-treinados do *MoViNet* num conjunto de dados mais abrangente, seguida de uma afinação com o conjunto de dados preparado especificamente para a tarefa de reconhecimento de ações em vídeos.

Assim, este processo exige a adaptação dos parâmetros, de forma a refletir as nuances e particularidades do novo conjunto de dados. As camadas superiores do modelo são ajustadas para se adequarem à tarefa em questão, ao passo que as camadas mais profundas, responsáveis por capturar características genéricas, permanecem inalteradas.

A figura 4.10 representa a progressão da precisão no treino dos modelos de áudio e vídeo, nos quais foram utilizadas 20 *epochs* para o modelo de áudio e 10 *epochs* para o modelo de vídeo.




Figura 4.10: Evolução da precisão no treino dos modelos *YAMNet* e *MoViNet*

A eficácia do treino é ampliada pela qualidade do conjunto de dados adequadamente tratado e balanceado. A seleção de exemplos representativos de cada classe de ação, em quantidade suficiente para evitar desequilíbrios, é fundamental para o sucesso da transferência de aprendizagem. Este enfoque permite que o modelo generalize com precisão para dados não observados previamente.

Posto isto, o processo de treino do modelo *MoViNet* mediante a transferência de aprendizagem, apoiado por um conjunto de dados devidamente tratado e equilibrado, constitui uma abordagem sólida para aprimorar a capacidade de classificação de ações em vídeos, conferindo ao modelo a capacidade de realizar inferências eficientes e precisas em tempo real, maximizando, simultaneamente, a exploração do contexto temporal.

### 4.4.3 Conversão dos modelos

À medida que os sistemas de monitorização inteligente ganham terreno em ambientes domésticos, surge uma necessidade premente: otimizar o processamento em dispositivos de recursos limitados, como é o *Jetson Nano* e/ou *Raspberry Pi*. Neste contexto, a otimização de modelos de ML complexos, como o *Yamnet* para áudio e o *Movinet* para vídeo, assume um papel crucial, exigindo abordagens inovadoras.

Assim, após o treino dos modelos num conjunto de dados audiovisuais cuidadosamente pré-processados, a etapa seguinte envolve a sua conversão para um formato mais leve, como o formato *.tflite*.

A transformação de modelos complexos para o formato *.tflite* oferece uma série de vantagens significativas. Em primeiro lugar, a compactação resultante otimiza consideravelmente o espaço que esses modelos ocupam, desempenhando um papel vital em

---

ambientes onde o espaço de armazenamento é limitado, permitindo a inclusão de vários modelos no mesmo dispositivo, sem comprometer a qualidade ou a eficiência.

Adicionalmente, apresenta melhorias notáveis em termos de agilidade operacional, sendo que a latência da inferência é reduzida através da eliminação de etapas de análise e descompressão, resultando em interações mais ágeis e na detecção de eventos em tempo real. Este aspecto é crucial na implementação do sistema *DistSense*, onde a resposta imediata é fundamental para o funcionamento eficaz do sistema.

A integração de meta dados durante o processo de conversão é outra vantagem substancial. Esses meta dados não fornecem apenas descrições compreensíveis das funcionalidades dos modelos, mas também apresentam informações estruturadas que simplificam a configuração do fluxo de trabalho. Num ambiente distribuído, essa característica fortalece ainda mais a eficiência operacional, uma vez que os modelos otimizados podem ser ajustados com precisão às necessidades específicas de processamento.

No entanto, a conversão de modelos complexos para o formato *.tflite* não está isenta de desafios. Um dos desafios mais comuns é a incompatibilidade de operações, onde determinadas operações existentes nos modelos originais não são suportadas pelo formato *.tflite*, como é o caso do modelo de áudio nas operações: *ComplexAbs* e *RFFT2D*. A solução implica a criação de modelos equivalentes que fazem uso de operações compatíveis. Esta tarefa requer a análise e recriação cuidadosa das partes do modelo afetadas.

Além disso, esta etapa pode levar a uma ligeira perda na qualidade da inferência, sendo atenuada pela aplicação de técnicas de otimização, como a quantização, que permite representar números de ponto flutuante com menos *bits*, mantendo um nível aceitável de precisão, como descrito no estudo de (Verma et al., 2021). Este aspecto é particularmente relevante quando se lida com os recursos limitados dos dispositivos.

Neste contexto, a implementação da conversão de modelos complexos para o formato *.tflite* revela-se altamente vantajosa e estratégica para o sistema *DistSense*, visto que alinha-se perfeitamente com a necessidade premente de otimizar o processamento em dispositivos com recursos escassos, como os dispositivos *Jetson Nano* utilizados para executar o sistema.

## 4.5 Processamento e representação do conhecimento

Com a evolução tecnológica e a crescente necessidade de sistemas de monitorização inteligentes, o processamento e a representação do conhecimento desempenham um papel vital na criação de sistemas eficazes e seguros. Após o treino cuidadoso dos modelos de análise audiovisual, surgem etapas essenciais de recolha e análise de dados, como ilustrado na figura 3.3.

Numa fase inicial, a captura dos dados através de câmaras e microfones estrategicamente posicionados, frequentemente apresentados sob a forma de imagens, sequências

---

de áudio e dados temporais, são submetidos a um processo minucioso de processamento, onde são normalizados e convertidos em formatos que se alinham com os requisitos específicos dos modelos previamente treinados.

```
1 def pre_process(image: np.ndarray) -> np.ndarray:
2     """Preprocess the image as required by the TFLite model."""
3     input_tensor = cv2.resize(image, (224, 224))
4     input_tensor = input_tensor[np.newaxis, np.newaxis]
5     input_tensor = np.float32(input_tensor - 0 ) / 255
6
7     return input_tensor
```

Figura 4.11: Pré-processamento dos dados para inferência do modelo *MoViNet* em *python*

Neste contexto, são implementados mecanismos que desempenham funções essenciais para otimizar o desempenho do sistema. Estas funções incluem o redimensionamento da imagem capturada para uma resolução padronizada, a normalização das intensidades dos pixels para um intervalo entre 0 e 1, e a aplicação da padronização *z-score*. Estas etapas visam alinhar as características das imagens com o modelo pré-treinado, otimizando assim as entradas para a inferência de dados visuais em tempo real, tal como é demonstrado na figura 4.11.

Com a utilização de sensores audiovisuais integrados no *Jetson Nano*, para inferir atividades do quotidiano do utilizador em tempo real, surge a necessidade de adotar tecnologias que desempenham um papel crucial na viabilização, processamento e representação do conhecimento do sistema. Duas das tecnologias em destaque e pertinentes para o sistema *DistSense* são a *blockchain* e o *Home Assistant*.

### 4.5.1 *Blockchain*

A utilização da tecnologia *blockchain* oferece uma abordagem segura e transparente para registar e validar as informações recolhidas pelo sistema, como descrito na secção 3.7. Através da sua imutabilidade e descentralização é garantido o armazenamento confiável de todas as atividades e dados inferidos, preservando a integridade e autenticidade das informações. Adicionalmente, permite criar registos à prova de adulteração, contribuindo para a confiança das atividades inferidas pelo sistema proposto, proporcionando um nível adicional de segurança.

Neste sentido, a arquitetura da *blockchain* é especialmente pertinente para o sistema *DistSense*, uma vez que oferece uma maneira confiável e segura de armazenar e manter um registo cronológico das atividades capturadas. Adicionalmente, esta arquitetura possibilita que os nós consultem o registo de eventos, o que, em situações de incerteza, facilita a inferência mais precisa das informações percecionadas por outros nós do sistema.

Esta tecnologia, segura e descentralizada, é alicerçada na estruturação dos blocos, que são os alicerces da *chain*.

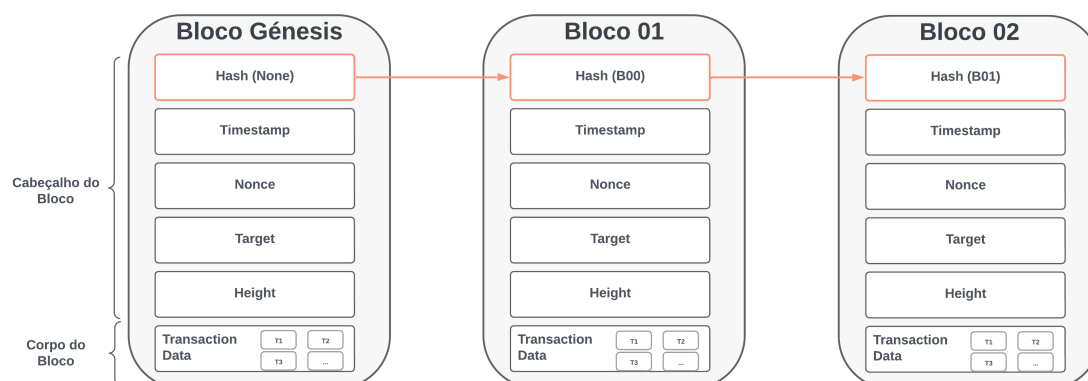


Figura 4.12: Estrutura de cada bloco da *blockchain* do sistema *DistSense*

Cada bloco na *blockchain* segue uma estrutura cuidadosamente definida, sendo composta por elementos essenciais como *timestamp*, *hash*, *target*, *nonce*, *height* e transações, conforme representado na figura 4.12.

O *timestamp*, registra a data e hora exatas da criação do bloco, assumindo uma importância crucial para ordenar cronologicamente os eventos na *blockchain*, conferindo à solução a capacidade de distinguir sequências de ocorrências, revelando-se crucial em cenários de monitorização nos quais a ordem das ações é imperativa para a análise dos dados.

O *hash*, por sua vez, consiste numa assinatura digital única derivada do conteúdo do bloco, gerada com auxílio de algoritmos criptográficos. Esta representação compacta e segura do bloco serve como um mecanismo de autenticação e identificação infalível, uma vez que ao ligar cada bloco ao seu antecessor através do *hash*, a *blockchain* constrói uma *chain* inquebrável e imutável de transações e eventos.

Em seguida, o parâmetro *target* assume um papel essencial ao determinar a complexidade do processo de *mining*. Ao estabelecer o grau de dificuldade necessário para validar os blocos, o *target* regula a frequência da incorporação de novos blocos na *blockchain*. No âmbito da monitorização, esta parametrização revela-se crucial para garantir uma vigilância eficiente e em tempo real, evitando excessos ou lacunas temporais indesejadas.

Posteriormente, o *nonce*, o componente "*number only used once*", desempenha um papel crucial no algoritmo *Proof of Work* (PoW). Este valor, subjacente a complexos cálculos criptográficos, é ajustado iterativamente pelos *miners* até que um *hash* válido seja alcançado. A energia computacional exigida por este processo constitui uma camada de segurança adicional, essencial para a confirmação e validação das transações na rede (Ammous, 2016).

Adicionalmente, a altura do bloco indica a sua posição na *chain*, definindo a sequência ordenada dos eventos registados. O conceito de altura fornece uma perspetiva hierárquica

na visualização dos dados, promovendo a compreensão da evolução temporal dos eventos monitorizados.

As transações são módulos essenciais da *blockchain*, onde registam a transferência de informação, bens ou contratos. Na perspetiva do sistema *DistSense*, estas transações assumem o papel de dados monitorizados e registados de forma imutável, conferindo uma sequência cronológica de acontecimentos na rede e de inferência.

Neste sentido, a operação de inferência do sistema *DistSense* consiste na inserção dos dados previamente processados nos modelos, conferindo-lhes a habilidade de identificar padrões, eventos e anomalias. No momento em que a precisão da inferência ultrapassa um limiar crítico  $\Delta \%$ , o sistema entra em ação para registar o evento identificado e todos os pormenores a ele associados, garantindo que apenas sejam armazenadas informações de alto nível.

Por outro lado, quando a precisão da inferência não atinge o limiar previamente estabelecido, o nó encarregado de registar a atividade doméstica consulta a *blockchain* para obter informações mais precisas acerca dos eventos mais recentes ocorridos, num determinado intervalo de tempo correspondente ao local onde a atividade foi registada. Este procedimento visa aprimorar a qualidade da deteção e compreensão do que está a acontecer, assegurando que apenas informações pertinentes e de elevado nível sejam armazenadas.

Além disso, o processo de registo de eventos baseia-se na comparação de cada novo evento com o evento capturado previamente, sendo que apenas os eventos que apresentam diferenças significativas em relação ao evento anterior são registados, uma vez que estes representam momentos de mudança ou transição na atividade monitorizada.

Assim, eventos idênticos ao seu antecessor são considerados como partes de uma continuidade de atividade e, portanto, não são armazenados, uma vez que não adicionam informação relevante sobre a evolução temporal.

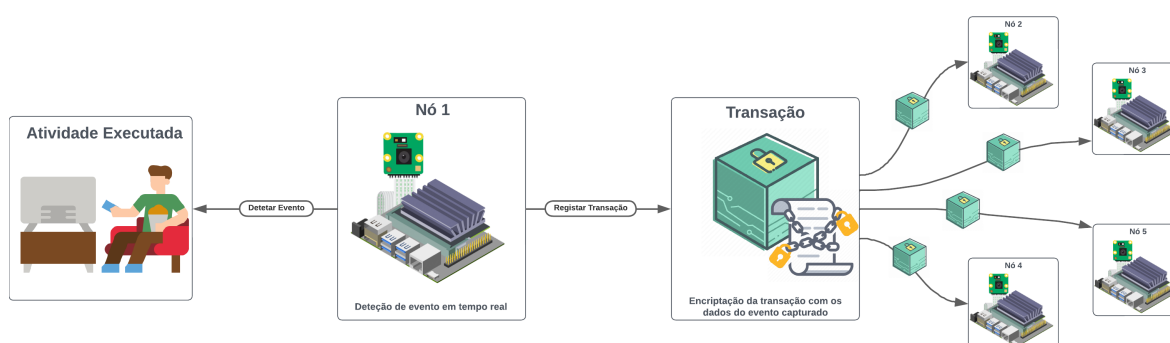


Figura 4.13: Fluxo de registo de transação na *blockchain*

O evento identificado, em conjunto com detalhes como o tipo, data, localização e o UUID do dispositivo específico que detetou o evento, é integrado numa transação, sendo posteriormente, transmitida para todos os nós presentes na rede doméstica, ilustrado na figura 4.13. No entanto, antes do envio da transação, é importante garantir a integridade

---

e a confiabilidade dos dados para que os outros dispositivos presentes na rede validem a transação.

Desta forma, a transação passa por um processo de encriptação, onde é submetida a algoritmos criptográficos robustos que assinam a mensagem após esta ser submetida a um processo de *hash*. Posteriormente, a transação encriptada é enviada para os outros dispositivos na rede local.

