



Solução ciber-física para a gestão de edifícios suportada por dispositivos inteligentes e modelos de ambientes inteligentes

NUNO DANIEL SILVA TEIXEIRA

Julho de 2023



Solução ciber-física para a gestão de edifícios suportada por dispositivos inteligentes e modelos de ambientes inteligentes

Nuno Daniel Silva Teixeira

Aluno nº: 1201719

Dissertação para obtenção do Grau de Mestre em Engenharia de Inteligência Artificial

Orientador: Doutor Luís Filipe Oliveira Gomes, Investigador Auxiliar do Instituto Superior de Engenharia do Instituto Politécnico do Porto

Coorientadora: Doutora Zita Maria Almeida do Vale, Professora Coordenadora Principal do Instituto Superior de Engenharia do Instituto Politécnico do Porto

Júri:

Presidente:

Doutora Isabel Cecília Correia da Silva Praça Gomes Pereira, Professora Coordenadora do Instituto Superior de Engenharia do Instituto Politécnico do Porto

Vogais:

Doutor Joaquim Filipe Peixoto dos Santos, Professor Adjunto do Instituto Superior de Engenharia do Instituto Politécnico do Porto

Doutor Luís Filipe Oliveira Gomes, Investigador Auxiliar do Instituto Superior de Engenharia do Instituto Politécnico do Porto

Porto, julho 2023

Resumo

A utilização de dispositivos ligados à internet e modelos de ambientes inteligentes em sistemas de gestão de edifícios tem vindo a ganhar notoriedade nos últimos anos, sendo cada vez mais comum a sua aplicação em edifícios. Estes conceitos, de internet das coisas e ambientes inteligentes, fornecem um meio para automatizar e otimizar as operações de gestão de edifícios, levando a uma maior eficiência no uso dos recursos, diminuição de custos e aumento do conforto dos utilizadores. Contudo, muitas das soluções existentes carecem de interoperabilidade e modelos inteligentes que considerem as necessidades e requisitos únicos de edifícios individuais e as preferências e necessidades dinâmicas dos utilizadores.

Como principal objetivo, esta dissertação propõe a conceção, implementação, teste e validação de uma solução robusta que integra modelos de ambientes inteligentes e mecanismos de acesso controlado a dados. A solução proposta inclui a utilização de sensores e dispositivos ligados à internet para a recolha e análise de dados em tempo real, que serão posteriormente usados para a criação de modelos de previsão de comportamento do edifício e dos seus utilizadores. Para a identificação de padrões e contextos, foram concebidos algoritmos de aprendizagem automática e técnicas de análise de dados. O acesso aos dados, da solução proposta, contempla um mecanismo de acesso seguro e eficiente, seguindo as diretrizes do Regulamento Geral sobre a Proteção de Dados (RGPD), nacional e europeu.

Para suportar o uso da solução proposta, foi concebida e implementada uma interface gráfica que permite aos gestores e utilizadores do edifício monitorizarem e controlarem as operações em tempo real, proporcionando-lhes a capacidade de responder rapidamente às condições atuais, tomando decisões informadas. Esta interface gráfica, baseada em web, permite ainda consultar os dados históricos e interagir com os modelos de suporte que foram desenvolvidos.

A solução proposta foi avaliada através de casos de estudo executados em ambiente realista. Os resultados destes estudos foram utilizados para avaliar a eficácia da solução proposta na melhoria do desempenho dos edifícios. Os estudos concluem que a utilização de dispositivos inteligentes e modelos de ambientes inteligentes na gestão de edifícios é uma abordagem promissora que pode culminar em melhorias significativas no desempenho e operação dos edifícios inteligentes.

Esta dissertação contribui para o domínio dos edifícios inteligentes, fornecendo uma solução abrangente que integra dispositivos ligados à internet e modelos de ambientes inteligentes para melhorar o desempenho dos edifícios e o conforto dos utilizadores.

Palavras-chave: ambiente inteligente, aprendizagem automática, extração de conhecimento, dispositivos IoT, edifício inteligente

Abstract

The use of internet connected devices and ambient intelligence models in building management systems has been gaining notoriety in recent years, and its application in buildings is becoming more and more common. These concepts, of the internet of things and ambient intelligence, provide a means to automate and optimise building management operations, leading to greater efficiency in the use of resources, reduced costs and increased user comfort. However, many existing solutions lack interoperability and intelligent models that consider the unique needs and requirements of individual buildings and the dynamic preferences and needs of users.

As the main objective, this dissertation proposes the design, implementation, testing and validation of a robust solution that integrates ambient intelligence models and controlled data access mechanisms. The proposed solution includes the use of sensors and devices connected to the internet for real-time data collection and analysis, which will be later used for the creation of forecasting models for the behaviour of the building and its users. For the identification of patterns and contexts, machine learning algorithms and data analysis techniques were designed. The data access, of the proposed solution, contemplates a safe and efficient access mechanism, following the guidelines of the national and European General Data Protection Regulation (GDPR).

To support the use of the proposed solution, a graphic interface was designed and implemented to allow building managers and users to monitor and control operations in real time, providing them with the ability to quickly respond to current conditions, making informed decisions. This web-based graphical interface also allows consulting historical data and interacting with the support models that were developed.

The proposed solution was evaluated through case studies executed in a realistic environment. The results of these studies were used to evaluate the effectiveness of the proposed solution in improving building performance. The studies conclude that the use of smart devices and ambient intelligence models in building management is a promising approach that can culminate in significant improvements in the performance and operation of smart buildings.

This dissertation contributes to the domain of intelligent buildings by providing a comprehensive solution that integrates internet-connected devices and ambient intelligence models to improve building performance and user comfort.

Keywords: ambient intelligence, internet of things devices, knowledge retrieval, machine learning, smart building

Agradecimentos

Gostaria de expressar a minha sincera gratidão à minha família, que tem sido sempre o meu pilar de força e apoio ao longo da minha jornada académica. O seu amor inabalável e encorajamento têm sido fundamentais para me ajudar a superar vários desafios e a alcançar este marco significativo na minha vida.

Gostaria também de estender os meus agradecimentos à minha namorada, Verónica, pela sua constante motivação e encorajamento. A sua incansável crença em mim tem sido uma fonte de inspiração e o seu amor e apoio têm-me ajudado a manter-me concentrado e motivado durante os tempos mais difíceis.

Gostaria de agradecer ao meu amigo, Hélder, que tem sido uma constante fonte de ajuda e apoio, mesmo quando tinha o seu próprio trabalho a fazer. A sua vontade de dar uma ajuda e a sua atitude positiva fizeram uma diferença significativa no meu percurso académico.

Por último, mas não menos importante, gostaria de expressar a minha sincera gratidão aos meus orientadores. A orientação, sabedoria e apoio têm sido inestimáveis ao longo desta jornada. O empenho incansável na excelência e a paixão pela investigação têm sido uma fonte constante de inspiração e o feedback e crítica construtiva têm-me ajudado a melhorar significativamente o meu trabalho.

Mais uma vez, estou profundamente grato a todos os que contribuíram para a minha jornada académica e me ajudaram a alcançar este marco significativo na minha vida.

Índice

1	Introdução	1
1.1	Contextualização	1
1.2	Descrição do Problema	2
1.3	Objetivos	5
1.4	Contribuição Científica	6
1.5	Estrutura da Dissertação	7
2	Estado de Arte	9
2.1	Internet das Coisas	9
2.1.1	Protocolos de comunicação	15
2.1.2	Aplicações de IoT	17
2.2	Aprendizagem automática	19
2.2.1	Aprendizagem supervisionada	22
2.2.2	Aprendizagem não supervisionada	29
2.3	Edifícios Inteligentes e Ambientes Inteligentes	32
2.3.1	Edifícios Inteligentes	32
2.3.2	Ambientes Inteligentes	35
2.4	Conclusões do Capítulo	38
3	Métodos e Ferramentas	41
3.1	Métodos	41
3.1.1	Processamento Paralelo	41
3.1.2	Aprendizagem Automática	41
3.1.3	Identificação de correlações nos dados	43
3.2	Ferramentas	44
3.2.1	Conjunto de dados e construção de histórico	44
3.2.2	Ferramenta de acesso e partilha de dados	45
3.2.3	Bibliotecas utilizadas para a Interface Computacional	46
3.2.4	Framework da Interface Gráfica	47

3.2.5	Bibliotecas de identificação de correlações entre dados	47
3.2.6	Bibliotecas para a previsão de consumos energéticos	48
3.2.7	Bibliotecas para o <i>clustering</i>	49
3.2.8	Protocolos de Interligação de dispositivos IoT heterogéneos	50
3.3	Desafios Técnicos e Sociais	51
3.3.1	Proteção dos dados	52
3.3.2	Análise de Segurança	53
3.3.3	Aspetos Éticos	54
3.4	Conclusões do capítulo	54
4	<i>Building Ambient Intelligent System (BAIS)</i>	57
4.1	Arquitetura de Software	57
4.1.1	Camada de Conectividade	59
4.1.2	Camada de <i>Middleware</i>	59
4.1.3	Camada Principal	61
4.2	Integração dos IoT's Heterogéneos	62
4.3	Mecanismo de partilha e acesso aos dados	64
4.3.1	JSON Web Tokens	64
4.3.2	RESTful API.....	64
4.4	Extração de conhecimento.....	66
4.5	Aprendizagem e Identificação de Contextos	68
4.6	Perfil Energético do Utilizador	70
4.7	Algoritmos de Previsão de consumos de energia elétrica	72
4.8	Interface gráfica do BAIS.....	77
4.9	Conclusões do capítulo	82
5	Casos de Estudo	85
5.1	Integração de IoTs e mecanismo de acesso a dados.....	85
5.2	Perfil e Previsão de consumos energéticos	88
5.3	Contextos Inteligentes.....	92
5.4	Participação direta de dispositivos IoT em programas de <i>demand response</i>	95
5.5	Conclusões do Capítulo	97

6	Conclusões.....	99
6.1	Conclusões Principais	99
6.2	Trabalho Futuro	101
	Referências	103

Lista de Figuras

Figura 1 - Algumas das Aplicações da IoT	19
Figura 2 - Processos da Aprendizagem Supervisionada.....	22
Figura 3 - Uma árvore de decisão para determinar qual é o animal em questão	24
Figura 4 - Uma representação da classificação através do uso de SVM com hiperplano.....	25
Figura 5 - Um exemplo da abordagem do algoritmo <i>K-Nearest Neighbor</i>	27
Figura 6 - Fluxo de execução de uma previsão	42
Figura 7 - Arquitetura de Software	58
Figura 8 - Código do ficheiro de configuração dos dispositivos IoT	63
Figura 9 - Diagrama de Sequência do Processo de Aquisição dos Dados e Atuação do Utilizador	66
Figura 10 - Exemplo de um diagrama de Taylor	77
Figura 11 - Formulário de geração do JSON Web Token	78
Figura 12 - Página Web <i>Building Energy</i>	80
Figura 13 - Página Web <i>Building Historic</i>	80
Figura 14 - Página Web <i>Energy Forecast</i>	81
Figura 15 - Página Web das Correlações.....	81
Figura 16 - Página Web da Lista dos <i>Tokens</i>	82
Figura 17 - Dados energéticos lidos pelo proprietário do edifício	87
Figura 18 - Dados energéticos lidos pelo utilizador de um escritório.....	87
Figura 19 - Dados energéticos lidos pelo gestor da <i>microgrid</i>	88
Figura 20 - Perfil energético global do utilizador	89
Figura 21 - Perfil energético considerando o contexto semanal	89
Figura 22 - Perfil energético considerando o contexto mensal	90

Figura 23 - Perfil energético considerando o contexto térmico	90
Figura 24 - Previsão dos diferentes modelos e do perfil energético para o consumo do dia seguinte vs valor real	91
Figura 25 - Gráfico de Taylor dos diferentes modelos de previsão	92
Figura 26 - Método Elbow para determinar o número de <i>clusters</i>	93
Figura 27 - Gráfico dos diferentes <i>clusters</i> identificados pelo modelo.....	94
Figura 28 - Gráfico de um dia inteiro de identificação de contextos.....	94
Figura 29 - Distribuições de <i>shifting</i> para o evento de <i>demand response</i> às 11 horas.....	97

Lista de Tabelas

Tabela 1 - Aplicações e plataformas IoT existentes	12
Tabela 2 - Uso de IoT em aplicações industriais, residenciais e de cidades inteligentes.....	14
Tabela 3 - Comparação entre protocolos de comunicação de IoT	17
Tabela 4 - Vantagens e Desvantagens de Algoritmos de Aprendizagem Supervisionada	27
Tabela 5 - Recursos energéticos monitorizados	45
Tabela 6 – Rotas disponíveis na API REST	65
Tabela 7 - Métricas de avaliação dos modelos de previsão.....	91
Tabela 8 - Tabela descritiva dos contextos identificados	95

Acrónimos e Símbolos

Lista de Acrónimos

6LoWPAN	<i>Low Power Wireless Personal Area Network</i>
AA	Aprendizagem Automática
AG	Algoritmos Genéticos
AmI	Ambiente Inteligente
AMQP	<i>Advanced Message Queuing Protocol</i>
BAIS	<i>Building Ambient Intelligence System</i>
BD	<i>Big Data</i>
BLE	Bluetooth LowEnergy
CNN	<i>Convolutional Neural Networks</i>
DR	<i>Demand Response</i>
DRL	<i>Deep Reinforcement Learning</i>
GAN	<i>Generative Adversarial Network</i>
GECAD	<i>Research Group on Intelligent Engineering and Computing for Advanced Innovation and Development</i>
HTTP	<i>Hypertext Transfer Protocol</i>
HVAC	<i>Heating, Ventilation, and Air Conditioning</i>
IA	Inteligência Artificial
IoT	Internet das Coisas
IoTEP	<i>IoT Energy Platform</i>
ISEP	Instituto Superior de Engenharia do Porto
JSON	JavaScript Object Notation
JWT	Json Web Token
K-NN	<i>K-Nearest Neighbor</i>
LSTM	<i>Long Short-Term-Memory</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MQTT	<i>Queuing Telemetry Transport</i>
MSE	<i>Mean Squared Error</i>
NFC	<i>Near Field Communication</i>
NZEB	<i>Nearly Zero-Energy Building</i>

PSO	<i>Particle Swarm Optimizer</i>
RAE	<i>Relative Absolute Error</i>
RETINA	<i>REal-Time support Infrastructure and Energy management for Intelligent carbon-Neutral smArt cities</i>
RGPD	Regulamento Geral Sobre Proteção de Dados
RL	<i>Reinforcement Learning</i>
RNA	Rede Neuronal Artificial
RMSD	<i>Root Mean Squared Deviation</i>
RMSE	<i>Root Mean Squared Error</i>
SCADA	<i>Supervisory Control and Data Acquisition System</i>
SIL	<i>Software-In-the-Loop</i>
SVM	<i>Support Vector Machines</i>
TCP	<i>Transmission Control Protocol</i>
TIC	Tecnologias de Informação e Comunicação
TIoCPS	<i>Trustworthy and Smart Communities of Cyber-Physical Systems</i>
UDP	<i>User Datagram Protocol</i>
UE	União Europeia
XGBoost	<i>eXtreme Gradient Boosting</i>

1 Introdução

Este capítulo fornece uma contextualização geral do trabalho apresentado nesta dissertação. São apresentados a contextualização dos temas, a descrição do problema, os objetivos principais da investigação, as contribuições científicas da dissertação e a estrutura do presente documento.

1.1 Contextualização

Os edifícios podem ser melhorados quer em termos de gestão de recursos, quer de interação com o utilizador. Nesse sentido, o conceito de edifícios inteligentes pode mudar a forma como nós, utilizadores, interagimos com o próprio edifício. A aplicação e uso de tecnologias de edifícios inteligentes tem diversos propósitos, nomeadamente a automação do edifício (Vujović & Maksimović, 2015), gestão da energia (Joo & Choi, 2017), segurança (Yared & Abulrazak, 2018) e assistência aos cuidados de saúde¹ (Ghayvat et al., 2015). Apesar das inúmeras vantagens inerentes à utilização de edifícios inteligentes, um dos principais problemas destes edifícios é permitir a integração de múltiplos sistemas de diferentes marcas e produtores, uma vez que estes edifícios teriam de permitir a interoperabilidade destes sistemas (Hazra et al., 2021). Por outro lado, de um ponto de vista energético, os edifícios inteligentes podem ser vantajosos, visto que estes têm a capacidade de gerir recursos energéticos (Miceli, 2013). Para isso, estes edifícios recorrem a sistemas de gestão de energia, sendo que estes sistemas, por sua vez, utilizam algoritmos de aprendizagem no sentido de compreender melhor as preferências do utilizador, tornando assim o uso destes edifícios mais cómodo e eficiente (Shi et al., 2022).

Com o intuito de aprender e entender as preferências do utilizador, bem como o contexto que o rodeia, podem ser então usados modelos de Ambientes Inteligentes (AMI) (Arens et al., 2005).

¹ Tradução do autor para o termos anglo-saxónico *assisted living*

Os sistemas de Aml beneficiam de uma integração de técnicas de inteligência artificial (Ramos et al., 2008), que permitem, a estes sistemas, aprender com o ambiente e com o utilizador. Os sistemas Aml podem ser caracterizados por diferentes fases (Ramos et al., 2008): interpretar o estado do ambiente, representar a informação e o conhecimento associado com o ambiente, modelar, simular e representar as entidades no ambiente, planear as decisões e as ações, aprender sobre o ambiente e aspetos associados, interagir com os humanos e agir no ambiente. Soluções com Aml necessitam, ainda assim, da integração de vários protocolos de comunicação. Todas estas práticas de utilização de sistemas de gestão de energia, juntamente com Aml, servem para melhorar o conforto do utilizador e podem ajudá-lo a ter uma maior poupança energética, objetivando atingir o *green computing*.

O conceito de *green computing* compreende práticas que tornam mais sustentável e menos prejudicial o uso de tecnologia, tendo assim, como objetivo, a maximização da eficiência energética durante a vida dos produtos, sendo esta essencial quer para grandes centros de dados, como para sistemas mais pequenos (Muniswamaiah et al., 2020).

Com a junção de sistemas de gestão de energia, de Aml e de dispositivos da Internet das Coisas (IoT) é possível maximizar a sustentabilidade dos edifícios inteligentes e tentar chegar o mais próximo do *Nearly Zero-Energy Building* (NZEB) (D'Agostino et al., 2017). Isto significaria que os edifícios teriam necessidades energéticas quase nulas, sendo que a satisfação dessas necessidades seria feita maioritariamente por energia proveniente de fontes renováveis.

A obtenção de dados contextuais dos diferentes dispositivos IoT e utilização de modelos de Aml também tornaria possível a tomada de decisões e sugestões para que o utilizador pudesse adaptar a utilização dos recursos de acordo com o consumo de cada um e para averiguar se poderia, ou não, diminuir os consumos (Khakifirooz et al., 2020).

Tendo em consideração a importância crescente das práticas energéticas sustentáveis e a necessidade de uma melhor gestão dos recursos energéticos, esta dissertação propõe um novo sistema Aml que pode ser facilmente instalado em qualquer edifício. Este sistema foi concebido para ajudar os utilizadores a reduzir o seu consumo de energia sem sacrificar os níveis de conforto necessários. Ao utilizar várias técnicas de poupança de energia e capacidades avançadas de monitorização, o sistema é capaz de se adaptar às necessidades e preferências do utilizador, enquanto fornece *feedback* em tempo real e recomendações sobre como otimizar a utilização de energia. Em última análise, este sistema visa promover práticas mais sustentáveis e ecológicas, enquanto melhora a satisfação e o conforto do utilizador.

1.2 Descrição do Problema

Apesar do mercado IoT ter emergido nos últimos anos, os produtores e consumidores destas tecnologias enfrentam grandes desafios relacionados com a recolha e gestão de dados, desta forma existe uma necessidade crescente do uso de sistemas mais inteligentes e eficientes em termos energéticos para gerir e controlar estes dispositivos em ambientes inteligentes. Em

particular, o consumo de energia nos edifícios tornou-se uma grande preocupação, com a necessidade de reduzir o desperdício de energia e promover práticas mais sustentáveis. No entanto, a falta de conhecimento do contexto e de capacidade de previsão energética nos atuais sistemas IoT impede frequentemente a sua capacidade de otimizar a utilização de energia e reduzir o desperdício.

Apesar dos muitos benefícios dos dispositivos IoT e dos ambientes inteligentes em edifícios inteligentes, existem ainda vários desafios e problemas que precisam de ser resolvidos. Alguns dos problemas atuais relacionados com este tópico envolvem questões de interoperabilidade, com o número crescente de dispositivos e plataformas de IoT disponíveis no mercado, a interoperabilidade tornou-se uma questão importante. Muitos dispositivos e plataformas não são concebidos para funcionar em conjunto, o que dificulta a sua integração num sistema de construção inteligente e coeso. Uma vez que dispositivos heterogêneos, de diferentes marcas ou produtores, possuem protocolos de comunicação diferentes, tornando difícil a comunicação entre dispositivos. As aplicações de IoT devem ser desenvolvidas tendo em consideração as mudanças tecnológicas do futuro, sendo que este desenvolvimento requer um equilíbrio de funções de *hardware* e *software*. Há falta de padronização na indústria da Internet de alta velocidade, com diferentes produtores a oferecerem diferentes protocolos e interfaces. Isto pode tornar difícil o desenvolvimento e implementação de sistemas interoperáveis de edifícios inteligentes.

Também existem muitas preocupações de segurança, à medida que mais dispositivos se ligam à Internet, as preocupações de segurança tornam-se mais proeminentes. Os dispositivos IoT são frequentemente vulneráveis a ciberataques e *hacking*, o que pode comprometer a segurança e a privacidade dos ocupantes dos edifícios inteligentes. Um dos maiores problemas a nível de segurança é a falta de encriptação de dados, que promove o aumento dos ataques, nos quais os *hackers* conseguem facilmente manipular algoritmos desenvolvidos para proteção. Além disso, testes e atualizações insuficientes, força bruta, risco de palavras-passe por defeito, credenciais fracas e detalhes de *login* deixam quase todos os dispositivos IoT vulneráveis à pirataria e à utilização de *malwares* e *ransomwares*. A cibersegurança também pode ser problemática, uma vez que, os edifícios inteligentes são o epitome de *Big Data* e que cada dispositivo conectado à internet é uma porta de entrada potencial para um ataque malicioso. Contudo, atualmente, está a tornar-se cada vez mais fácil assegurar os dados.