Este procedimento não apenas acrescenta uma camada adicional de segurança, mas também assegura que os dados se mantenham íntegros e confidenciais durante todo o processo de transmissão. A assinatura criptográfica resultante atua como garantia da preservação da integridade da transação à medida que é partilhada entre os diversos nós da rede.

Quando a transação chega a cada nó do sistema *DistSense* na rede doméstica, esta segue um processo rigoroso de validação, onde certifica-se de que a transação é legítima e cumpre com as regras pré-estabelecidas pelo sistema, caso a validação seja bem-sucedida, a transação é adicionada a uma lista de transações pendentes.

Quando a transação chega a cada nó da rede, esta passa por um processo rigoroso de validação para garantir a sua legitimidade e conformidade com as regras do sistema *DistSense*, se a validação for bem-sucedida, a transação é adicionada a uma lista de transações pendentes.

À medida que o número de transações pendentes aumenta e atinge o limite estabelecido, o nó coordenador é notificado, desencadeando o início do processo de *mining*. Este processo envolve a resolução de desafios computacionais complexos, culminando na criação de um novo bloco que agrupa as transações previamente validadas, sendo, posteriormente, incorporado à *blockchain*, assegurando de forma segura e imutável a integridade das transações.

Assim, o sistema *DistSense* demonstra uma sofisticação ao permitir a aquisição, análise e armazenamento de informações originárias de fontes de áudio e vídeo. Através da aplicação de algoritmos de ML, este sistema é capaz de identificar eventos relevantes, como sons anómalos ou atividades do quotidiano do utilizador. Após o processamento dos dados, esses eventos são registados de forma imutável na *blockchain*, garantindo a autenticidade e inviolabilidade dos dados.

## **4.5.2 Home Assistant**

Num contexto onde a automação residencial é cada vez mais um paradigma essencial, a ligação entre dispositivos e sistemas inteligentes assume um papel primordial na construção de ambientes residenciais inteligentes e reativos. Perante isto, é necessário a implementação de uma comunicação bidirecional fluida entre a plataforma de automação residencial e o sistema *DistSense*, apoiando-se no protocolo MQTT, concebido especialmente para ambientes IoT e de domótica.

---

A preferência pelo HA, em detrimento de outras plataformas de automação residencial, fundamenta-se numa série de vantagens e características que convergem para uma escolha bem fundamentada e ajustada à visão do sistema *DistSense*.

Em primeiro lugar, a seleção do HA assenta na sua flexibilidade e adaptabilidade. Como plataforma de código aberto, oferece uma capacidade ímpar de ajuste às necessidades específicas da casa inteligente, permitindo não só personalizar a interface, mas também desenvolver automatizações e integrações de uma variedade abrangente de dispositivos de diferentes origens. A modularidade e expansibilidade inerentes à plataforma são fatores que garantem uma solução perfeitamente sintonizada com as preferências individuais do sistema.

A diversidade de integrações oferecidas pela plataforma é outro fator de ponderação crucial, sendo compatível com uma ampla panóplia de dispositivos e serviços, garantindo uma inclusão abrangente de quase todos os elementos do ambiente doméstico inteligente no contexto da automação. Este atributo não apenas previne o bloqueio a produtos de um único fabricante, mas também assegura a interconexão fluida entre distintos dispositivos.

Além disso, a segurança constitui uma consideração essencial subjacente à preferência pelo HA. A priorização da salvaguarda da privacidade dos dados sensíveis do utilizador é atendida pela capacidade desta plataforma em manter o controlo local sobre as informações, evitando a dependência de servidores externos para armazenamento e processamento, minimiza consideravelmente os riscos inerentes a potenciais ciberataques e fugas de informação.

O dinamismo da comunidade e o suporte permanente contribuem também de forma significativa para a nossa opção pelo HA. O contínuo envolvimento de programadores e utilizadores na melhoria e otimização da plataforma reflete-se nas atualizações regulares e na pronta resolução de problemas.

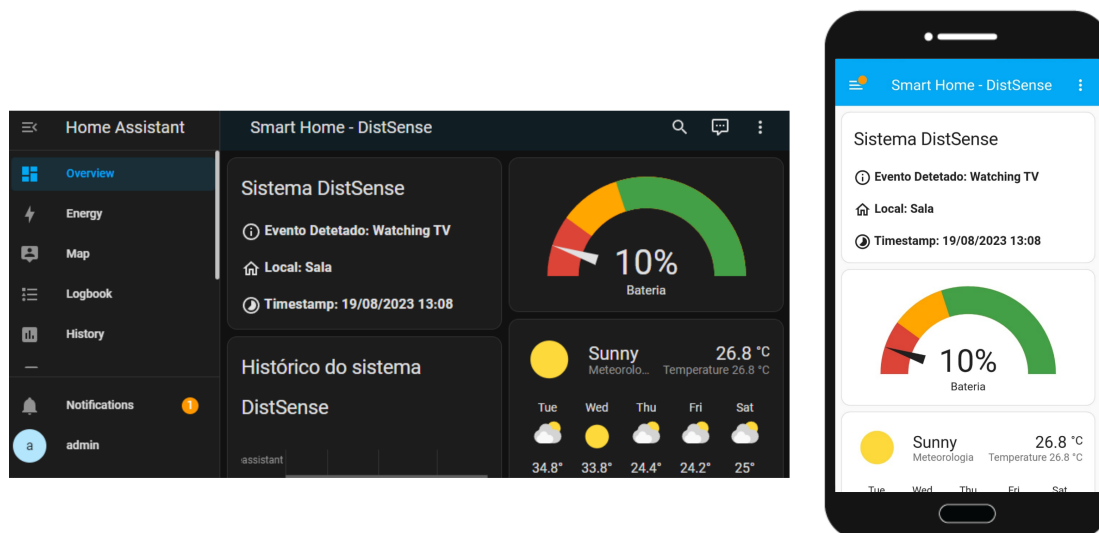


Figura 4.14: Interface da plataforma HA em vistas distintas

A interface de fácil utilização do HA facilita a interação com a plataforma, seja através da aplicação móvel ou da interface web, conforme ilustrado na figura 4.14, onde é possível controlar dispositivos, criar cenários e estabelecer regras sem dificuldades. Esta simplicidade de operação é essencial para a maximização do benefício da automação residencial, tornando-a acessível a todos os membros da família.

Um dos elementos essenciais desta implementação reside na utilização do protocolo MQTT para a comunicação entre o sistema *DistSense* e o exterior. Neste sistema, o nó coordenador assume a responsabilidade de enviar os eventos inferidos, os quais são encapsulados em mensagens JSON, para tópicos MQTT específicos.

Em contrapartida, a função do HA é desempenhar o papel de subscritor, permanecendo à escuta pela chegada de mensagens nos tópicos utilizados, simplificando a transferência das informações do sistema para o utilizador, estabelecendo assim um ambiente de partilha de dados em tempo real de forma eficiente e contínua.

A fase inicial requer a configuração de um *broker* MQTT, que atua como intermediário para as trocas de mensagens, este *broker*, acessível tanto ao sistema *DistSense* como ao HA, desempenha um papel central na facilitação da comunicação bidirecional. A atribuição criteriosa dos tópicos, organizados de maneira hierárquica, destaca-se como um aspeto fundamental para assegurar a fluidez de todo o processo.

Com os tópicos estabelecidos, o sistema distribuído implementado cumpre o seu papel ao identificar e processar localmente eventos relevantes ao contexto do utilizador, que posteriormente são encapsulados em mensagens JSON, contendo detalhes críticos de alto nível para a representação do conhecimento, como o tipo de evento, o registo temporal e uma breve descrição. Uma vez publicadas nos tópicos MQTT correspondentes, as mensagens iniciam a sua transmissão em direção ao HA.

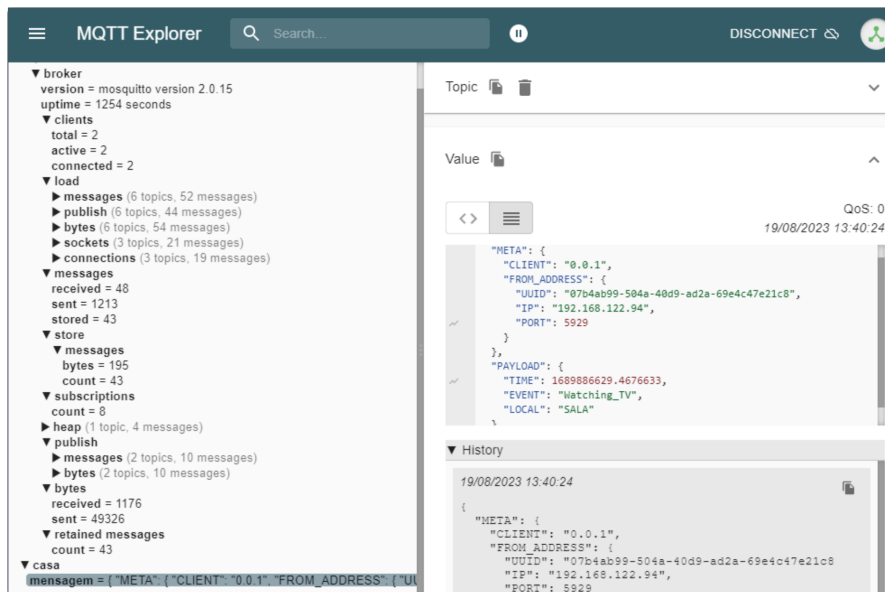


Figura 4.15: Mensagem enviada pelo nó coordenador via MQTT para o HA

Após configurado para subscrever os tópicos específicos, o HA permanece à espera de novas mensagens provenientes do sistema *DistSense* via MQTT, quando recebe uma mensagem, é acionado um gatilho que desencadeia uma automação predefinida, que neste caso se limita a demonstrar visualmente o evento detetado, embora possa ser personalizado conforme as necessidades do utilizador.

A elegância desta integração manifesta-se na automação e visualização dos eventos. O HA, ao receber uma mensagem MQTT, interpreta-a e ativa uma automação correspondente. Por exemplo, os detalhes do evento são extraídos da mensagem JSON e apresentados de forma visualmente apelativa na interface do utilizador, onde um elemento simples, como uma *label*, pode conter informações essenciais, como o tipo de evento, a descrição e o *timestamp* da inferência dos dados.

Para aprimorar a experiência, regras personalizadas podem ser implementadas em *python*. Estas regras facultam uma manipulação mais refinada das mensagens MQTT, permitindo a realização de ações específicas ou interações com outros componentes do HA.

Para enriquecer a experiência, são implementadas regras personalizadas em *Python*, como demonstrado na figura 4.16, permitindo uma manipulação mais refinada das mensagens MQTT, possibilitando a realização de ações específicas ou interações com outros componentes do HA.

```

1 automation:
2   - id: exibir_evento_mqtt
3     alias: Exibir Evento MQTT
4     trigger:
5       platform: mqtt
6       topic: casa/mensagem/
7     action:
8       service: persistent_notification.create
9       data_template:
10        title: "DistSense Info - Alerta"
11        message: "{{ trigger.payload_json.PAYLOAD }}"

```

Figura 4.16: Regra de automação no *Home Assistant* em *python*

A regra de automação implementada no HA, presente na figura 4.16, tem o objetivo de exibir uma notificação persistente sempre que um novo evento é detectado através do protocolo MQTT.

O gatilho da automação é acionado quando uma mensagem MQTT é publicada no tópico especificado, quando isso acontece, a ação é desencadeada, o que por sua vez cria uma notificação com o título "Novo Evento MQTT Recebido".

A mensagem da notificação inclui detalhes sobre o evento, como a atividade capturada, que é extraído dos dados JSON contidos na mensagem MQTT, proporcionando aos utilizadores uma visualização rápida dos eventos recentes identificados pelo sistema *DistSense*, tornando a automação residencial mais informativa e interativa.

A interação dinâmica entre o sistema desenvolvido e o HA, mediada pelo protocolo MQTT, redefine a automação residencial, uma vez que ao identificar e capturar eventos significativos, potenciados por algoritmos de ML, esta implementação cria um ambiente verdadeiramente seguro e personalizado.

Através desta fusão de tecnologias, a automação residencial eleva-se para um novo patamar de inteligência e capacidade de resposta, proporcionando uma experiência envolvente e individualizada aos utilizadores que adotam o sistema *DistSense*.

# Capítulo 5

## Testes e Avaliação

A análise e avaliação de um sistema distribuído com estas características são importantes para garantir, não apenas a sua eficiência, mas também a sua adaptabilidade e confiabilidade num ambiente operacional real. Nesta secção, é dado destaque aos testes e avaliações realizados ao sistema *DistSense* e aos resultados obtidos.

Este sistema tem como principal objetivo capturar dados audiovisuais através de uma rede de sensores distribuída residencial, apresentando um paradigma único de colaboração entre dispositivos distribuídos, propondo uma abordagem segura e precisa para deteção de eventos num ambiente doméstico inteligente.

O sistema *DistSense* distingue-se pela sua natureza distribuída, com múltiplos dispositivos inteligentes interconectados, cada um contribuindo com informações para uma visão holística das atividades num espaço residencial, permitindo uma avaliação mais precisa e eficaz das atividades do dia-a-dia do utilizador.

Neste contexto, a avaliação do sistema realiza-se em três fases distintas, com o propósito de assegurar que este é capaz de lidar com os desafios tanto num ambiente controlado quanto nas complexidades do mundo real.

A primeira fase de testes concentra-se na avaliação individual de cada módulo do sistema de segurança, com o objetivo de garantir que cada módulo implementado funcione harmoniosamente em conjunto, assegurando a escalabilidade e a eficiência global do sistema, de acordo com as especificações da investigação.

Na segunda fase, o sistema é submetido a testes que simulam um caso de uso específico: a deteção de perigos domésticos. Este caso de uso envolve situações de risco, como fugas de água, por exemplo, ou outras ameaças comuns no ambiente doméstico. Os testes simulados são realizados em ambientes controlados, onde os perigos são encenados através da utilização de vídeos, e a resposta do sistema é avaliada. É crucial verificar se o sistema identifica adequadamente os perigos simulados e age de acordo com as diretrizes de segurança estabelecidas. Esta fase permite avaliar os algoritmos e lógicas de decisão implementados para garantir a deteção precisa e a atuação eficaz do sistema.