A gestão dos dados também é um dos problemas que abrange os sistemas baseados em dispositivos IoT, com a quantidade crescente de dados gerados pelos dispositivos de IoT, a gestão de dados tornou-se um grande desafio. Pode ser difícil armazenar, processar, e analisar grandes quantidades de dados em tempo real, o que pode dificultar a capacidade de tomar decisões informadas. Tendo em conta que os dados têm uma função muito importante, é preciso assegurar e planear bem de que forma é que estes são recolhidos, armazenados e processados dentro de um ambiente.

Tendo em conta que os edifícios inteligentes consomem uma quantidade significativa de energia e que a otimização do consumo de energia é um grande desafio, é essencial a utilização

de sistemas mais inteligentes que possam prever padrões de consumo de energia e ajustar a utilização em conformidade, a fim de reduzir o desperdício e promover a sustentabilidade.

Os dispositivos IoT impulsionaram o surgimento em massa de edifícios inteligentes. Estes edifícios permitem uma alta produtividade, custos mais baixos no local de trabalho e melhor planeamento de oportunidades. No entanto, a implementação de dispositivos IoT é resultado do investimento monetário, de tempo e de conhecimento. Os problemas associados à implementação destes dispositivos são diversos. O custo associado à sua implementação é um exemplo desses problemas, custo dos dispositivos necessários para estabelecer a IoT, mas também os custos de instalação e de formação.

Perceber as integrações poderá também ser uma dificuldade inerente à IoT devido à complexidade da mesma. De forma a simplificar o entendimento da mesma é necessário pensar nela como se se tratasse da montagem de um puzzle sem a imagem final do mesmo que serve como guia. Neste sentido, é possível saber que certas peças encaixam em determinados sítios, e pode também começar a ser vista uma imagem, mas esta não se torna completa até ao puzzle estar resolvido. Em suma, a melhor maneira de abordar este problema é pensar na IoT num sentido prático, estabelecer integrações simples e compreender a natureza das integrações.

Edifícios inteligentes demoram tempo a serem planeados. Para perceber os benefícios destes edifícios é necessário compreender os obstáculos inerentes aos mesmos. Assim, dedicar tempo a cada tarefa contribui para o desenvolvimento de um edifício inteligente que se pode compreender e utilizar para otimizar o conforto do utilizador e aumentar a sustentabilidade.

Com os edifícios inteligentes, e através do uso de dispositivos IoT, podem emergir sistemas de Aml. Estes sistemas também possuem alguns problemas associados, principalmente no que diz respeito ao utilizador, visto que são sistemas que interagem diretamente com este. Um sistema de Aml deve ter em atenção o tratamento transparente dos dados e ter um conhecimento claro das limitações dos métodos de processamento utilizados. É necessário haver um especial cuidado com os direitos dos utilizadores principalmente a nível da privacidade e da segurança. Os dados deverão apenas ser recolhidos com base no consentimento do utilizador, fornecendo escolhas e controlo do processo, incluindo modelos de fornecimento temporário e acesso ou obrigações de apagar dados posteriormente. Os regulamentos do Regulamento Geral sobre Proteção de Dados (RGPD) emitidos pela União Europeia (UE) fornecem uma boa base. A aquisição e gestão de dados tem de ser tida em atenção, para que seja incutida alguma consciência de como gerir os próprios dados, em situações da vida quotidiana. Em suma, é preciso ver um edifício inteligente e os utilizadores como parceiros de cooperação mútua, onde um edifício é inteligente no sentido de ser autoconsciente e cooperativo para com os utilizadores, ajudando-os nas suas atividades.

1.3 Objetivos

Os objetivos desta dissertação visam resolver alguns dos problemas da atualidade associados aos dispositivos IoT, aos edifícios inteligentes e aos sistemas de Aml. O principal objetivo desta dissertação é a concepção, implementação, teste e validação de uma solução robusta que integra modelos de ambientes inteligentes e mecanismos de acesso controlado a dados. De modo a facilitar a realização do objetivo principal, foram definidos os seguintes objetivos secundários para realizar esta dissertação:

- O1 – Investigar o atual estado de arte dos ambientes inteligentes em geral, a sua aplicação nos diferentes domínios e dos diferentes componentes que compõem essas soluções, como, os dispositivos IoT e aprendizagem automática;
- O2 – Conceber e implementar uma solução, para edifícios inteligentes, que permita a integração de dispositivos IoT heterogéneos, ultrapassando o problema de interoperabilidade;
- O3 – Conceber e implementar um mecanismo de acesso aos dados para assegurar a privacidade dos dados dos utilizadores, respeitando o atual Regulamento Geral sobre a Proteção de Dados (RGPD) nacional e europeu;
- O4 – Conceber e implementar um modelo para descoberta de conhecimento e identificação de contextos através do uso de técnicas de *clustering*;
- O5 – Conceber e implementar modelos preditivos contextuais de consumo de energia elétrica;
- O6 – Conceber e implementar uma interface gráfica para o(s) utilizador(es) visualizar(em) todas as funcionalidades que o sistema tem disponível;
- O7 – Testar as funcionalidades de integração dos IoT, monitorização e acesso aos dados propostas num contexto de edifício inteligente;
- O8 – Testar o sistema proposto baseado em IoT e todos as suas funcionalidades como uma solução de ambiente inteligente para edifícios inteligentes.

Esta dissertação visa aplicar uma gestão eficiente que pode promover, entre outros, a sustentabilidade do edifício, a redução dos custos de energia, o apoio a ações de manutenção e o aumento do conforto das pessoas. Como todos os objetivos delineados foram alcançados, este documento serve como relatório final do trabalho desenvolvido.

1.4 Contribuição Científica

Os desenvolvimentos científicos desta dissertação contribuíram ativamente para os projetos ITEA3 *Trustworthy and Smart Communities of Cyber-Physical Systems (TloCPS)*², financiado nacionalmente pela ANI (POCI-01-0247-FEDER-046182), e *REal-Time support Infrastructure and Energy management for Intelligent carbon-Neutral smArt cities (RETINA)*³, financiado pela Programa Operacional Regional Norte2020 (NORTE-01-0145-FEDER-000062).

O projeto TloCPS foi desenvolvido no sentido de colmatar um dos maiores desafios que os sistemas ciberfísicos (CPS) possuem: a falta de informação/partilha de dados e troca de valores fiáveis, inteligentes e interoperáveis que impedem o estabelecimento de uma economia de dados em torno dos CPS. Assim, o principal objetivo do projeto é desenvolver comunidades inteligentes e confiáveis para sistemas CPS (de onde surge o conceito TloCPS) de forma a mitigar este grande desafio no contexto industrial que lida com a energia, mobilidade e sistemas CPS de utilizador/proprietário. O conceito TloCPS combinado com as soluções dos casos de estudo contribui para o impulsionamento dos negócios das respetivas indústrias e permite uma maior fiabilidade, inteligência, interoperabilidade e sustentabilidade do ecossistema CPS industrial e da sociedade.

O projeto RETINA aborda aspetos complementares das infraestruturas de apoio a aplicações de cidade inteligente. O RETINA impulsiona o estado da arte em redes de comunicação e dispositivos informáticos de alto desempenho que compõem a infraestrutura sobre a qual esses serviços da cidade inteligente são construídos. Com o aproveitamento de tais avanços, serão integradas tais tecnologias em dois casos de utilização de cidades inteligentes relacionados com a mobilidade, nomeadamente arquiteturas de tecnologias de informação e comunicação (TIC) para fornecer serviços cooperativos de veículos, por exemplo, protocolos de coordenação para uma gestão mais segura e eficiente de veículos de energia em cruzamentos e segurança das comunicações entre e/ou fornecidos por drone. O projeto RETINA também considera a capacitação dos consumidores e de outros pequenos e médios atores do setor da energia. Esta capacitação requer decisões inteligentes e ações automatizadas que devem ser baseadas em inteligência artificial, através da utilização estratégica de abordagens baseadas em dados e no conhecimento.

Esta dissertação contribui para o desenvolvimento de um sistema de ambiente inteligente que privilegia e considera o uso intensivo de dispositivos IoT e as questões de privacidade e acesso aos dados. Neste sentido foram feitos vários contributos para o projeto TloCPS, nomeadamente contribuições nas atividades 2 (*Use case Requirements & TloCPS Architecture*), 4 (*Secure and trustworthy CPS System Communications*) e 5 (*Enablers of TloCPS devices, Trust and Security*) e nos entregáveis D2.4 (*TloCPS framework architecture and methodology specification*), D4.3

² <https://tiocps.pt/>

³ <https://www.gecad.isep.ipp.pt/RETINA/>

(Preliminary Specification of the trustworthy and secure communications for TloCPS communities, for 2nd demonstration(s)) e D5.3 (Specification of the key enablers for physical CPS resources).

No âmbito desta dissertação, para além das contribuições diretas para os dois projetos científicos acima apresentados, foram feitas algumas contribuições científicas, como publicações de revistas científicas, um capítulo de um livro e publicações de conferências científicas:

- [Capítulo de livro] **Nuno Teixeira**, Luis Gomes, and Zita Vale, "Knowledge Retrieval Mechanism for Smart Buildings Based On IoT Devices Data," aceite e apresentado em "The 9th International Conference on Energy and Environment Research" (ICEER 2022) e indicado para publicação em livro na Springer.
- [Capítulo de livro] Tiago Pinto, Luis Gomes, Pedro Faria, Zita Vale, **Nuno Teixeira**, and Daniel Ramos, "Intelligent Simulation and Emulation Platform for Energy Management in Buildings and Microgrids," Machine Learning for Smart Environments/Cities, Springer, 2022, doi: 10.1007/978-3-030-97516-6_9.
- [Revista, Fator de impacto: 2,690] **Nuno Teixeira**, Ruben Barreto, Luis Gomes, Pedro Faria, and Zita Vale, "A Trustworthy Building Energy Management System to Enable Direct IoT Devices' Participation in Demand Response Programs," Electronics, 2022, doi: 10.3390/electronics11060897.
- [Conferência] **Nuno Teixeira**, Luis Gomes, and Zita Vale, "Data Access Mechanism to Allow Multiple Level Permissions in Energy Management Solutions Supported by IoT devices," 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 2021, doi: 10.1109/EEEIC/ICPSEurope51590.2021.9584750.

Para além de tudo o que foi feito em termos científicos, o autor desta dissertação também participou em duas avaliações internacionais anuais do projeto TloCPS, participando na apresentação das soluções propostas pelo grupo de investigação Research Group on Intelligent Engineering and Computing for Advanced Innovation and Development (GECAD).

1.5 Estrutura da Dissertação

Esta dissertação é composta por seis capítulos organizados em secções e subsecções. Após o capítulo de introdução que é o capítulo 1, o capítulo 2 apresenta o levantamento do estado de arte onde são abordados diversos temas relacionados com a internet das coisas, aprendizagem automática, edifícios inteligentes e ambientes inteligentes.

O capítulo 3 contém todas as ferramentas, métodos e os desafios técnicos e sociais. Dentro das ferramentas é apresentada a parte tecnológica das ferramentas, como o conjunto de dados e a

construção do histórico, a ferramenta de acesso e partilha dos dados, as bibliotecas utilizadas para a interface computacional, a *framework* da interface gráfica do utilizador, as bibliotecas utilizadas para a identificação de correlações entre os dados, as bibliotecas para a previsão de consumos energéticos, as bibliotecas para o *clustering* e os protocolos de interligação de dispositivos IoT heterogéneos. Os métodos contêm o processamento paralelo e a aprendizagem automática uma explicação mais teórica dos modelos utilizados. Por fim neste capítulo será discutido os desafios técnicos e sociais, como a proteção dos dados, análise de segurança e os aspetos éticos.

O capítulo 4 incorpora a metodologia e implementação, que contém a arquitetura de software, como foi feita a integração dos dispositivos IoT heterogéneos, o mecanismo de partilha e acesso aos dados, a extração de conhecimento, a aprendizagem e identificação dos contextos, o perfil energético do utilizador, os algoritmos de previsão e a interface gráfica do BAIS.

O capítulo 5 contém diferentes casos de estudo para descrever e analisar o conjunto de resultados obtidos nos diferentes cenários criados para validar os diferentes mecanismos pertencentes ao BAIS.

Por fim, o capítulo 6 apresenta as conclusões principais da dissertação enquadradas em função dos objetivos propostos. No sentido da prossecução do trabalho realizado, será sugerido o trabalho futuro.

2 Estado de Arte

Este capítulo aborda o estado de arte dos tópicos mais relevantes utilizados no projeto, tais como internet das coisas, aprendizagem automática, subdividido em aprendizagem supervisionada e aprendizagem não supervisionada, e edifícios inteligentes e ambientes inteligentes. Para além de explorar alguns trabalhos propostos nestes domínios, também foram tidas em conta aplicações de aprendizagem automática, de IoT, de edifícios inteligentes e de ambientes inteligentes na gestão energética.

2.1 Internet das Coisas

O primeiro dispositivo IoT conhecido foi desenvolvido em 1982 para monitorizar uma máquina de coca cola na Universidade Carnegie Mellon em Pittsburgh (*The Little-Known Story of the First IoT Device - Industrious*, n.d.). A partir deste momento o conceito de IoT começou a crescer exponencialmente e começaram a surgir imensas soluções que utilizavam dispositivos IoT. Os dispositivos IoT estão a revolucionar os tempos atuais e estão a ser cada vez mais usados. O IoT pode ser visto como um ecossistema onde todos os dispositivos, como máquinas inteligentes ou qualquer tipo de objeto estão todos conectados (Lee, 2019).

A IoT surgiu como uma tecnologia disruptiva que está a transformar várias indústrias e setores. IoT refere-se à rede de dispositivos físicos, veículos e outros itens que estão incorporados com sensores, software e conectividade à Internet, permitindo-lhes recolher e transmitir dados para outros dispositivos ou sistemas centralizados. A IoT tem sido aplicada em vários domínios, tais como cuidados de saúde, transportes, agricultura e fabrico, entre outros, para melhorar a eficiência, reduzir custos e melhorar a qualidade dos serviços (Atzori et al., 2010).

Contudo, o IoT também apresenta desafios significativos, tais como segurança, privacidade e gestão de dados. Investigadores e profissionais estão a enfrentar estes desafios através do

desenvolvimento de novas tecnologias e protocolos que garantem a segurança e privacidade dos dados e dispositivos da internet das coisas (Al-Fuqaha et al., 2015).

A utilização de dispositivos IoT em edifícios inteligentes pode beneficiar da monitorização remota e do controlo do edifício e do seu equipamento (Casado-Vara et al., 2018). A maioria dos dispositivos IoT não requer trabalho de instalação invasivo, nem são dispositivos de difícil instalação, o que torna mais fácil o reequipamento dos edifícios.

Um dos dispositivos IoT mais utilizado é a *smart plug*. Uma *smart plug* é um dispositivo que se pode ligar a uma tomada elétrica e que é capaz de controlar qualquer outro dispositivo a ela conectado, tal como uma lâmpada, um ventilador ou uma cafeteira. As *smart plugs* costumam possuir uma ligação direta ou indireta (i.e., usando uma *gateway*) à rede Wi-Fi doméstica e pode ser controlada remotamente. A solução proposta por Heo et al., (Heo et al., 2017) utiliza as *smart plugs* num sistema de gestão de energia centralizado. Todavia, os dispositivos IoT disponíveis no mercado apresentam um grande problema relacionado com a integração de *software* de terceiros: alguns são sistemas fechados e outros fornecem pouca informação no que concerne à sua utilização por terceiros. No sentido de resolver este problema, algumas *frameworks* para integração de dispositivos IoT foram propostas. A *framework* proposta por Barbierato et al. (Barbierato et al., 2019) permite a simulação em tempo real de *software-in-the-loop* (SIL) com controladores de sistemas embutidos ou controladores inteligentes. Já a *framework* proposta por Terroso-Saenz et al. (Terroso-Saenz et al., 2019) é um sistema capaz de enfrentar a heterogeneidade dos dispositivos IoT, sendo capaz de analisar os dados de energia provenientes destes dispositivos.

A integração dos dispositivos IoT em edifícios inteligentes permitirá o desenvolvimento de várias aplicações, tais como a gestão de energia, gestão de instalações e melhoria do conforto interior (Daissaoui et al., 2020). A incorporação destes dispositivos em edifícios inteligentes tem vindo a crescer, principalmente com a integração de sistemas de gestão de energia. Apesar da utilização destes sistemas ser consideravelmente benéfica, estes apresentam algumas limitações quanto à interoperabilidade (Bashir & Gill, 2018). No entanto, estas limitações são ultrapassadas pelo sistema de gestão de energia proposto por Gomes et al. (L. Gomes et al., 2020b). Este sistema é suportado por dispositivos IoT que podem ser implantados num *single-board computer*. Esta solução permite a gestão das instalações dos utilizadores finais, bem como a sua representação em micro redes e redes inteligentes. Em suma, os dispositivos IoT permitem a gestão da energia (L. Gomes, Spínola, et al., 2019) e a possibilidade de transação de energia entre os utilizadores finais (L. Gomes et al., 2020a).

Sistemas IoT e CPS bem desenvolvidos podem reduzir o consumo energético, aumentar a segurança edifícios e cidades, ou poderá aumentar o conforto no edifício. Nos últimos anos, as comunidades de investigação começaram a estudar e a investigar estes dois cenários de uso, IoT e sistemas ciber-físicos para desenvolver protótipos ou serviços comerciais (Shih et al., 2016).

Participação ativa, gestão do lado da procura e edifícios inteligentes podem ser extremamente benéficos para os utilizadores finais e para a rede inteligente (Alquthami & Meliopoulos, 2018). Este benefício pode ser alcançado com o uso de dispositivos IoT. (Mashima & Chen, 2016) propôs o uso de dispositivos IoT para ativar a participação do utilizador final em programas de *demand response* utilizando uma aplicação de telemóvel inovadora que centraliza os dispositivos IoT. (Correa-Florez et al., 2018) mostra como é que os utilizadores podem participar no mercado de energia do dia seguinte com casas inteligentes. (Erdinc et al., 2015) propõe um sistema de gestão de energia capaz de participar num programa de *demand response* baseado em preços dinâmicos.

Os sistemas mencionados anteriormente podem ser ainda mais aperfeiçoados com a utilização da plataforma *IoT Energy* (IoTEP) que é uma plataforma que ajuda a monitorizar e a controlar cargas de energia de um edifício, no qual permite utilizando funcionalidades para lidar com a qualidade de energia e para suportar análises de dados (Terroso-Saenz et al., 2019). Esta plataforma tem em atenção a falta de suporte para o domínio da energia doméstica e fornece suporte para a análise de dados. (Gochhayat et al., 2019) propôs uma arquitetura sensível ao contexto para dar serviços aos utilizadores. (Mocnej et al., 2018) propõe uma abordagem descentralizada para otimização de recursos.

Os dispositivos IoT tem muitas vantagens, mas também tem problemas. O principal problema dos dispositivos IoT é relacionado com a segurança e a privacidade dos dados devido às comunicações web (Mohamad Noor & Hassan, 2019). Nos estados unidos muitos contadores inteligentes foram instalados no qual colocavam a privacidade dos dados em questão e levantavam problemas, foi levado a tribunal, e foi decidido que dados energéticos se devem manter privados (*Naperville Smart Meter Awareness v. City of Naperville, No. 16-3766 (7th Cir. 2018) :: Justia, n.d.*). Outros problemas que sistemas de energia incluem são a tolerância a falhas e descoberta, a interoperabilidade e a complexidade do software, o fornecimento de energia e estabilidade e o volume de dados e a interpretação (Ahmad & Zhang, 2021).

A tolerância a falhas aplica-se a operações de rede em condições sensíveis, tais como falha de nós ou esgotamento de recursos da rede (V. Sharma et al., 2017). A tolerância a falhas é utilizada para operações de rede em condições sensíveis, tais como a falha de nó ou esgotamento de recursos de rede. Existem três aspetos chave que são desafiantes, tais como as propriedades operacionais de tolerância a falhas, incluindo a fiabilidade da energia, a fiabilidade do nó e a fiabilidade da rota. Se todas estas propriedades forem abordadas em conjunto, as redes de IoT podem tornar-se cada vez mais eficazes. Os desafios da descoberta de dispositivos baseados em IoT incluem a automatização de marcação de rotas e gestão de identificação de centros de operações, integração/descoberta e serviços *on-demand* (K. K. Patel & Patel, 2016).

Estudos recentes sobre a interoperabilidade de dispositivos IoT centraram-se na seleção de *gateways* de protocolo. Contudo, o protocolo parece estar a prejudicar a questão da interoperabilidade invés de a resolver, pelo que existem problemas de otimização com um número crescente de servidores, reconfigurando o esforço, exigindo sobrecarga de

processamento e largura de banda (Noura et al., 2019). A escalabilidade para um ecossistema igual a este é um grande desafio, mas é crucial para um IoT útil. A indústria exige que a ponte protocolar e a sua interoperabilidade sejam escaláveis, transparentes, verificáveis e seguras. Deve também permitir o fornecimento de cobertura verbosa e promover a qualidade de serviço (Niu et al., 2020). A Tabela 1 mostra os principais softwares, hardwares e empresas de informática centradas na IoT. É apenas uma lista parcial, mais centrada na lista de atividades económicas centradas na IoT (*Internet of Things : The New Government to Business Platform - a Review of Opportunities, Practices, and Challenges*, n.d.).

Os sistemas de segurança empresarial, tanto *software* como *hardware*, não partilham nem processam grandes quantidades de informação detalhada de dispositivos e sensores ligados (Ande et al., 2020). É um desafio enriquecer dados gerados por máquinas e integrar rapidamente dados de aplicações empresariais. Além disso, as empresas precisam de procurar soluções que permitam efetivamente que os dados comuniquem uns com os outros para aproveitar a informação completa da empresa.