Na terceira e última fase, o sistema é submetido a uma avaliação em ambiente real,

---

recorrendo a dois dispositivos *Jetson Nano*. Neste contexto, são introduzidos vários tipos de ruído e interferências comuns num ambiente doméstico. Estes incluem ruído de fundo, variações na iluminação, movimentação de animais de estimação e outras condições do mundo real. O objetivo é avaliar o desempenho do sistema sob condições mais desafiantes, que podem afetar a sua capacidade de detetar perigos e agir adequadamente.

A colaboração entre os dispositivos para assegurar uma deteção de eventos mais precisa e confiável foi avaliada sob essas circunstâncias mais dinâmicas, e a escalabilidade do sistema foi analisada à medida que mais dispositivos foram integrados na rede local.

Através de testes criteriosos, o sistema *DistSense* demonstra a sua viabilidade e eficácia no contexto de uma rede distribuída destinada a capturar dados audiovisuais num contexto doméstico. Os dados derivados destes testes não validam apenas a eficácia do sistema, mas também fornecem um alicerce confiável para a implementação futura e aprimoramentos contínuos do mesmo.

## 5.1 Testes funcionais

No âmbito do desenvolvimento de sistemas residenciais inteligentes, a avaliação individual dos módulos emerge como um método fundamental para garantir um funcionamento eficaz e confiável. Esta abordagem revela-se particularmente útil quando se considera o impacto direto que o desempenho dos módulos tem na operação global do sistema.

Os testes funcionais por módulo concentram-se na avaliação das funcionalidades específicas de cada componente integrante do sistema. Esta estratégia envolve a aplicação de casos de teste delineados para verificar a conformidade de cada módulo com os requisitos funcionais estabelecidos no processo de desenvolvimento do sistema *DistSense*.

A figura 5.1 demonstra as interações entre os módulos de aprendizagem computacional e o processamento da representação do conhecimento após a inicialização do nó e o estabelecimento da comunicação com os demais nós na rede.

O funcionamento e a interação com os módulos do sistema *DistSense* iniciam-se com o módulo de descoberta na rede para estabelecer as conexões e as operações iniciais. Cada nó inicializado na rede está equipado com sensores audiovisuais que permitem a deteção em tempo real das atividades domésticas, sendo que quando um nó deteta uma atividade doméstica, surgem duas condições possíveis de funcionamento, conforme ilustrado na figura 5.1.

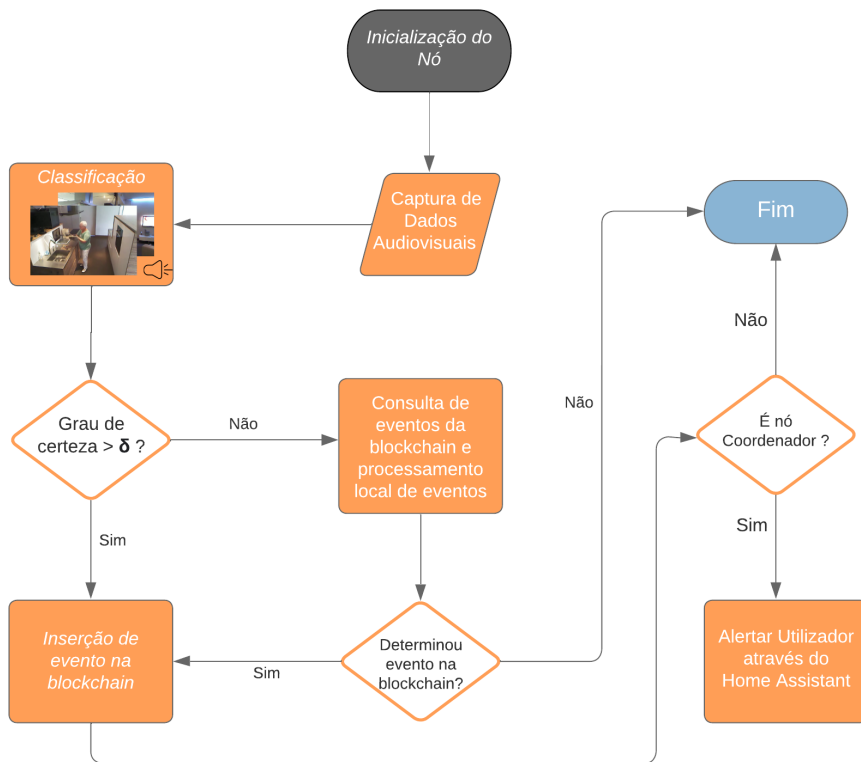


Figura 5.1: Interação entre módulos do sistema *DistSense*

Primeiramente, se o grau de certeza na deteção da atividade atingir um limiar previamente estabelecido pelo sistema, o evento capturado é registado na *blockchain*, juntamente com detalhes cruciais, como o tipo de atividade, o local, a data e a hora em que ocorreu.

No entanto, se a atividade for detetada abaixo desse limiar de certeza, o sistema realizará uma consulta à *blockchain* para verificar o último evento registado no local onde a atividade está a ser detetada, aproveitando a colaboração e o registo de eventos distribuídos. Após a consulta à *blockchain*, o fluxo conduz a uma nova condição: se o nó conseguir determinar o evento mesmo após a consulta à *blockchain*. Se conseguir, o evento será registado na *blockchain*, incluindo todos os detalhes relevantes. Caso contrário, o fluxo de operações será encerrado.

Posteriormente ao registo do evento na *blockchain*, todos os outros nós no sistema recebem a transação e procedem à sua validação. Se o nó em questão for o coordenador do sistema, este envia as informações ao utilizador através do protocolo MQTT, integrando-as na plataforma de automatização HA.

Este fluxograma representa o processo genérico de funcionamento do sistema, assegurando que as informações sejam armazenadas de forma segura na *blockchain* e disponibilizadas eficientemente para os utilizadores através do HA.

## 5.1.1 Módulo de descoberta na rede

O módulo de descoberta desempenha um papel crucial na execução do sistema *DistSense*, onde a sua função principal consiste na identificação automatizada dos dispositivos presentes na rede, fornecendo uma base sólida para a recolha e análise de dados.

Nesse sentido, foram realizados uma série de testes rigorosos para avaliar o desempenho e a precisão deste módulo vital para o bom funcionamento do sistema. Os objetivos fundamentais destes testes envolveram a verificação da capacidade do sistema em três tarefas principais. Num primeiro momento, o foco foi direcionado para a capacidade de deteção inicial de dispositivos na rede local. Para este efeito, procedeu-se à inicialização de quatro nós em ambiente simulado, com a atribuição automatizada de endereços IP via DHCP.

Este primeiro teste exigiu que o sistema demonstrasse a sua capacidade de identificar, de forma rigorosa e precisa, todos os dispositivos presentes na rede no momento da sua inicialização. A identificação desses dispositivos abrangeu uma série de informações relevantes, incluindo a sua nomeação, a tipificação, a aquisição de endereços IP e portas, bem como outras informações específicas, como o local na residência inteligente onde cada nó está a operar. A inclusão de um dispositivo fictício na rede foi prontamente detetada pelo módulo de descoberta, que atualizou a lista de dispositivos identificados de forma imediata e sem qualquer falha perceptível, conforme ilustrado na figura 5.2.

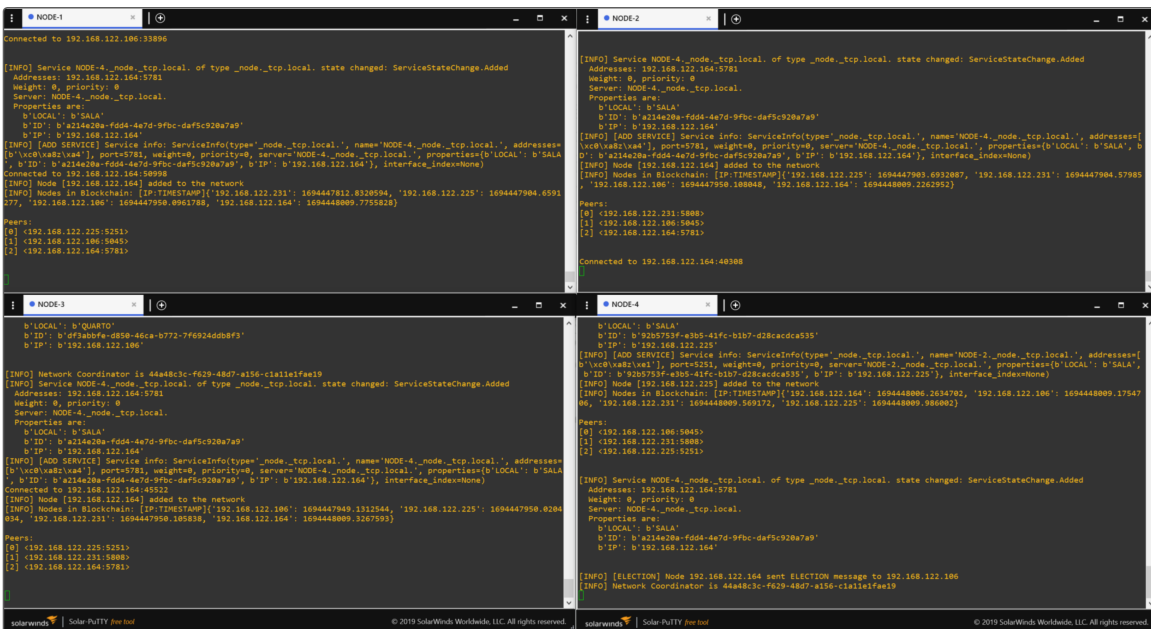


Figura 5.2: Resultado da adição de novos dispositivos na rede do sistema *DistSense*

Num segundo momento, avaliou-se a capacidade do sistema adaptar-se, de forma dinâmica, à adição de novos dispositivos na rede doméstica sem intervenção manual do utilizador. Esta característica é de particular importância em ambientes onde a rede é

sujeita a mudanças frequentes, com a adição de novos dispositivos garantindo a escalabilidade do sistema.

Ao adicionar um dispositivo fictício à rede, o módulo de descoberta respondeu prontamente, atualizando a lista de dispositivos identificados sem qualquer falha perceptível, tal como é ilustrado na figura 5.2.

```
connected to 192.168.122.98:5082
[INFO] Node [192.168.122.98] added to the network
[INFO] Nodes in Blockchain: [IP:TIMESTAMP] (192.168.122.124: 1697736826.222865, '192.168.122.98': 1697736112.563682)
Peers:
[ ] 192.168.122.98:5082
[INFO] CHAIN MESSAGE: {
  "WALLET": {
    "CLIENT": "N.B.1",
    "FROM_ADDRESS": {
      "ID": "cfe8a589-80af-4843-a3af-656c11719636",
      "IP": "192.168.122.124",
      "PORT": 5558
    },
    "TO_ADDRESS": {
      "ID": "546e998b-1866-48bc-98f9-3698f614d5e1",
      "IP": "192.168.122.98",
      "PORT": 5558
    },
    "MESSAGE": "RESPONSE_CHAIN",
    "MESSAGE_ID": "546e998b-1866-48bc-98f9-3698f614d5e1",
    "LAST_TIME_ALIVE": 1697736112.578989,
    "COORDINATOR": "cfe8a589-80af-4843-a3af-656c11719636",
    "CHAIN": {
      "HEIGHT": 0,
      "PREVIOUS_HASH": null,
      "BLOCKS": [
        {
          "HASH": "4d1c09fad986c2",
          "TARGET": "0000000000000000000000000000000000000000000000000000000000000000",
          "TIMESTAMP": 1697736336.098862,
          "MINE": "0000000000000000000000000000000000000000000000000000000000000000"
        }
      ]
    }
  }
}
[INFO] Service NODE-2_node_tcp.local of type_node_tcp.local state changed: ServiceStateChange.Added
Address: 192.168.122.98:5082
Height: 0, priority: 0
Server: NODE-2_node_tcp.local.
Properties: {
  "IP": "192.168.122.98",
  "ID": "546e998b-1866-48bc-98f9-3698f614d5e1",
  "LOCAL": "B.SALA"
}
[INFO] [MESSAGE TYPE]: RESPONSE_CHAIN
[INFO] IP: 192.168.122.98, CHAIN: [{"HEIGHT": 0, "TRANSACTIONS": [], "PREVIOUS_HASH": None, "MINE": "4d1c09fad986c2", "TARGET": "0000000000000000000000000000000000000000000000000000000000000000", "TIMESTAMP": 1697736336.098862, "MINE": "0000000000000000000000000000000000000000000000000000000000000000"}]
[INFO] Blockchain chain was updated with information from coordinator
[INFO] [MESSAGE TYPE]: RECEIVE_TRANSACTION
[INFO] Network Coordinator: {
  "ID": "cfe8a589-80af-4843-a3af-656c11719636"
}
[INFO] [MESSAGE TYPE]: TRANSACTION
[INFO] [TRANSACTION] Transaction is valid
[INFO]
Pending Transactions: [{"SENDER": "5815151804718508690VTE1DIEF488180C11309B88C051C112012K3V3A28hTtWwR5", "RECEIVER": "546e998b-1866-48bc-98f9-3698f614d5e1", "EVENT_LOCAL": "COZINHA", "PRECISION": "1.8", "TIMESTAMP": 1697736112.563682, "SIGNATURE": "411624380", "DATA": [{"SENDER": "5815151804718508690VTE1DIEF488180C11309B88C051C112012K3V3A28hTtWwR5", "RECEIVER": "546e998b-1866-48bc-98f9-3698f614d5e1", "EVENT_LOCAL": "COZINHA", "PRECISION": "1.8", "TIMESTAMP": 1697736112.563682, "SIGNATURE": "411624380"}]}]
```

Figura 5.3: Envio do estado atual da *blockchain* no momento de adição de um novo nó na rede

Adicionalmente, ao incorporar um novo dispositivo na rede, é fundamental assegurar que o nó se encontre sincronizado com as informações armazenadas na *blockchain*. Esta sincronização é crucial para preservar a integridade do sistema como um todo. Através da análise da figura 5.3, é possível constatar que o nó coordenador executa com sucesso o envio preciso das informações necessárias para o nó recém-adicionado à rede.

Esse processo de sincronização assume uma relevância crítica no contexto dos sistemas distribuídos, uma vez que a *blockchain* serve como um registro imutável e confiável de todas as transações e eventos no sistema. Portanto, garantir que o novo dispositivo tenha acesso a essa base de dados é essencial para garantir a consistência das operações e a confiabilidade do sistema como um todo.

A figura 5.3 ilustra a troca de informações entre o nó coordenador e o novo nó, destacando a eficácia do processo de transmissão de dados. Esse mecanismo é um componente crítico na integração bem-sucedida de novos dispositivos na rede, contribuindo para a estabilidade e funcionalidade contínua do sistema distribuído.