Tabela 1 - Aplicações e plataformas IoT existentes

Características	Módulos	Empresa
Recolha de tecnologias e produtos para aplicações IoT <i>cloud-to-fog</i>	Cibersegurança e aplicação, análise de dados, conectividade de rede	Computer Information System Company
Serviço de alojamento em nuvem	Plataforma Watson IoT, Node-RED	International Business Machines
Integração de serviços de nuvem e módulos de <i>hardware</i>	Módulo ARTIK IoT	Samsung
Zigbee, wi-fi, <i>thread</i> , Bluetooth, plataforma de processamento, interoperabilidade de segurança	Cidades Inteligentes, Sensores	Qualcomm
Rede de nuvem que permite milhares de milhões de conexões de computadores	Plataforma AWS IoT	Amazon
Serviço de alojamento em nuvem	Nectar Cloud	Nectar
Ethernet, Wi-Fi, System-on-module	Premier wave	Lantronix
Cidades Inteligentes, sensores, dispositivos IoT	Padrões de redes móveis, telemática, contagem inteligente, segurança	Huawei
Foco na Indústria	Visualização inteligente	Tecnologia HIRUN
Soluções em nuvem, sensores	Gateways	SensorUp
Dispositivos IoT para o setor agrícola	Plataforma de IoT	Trimble
Camadas de aplicação, segurança na rede	Thread Network	Thread

Controlo de luzes, sensores, plataforma centrada na energia	Plataformas IoT para o planeamento energético e para a gestão da energia	Autani
Sensores na nuvem, Sigfox, LoRa, Zigbee, Wi-Fi	Meshlium extreme, <i>hardware</i> WSN	Libelium
<i>Fog to cloud</i> , combinar dados	Intel IoT Gateway	Intel

Melhorar as redes de energia através da utilização de dispositivos IoT também se torna um desafio (Radhakrishnan & Gopalakrishnan, 2020). Assegurar a proteção, fiabilidade, durabilidade e estabilidade das aplicações e serviços da internet para sistemas energéticos é essencial para manter o apoio e utilização da internet. O problema é como manter todos os dispositivos estáveis. Muitos dispositivos IoT, tais como bens de consumo e sensores são desenvolvidos globalmente, incluindo dispositivos convencionais ligados à rede. O número possível de ligações interligadas entre estas aplicações é inigualável. Além disso, muitas destas aplicações podem interagir e criar ligações dinâmicas e imprevisíveis com outros sistemas por si só. Os atuais recursos, técnicas e abordagens relacionados com a IoT exigem atenções novas para enfrentar estes desafios (Bedi et al., 2018).

O volume de dados também é um dos grandes desafios para os dispositivos IoT uma vez que estes dispositivos estão sobrecarregados com grandes volumes de dados. Existe uma vasta gama de dispositivos ligados e nenhuma destas soluções se adapta a todos. O fluxo de fluxos de dados é um desafio tanto no interior como no exterior do dispositivo. Isto é particularmente desafiante no setor energético e na organização industrial, onde os grandes consumidores e fabricantes industriais normalmente recolhem milhares de milhões de conjuntos de dados de vários dispositivos, aplicações comerciais internas e sensores (Abdul Rahman et al., 2016).

O grande volume de dados inclui uma variedade de outros desafios, incluindo o próprio volume, a velocidade, a variedade, como por exemplo, formatos de dados não estruturados, estruturados e semiestruturados, a veracidade, a variabilidade e os valores, por exemplo, a informação de dados. Além disso, o desenvolvimento de dispositivos IoT capaz de gerir a precisão, os padrões complexos de aprendizagem, a complexidade de formação e a transferência de aprendizagem é também um grande desafio (Amanullah et al., 2020). Qualquer interação entre o utilizador e o ambiente envolverá software de visualização, que também ilustrará a interpretação e o mecanismo de deteção de cenários de dados através da segurança, privacidade e gestão de dados (Singh et al., 2014).

Os dispositivos IoT são muito utilizados para planeamento e gestão de energia. O desafio da gestão da energia do lado da procura e do lado da oferta concentra-se na utilização de fontes renováveis (Pawar et al., 2020). A monitorização do funcionamento de um sistema de energia seguro e fiável depende geralmente do planeamento diário com o consumo da procura e informação sobre a produção de energia renovável (Ciabattini et al., 2013). Informação crítica precisa de ser detetada através da utilização de ferramentas IoT que são escassamente instaladas em diferentes sistemas energéticos e cidades inteligentes para apoiar esta infraestrutura (Khan, 2018). A IoT pode ser utilizada para aumentar a eficiência energética,

maximizar a entrada de fontes de energia renováveis e reduzir o impacto ambiental da utilização de energia (Motlagh et al., 2020).

Os dispositivos IoT já foram implementados num grande número de aplicações de planeamento e gestão de energia, incluindo planeamento de energia de casas (Orsi & Nesmachnow, 2017), gestão de energia de cidades inteligentes e poupança de energia (Shrouf & Miragliotta, 2015), monitorização de energia (X. Liu et al., 2014), controlo de energia em diferentes nós (Gordić et al., 2010), poupança de energia em edifícios inteligentes, gestão de energia na indústria (Wei et al., 2016), redes inteligentes e resposta à procura (Neves et al., 2015) entre muitas outras aplicações. Para além destes exemplos de algumas aplicações, a IoT ajudou na implementação de estratégias inteligentes de gestão de energia que ajudam os fornecedores a reduzir os seus custos operacionais e a planear a procura de picos de carga. Estas redes habilitadas para a IoT são importantes para empresas com contratos especiais que coordenam e controlam o fornecimento de energia. Os sistemas inteligentes de controlo do consumo de energia dos edifícios operados por tecnologias IoT vão muito além da maioria dos sistemas convencionais de gestão de edifícios que controlam e regulam os sistemas de energia dos edifícios, tais como ventilação, iluminação, aquecimento, ar condicionado, elevadores e muito mais. Os dispositivos IoT podem ajudar a reduzir as faturas de energia e apoiar ainda mais as iniciativas empresariais em desenvolver sistemas ecológicos no domínio da energia (Saini et al., 2021).

A maioria das aplicações de casas inteligentes, tais como iluminação inteligente, aparelhos inteligentes e automação da casa, têm poucos requisitos de canais de comunicação para os quatro parâmetros, sendo eles, frequência, alcance, latência e a taxa de dados. Este requisito torna-se desafiante em casos que envolvam um sistema de vigilância para casa, devido ao envolvimento de dados em grande escala. Outra dimensão importante, como é mostrado na Tabela 2, é a indústria, as casas e as cidades inteligentes que utilizam dispositivos IoT para gerir o controlo de informação de ativos que contribuem para a transformação organizacional.

Tabela 2 - Uso de IoT em aplicações industriais, residenciais e de cidades inteligentes

Área de Uso	Aplicações
Rede Elétrica	Comutação, proteção, energias renováveis conectadas à rede, medidores de qualidade de energia, compensadores, retransmissores de proteção, indicadores de falha de linhas, microrredes, infraestruturas de medição avançadas
Setor Industrial	Sensores de ocupação, submedição, sistemas de controlo de edifícios, medição da qualidade da energia, controlo de microrrede, controlo da alimentação do edifício, sistemas de armazenamento de energia, controlo do fator de potência e compensadores, automatização de processos
Setor Doméstico	Armazenamento solar térmico, painéis solares no telhado, aplicações inteligentes, sistema de segurança, carregamento de veículos elétricos, geradores de reserva, vedações geo, estações meteorológicas

Uma das principais motivações para desenvolver sistemas de energia é gerir a energia de uma maneira ótima. Para tornar esta declaração clara, assumindo um sistema baseado em IoT incluindo veículos elétricos (Yoon et al., 2016). Neste estudo, cada veículo tenta maximizar o objetivo comum, pagar menos dinheiro, enquanto um retalhista de energia tenta maximizar o seu próprio objetivo, ganhar mais dinheiro. Ambos os lados atuam de forma inteligente e tentam maximizar o seu próprio lucro, que neste caso os objetivos entram em conflito. Uma solução para encontrar o ponto ótimo, em que ambos podem sair satisfeitos com o seu lucro, é contratar uma infraestrutura IoT, por exemplo, usar wi-fi, sensores para recolher informação dos veículos.

Alguns esforços foram feitos para melhorar os sistemas de gestão de energia considerando diferentes objetivos como reduzir as perdas de energia, minimizar os custos ou até mesmo alguns objetivos técnicos como minimizar o desvio da voltagem (Luna et al., 2016). No estudo de (Falahi et al., 2013), é introduzida uma estratégia de controlo dinâmico, algumas limitações do sistema de comunicação são consideradas desvantagens que tornam os desafios numa resposta rápida do sistema de controlo que foi concebido. Por outro lado, com a tendência do crescimento do uso da internet em edifícios e cidades inteligentes, é imprescindível desenvolver uma plataforma baseada em IoT que tenha em conta a eficiência energética, a rentabilidade, a segurança e que seja fiável para propósitos de gestão de energia (Ejaz et al., 2017). As soluções IoT para gestão de energia são desenvolvidas para reduzir ou fazer o *shift* dos consumos energéticos, aplicando ofertas de incentivos ou através da otimização da utilização das fontes de energia.

2.1.1 Protocolos de comunicação

Os diferentes dispositivos IoT podem ter diferentes plataformas de comunicação, ligação em rede, processamento dos dados, capacidade de armazenamento de dados e potência de transmissão. Todos os dispositivos IoT presentes num sistema têm de estar ligados em rede e por protocolos de comunicação que lhes permitam comunicar e cooperar entre si para partilhar os seus dados (Xu et al., 2014).

Os protocolos de comunicação desempenham um papel vital nos sistemas IoT. Representam a estrutura do sistema IoT ao permitir que os dispositivos IoT troquem os seus dados através da rede. Estes protocolos especificam o formato de troca de dados, codificação de dados, esquemas de endereçamento para os dispositivos e o encaminhamento de pacotes desde a origem até ao destino. Além disso, fornecem outras funções tais como o controlo de sequência, controlo de fluxo e a retransmissão de pacotes perdidos (FathyAtlam et al., 2013).

O protocolo ZigBee foi inventado pela ZigBee Alliance que se baseia na norma de redes sem fios de baixa potência IEEE802.15.4 (Samie et al., 2016). O objetivo deste protocolo é estabelecer uma norma que forneça um protocolo de comunicação de baixo custo para criar redes de área pessoal. ZigBee é o protocolo de comunicação adequado para aplicações que necessitam de uma baixa taxa de dados, maior duração de bateria e dispositivos de rede seguros. Além disso, o ZigBee pode trabalhar com diferentes tipologias de rede, tais como, em malha, estrela ou árvore.

Bluetooth é um protocolo de comunicação de curto alcance que é considerado como o elemento-chave para produtos usáveis. A nova versão do Bluetooth, o Bluetooth Smart ou Bluetooth LowEnergy (BLE) é um protocolo significativo para diferentes aplicações IoT uma vez que suporta consumo de potência reduzida e pode ser integrado com telemóveis e outros dispositivos móveis (Kuzlu et al., 2016).

Z-Wave é um protocolo de comunicação de radiofrequência de baixa potência, construído principalmente para automação da casa. Proporciona fiabilidade e comunicação de baixa latência de pequenos pacotes de dados com taxas de dados até 100 kbit/s. Além disso, é um protocolo escalável e suporta a topologia de rede em malha completa. O Z-Wave é um protocolo mais simples que permite uma maior rapidez e simplicidade no desenvolvimento (Al-Sarawi et al., 2017).

Near Field Communication (NFC) é um protocolo de comunicação sem fios de muito curto alcance que proporciona um protocolo de comunicação bidirecional simples e seguro entre dispositivos eletrónicos especialmente para telemóveis. Também permite aos utilizadores realizar transações de pagamento sem contacto, aceder a conteúdos digitais e conectar dispositivos eletrónicos. Basicamente, o NFC facilita a ligação e o controlo de dispositivos IoT para partilhar informação a uma distância inferior a 4cm (Cerruela García et al., 2016).

IPv6 sobre *Low Power Wireless Personal Area Network* (6LoWPAN) é o primeiro protocolo de comunicação para a IoT. Encapsula eficientemente cabeçalhos longos IPv6 em pequenos pacotes IEEE802.15.4, que não podem exceder 128 bytes. Também suporta diferentes comprimentos de endereços, baixa largura de banda, diferentes tipologias de rede incluindo estrela ou em malha, consumo de energia, baixo custo, redes escaláveis, mobilidade, falta de fiabilidade e longo tempo de repouso. Uma vez que é uma norma baseada em IP, pode ser ligada diretamente a outra rede IP sem entidades intermediárias, tais como *gateways* ou *proxies* (Al-Sarawi et al., 2017).

A Tabela 3 fornece uma comparação entre protocolos de comunicação comuns da IoT em termos de protocolo padrão, tipo de rede, banda de frequência, alcance suportado, taxa de dados, potência, topologia suportada para cada protocolo, norma de segurança e aplicações comuns que usam o protocolo. Os dispositivos IoT têm a capacidade de conectar os objetos do dia a dia. Introduziram muitas aplicações e serviços inteligentes que afetaram as vidas diárias dos seus utilizadores.

Tabela 3 - Comparação entre protocolos de comunicação de IoT

Características	ZigBee	Bluetooth	Z-Wave	NFC	6LoWPAN
Padrão	IEEE 802.15.4	IEEE 802.15.4	Z-Wave	ISO/IEC 18000-3	IEEE 802.15.4
Tipo de Rede	WPAN	WPAN	WPAN	Rede P2P	WPAN
Banda de Frequência	2.4 GHz	2.4 GHz	900 MHz	13.56MHz	2.4 GHz
Alcance	Curto alcance 10-100m	Curto alcance 15-30m	Curto alcance 30-100m	Curto alcance – Até 200m	Curto alcance 10-100m
Taxa de dados	250 kbps	1 Mbps	100 kbps	100 - 420 kbps	250 kbps
Potência	30 mA baixa potência	30 mA baixa potência	2.5 mA baixa potência	50 mA baixa potência	Muito pouco consumo energético
Topologia Suportada	Rede em estrela e em malha	Rede em estrela e de barramento	Rede em malha	Rede P2P	Rede em estrela e em malha
Segurança	AES	AES	AES	RSA e AES	AES
Aplicações Comuns	Controlo e monitorização de casas	Auriculares sem fios e aplicações de áudio	Controlo e monitorização de casas	Acesso e pagamento	Monitorização e controlo via internet

2.1.2 Aplicações de IoT

A IoT trouxe muitos benefícios e oportunidades para o ramo dos cuidados de saúde. Ajuda a desenvolver e melhorar os serviços de cuidados de saúde e a manter o campo inovador. Por exemplo, o controlo inteligente de medicamentos e a gestão hospitalar, acrescenta ainda mais benefícios ao monitorizar a saúde individual em tempo real. As ambulâncias podem também ser imediatamente enviadas para locais de acidentes e os pacientes podem ser monitorizados nas suas casas eficazmente, tal como são nos hospitais. Por exemplo, um médico pode ser imediatamente informado se o paciente sofrer de um ataque cardíaco (M. Chen et al., 2012). O conceito de cidade inteligente é utilizado para descrever a melhor utilização dos recursos públicos, através do aumento da qualidade do serviço apresentado aos cidadãos e ao mesmo tempo conseguindo reduzir os custos operacionais de administrações públicas (M. Chen et al., 2012).

A IoT fornece vários benefícios na gestão e optimização de serviços públicos, tais como transportes e estacionamento, iluminação, vigilância e manutenção de áreas públicas, preservação do património cultural e recolha do lixo. A disponibilidade de diferentes tipos de dados recolhidos por dispositivos IoT podem ser utilizados para aumentar a consciência das

pessoas sobre o estado da sua cidade e estimular a participação ativa dos cidadãos na gestão da administração pública (Zanella et al., 2014).

As pessoas procuram sempre novas abordagens para aumentar o seu luxo e conforto. Atualmente, as pessoas podem instalar aparelhos inteligentes dentro das suas casas para controlar muitas das tarefas da casa. Estes dispositivos inteligentes têm a opção de controlo remoto, o que elimina a necessidade de estar perto do dispositivo (Pătru et al., 2016). Por conseguinte, estes dispositivos permitiram a automatização das atividades domésticas através da utilização de vários dispositivos incorporados (Risteska Stojkoska & Trivodaliev, 2017).

Para os retalhistas, a IoT oferece oportunidades ilimitadas para aumentar a eficiência da cadeia de fornecimento, desenvolver novos serviços e reformular as experiências dos clientes. Por exemplo, aplicações para seguir as mercadorias, inventário em tempo real, troca de informação entre fornecedores e retalhistas e capacidade de entrega automatizada irão melhorar o setor de retalho (Guo et al., 2012)(*SMART RETAIL SOLUTION: CONVERT CUSTOMER INSIGHTS INTO DOLLARS*, 2017).

Os carros interligados estão equipados com acesso à internet e podem partilhar o seu acesso com os outros, tal como a ligação a uma rede sem fios em casa. Mais veículos estão a começar a vir equipados com esta funcionalidade, por isso mais aplicações irão estar incluídas em futuros veículos (Kalmeshwar & K S, 2017). O carro interligado é considerado como a melhor forma de minimizar acidentes, de modo que um condutor possa operar o carro à distância para minimizar acidentes de automóvel e reduzir os erros humanos. Estes carros sem condutor podem fornecer funções mais do que apenas segurança, tais como poupar tempo valioso, reduzir o stress da condução (Xu et al., 2014).

O elemento-chave de um sistema IoT são os sensores que recolhem informações sobre o ambiente que os rodeia. Portanto, com a IoT, pode ser fornecido um sistema de informação de alta velocidade. Isto permite a entidade que monitoriza ambientes de área ampla e sensores instalados na área transmitir uma enorme quantidade de dados facilmente, tais como a monitorização de fontes de poluição, monitorização da qualidade da água, monitorização da qualidade do ar (Ibrahim et al., 2015). Na Figura 1, estão representadas algumas das aplicações da IoT.

Com a presença de sensores, os agricultores podem utilizar a grande quantidade de informação recolhida para obter um melhor retorno do investimento. A deteção da humidade do solo e nutrientes, o controlo da utilização da água para o crescimento das plantas e a determinação de fertilizantes personalizados são algumas utilizações simples da IoT na agricultura. Muitas tecnologias sem fios foram utilizadas na agricultura, tais como a deteção remota, o sistema de posicionamento global e o sistema de informação geográfico. Isto substituirá o trabalho humano por trabalho automático de máquinas que irá aumentar por consequência a produtividade (*Wearable Technology Market Size, Share & Trends Analysis Report By Product (Head & Eyewear, Wristwear), By Application (Consumer Electronics, Healthcare), By Region (Asia Pacific, Europe), And Segment Forecasts, 2023 - 2030*, n.d.)



Figura 1 - Algumas das Aplicações da IoT

2.2 Aprendizagem automática

A aprendizagem automática é um campo de inteligência artificial em rápido crescimento que permite às máquinas aprender com os dados e melhorar o seu desempenho ao longo do tempo. Os algoritmos de aprendizagem automática podem analisar grandes volumes de dados e identificar padrões, permitindo-lhes fazer previsões e tomar decisões com um elevado grau de precisão (Jordan & Mitchell, 2015).

Os recentes avanços na aprendizagem automática têm sido impulsionados pela disponibilidade de grandes conjuntos de dados e poderosos recursos informáticos, bem como pelo desenvolvimento de novos algoritmos e técnicas, tais como aprendizagem profunda e aprendizagem por reforço. Estas técnicas levaram a avanços em áreas como o reconhecimento da imagem e da fala, processamento da linguagem natural e veículos autónomos. Apesar do rápido progresso na aprendizagem automática, há ainda muitos desafios a enfrentar, tais como a difícil interpretação, equidade e preocupações éticas relacionadas com preconceitos e privacidade (Lecun et al., 2015).

Atualmente, os edifícios podem ter a capacidade de aprender graças ao rápido avanço da inteligência artificial (IA) e da aprendizagem automática. Aplicações específicas de aprendizagem automática para períodos específicos do ciclo de vida de um edifício têm merecido crescente atenção.

A aplicação da aprendizagem automática no contexto dos edifícios inteligentes e da energia tem ganho uma atenção significativa nos últimos anos. As técnicas de aprendizagem automática podem ser utilizadas para analisar dados de várias fontes em edifícios, tais como ocupação,

temperatura e utilização de energia, para fazer previsões, otimizar o desempenho e reduzir o consumo de energia. Desta forma, pode contribuir para a criação de edifícios mais sustentáveis e energeticamente eficientes (H. Zhang et al., 2022). Por exemplo, os modelos de aprendizagem automática podem analisar dados históricos de utilização de energia e identificar padrões e tendências no consumo de energia. Esta informação pode ser utilizada para prever a utilização futura de energia e otimizar as operações dos edifícios, resultando na redução dos custos energéticos e no aumento da eficiência energética (Rajagukguk et al., 2020).

A capacidade dos sistemas energéticos para lidar com a crescente implementação de recursos energéticos renováveis intermitentes em condições de exigência de eficiência energética, flexibilidade e resiliência é assumida no desenvolvimento de edifícios, cidades e sociedades sustentáveis (Aduda et al., 2017). Os edifícios, por outro lado, requerem a flexibilidade para reagir à alteração das condições limite, tais como as necessidades dos utilizadores, as alterações climáticas e a alteração dos preços da rede (Al Dakheel et al., 2020). As variáveis associadas ao ambiente operacional, tais como padrões de ocupação, são suscetíveis a condições em mudança imprevisíveis. Desta forma, o sistema necessita de aprender rápida e autonomamente a partir de conjuntos de dados históricos externos recolhidos durante um longo período de tempo (Xiang Xie et al., 2021). Neste contexto, os algoritmos de aprendizagem automática podem desempenhar um papel crítico no desenvolvimento de sistemas inteligentes de gestão de energia que possam otimizar o consumo de energia, reduzir o desperdício e aumentar a eficiência energética.

No contexto dos edifícios inteligentes, uma das principais tendências de desenvolvimento é automática utilização crescente de algoritmos de aprendizagem automática (Alanne & Sierla, 2022). Dadas as complexidades do ambiente operacional, abordagens de aprendizagem automática como a *reinforcement learning* (RL) e a sua derivada *deep reinforcement learning* (DRL) foram consideradas benéficas para redes de controlo autónomo de edifícios (M. Han et al., 2019).

Para desenvolver algoritmos de aprendizagem automática é necessária uma base de dados histórica e, de preferência, o acesso a outras bases de dados externas, por exemplo, bases de dados meteorológicos, energéticos e de custos, são as principais fontes de dados de treino (Mehmood et al., 2019). Uma ligação ao IoT permite a transferência de dados entre qualquer componente, desde lâmpadas elétricas a sensores de presença, através da Internet. Também fornece acesso a *big data* (BD), que inclui elementos tais como dados hiperlocais e específicos do local, fotografias de vistas de rua, e códigos de construção, além de dados meteorológicos e de sensores (Daissaoui et al., 2020). O crescimento constante de dados em massa é típico da BD, permitindo aprender com a experiência. Já o treino em IA pode basear-se no reconhecimento de correlações e padrões usando uma técnica de análise de dados denominada *data mining* (Y. Zhao et al., 2020) ou então a aprendizagem automática.