De igual importância é a capacidade do sistema para gerir de forma adequada a remoção de dispositivos da rede, sendo que quando um dispositivo é desconectado ou deixa de estar acessível, o sistema deve ser capaz de identificar essa alteração e remover o dispositivo da lista de dispositivos conhecidos após um tempo de *timeout* definido previamente, promovendo a integridade das informações sobre a rede.

Por fim, a avaliação da capacidade do sistema em eleger um nó coordenador durante a fase de inicialização do módulo de descoberta de dispositivos é essencial para garantir a eficiência e funcionalidade do sistema *DistSense*. A eleição de um nó coordenador é

---

uma tarefa crucial, pois este nó desempenha um papel central na gestão e coordenação das operações na rede doméstica, como enviar informações para o utilizador acerca dos eventos capturados.

Neste contexto e após a configuração inicial da rede e a descoberta de *peers*, a especificação do algoritmo de eleição do coordenador é crucial, ocorrendo uma vez que estabelece os critérios e a lógica utilizados para determinar qual nó será eleito como coordenador. Os resultados obtidos na figura 5.2 não apenas validam os testes realizados anteriormente, mas também indicam que o nó coordenador foi estabelecido corretamente e que seus *peers* foram notificados sobre esse evento.

Assim, os testes efetuados a este módulo corroboraram a eficácia na identificação automatizada de dispositivos na rede, estabelecendo assim uma fundação sólida para a inicialização do sistema e a subsequente operação harmoniosa do mesmo.

### 5.1.2 Módulo de comunicação

O módulo de comunicação desempenha um papel de destaque ao garantir a troca eficaz e confiável de informações entre os nós da rede. Em particular, num contexto de captura de atividades em tempo real, a capacidade de comunicação assume uma importância significativa.

Para efetuar a avaliação do módulo mencionado, foi implementada uma metodologia de testes abrangente que contempla diversas situações de comunicação numa rede distribuída. Esta metodologia abrange uma combinação de cenários de teste, os quais procuram simular situações realistas que podem ocorrer durante o funcionamento do sistema em ambientes residenciais inteligentes.

A avaliação da capacidade deste componente centrou-se em duas funcionalidades críticas:

- **Comunicação Bidirecional:** A primeira funcionalidade avaliada consistiu na capacidade do sistema em estabelecer comunicação bidirecional entre os nós da rede. Este cenário é de importância crucial, uma vez que garante que os nós possam trocar informações de maneira eficaz, contribuindo para a sincronização e a partilha de dados entre os dispositivos;
- **Recuperação de Falhas e Reeleição do Coordenador:** A segunda funcionalidade avaliada visou testar a resiliência do sistema ao simular falhas temporárias de conexão entre os nós, incluindo desconexões temporárias e subsequentes tentativas de reconexão. Neste contexto, também foi avaliada a capacidade do sistema em reeleger um novo coordenador em caso de falha do coordenador atual, assegurando a continuidade da operação da rede.

- Integridade dos dados: A última funcionalidade avaliada neste módulo refere-se à integridade dos dados armazenados na *blockchain*. Essa verificação é crucial para garantir a resiliência e a confiabilidade do armazenamento;

Os resultados obtidos nos testes revelaram um desempenho satisfatório nas situações submetidas a avaliação. No âmbito da comunicação bidirecional, a transferência de informações decorreu de forma ininterrupta e com notória eficiência, conforme ilustrado na Figura 5.4 por meio da análise dos pacotes de dados capturados através do programa *Wireshark*.

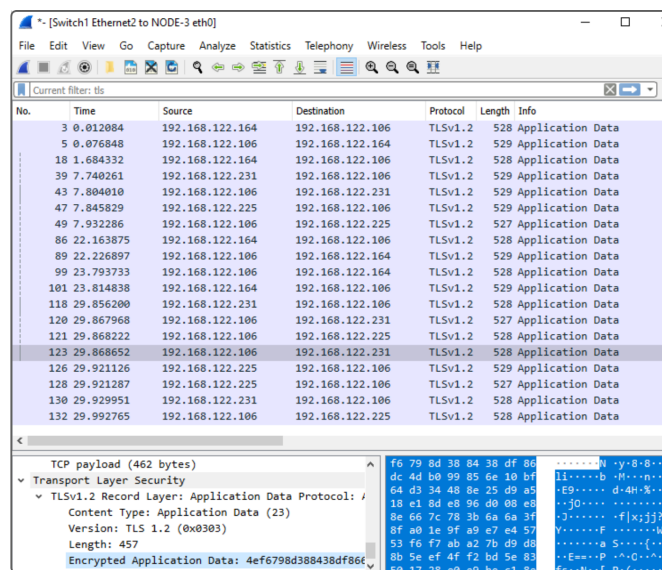


Figura 5.4: Comunicação entre os dispositivos do sistema *DistSense*

Adicionalmente, a capacidade do sistema de recuperar-se de desconexões temporárias e reeleger um novo coordenador após a falha do coordenador atual foi igualmente avaliada. Essa característica garante a continuidade da comunicação, mesmo em situações adversas, mantendo a integridade e eficácia da rede.

Nesse sentido, foram realizados testes experimentais que envolveram a interligação de três nós distintos. Após a fase inicial de configuração e o estabelecimento de comunicação bidirecional entre esses nós, provocou-se uma desconexão com o "*NODE-3*" no simulador GNS3, emulando, dessa forma, uma falha na conexão. Como resultado dessa ação, observou-se que o nó designado como "*NODE-3*" iniciou um processo de tentativa de reconexão, conforme apresentado na figura 5.5.

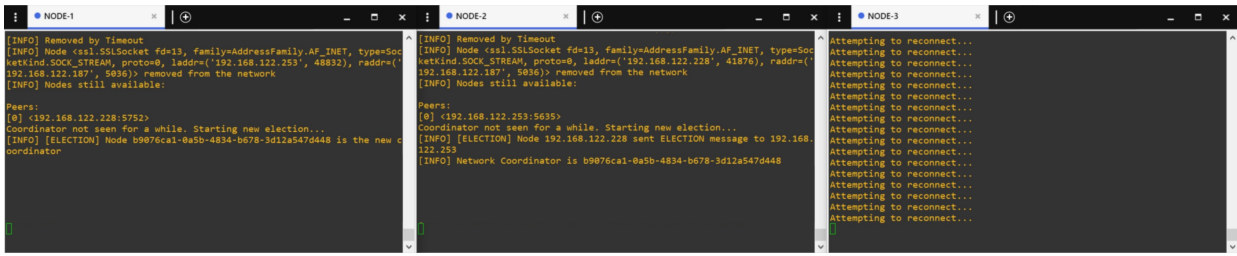


Figura 5.5: Simulação de comportamento de falha de um nó na rede local

Nesse mesmo processo, os outros dois nós, ao detetarem a suspensão da conexão com o "NODE-3", procederam à sua exclusão da lista de *peers* devido à ausência de pacotes de *keep-alive* durante um período de tempo previamente definido pelo sistema, que era de 60 segundos. Posteriormente, reorganizaram-se dentro da rede, o que levou à reeleição de um novo coordenador, uma vez que o "NODE-3" detinha, previamente, a função de coordenador.

A Figura 5.6 ilustra de forma representativa o processo de recuperação após a ocorrência de falhas temporárias, evidenciando a habilidade do sistema em restabelecer as conexões interrompidas e informar sobre a identidade do novo nó coordenador.

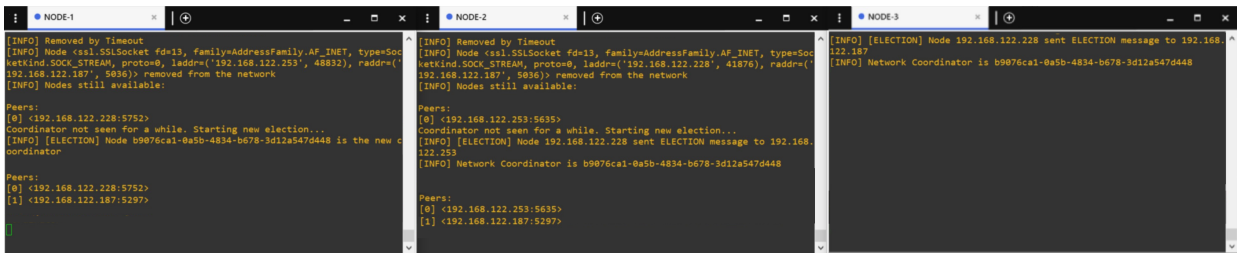


Figura 5.6: Recuperação e reconexão da ligação do nó na rede local

Além disso, a figura 5.7 ilustra de forma representativa o processo de recuperação da *blockchain* após a ocorrência de falhas temporárias, evidenciando a habilidade do sistema em restabelecer o seu funcionamento normal e a integridade da *blockchain* quando confrontado com interrupções passageiras. O processo de recuperação demonstrado na figura destaca a capacidade do sistema em identificar, corrigir e registrar qualquer evento que possa ter sido afetado devido a falhas temporárias, garantindo assim a continuidade e a precisão das transações na *blockchain*.



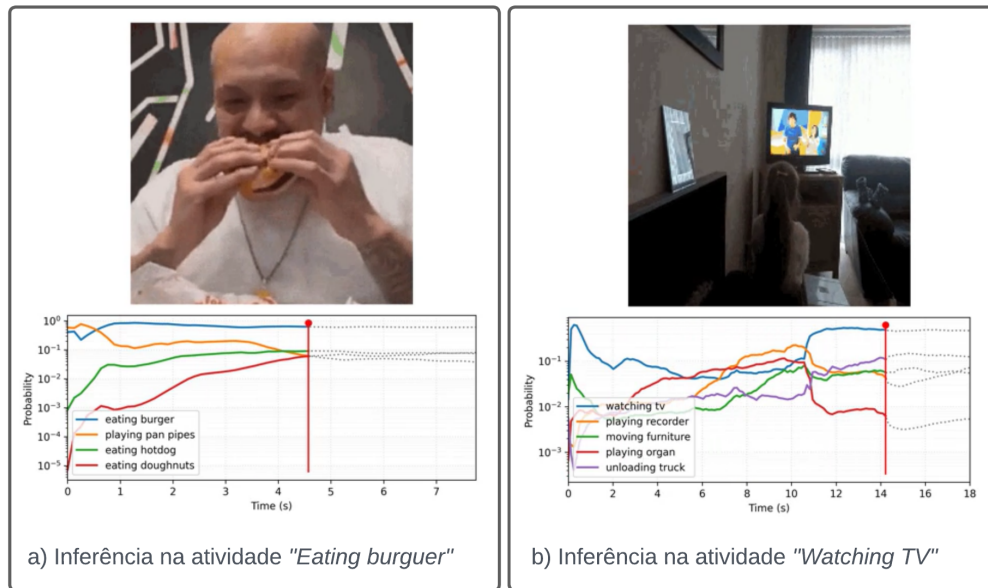


Figura 5.8: Classificação de atividades domésticas em vídeo

Outro aspecto relevante da avaliação diz respeito ao desempenho dos modelos na classificação das classes treinadas. A avaliação é realizada com base numa matriz de confusão, apresentada na figura 5.9, que fornece informações detalhadas sobre as previsões dos modelo em relação aos resultados reais.

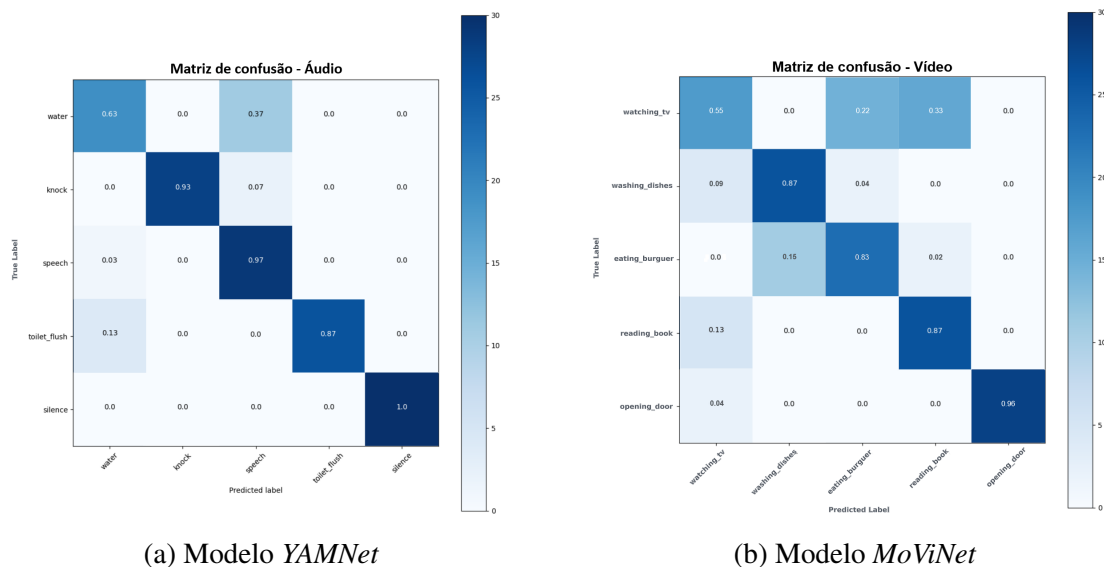


Figura 5.9: Matriz de confusão para os modelos de áudio e vídeo

Observa-se que o modelo enfrentou maiores desafios na classificação das atividades "Water" e "Toilet Flush", devido à semelhança acústica entre essas duas classes, sendo que tal similaridade pode induzir o sistema a cometer erros durante o processo de treino, uma vez que as características sonoras dessas atividades apresentam sobreposições consideráveis, visto que partilham características de ruídos líquidos e de descarga. Esse

fator ressalta a importância de aprimorar ainda mais o modelo, explorando estratégias avançadas de processamento de áudio e ML. No entanto, apesar dessas dificuldades, o modelo de áudio demonstrou um desempenho satisfatório, alcançando uma taxa de precisão de aproximadamente 88%.

O resultado de precisão de aproximadamente 88% para o modelo de áudio e aproximadamente 80% para o modelo de vídeo é indicativo do desempenho geralmente satisfatório de ambos os modelos. No entanto, uma análise aprofundada das métricas de desempenho, como sensibilidade, especificidade e pontuação F1, pode fornecer uma visão mais completa do quão bem os modelos estão a lidar com as nuances da classificação sonora, permitindo a identificação de áreas que necessitam de melhorias específicas.