A combinação de IoT e da inteligência artificial pode levar a muitas outras aplicações, como a agricultura. O sistema de monitorização proposto em (Patil & Thorat, 2016) permite a identificação de oportunidades nas uvas para detetar doenças nas suas fases iniciais, utilizando

o modelo *hidden markov* e um sistema de alarme para o agricultor ou para um perito. Ainda com o uso do sistema, os agricultores têm a informação sobre o tempo ideal para por fertilizantes, para a aplicação de pesticidas e para a irrigação. O sistema é útil para aumentar os lucros dos agricultores e para prevenir que as vinhas sejam afetadas por doenças. Há muitas soluções já desenvolvidas para a agricultura tal como a que foi proposta em (Ding et al., 2013), uma framework de aviso prévio, que junta informação da humidade do solo, concentração de nitrogénio, estimativa do pH, viscosidade do ar e a fixação do CO₂, toda esta informação é usada para enviar mensagens de aviso para os agricultores, utilizando o servidor central para analisar os dados.

A agricultura pode ser melhorada através de métodos de aprendizagem automática pela recolha de informação de parâmetros do solo do campo, utilizando uma rede de sensores sem fios para recolher todos os dados para carregar os dados para a nuvem. Em (Aruul Mozhi Varman et al., 2018), estes dados alimentam uma rede neuronal *Long Short-Term Memory* (LSTM) para prever qual a colheita mais apropriada para a próxima rotação de colheitas e os resultados são enviados via SMS para o utilizador. Para aumentar a produção de comida em agricultura inteligente, um sistema IoT baseado em aprendizagem profunda por reforço pode ser utilizado, em (Bu & Wang, 2019), é proposto um modelo de aprendizagem profunda por reforço para fazer decisões inteligentes, como determinar a quantidade de água para a irrigação para aumentar o crescimento do ambiente das colheitas.

Outro domínio onde as aplicações IoT podem beneficiar de modelos de aprendizagem automática, são as cidades inteligentes onde o volume de dados é ideal para os modelos de aprendizagem automático. Sistemas de transporte inteligentes podem ser melhorados através do uso de IoT e de aprendizagem automática, focando-se nas seguintes categorias (Zantalis et al., 2019): otimização de rota, estacionamento, luzes, prevenção e deteção de acidentes, anomalias na estrada e infraestruturas. Dentro do domínio de cidades inteligentes, anomalias e ataques também estão a subir. Em (Alrashdi et al., 2019), é proposta uma abordagem baseada num sistema de deteção de intrusos de rede chamada AD-IoT para detetar ataques de IoT numa camada distribuída de nevoeiro. Esta solução é capaz de detetar comportamentos maliciosos pela avaliação de um conjunto de dados para detetar classificação binária categorizada antes de distribuir para os nós de nevoeiro.

A aprendizagem automática pode ser dividida em duas categorias aprendizagem supervisionada e não supervisionada. Na aprendizagem supervisionada, uma grande quantidade de dados históricos é utilizada para formar um mapeamento, desde fatores independentes até uma variável dependente prevista. As medições dos sensores são frequentemente utilizadas como variáveis independentes em contextos de edifícios e as previsões ou classificações de séries temporais são as previsões mais comuns. As previsões do consumo energético dos edifícios são um exemplo das primeiras. Já o diagnóstico do tipo de defeito que ocorreu no equipamento HVAC é um exemplo do segundo. Além disso, a aprendizagem supervisionada requer um grande conjunto de dados de treino para as variáveis independentes, bem como os valores exatos das variáveis dependentes. Os rótulos são os nomes dados a estes valores próprios. Após a fase de treino, o modelo desenvolve um

mapeamento entre as variáveis independentes para a variável dependente, permitindo-lhe receber uma combinação desconhecida de fatores independentes e prever o valor da variável dependente (Alawadi et al., 2020). Quando um conjunto de treino rotulado não está disponível, a aprendizagem não supervisionada pode ser utilizada. Este subtipo de aprendizagem é frequentemente utilizado para a deteção de anomalias. O modelo de aprendizagem automática é treinado utilizando dados em condições normais, e pode então determinar se o sistema é ou não normal. Não poderá, contudo, determinar o tipo de falha (Mirnaghi & Haghghat, 2020).

2.2.1 Aprendizagem supervisionada

A aprendizagem automática é adequada para a complexidade do manuseamento através de origens de dados diferentes e de uma vasta gama de variáveis, bem como da quantidade de dados em causa. A aprendizagem automática prospera em conjuntos de dados cada vez maiores. Quanto maior for o fornecimento de dados adicionais para uma estrutura de aprendizagem automática, melhor poderá ser o seu treino e preocupar-se com as consequências para o valor dos conhecimentos. À margem dos limites do pensamento e estudo a nível individual, a aprendizagem automática é inteligente para descobrir e mostrar os padrões escondidos nos dados (K R & N C, 2017).

Uma definição padrão de aprendizagem supervisionada é o problema de classificação. O exemplo de aprendizagem é obrigado a aprender, para aproximar o comportamento de uma função que mapeia um vetor numa de várias classes, tendo em conta vários exemplos de saída e de entrada da função. O processo de aprendizagem supervisionada aplicado a um problema do mundo real está descrito na Figura 2.

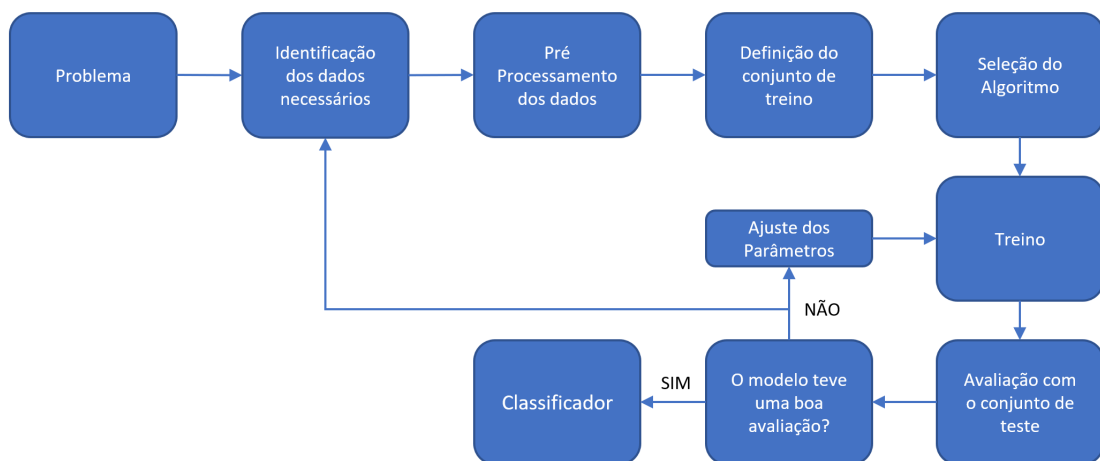


Figura 2 - Processos da Aprendizagem Supervisionada

Este estudo do atual estado de arte incide sobre a classificação de algoritmos de aprendizagem automática e na determinação dos algoritmos mais eficientes com a maior precisão e exatidão. Em (Ayodele & Ayodele, 2010), os algoritmos de aprendizagem supervisionada que lidam mais

com a classificação são os seguintes: classificadores lineares, regressão logística, classificador naive bayes, perceptron, *support vector machines*, classificadores quadráticos, *boosting*, árvores de decisão, floresta aleatória, redes neuronais e redes *bayesianas*.

Os modelos lineares para classificação separam vetores de entrada em classes através do uso de limites de decisão lineares, ou seja, hiperplanos (Aurélien Géron, 2019). O objetivo da classificação em classificadores lineares na aprendizagem automática é agrupar itens que tenham valores de características semelhantes em grupos. (Verlinde et al., 1998) declarou que um classificador linear atinge o seu objetivo ao tomar uma decisão de classificação com base no valor da combinação linear das características. Um classificador linear é frequentemente utilizado em situações em que a velocidade da classificação é um problema, uma vez que é classificado como o classificador mais rápido (Ayodele & Ayodele, 2010). Os classificadores lineares funcionam frequentemente muito bem quando o número de dimensões é grande, como na classificação de documentos, em que cada elemento é tipicamente o número de contagens de uma palavra num documento. A taxa de convergência entre as variáveis do conjunto de dados depende da margem. De grosso modo, a margem quantifica o quão linearmente divisível é um conjunto de dados e, por conseguinte, o quão fácil é resolver um determinado problema de classificação (Minaee et al., 2020).

A regressão logística é uma função de classificação que utiliza classes para construção e utiliza um único modelo de regressão logística multinomial com um único estimador. A regressão logística geralmente declara onde existe a fronteira entre as classes, também declara que as probabilidades da classe dependem da distância da fronteira, numa abordagem específica. Isto avança para os extremos, 0 e 1, mais rapidamente quando o conjunto de dados é maior. Estas afirmações sobre probabilidades é o que torna a regressão logística mais do que um simples classificador. Faz previsões mais fortes, mais detalhadas, e podem ser ajustadas de uma forma diferente, mas essas fortes previsões por vezes podem estar erradas. A regressão logística é uma abordagem à previsão, como a regressão dos mínimos quadrados. No entanto, com a regressão logística, a previsão resulta num resultado dicotómico (Menard, 2014). A regressão logística é uma das ferramentas mais comuns utilizadas para estatísticas aplicadas e análise discreta de dados.

Redes *bayesianas* são um modelo gráfico para representar relações probabilísticas entre conjuntos de variáveis. Inicialmente, a rede tem de ser representada e depois são determinados os parâmetros que dificultam a sua implementação sem a opinião de um perito. A informação prévia sobre o problema pode ser representada como relação estrutural entre as suas características (Pernkopf, 2005). Contudo, redes *bayesianas* não são muito boas com conjuntos de dados de alta dimensão porque redes grandes não são viáveis em termos de tempo e espaço.

Naive Bayes é uma rede *bayesiana* mas com apenas um pai e muitos filhos com um forte pressuposto de independência entre os seus nós filhos. Se esta suposição se mantiver, este tipo de classificador converge mais rápido que os modelos discriminativos, como por exemplo a regressão logística. Naive Bayes leva menos tempo computacional para o treino. Ao contrário das redes neuronais e das *support vector machines*, não há parâmetros livres a definir, o que

simplifica muito o Naive Bayes (Kuncheva, 2006). Naive Bayes retorna a probabilidade o que torna simples a sua aplicação a uma grande variedade de tarefas. Não é aplicável quando é necessário ter em consideração as interações entre características (Islam et al., 2008).