Class	Accuracy	Precision	Recall	F1 Score
water	89.40%	0.63	0.80	0.70
knock	98.60%	0.93	1.00	0.96
speech	90.60%	0.97	0.69	0.80
toilet_flush	97.40%	0.87	1.00	0.93
silence	100%	1.00	1.00	1.00

**Accuracy: 0.881988178730011**

(a) Modelo *YAMNet*

Class	Accuracy	Precision	Recall	F1 Score
watching_tv	84.12%	0.50	0.68	0.58
washing_dishes	94.51%	0.87	0.85	0.86
eating_burguer	91.57%	0.83	0.76	0.79
reading_book	90.59%	0.87	0.71	0.78
opening_door	99.22%	0.96	1.00	0.98

**Accuracy: 0.801502019508174**

(b) Modelo *MoViNet*

Figura 5.10: Métricas de desempenho para os modelos de áudio e vídeo

Na avaliação do desempenho do modelo de classificação de áudio, observam-se resultados sobre a capacidade do sistema em identificar diferentes classes. Os resultados das métricas de desempenho, apresentados na figura 5.10, possibilitam uma análise minuciosa e a elaboração de conclusões pertinentes sobre ambos os modelos implementados.

Na figura 5.10a, o modelo *YAMNet* demonstrou uma taxa de precisão consistente para a maioria das classes, indicando uma capacidade geral de realizar previsões corretas. É possível observar que a classe "*silence*" obteve resultados exemplares, com uma taxa de precisão, *recall* e pontuação F1 de 100%, sugerindo que o modelo é competente na detecção do silêncio.

Por outro lado, e tal como mencionado anteriormente, a classe "*water*" apresentou alguns desafios, decorrentes da sua similaridade acústica com a classe "*toilet\_flush*". A

---

precisão de 63% para a classe *"water"* revela que o modelo pode, em algumas situações, confundir o som da água com o som do autoclismo. No entanto, o *recall* de 80% indica que o modelo é capaz de identificar a maioria das instâncias da classe *"water"* com sucesso.

Destaca-se ainda o desempenho na classe *"knock"*, com uma taxa de precisão de 98,60% e uma pontuação F1 de 0,96, demonstrando a alta precisão do modelo na identificação da classe *"knock"* o que é particularmente relevante em casos de uso para a detecção de impactos e/ou pancadas provocadas num ambiente doméstico inteligente.

As discrepâncias nos resultados entre as classes enfatizam a necessidade de melhorias futuras, para tal torna-se fundamental realizar uma análise aprofundada dos falsos positivos e falsos negativos em cada classe, a fim de identificar as situações em que o modelo falha. Além disso, é possível explorar estratégias avançadas de processamento de áudio e treino de modelos para aprimorar a distinção entre classes com características sonoras semelhantes, como *"water"* e *"toilet\_flush"*.

Adicionalmente, os resultados das métricas de desempenho, apresentados na figura 5.10b, forneceram informações sobre as capacidades e limitações do modelo de vídeo, visto que ao considerar esses resultados é possível retirar conclusões importantes e delinear potenciais áreas de melhoria, como por exemplo treinar o modelo com uma maior quantidade de dados.

As métricas revelaram que o modelo atingiu níveis diversos de precisão em relação às diferentes classes. A classe *"opening\_door"* demonstrou um desempenho excepcional, atingindo uma taxa de precisão de 99.22%, bem como uma precisão e *recall* próximos a 1.00, destacando a eficácia do modelo na identificação dessa atividade.

No entanto, outras classes, como *"watching\_tv"*, *"eating\_burger"* e *"reading\_book"* exibiram um desempenho menos consistente, com variações na precisão e no *recall*. Especificamente, a classe *"watching\_tv"* apresentou uma precisão de 0.50, sugerindo uma alta taxa de falsos positivos, enquanto a classe *"eating\_burger"* teve um *recall* de 0.76, indicando espaço para melhorias na identificação das instâncias reais.

Esta análise detalhada dos resultados sugere a necessidade de direcionar esforços para otimizar o desempenho nas classes com desafios de classificação. Um caminho promissor para o trabalho futuro inclui a revisão e expansão do conjunto de dados de treino, permitindo ao modelo aprender a lidar com uma maior diversidade de situações. Além disso, técnicas avançadas de processamento de vídeo e treinamento de modelos podem ser exploradas para aprimorar a precisão e o *recall* em todas as classes.

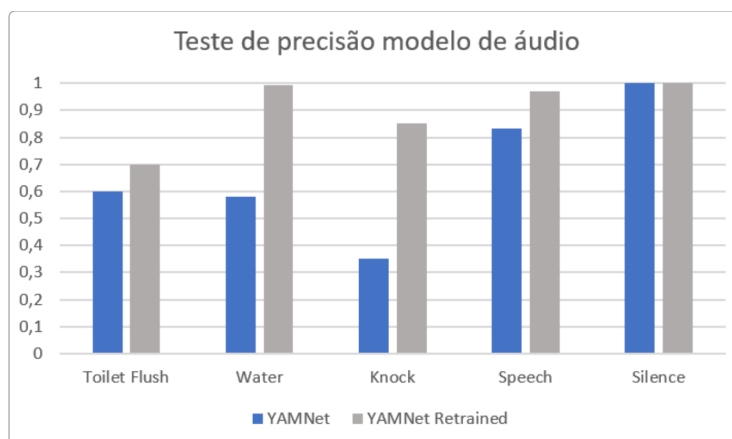


Figura 5.11: Comparação de precisão do modelo retreinado com modelo *YAMNet* original através da classificação de áudios para as diferentes classes selecionadas

A figura 5.11 apresenta uma comparação de precisão com o modelo *YAMNet* através da classificação de áudios para diferentes classes retreinadas. Para esse fim, foi utilizado um conjunto de dez áudios por classe, calculando a média dos resultados obtidos na classificação desses áudios através do modelo *YAMNet* original e o modelo retreinado. Essa análise revela o aumento na precisão alcançado pelo sistema após o treino, demonstrando a eficácia do modelo de aprendizagem.

Através dos testes realizados observou-se que o sistema é capaz de identificar com precisão as atividades realizadas pelo utilizador, apesar de existirem variações de precisão em algumas classes, o sistema continua a oferecer resultados eficazes. Este bom desempenho é atribuído à capacidade de aprendizagem do sistema, que utiliza técnicas avançadas de processamento de imagens e reconhecimento de padrões para extrair características relevantes dos vídeos e do áudio associado, visto que ao ser treinado com um conjunto de dados diversificado, este adquiriu a habilidade de generalizar e reconhecer atividades em tempo real.

A eficácia do presente módulo é essencial para o sucesso global do sistema, pois contribui para uma compreensão aprofundada do contexto em que as atividades ocorrem, sendo crucial para a criação de respostas adequadas e personalizadas às necessidades dos utilizadores, tornando o sistema verdadeiramente adaptável e útil em ambientes domésticos em constante evolução.

#### 5.1.4 Módulo de processamento e representação do conhecimento

A utilização de tecnologias como a *blockchain* e a integração com o HA desempenham um papel fundamental no módulo de processamento e representação do conhecimento, sendo responsáveis por armazenar informações de forma sequencial e cronológica, garantindo segurança e confiabilidade, bem como coordenar a comunicação com outros dispositivos domésticos e disponibilizar informações para o utilizador.

---

A *blockchain* permite armazenar informações sequenciais e cronológicas de maneira segura e confiável. Durante a análise e avaliação a implementação e execução desta tecnologia, observou-se de perto as seguintes funcionalidades-chave:

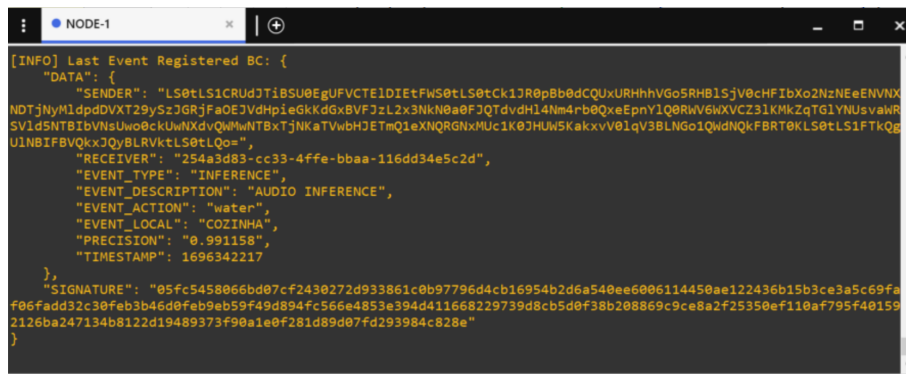
- **Registo e Validação de Eventos:** O sistema foi submetido a testes rigorosos para verificar a capacidade de registar dados na *blockchain*, mantendo uma ordem cronológica precisa. Este processo é essencial para assegurar que as informações capturadas sejam armazenadas de forma precisa e rastreável ao longo do tempo;
- **Consulta de Eventos:** A avaliação incluiu a análise da capacidade do sistema em consultar a *blockchain* quando a deteção de atividade não atingia um limiar previamente definido. Este recurso proporciona um contexto robusto e preciso para determinar a atividade atual do utilizador.

A precisão na deteção de atividades e a subsequente consulta à *blockchain* representam componentes cruciais no sistema de processamento e representação do conhecimento, devido à necessidade de garantir que as atividades dos utilizadores sejam detetadas com precisão sendo esta uma preocupação comum em sistemas de monitorização. Perante isto, foram realizados testes para verificar a eficácia deste processo, com enfoque na consulta à *blockchain* quando a deteção de atividade não atinge um limiar previamente definido.

É de ressaltar que a definição precisa do limiar para a consulta à *blockchain* é um parâmetro que deve ser definido previamente pelo sistema, uma vez que deve ser estabelecido um equilíbrio entre a deteção de atividades e o recurso à *blockchain* sempre que necessário.

Para testar o registo e a validação dos eventos foram utilizados dois nós num ambiente controlado para emular o comportamento de deteção e armazenamento dos eventos na *blockchain*. Os eventos armazenados são classificados em dois tipos: eventos de rede e eventos de inferência. Os eventos de rede são armazenados sempre que existe uma alteração na rede, como por exemplo a adição de um novo dispositivo. Os eventos de inferência são registados sempre que um dos nós atinja um limiar previamente definido pelo sistema na deteção de uma atividade doméstica realizada pelo utilizador.

No entanto, é inegável que a deteção de atividades pode, por vezes, falhar e não atingir esse limiar de precisão, levando a uma incerteza sobre a atividade corrente. Neste contexto, a consulta à *blockchain* assume um papel crucial, uma vez que quando a deteção de atividade não atinge um limiar previamente definido, os nós do sistema têm a capacidade de recorrer à *blockchain* para obter um histórico completo de transações para um determinado tempo e local definido em que a atividade ocorre, proporcionando um contexto mais confiável e preciso para a determinação da atividade atual do utilizador, conforme ilustrado na figura 5.12.



```
[INFO] Last Event Registered BC: {
  "DATA": {
    "SENDER": "LS0tLS1CRUdJTiBSU0EgUFVCTE1DIETfWS0tLS0tCK1JR0pbB0dCQUxURHhhVGo5RHB1SjV0cHFibXo2NzNEeENVNX
NDTjNyM1dpdDVXT29ySzJGRjFAOEJVDhpieGkkdGx8VFJzL2x3NkN0a0FJQTdvdH14Nm4rb0QxeEpnY1Q8RwV6WxVCZ31KMkZqTG1YNUsvaWR
SV1dSNTBibVnsUwo0ckUwNXdvQWwNTBxTjNkaTVvbHJETmQ1eXNQGNxMuc1K0JHUM5KakxvV01qV3BLNGo1QwdNqkFBRT0KLS0tLS1FTkQg
U1NBIFBvQkxJQyBLRVktLS0tLQo=",
    "RECEIVER": "254a3d83-cc33-4ffe-bbaa-116dd34e5c2d",
    "EVENT_TYPE": "INFERENCE",
    "EVENT_DESCRIPTION": "AUDIO INFERENCE",
    "EVENT_ACTION": "water",
    "EVENT_LOCAL": "COZINHA",
    "PRECISION": "0.991158",
    "TIMESTAMP": 1696342217
  },
  "SIGNATURE": "05fc5458066bd07cf2430272d933861c0b97796d4cb16954b2d6a540ee6006114450ae122436b15b3ce3a5c69fa
f06fadd32c30Feb3b46d0feb9eb59f49d894fc566e4853e394d411668229739d8cb5d0f38b208869c9ce8a2f25350ef110af795f40159
2126ba247134b8122d19489373f90a1e0f281d89d07fd293984c828e"
}
```

Figura 5.12: Consulta à *blockchain* do último evento capturado por um nó

Na análise do registo de dados por ordem cronológica, observou-se que após a deteção de um evento na rede ou por deteção de atividades o dispositivo cria uma transação pendente e envia a todos os nós presentes na rede, tal como é apresentado na figura 5.13. Posteriormente, cada nó valida a transação e verifica se já contém essa transação na sua lista de *peers*, no caso da transação ser válida e não existir, os nós adicionam essa transação à lista de transações pendentes, conforme apresentado na figura 5.13 para o "NODE-2".

Contudo durante os testes realizados surgiu a necessidade de impor um limite no número de transações por bloco devido a algumas considerações fundamentais no âmbito do funcionamento da *blockchain*.

Em primeiro lugar, a imposição de um limite no número de transações por bloco é essencial para manter o tamanho dos blocos sob controle. Verificamos que blocos muito grandes podem resultar na degradação da rede, levando a tempos de confirmação mais longos e uma menor eficiência na propagação dos blocos pela rede. Portanto, ao definir um limite, assegura-se que os blocos permaneçam num tamanho razoável, otimizando o desempenho da *blockchain*.

Além disso, ao restringir o número de transações por bloco, reduz-se o risco de congestionamento da rede. Em sistemas de monitorização onde podem ocorrer a deteção de várias atividades ao longo do dia, o congestionamento da rede pode levar a taxas de transação mais elevadas e tempos de confirmação mais lentos. Portanto, limitar o número de transações por bloco ajuda a manter a rede operando de maneira eficiente, garantindo que as transações sejam processadas em tempo hábil.

Portanto, o estabelecimento de um limite no número de transações por bloco é uma medida essencial para otimizar o desempenho do sistema, a segurança e a eficiência da *blockchain*, garantindo a estabilidade do sistema *DistSense* como um todo.

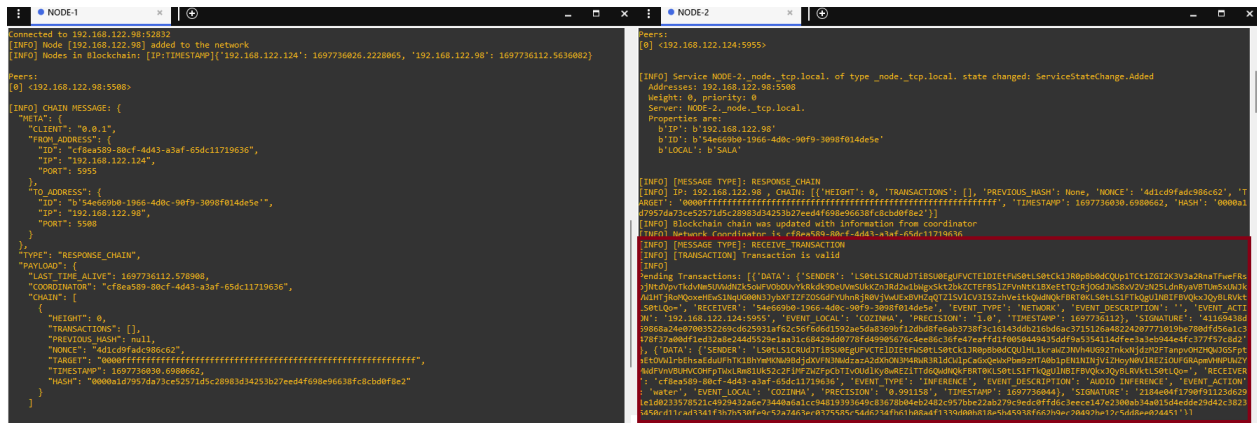


Figura 5.13: Criação, recepção e validação de transações na *blockchain*

Os resultados dos testes realizados confirmaram a eficácia da implementação da *blockchain*, demonstrando a sua capacidade de armazenar informações sequenciais e cronológicas de maneira confiável e segura, com um desempenho eficiente.

Em seguida, conduziram-se testes cruciais no contexto da integração com o HA, que desempenha um papel crucial na comunicação entre o sistema e o utilizador. Esses testes foram planeados com o objetivo de garantir que os eventos capturados e inferidos fossem transmitidos de maneira precisa e eficiente ao HA, mantendo um acesso estritamente controlado pelo coordenador do sistema.

Os cenários de teste abordaram diversos aspectos essenciais relacionados à restrição de acesso entre o sistema e o HA. Através da realização destes testes, verificou-se a capacidade exclusiva do coordenador de autorizar o envio de mensagens para o HA. Essa restrição de acesso reveste-se de suma importância para assegurar a segurança e a integridade das informações transmitidas. Observou-se que o sistema conseguiu manter um controle rigoroso sobre a autorização de envio de mensagens, cumprindo de forma bem-sucedida a sua função de garantir a segurança durante a transmissão de eventos.

Uma outra vertente crítica destes testes teve como objetivo verificar a eficácia na entrega e recepção de eventos capturados pelo sistema, garantindo que essas informações fossem transmitidas de maneira confiável e recebidas pelo HA de forma adequada. Essa avaliação desempenha um papel crucial na garantia de que as interações entre o sistema e o utilizador ocorram sem contratempos, proporcionando uma experiência de utilização confiável e consistente. Os resultados destes testes validaram que o sistema foi capaz de transmitir eventos de forma segura e coordenada, assegurando que as informações fossem entregues com êxito ao HA e prontamente disponibilizadas para o utilizador.

---

## 5.2 Caso de uso em ambiente simulado: Detecção de perigos domésticos

A segurança desempenha um papel essencial nos ambientes residenciais inteligentes, sendo crucial a identificação atempada e assertiva de potenciais perigos, como inundações e incêndios, a fim de assegurar a salvaguarda dos moradores. A implementação de um sistema distribuído que beneficia da colaboração entre diversos nós na rede local emerge como uma abordagem sólida e eficiente na deteção precoce de ameaças domésticas, com o intuito de reduzir falsos alarmes em casos de incerteza. Neste contexto, aborda-se a capacidade do sistema *DistSense* para reconhecer e alertar os utilizadores sobre as situações de risco detetadas, contribuindo para a preservação da segurança numa habitação inteligente.

Os testes implementados para este caso de uso foram realizados em ambiente de simulação através de dois nós, "*NODE-1*" e "*NODE-2*", utilizando vídeos que retratavam situações perigosas no contexto doméstico, como, por exemplo, ocorrências de fugas de água de uma torneira mantida aberta, conforme ilustrado na figura 5.14.



Figura 5.14: Representação de fugas de água de uma torneira mantida aberta pelo utilizador

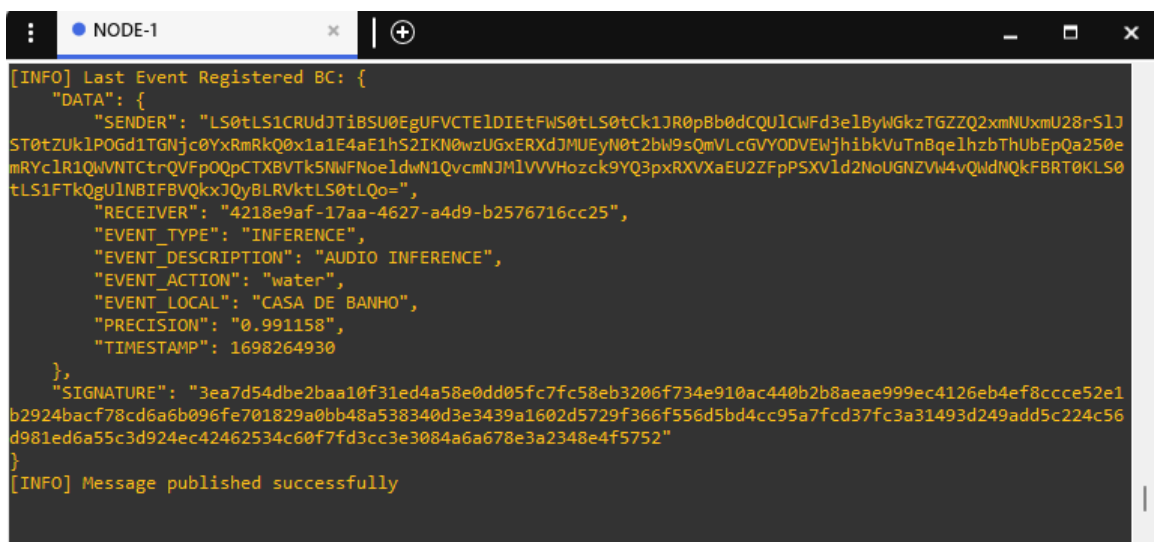
O período de tempo definido para considerar a ação como potencial perigo, neste caso de uso, foi de 30 segundos, assumindo que o utilizador não se encontra no local. Esta escolha corresponde ao ponto no tempo em que o sistema interrompe a sua avaliação ao detetar situações de potencial perigo. Esta justificação reflete a necessidade do sistema atuar dentro de um intervalo de tempo realista e praticamente útil, garantindo uma resposta eficiente quando necessário.

Optou-se por utilizar vídeos com a mesma perspetiva, mas com diferentes níveis de aproximação sonora, com o propósito de avaliar a deteção sonora em profundidade. Esta abordagem assegurou que, em situações ambíguas, o sistema tivesse a capacidade de recorrer a outros nós para corroborar a deteção, reduzindo assim a probabilidade de falsos

positivos e garantindo a eficácia do sistema. Desta forma, alcançou-se um equilíbrio entre a sensibilidade do sistema e a minimização de alarmes indesejados no quotidiano.

A consideração atenta dos falsos positivos e a implementação de um mecanismo de recorrência a outros nós em caso de dúvida demonstram uma abordagem interessante na procura por minimizar alarmes desnecessários, evitando que o utilizador seja alertado em situações comuns do quotidiano.

Foi observado que o "NODE-1" não alcançou o limiar de certeza, obtendo uma taxa de precisão na inferência de áudio de apenas 43%. No entanto, através da colaboração na rede e da consulta à *blockchain*, este conseguiu obter informações acerca do último evento capturado naquela divisão durante um período de tempo definido previamente pelo sistema. Como resultado dessa análise colaborativa, foi possível confirmar que a atividade em questão era o som da água de uma torneira.



```
[INFO] Last Event Registered BC: {
  "DATA": {
    "SENDER": "LS0tLS1CRUdJTiBSU0EgUFVCTE1DIETfWS0tLS0tCk1JR0pBb0dCQU1CWfd3e1ByWGkzTGZZQ2xmNUxmU28rS1J
ST0tZUKlPOGd1TGNjc0YxRmRkQ0x1a1E4aE1hS2IKN0wzUGxERXkJMUEyN0t2bW9sQmVlcGVYODVEVjhibkVuTnBqe1hzbThUbEpQa250e
mRYc1R1QWVNTCtRQVFPQpCTXBVTk5NWfNoe1dwN1QvcmlJN1VWVHozck9YQ3pxRXVXaEU2ZFpPSXVld2NoUGNZVW4vQWdNQkFBRT0KLS0
tLS1FTkQgU1NBIFBvQkxJQyBLRVktLS0tLQo=",
    "RECEIVER": "4218e9af-17aa-4627-a4d9-b2576716cc25",
    "EVENT_TYPE": "INFERENCE",
    "EVENT_DESCRIPTION": "AUDIO INFERENCE",
    "EVENT_ACTION": "water",
    "EVENT_LOCAL": "CASA DE BANHO",
    "PRECISION": "0.991158",
    "TIMESTAMP": 1698264930
  },
  "SIGNATURE": "3ea7d54dbe2baa10f31ed4a58e0dd05fc7fc58eb3206f734e910ac440b2b8aeae999ec4126eb4ef8ccce52e1
b2924bacf78cd6a6b096fe701829a0bb48a538340d3e3439a1602d5729f366f556d5bd4cc95a7fcd37fc3a31493d249add5c224c56
d981ed6a55c3d924ec42462534c60f7fd3cc3e3084a6a678e3a2348e4f5752"
}
[INFO] Message published successfully
```

Figura 5.15: Consulta à *blockchain* do último evento capturado por um nó

As tarefas e a interação entre os módulos seguem o fluxo de dados apresentado na figura 5.1. A diferença principal reside na automação do HA em notificar imediatamente o utilizador caso alguma situação de perigo seja detetada, sendo que apenas o nó coordenador tem comunicação com o HA.

Quando os sensores identificam concentrações anómalas no contexto doméstico, é emitido um alerta para o utilizador através da plataforma HA, demonstrando a aptidão do sistema na identificação de perigos emergentes e acionando respostas preventivas.

Para ilustrar, foi criada uma regra no HA de forma a que, quando uma atividade considerada perigosa permanece ativa por mais de 30 segundos, seja enviado um alerta para o utilizador, como exemplificado na figura 5.16.

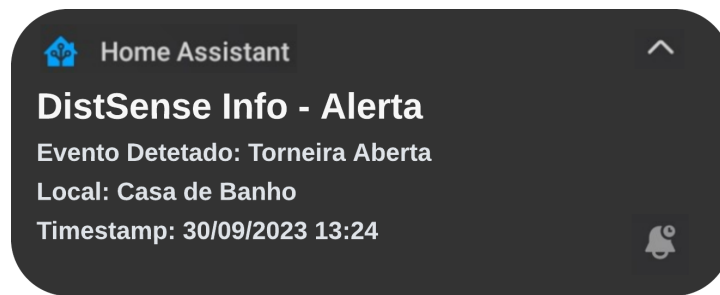


Figura 5.16: Alerta enviado ao utilizador através da plataforma HA após deteção de perigos no contexto doméstico

A deteção atempada de ameaças domésticas é bastante importante para a salvaguarda dos residentes e dos bens materiais. Mediante a colaboração entre os nós distribuídos, o sistema permite identificar situações de risco e promover respostas imediatas, minimizando eventuais prejuízos que possam ocorrer.

Além disso, a integração com a plataforma HA e o armazenamento na *blockchain* asseguram que os utilizadores se mantenham informados sobre situações perigosas, mesmo na sua ausência.

Este caso de uso sublinha a relevância de reduzir falsos alarmes através da colaboração dos nós do sistema em contextos críticos. A habilidade de detetar fugas de água e alertar os utilizadores pro ativamente pode, efetivamente, preservar vidas e reduzir danos materiais. Esta natureza distribuída confere ao sistema uma resiliência acrescida, visto que a cooperação entre os nós garante uma deteção de perigos mais precisa.

### **5.3 Caso de uso em ambiente real: Deteção colaborativa de atividades domésticas com variações de ruído audiovisual**

A identificação das atividades do dia-a-dia dos utilizadores desempenha um papel essencial na otimização da experiência nas residências inteligentes. O presente estudo de caso visa demonstrar o funcionamento e a cooperação dos diversos módulos do sistema *DistSense* em ambiente real. Este sistema, baseado na colaboração entre múltiplos nós, possibilita a captura e interpretação precisa de informações relacionadas com as atividades habituais dos residentes, tais como assistir televisão, leitura de um livro, realização de refeições e tarefas domésticas, como lavagem de louça. Os dados provenientes dos sensores são fundidos e algoritmos avançados são aplicados para inferir com precisão as atividades do utilizador.

Parâmetro	Descrição
Processador	<i>Quad-core ARM® Cortex®-A57 MPCore processor</i>
Placa Gráfica	<i>128-core NVIDIA Maxwell™ architecture GPU</i>
Memória RAM	<i>2GB 64-bit LPDDR4</i>
Armazenamento	<i>microSD de 64GB</i>
Sistema Operativo	<i>Ubuntu 18.04 LTS</i>

Tabela 5.1: Especificações do dispositivo *Jetson Nano*

No âmbito de avaliar o sistema num ambiente real, procedeu-se à instalação e inicialização de dois dispositivos *Jetson Nano* integrados com sensores audiovisuais em locais estratégicos da habitação, abrangendo áreas onde as atividades domésticas são mais frequentes, como a cozinha e/ou a sala de estar. As especificações pormenorizadas desses equipamentos podem ser encontradas na tabela 5.1. Para realizar os testes, executou-se o contentor *Docker*, que contém todas as funcionalidades desenvolvidas ao longo da investigação, em cada dispositivo *Jetson Nano*.

Durante esta fase inicial, verificou-se que a inicialização e integração de dispositivos na rede local ocorreram sem contratempos durante a implementação deste caso de uso, de modo análogo aos resultados obtidos na avaliação realizada em ambiente controlado apresentados na secção 5.1.1.

Para determinar e classificar as atividades diárias do utilizador, o módulo de aprendizagem computacional desempenha um papel central no sistema *DistSense*. Contudo, devido aos desafios apresentados em ambientes em constante mutação, como a oclusão, variações nos níveis de iluminação e interferência de ruído acústico, a sua eficácia pode ser comprometida.

Nestas condições variáveis, o sistema enfrenta obstáculos que podem afetar a precisão da identificação e classificação das atividades do utilizador. A oclusão, por exemplo, pode ocultar partes do corpo, tornando a deteção das ações mais complexa. As variações nos níveis de iluminação dificultam a interpretação das imagens e a análise do ambiente. Além disso, o ruído acústico pode interferir na qualidade dos dados recolhidos, afetando a exatidão do reconhecimento de voz e áudio.




Figura 5.17: Diferentes perspetivas de visualização do ambiente inteligente por dois nós distintos na rede para a atividade "Lavar/Limpar louça"

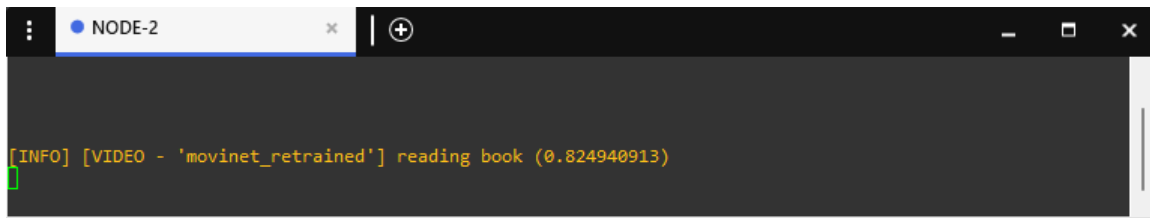


Figura 5.18: Diferentes perspetivas de visualização do ambiente inteligente por dois nós distintos na rede para a atividade "Ler um livro"

Ambas as figuras 5.17 e 5.18 ilustram perspetivas de visualização de duas das divisões da habitação inteligente por dois nós distintos na rede, cozinha e sala de estar respetivamente, onde os sensores foram distribuídos de forma a cobrir o maior número de ângulos possível, a fim de minimizar o impacto da oclusão.

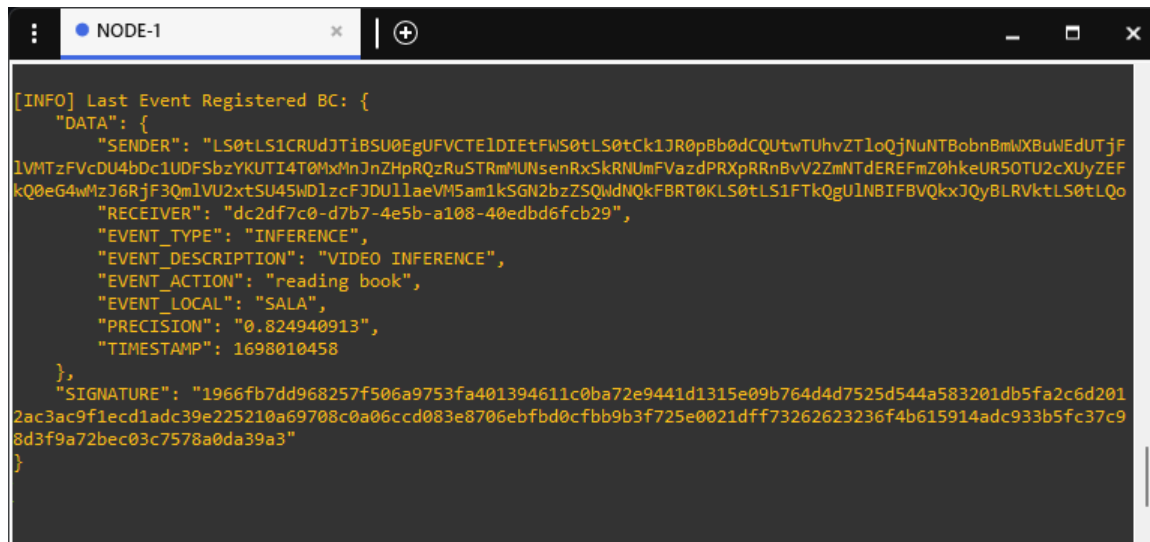
No primeiro cenário, conforme ilustrado na figura 5.17, o sistema demonstrou eficácia na deteção da atividade de "Lavar/Limpar louça" realizada pelo utilizador, obtendo uma precisão de, aproximadamente, 78%. Devido à deteção bem-sucedida da atividade acima do limiar de precisão estabelecido, o nó responsável procedeu ao registo desse evento na *blockchain*.

Posteriormente, esses dados foram distribuídos para os *peers* do nó, a fim de que o evento inserido na *blockchain* fosse validado por todos os nós na rede. Em seguida, após essa validação, as informações sobre o evento detetado foram enviadas para o HA pelo nó coordenador, com o propósito de informar e armazenar esses dados. Esse armazenamento permitirá, mais tarde, a realização de uma análise mais detalhada das atividades executadas ao longo do dia pelo utilizador.



```
[INFO] [VIDEO - 'movinet_retrained'] reading book (0.824940913)
```

Figura 5.19: Detecção da atividade "Ler um livro" através do nó com um grau de certeza confiável



```
[INFO] Last Event Registered BC: {
  "DATA": {
    "SENDER": "LS0tLS1CRUdJTTI5SU0EgUFVCTEldIeTFWS0tLS0tCk1JR0p8b0dCQUtwUHVZTl0QjNuNTBobnBmlWXBuWEdUTjF
    LVMTzFVcDU4bDc1UDF5bzYKUTI4T0MxMnJnZHpRQzRuSTRmMUNsenRxSkRNuMFvazdPRXpRRnBvV2ZmNTdEREFmZ0hkeUR50TU2cXUyZEF
    kQ0eG4wMzJ6RjF3Qm1VU2xtSU45WD1zcFJDU1laeVM5am1kSGN2bzZSQndNQkFBRT0KLS0tLS1FTkQgU1N8IFBVQkxJQyBLRVktLS0tLQo
    "RECEIVER": "dc2df7c0-d7b7-4e5b-a108-40edbd6fcb29",
    "EVENT_TYPE": "INFERENCE",
    "EVENT_DESCRIPTION": "VIDEO INFERENCE",
    "EVENT_ACTION": "reading book",
    "EVENT_LOCAL": "SALA",
    "PRECISION": "0.824940913",
    "TIMESTAMP": 1698010458
  },
  "SIGNATURE": "1966fb7dd968257f506a9753fa401394611c0ba72e9441d1315e09b764d4d7525d544a583201db5fa2c6d201
  2ac3ac9f1ecd1adc39e225210a69708c0a06ccd083e8706ebfbd0cbb9b3f725e0021dff73262623236f4b615914adc933b5fc37c9
  8d3f9a72bec03c7578a0da39a3"
}
```

Figura 5.20: Consulta à *blockchain* do último evento capturado

Por outro lado, no segundo cenário apresentado na Figura 5.18, um dos nós encarregados da detecção da atividade não conseguiu atingir um nível mínimo de confiabilidade na identificação dessa atividade audiovisual específica, obtendo aproximadamente 24% da precisão. Nesse contexto, o nó recorreu à colaboração com outro nó que também observou a mesma cena, mas a partir de uma perspectiva diferente obtendo uma precisão de, aproximadamente, 82%, conforme apresentado na figura 5.19. Nesse sentido, como o "NODE-1" não atingiu o limiar mínimo de certeza na detecção da atividade recorreu à *blockchain* para obter informações complementares, conforme demonstrado na figura 5.20.

Estas informações adicionais, obtidas através da consulta à *blockchain*, permitem ao nó identificar com maior precisão a atividade em execução, mesmo que esta não seja completamente visível ou clara para um único nó. Esta capacidade de cooperação e de consulta de fontes externas para melhorar o processo de tomada de decisões num contexto residencial inteligente é particularmente útil onde o ambiente está em constante mudança.

Adicionalmente, o sistema *DistSense* aborda o ruído acústico, não se limitando apenas à detecção de atividades baseadas em áudio, como por exemplo o som da água a correr de uma torneira, onde técnicas de filtragem de ruído foram implementadas para eliminar interferências sonoras indesejadas, como ruído de fundo e ecos, assegurando que apenas

---

as informações relevantes para a atividade do utilizador sejam considerados na inferência.

Através da colaboração entre os diversos nós distribuídos, o sistema é capaz de inferir as ações dos residentes com base nas mudanças ambientais capturadas pelos sensores audiovisuais.

À medida que o sistema continua a operar as informações são armazenadas em histórico de forma sequencial na *blockchain* e na plataforma HA, como referido anteriormente, sendo possível proceder-se à análise dos dados e à interpretação dos padrões de atividade observados ao longo do tempo. A identificação de padrões nas atividades diárias pode proporcionar uma série de benefícios tangíveis resultando em experiências personalizadas, onde as preferências e rotinas individuais são cuidadosamente consideradas.

Os resultados obtidos demonstram a capacidade do sistema de colaborar entre dispositivos na determinação das atividades do utilizador, com o objetivo de reduzir falsos positivos e aumentar a eficiência global do sistema. A transição para um ambiente residencial real trouxe consigo um nível acrescido de autenticidade e complexidade. As casas inteligentes são dinâmicas e complexas, podendo conter uma ampla variedade de atividades realizadas por diferentes utilizadores, com preferências individuais aumentando a heterogeneidade da tarefa de deteção e requerendo um sistema adaptável.

## 5.4 Discussão

A avaliação dos módulos integrantes do sistema *DistSense*, na secção 5.1, revelou uma compreensão do desempenho e eficácia dos componentes essenciais dentro do contexto de reconhecimento de atividades através de um sistema distribuído para um contexto doméstico inteligente. O racional da escolha dos casos de uso esteve relacionado com a operação entre a integração e colaboração entre os módulos e os contextos onde o sistema *DistSense* pode ser útil e benéfico para os utilizadores.

No primeiro caso de uso, a identificação de atividades diárias dos utilizadores emergiu como uma faceta crítica para proporcionar experiências personalizadas e eficientes em ambientes residenciais inteligentes. No entanto, é imperativo reconhecer a complexidade ambiental que caracteriza os ambientes domésticos. Estes espaços revelam-se extremamente dinâmicos, onde múltiplos fatores, como a oclusão de ângulos de visão, influenciam substancialmente a interpretação das ações dos utilizadores. Além disso, variáveis ambientais, tais como mudanças na iluminação, ruído de fundo e a presença de objetos diversos, contribuem para a complexidade do contexto.

Adicionalmente, a variedade de atividades realizadas no interior de uma residência e as preferências individuais dos utilizadores aumentam ainda mais a heterogeneidade da tarefa em questão. Neste cenário, a adaptabilidade do sistema é de primordial importância. Estes desafios foram ultrapassados através da colaboração entre os nós do sistema

---

com o objetivo de reduzir estes aspetos e melhorar a precisão na deteção da atividade doméstica.

Posteriormente, através da deteção de atividades durante um período de tempo, o capaz pode ajustar-se às singularidades e preferências individuais dos utilizadores, sendo este um fator crítico para a consecução de ambientes residenciais inteligentes que respondem de forma atenciosa e eficaz às necessidades de cada utilizador.

No contexto do segundo caso de uso, referente à deteção de perigos domésticos, o sistema demonstrou a sua eficácia na identificação precoce de situações de risco, como por exemplo a fuga de água. No entanto, a amplitude de cenários de perigo apresentou desafios adicionais, uma vez que os perigos em ambientes domésticos podem variar consideravelmente. A deteção precisa desses perigos e a emissão de alertas sem falsos positivos ou negativos representou um desafio técnico significativo. A integração com a plataforma HA e o armazenamento na *blockchain* foram elementos cruciais para assegurar a proteção dos dados do utilizador e garantir a comunicação eficaz das situações de perigo, mesmo na ausência dos utilizadores.

É importante destacar que um dos requisitos fundamentais do sistema *DistSense* é a proteção dos dados do utilizador. Para alcançar este objetivo, o processamento de dados foi realizado localmente de forma distribuída, minimizando a exposição de informações sensíveis do utilizador para o exterior. Além disso, o armazenamento na *blockchain* e a consulta à *blockchain* em caso de incerteza na deteção e classificação de atividades possibilitou a diminuição de falsos positivos e aumentou a confiabilidade do sistema para determinar as atividades executadas pelo utilizador.

Em ambos os casos de uso, a interação eficiente entre os módulos do sistema foi evidente. A colaboração dos nós desempenhou um papel fundamental na identificação de atividades complexas.

A implementação de algoritmos de aprendizagem computacional também se mostrou valiosa, uma vez que permitiu ao sistema adaptar-se e melhorar continuamente sua capacidade de deteção e interpretação de padrões. Essa capacidade de aprendizado torna o sistema *DistSense* resiliente e preciso na deteção de perigos em ambientes domésticos inteligentes.

# Capítulo 6

## Conclusão

Esta investigação descreve a concepção e implementação de um sistema distribuído de monitorização em ambientes residenciais inteligentes. O sistema integra módulos de descoberta, comunicação, aprendizagem computacional, processamento e representação do conhecimento. Ao longo do desenvolvimento e da integração desses módulos, tornou-se evidente a importância da privacidade e segurança dos dados do utilizador.

A necessidade de descobrir dispositivos de forma automatizada realçou a importância da utilização de algoritmos de criptografia para garantir comunicações seguras e confiáveis apenas com dispositivos legítimos. A aplicação de técnicas de ML para aprimorar a análise enfatizou a necessidade de salvaguardar os dados de treino e proteger os modelos contra possíveis ataques maliciosos. Além disso, a segurança na comunicação entre os módulos do sistema revelou-se essencial para evitar a interceção de dados sensíveis e a falsificação de mensagens.

A utilização de sensores intrusivos, como câmaras e microfones, exigiu uma atenção redobrada à privacidade e à integridade dos dados captados. O sistema *DistSense* teve por base esse requisito fundamental para proteger a informação sensível, assegurando que os dados capturados, sensíveis como imagens e áudio, sejam processados localmente, apenas armazenando dados de alto nível, sem comprometer a eficácia do sistema.

No entanto, é crucial reconhecer que a segurança é um esforço contínuo, e que o sistema deve ser constantemente avaliado e atualizado para permanecer resiliente e garantir a segurança dos dados do utilizador face às ameaças em evolução.

A arquitetura distribuída em si apresentou desafios durante a sua implementação. A necessidade de coordenar ações entre diferentes nós sem comprometer a integridade ou a confidencialidade dos dados exigiu a implementação de protocolos de segurança robustos e a adoção de algoritmos criptográficos. O módulo de processamento e representação do conhecimento, por sua vez, sublinhou a importância de garantir a consistência e a precisão dos dados em ambientes em constante mudança.

A utilização de técnicas de ML com o intuito de aperfeiçoar a deteção em ambientes domésticos sublinha a relevância desta tecnologia na otimização dos modelos audiovi-

---

suais implementados. Embora a taxa de precisão no treino dos modelos seja satisfatória, surgem desafios devido às variações no ambiente inteligente. A colaboração e a consulta do histórico de eventos na *blockchain* emergiram como elementos essenciais, uma vez que permitiram a redução de falsos positivos em situações em que as flutuações de ruído podem ser prejudiciais.

É importante salientar que a utilização de tecnologias para simulação de ambientes inteligentes, desempenhou um papel fundamental ao longo do desenvolvimento do sistema, visto que permitiram a identificação de erros e a otimização das funcionalidades do sistema de forma eficaz, economizando tempo em comparação com os testes em ambiente real durante a fase de desenvolvimento

Embora se tenha alcançado com sucesso a validação do sistema através da realização de testes funcionais e implementação de casos de uso, à medida que a tecnologia continua a avançar e as ameaças cibernéticas se tornam mais sofisticadas, a abordagem distribuída adotada no sistema *DistSense* pode ser um estudo interessante para futuros projetos na área de monitorização de ambientes residenciais inteligentes em que o espaço está em constante mudança. No entanto, é crucial reconhecer que a segurança e a colaboração entre dispositivos são um esforço contínuo, onde o sistema deve ser constantemente avaliado e atualizado para permanecer resiliente face às ameaças em evolução e garantir a segurança contínua dos dados do utilizador.

Um aspeto adicional a considerar é a deteção automática da localização de cada nó do sistema. Esta deteção poderia ser realizada por meio de técnicas de visão computacional, permitindo que cada dispositivo tenha consciência da divisão específica da casa em que se encontra. Através da análise das semelhanças nas imagens capturadas a partir de diferentes perspetivas, caso os mesmos elementos sejam detetados, seria possível inferir que os dispositivos estão no mesmo local. Desta forma, evitaria-se a necessidade de atribuir previamente a localização de cada nó no sistema, simplificando a configuração e otimizando a operação do sistema como um todo.

Outro aspeto que pode ser aperfeiçoado diz respeito à melhoria da precisão por meio da colaboração entre os nós na deteção de atividades, o que é fundamental, especialmente em ambientes dinâmicos e complexos. Este processo implica o desenvolvimento de algoritmos mais avançados de visão computacional e de processamento de dados.

Além disso, no âmbito da solução de deteção de atividades domésticas, os resultados promissores obtidos com a utilização dos modelos podem ser aprimorados através de um conjunto de dados mais diversificado, que englobe uma maior variedade de cenários em casas inteligentes. A expansão da capacidade do sistema para identificar uma gama mais ampla de situações de risco, como incêndios ou intrusões, requer a integração de sensores adicionais e o desenvolvimento de algoritmos especializados.

Uma outra vertente que pode ser explorada em trabalhos futuros é a identificação de padrões de atividades complexas a longo prazo. Um exemplo de aplicação seria a

---

capacidade de verificar se o utilizador está a adotar comportamentos mais sedentários ou menos sociáveis com base no seu histórico de atividades. Esta informação poderia ser relevante para inferir o seu estado emocional, especialmente se o utilizador estiver a sentir-se mais deprimido, desencadeando alertas para o próprio utilizador, bem como para os seus cuidadores ou familiares, sobre essas mudanças no padrão de atividades.

Por último, podem ser realizados estudos de usabilidade e avaliação das expectativas dos utilizadores finais, contribuindo para uma experiência mais satisfatória e para a compreensão das suas necessidades.

# Bibliografia

Batyrzhan K Akhmetzhanov, Omar Aslan Gazizuly, Zhanserik Nurlan, and Nurkhat Zhakiyev. Integration of a video surveillance system into a smart home using the home assistant platform. In *2022 International Conference on Smart Information Systems and Technologies (SIST)*, pages 1–5. IEEE, 2022. [40](#)

Ala Al-Fuqaha, Mohsen Guizani, Mehdi Mohammadi, Mohammed Aledhari, and Moussa Ayyash. Internet of things: A survey on enabling technologies, protocols, and applications. *IEEE Communications Surveys & Tutorials*, 17(4):2347–2376, 2015a. doi: 10.1109/COMST.2015.2444095. [42](#)

Ala Al-Fuqaha, Mohsen Guizani, Mehdi Mohammadi, Mohammed Aledhari, and Moussa Ayyash. Internet of things: A survey on enabling technologies, protocols, and applications. *IEEE communications surveys & tutorials*, 17(4):2347–2376, 2015b. [viii](#), [41](#)

Saifedean Ammous. Blockchain technology: What is it good for? *Available at SSRN 2832751*, 2016. [69](#)

Charles Anderson. Docker [software engineering]. *IEEE Software*, 32(3):102–c3, 2015. doi: 10.1109/MS.2015.62. [12](#)

Michael Blackstock and Rodger Lea. Iot interoperability: A hub-based approach. In *2014 International Conference on the Internet of Things (IOT)*, pages 79–84, 2014. doi: 10.1109/IOT.2014.7030119. [15](#)

Hung Cao, Monica Wachowicz, Chiara Renso, and Emanuele Carlini. Analytics everywhere: generating insights from the internet of things. *Ieee Access*, 7:71749–71769, 2019. [viii](#), [19](#)

Longbing Cao. Decentralized ai: Edge intelligence and smart blockchain, metaverse, web3, and desc. *IEEE Intelligent Systems*, 37(3):6–19, 2022. [5](#)

Joao Carreira, Eric Noland, Andras Banki-Horvath, Chloe Hillier, and Andrew Zisserman. A short note about kinetics-600. *arXiv preprint arXiv:1808.01340*, 2018. [62](#)

- 
- Stuart Cheshire and Marc Krochmal. DNS-Based Service Discovery. RFC 6763, February 2013. URL <https://www.rfc-editor.org/info/rfc6763>. 41
- Marie Clausen, Rolf Apel, Marc Dorchain, Matthias Postina, and Mathias Usler. Use case methodology: a progress report. *Energy Informatics*, 1:273–283, 10 2018. ISSN 25208942. doi: 10.1186/s42162-018-0036-0. 5
- Intersoft Consulting. General data protection regulation - gdpr. <https://gdpr-info.eu/>, 2020. Accessed: 2022-12-05. 4
- George F Coulouris, Jean Dollimore, and Tim Kindberg. *Distributed systems: concepts and design*. pearson education, 2005. 56
- Srijan Das, Rui Dai, Michal Koperski, Luca Minciullo, Lorenzo Garattoni, Francois Bremond, and Gianpiero Francesca. Toyota smarhome: Real-world activities of daily living. In *The IEEE International Conference on Computer Vision (ICCV)*, October 2019. 44, 62
- Ali Dorri, Salil S. Kanhere, Raja Jurdak, and Praveen Gauravaram. Blockchain for iot security and privacy: The case study of a smart home. In *2017 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops)*, pages 618–623, 2017. doi: 10.1109/PERCOMW.2017.7917634. 40, 46
- Issam El Naqa and Martin J Murphy. *What is machine learning?* Springer, 2015. 61
- Simone Facchini, Giacomo Giorgi, Andrea Saracino, and Gianluca Dini. Multi-level distributed intrusion detection system for an iot based smart home environment. In *ICISSP*, pages 705–712, 2020. 26, 29
- Sven Fleck and Wolfgang Straßer. Privacy sensitive surveillance for assisted living—a smart camera approach. In *Handbook of Ambient Intelligence and Smart Environments*, pages 985–1014. Springer, 2010. 25, 29
- Eduardo Fonseca, Xavier Favory, Jordi Pons, Frederic Font, and Xavier Serra. Fsd50k: An open dataset of human-labeled sound events. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 30:829–852, 2022. doi: 10.1109/TASLP.2021.3133208. 44, 62
- Patricia Franco, Jose Manuel Martinez, Young Chon Kim, and Mohamed A. Ahmed. Iot based approach for load monitoring and activity recognition in smart homes. *IEEE Access*, 9, 2021. ISSN 21693536. doi: 10.1109/ACCESS.2021.3067029. 24, 29
- Quazi Ehsanul Kabir Mamun, Salahuddin Mohammad Masum, and Mohammad Abdur Rahim Mustafa. Modified bully algorithm for electing coordinator in distributed systems. *WSEAS Transactions on Computers*, 3(4):948–953, 2004. 38

- 
- Dejan S Milojicic, Vana Kalogeraki, Rajan Lukose, Kiran Nagaraja, Jim Pruyne, Bruno Richard, Sami Rollins, and Zhichen Xu. Peer-to-peer computing, 2002. 15
- Caroline Lancelot Miltgen and Dominique Peyrat-Guillard. Cultural and generational influences on privacy concerns: a qualitative study in seven european countries. *European journal of information systems*, 23(2):103–125, 2014. 45
- Ehsan Adeli Mosabbeeb, Kaamran Raahemifar, and Mahmood Fathy. Multi-view human activity recognition in distributed camera sensor networks. *Sensors*, 13(7):8750–8770, 2013. 27, 29
- Joan Navarro, Ester Vidaña-Vila, Rosa Ma Alsina-Pagès, and Marcos Hervás. Real-time distributed architecture for remote acoustic elderly monitoring in residential-scale ambient assisted living scenarios. *Sensors*, 18(8):2492, 2018. 27, 29
- Jason C Neumann. *The book of GNS3: build virtual network labs using Cisco, Juniper, and more*. No Starch Press, 2015. 11, 12
- Official Website. Getting started with gns3. <https://docs.gns3.com/docs/>, 2023. URL <https://docs.gns3.com/img/getting-started/what-is-gns3/1.jpg>. viii, 12
- Haroon Shakirat Oluwatosin. Client-server model. *IOSR Journal of Computer Engineering*, 16(1):67–71, 2014. 14
- Mustafa Safa Ozdayi, Murat Kantarcioglu, and Bradley Malin. Leveraging blockchain for immutable logging and querying across multiple sites. *BMC Medical Genomics*, 13(7):1–7, 2020. 45, 46
- Bo Pang, Erik Nijkamp, and Ying Nian Wu. Deep learning with tensorflow: A review. *Journal of Educational and Behavioral Statistics*, 45(2):227–248, 2020. 43
- Karol J Piczak. Esc: Dataset for environmental sound classification. In *Proceedings of the 23rd ACM international conference on Multimedia*, pages 1015–1018, 2015. 45, 62
- Ismini Psychoula, Deepika Singh, Liming Chen, Feng Chen, Andreas Holzinger, and Huansheng Ning. Users’ privacy concerns in iot based applications. In *2018 IEEE SmartWorld, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation (SmartWorld/SCALCOM/UIC/ATC/CBD-Com/IOP/SCI)*, pages 1887–1894, 2018. doi: 10.1109/SmartWorld.2018.00317. 45

- 
- Pandia Rajan Jeyaraj and Edward Rajan Samuel Nadar. Smart-monitor: patient monitoring system for iot-based healthcare system using deep learning. *IETE Journal of Research*, 68(2):1435–1442, 2022. [22](#), [29](#)
- Kishore K Reddy and Mubarak Shah. Recognizing 50 human action categories of web videos. *Machine vision and applications*, 24(5):971–981, 2013. [44](#)
- IDMS Rupasinghe and MWP Maduranga. Towards ambient assisted living (aal): Design of an iotbased elderly activity monitoring system. *International Journal of Engineering and Manufacturing (IJEM)*, 12(2):1–10, 2022. [viii](#), [23](#), [24](#), [29](#)
- Justin Salamon, Christopher Jacoby, and Juan Pablo Bello. A dataset and taxonomy for urban sound research. In *Proceedings of the 22nd ACM international conference on Multimedia*, pages 1041–1044, 2014. [45](#)
- Ashutosh Satapathy, Jenila Livingston, et al. A comprehensive survey on ssl/tls and their vulnerabilities. *International Journal of Computer Applications*, 153(5):31–38, 2016. [43](#)
- Gunnar A. Sigurdsson, Gül Varol, Xiaolong Wang, Ivan Laptev, Ali Farhadi, and Abhinav Gupta. Hollywood in homes: Crowdsourcing data collection for activity understanding. *ArXiv e-prints*, 2016. URL <http://arxiv.org/abs/1604.01753>. [44](#), [62](#)
- Deepika Singh, Ismini Psychoula, Johannes Kropf, Sten Hanke, and Andreas Holzinger. Users’ perceptions and attitudes towards smart home technologies. In *Smart Homes and Health Telematics, Designing a Better Future: Urban Assisted Living: 16th International Conference, ICOST 2018, Singapore, Singapore, July 10-12, 2018, Proceedings 16*, pages 203–214. Springer, 2018. [46](#)
- Sam Solaimani, Wally Keijzer-Broers, and Harry Bouwman. What we do—and don’t know about the smart home: an analysis of the smart home literature. *Indoor and Built Environment*, 24(3):370–383, 2015. [13](#)
- Khurram Soomro, Amir Roshan Zamir, and Mubarak Shah. Ucf101: A dataset of 101 human actions classes from videos in the wild. *arXiv preprint arXiv:1212.0402*, 2012. [44](#)
- Usman Tariq, Atef Ibrahim, Tariq Ahmad, Yassine Bouteraa, and Ahmed Elmogy. Blockchain in internet-of-things: a necessity framework for security, reliability, transparency, immutability and liability. *IET Communications*, 13(19):3187–3192, 2019. [46](#)

---

Jordan Tewell, Dympna O’Sullivan, Neil Maiden, James Lockerbie, and Simone Stumpf. Monitoring meaningful activities using small low-cost devices in a smart home. *Personal and Ubiquitous Computing*, 23:339–357, 4 2019. ISSN 16174909. doi: 10.1007/s00779-019-01223-2. [21](#), [29](#)

Steve Tockey. *How to Engineer Software: A Model-Based Approach*. John Wiley & Sons, 2019. [35](#)

Gaurav Verma, Yashi Gupta, Abid M. Malik, and Barbara Chapman. Performance evaluation of deep learning compilers for edge inference. In *2021 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)*, pages 858–865, 2021. doi: 10.1109/IPDPSW52791.2021.00128. [67](#)

George Xylomenos and George C Polyzos. Tcp and udp performance over a wireless lan. In *IEEE INFOCOM’99. Conference on Computer Communications. Proceedings. Eighteenth Annual Joint Conference of the IEEE Computer and Communications Societies. The Future is Now (Cat. No. 99CH36320)*, volume 2, pages 439–446. IEEE, 1999. [42](#)