Árvores de decisão são fáceis de interpretar e de explicar, podem facilmente lidar com as interações entre as características. Uma vez que não é paramétrico, os *outliers* não afetam muito o modelo e pode lidar com dados linearmente inseparáveis. Alguns algoritmos famosos são: ID3, C4.5, C5.0 e CART de acordo com diferentes critérios de divisão, tais como coeficiente de gini, rácio de ganho e ganho de informação (H. Sharma & Kumar, 2016). As árvores de decisão têm a capacidade de manipular uma vasta variedade de dados, nominais, numéricos, textuais, valores em falta e atributos redundantes, têm boa capacidade de generalização, são robustas ao ruído, proporcionam alto desempenho para um esforço computacional relativamente pequeno. Na Figura 3, está representado um exemplo de como é uma árvore de decisão.

Contudo, é difícil lidar com dados de grande dimensão através do uso de árvores de decisão. Apesar do tempo computacional ser menor, o tempo necessário para construir a árvore é considerável. Estas utilizam uma abordagem de dividir e conquistar que funciona bem se existirem poucos atributos altamente relevantes, mas não funciona tão bem se estiverem presentes muitas interações complexas. Os erros propagam-se através das árvores, o que se torna um problema grave à medida que o número de classes aumenta (Xhemali et al., 2009). Além disso, à medida que a árvore cresce, o número de registos nos nós da folha pode ser demasiado pequeno para tomar decisões estatisticamente significativas sobre a representação da classe. A isto chama-se o problema da fragmentação de dados. Pode ser evitada através da proibição de mais divisões quando o número de registos cai abaixo de determinado limite. Sem um *pruning* adequado as árvores de decisão podem facilmente sobre ajustar-se, razão pela qual foi desenvolvido o modelo de florestas aleatórias.



Figura 3 - Uma árvore de decisão para determinar qual é o animal em questão

Uma floresta aleatória é um método de conjunto que funciona através da formação de várias árvores de decisão e do retorno da classe com a maioria sobre todas as árvores do conjunto (Lorena et al., 2011). As florestas aleatórias geralmente um pouco à frente das *support vector*

machines, são as vencedoras de muitos problemas de classificação. São rápidas, escaláveis, resistentes ao ruído, não fazem *overfit*, fáceis de interpretar e visualizar, sem parâmetros para gerir. No entanto, à medida que o número de árvores aumenta, o algoritmo torna-se lento para a previsão em tempo real. Foram feitas várias tentativas para melhorar as florestas aleatórias, tais como a diminuição da correlação entre as árvores, através do uso de várias medidas de avaliação de atributos na escolha das divisões. Outro mecanismo propõe primeiro estimar a margem média das árvores nas instâncias mais semelhantes à nova instância e de seguida, depois de descartar as árvores com margem negativa, ponderar os votos das árvores com a margem (Robnik-Šikonja, 2004).

A *support vector machine* (SVM) é um algoritmo complexo, mas pode fornecer alta precisão. Previne também garantias hipotéticas em relação ao *overfitting*. E com um núcleo adequado, podem funcionar bem mesmo que os seus dados não sejam linearmente separáveis no espaço de característica base. Baseiam-se no conceito de maximizar a distância mínima desde o hiperplano até ao ponto de amostra mais próximo (Mehra & Gupta, 2013). Ao contrário do *k-Nearest Neighbor*, a precisão e o desempenho são independentes do tamanho dos dados, mas dependem do número de ciclos de treino. Especialmente popular nos problemas de classificação de texto onde a norma são os espaços de dimensão muito elevada. A complexidade permanece inalterada pelo número de características. É robusta a dados de alta dimensão e tem uma boa capacidade de generalização. Mas, a velocidade de treino é menor e o seu desempenho depende da escolha dos parâmetros (Caruana & Niculescu-Mizil, 2006).

Uma vez que a seleção de parâmetros afeta o desempenho, é utilizada uma técnica conhecida como *Particle Swarm Optimizer* (PSO) para a seleção dos parâmetros ótimos. Este modelo híbrido é conhecido como PSO-SVM (Lin et al., 2008). As aplicações incluem a seleção de características e a classificação de imagens. Outro modelo deste tipo é o SVM evolutivo que é utilizado para resolver o problema da dupla otimização do SVM. Não só faz um classificador eficiente, como também um extrator de características adaptativo. Abaixo na Figura 4 pode ver-se uma representação da classificação através do uso de SVM com hiperplano.




Figura 4 - Uma representação da classificação através do uso de SVM com hiperplano

As redes neuronais são mecanismos computacionais baseados na estrutura neuronal, método de processamento e capacidade de aprendizagem do cérebro humano, mas em escalas muito menores. Esta técnica é aplicável a problemas onde as relações podem ser não lineares ou bastante dinâmicas. As redes neuronais constituem uma poderosa alternativa às técnicas convencionais que são frequentemente limitadas por fortes pressupostos de normalidade, linearidade e independência de variáveis (Neocleous & Schizas, 2002). Como uma rede neuronal pode captar muitos tipos de relações, permite ao utilizador modelar rápido e relativamente fácil fenómenos que de outra forma poderiam ter sido muito difíceis ou impossíveis de explicar de outra forma.

Um *perceptron* é a forma mais simples de uma rede neuronal, utilizado para a classificação de padrões ditos linearmente separáveis. Consiste num único neurónio com pesos ajustados. A presença de características irrelevantes torna o treino muito ineficiente e impraticável. Um *perceptron* de várias camadas é o classificador de redes neuronais mais utilizado, capaz de modelar funções complexas e é robusto a entradas e ruídos irrelevantes (Kotsiantis et al., 2006). É difícil de treinar, exceto se se optar por pesos mais próximos dos pesos ótimos inicialmente. Geralmente, determinar o tamanho da camada escondida é um problema. Uma avaliação insuficiente levará a uma má aproximação, enquanto uma avaliação excessiva levará a *overfitting* e a um erro de generalização. Da mesma forma, o desempenho também é sensível aos valores dos parâmetros escolhidos (Alzubaidi et al., 2021).

K-Nearest Neighbor é um algoritmo de classificação não paramétrico. Atribui a um ponto de amostra não identificado, a classe do mais próximo de um conjunto de pontos previamente identificados (Lorena et al., 2011). A regra é independente da distribuição conjunta dos pontos de amostra e das suas classificações. É bem adequado para classes multimodais, bem como para aplicações onde os elementos podem ter muitas classificações. É um método de aprendizagem simples e preguiçoso, tem menor eficiência. O desempenho do algoritmo depende da seleção de um bom valor do 'k'. Não há forma eficiente de escolher o 'k', exceto através de técnicas computacionalmente dispendiosas como a validação cruzada. É afetado negativamente pelo ruído e é também sensível a características irrelevantes. O desempenho também varia de acordo com o tamanho, uma vez que todos os dados devem ser revisitados (Islam et al., 2008). Está representado na Figura 5 um exemplo da abordagem do algoritmo *k-Nearest Neighbor*. Na Tabela 4 podem ser vistas as vantagens e desvantagens dos algoritmos de aprendizagem supervisionada mencionados anteriormente.

Os algoritmos de aprendizagem automática supervisionada demonstraram um grande potencial para melhorar a gestão e eficiência energética. Estes algoritmos podem ser utilizados para prever a procura de energia, otimizar a utilização de energia e detetar falhas nos sistemas energéticos (Forootan et al., 2022) (Ng & Lim, 2022). Por exemplo, as redes neuronais artificiais têm sido utilizadas em aplicações energéticas devido à sua capacidade de aprender complexas relações não lineares entre entradas e saídas. São maioritariamente utilizadas para previsão da procura de energia, reconhecimento de padrões de consumo de energia e diagnóstico de falhas do sistema energético, várias técnicas avançadas têm sido propostas para melhorar as

aplicações energéticas, tais como *convolutional neural networks* e redes neurais recorrentes (Runge & Zmeureanu, 2021).




Figura 5 - Um exemplo da abordagem do algoritmo *K-Nearest Neighbor*

As árvores de decisão têm sido utilizadas para a previsão do consumo de energia e identificação da poupança de energia (Musbah et al., 2021). As árvores de decisão também tem sido combinadas com outros algoritmos, tais como florestas aleatórias e *gradient boosting machines* (Qinghe et al., 2022). As florestas aleatórias têm sido utilizadas para previsão da procura de energia e previsão de energia renovável (H. ; Liu et al., 2023). As *support vector machines* têm sido utilizadas para a previsão de carga e do preço de energia e otimização da eficiência energética (Zendejboudi et al., 2018). Os métodos de *ensemble* são algoritmos que combinam múltiplos modelos para melhorar a precisão da previsão. Os métodos *ensemble* têm sido utilizados no setor da energia para melhorar o desempenho de tarefas de regressão e classificação. Várias técnicas avançadas tais como AdaBoost, XGBoost e LightGBM foram propostas para melhorar o desempenho dos métodos de *ensemble* (Sammelmann et al., 2022) (Ling Xiao et al., 2018) (Musbah et al., 2022).

Tabela 4 - Vantagens e Desvantagens de Algoritmos de Aprendizagem Supervisionada

Algoritmo	Vantagens	Desvantagens
Rede Bayesiana	Capacidade de interpretar problemas em termos de relação estrutural entre os previsores, leva menos tempo computacional para o treino, não há parâmetros livres a definir	O desempenho diminui à medida que os dados crescem, não conseguem lidar com dados de alta dimensão
Regressão Logística	A saída é interpretada como probabilidade, pode lidar com a não linearidade, efeito de interação e termos de potência	Tamanho do conjunto de dados grande para alcançar resultados estáveis, sofre de multilinearidade
Árvores de decisão	Não paramétrico, lida com interações de características, pode lidar com dados linearmente inseparáveis, lida com variedade de dados, valores em falta e atributos redundantes, tem boa capacidade de generalização, robusta ao ruído, fornece alto desempenho para um esforço computacional relativamente pequeno	Difícil de lidar com dados de alta dimensão, pode facilmente fazer <i>overfit</i> , tempo considerável necessário para construir a árvore, não consegue lidar com interações complexas, erros propagados através das árvores, problema de fragmentação de dados

Florestas Aleatórias	Rápido, escalável, robusto ao ruído, não faz <i>overfit</i> , oferece explicação e visualização da sua saída, sem quaisquer parâmetros com que se deva preocupar	O algoritmo fica mais lento à medida que o número de árvores aumenta
Support Vector Machines	Alta precisão, evita o <i>overfit</i> , seleção flexível de núcleos para não linearidade, precisão e desempenho são independentes do número de características, boa capacidade de generalização	Complexa, a velocidade de treino é menor e o seu desempenho depende da escolha dos parâmetros
K-Nearest Neighbor	Bem-adaptado às classes multimodais, independente da distribuição conjunta dos pontos de amostra e da sua classificação	Menor eficiência, dependente da seleção de um bom valor de 'k', afetado negativamente pelo ruído e características irrelevantes, o desempenho também varia de acordo com o tamanho do conjunto dos dados
Redes neuronais	Trata de relações que podem ser não lineares ou dinâmicas, não restringidas por fortes pressupostos de linearidade, normalidade, independência de variáveis, robusta a entradas irrelevantes e ao ruído	Geralmente mais lento a treinar, o desempenho é sensível ao tamanho das camadas escondidas e aos valores dos parâmetros escolhidos, difícil de interpretar

Equipas e proprietários de edifícios, bem como fornecedores de energia, engenheiros de investigação e utilizadores de estruturas modernas, são todos afetados pela nova tecnologia de edifícios inteligentes. A fim de reduzir os custos operacionais, há uma tendência para começar a empregar sensores para detetar a presença humana e ligá-los aos sistemas de informação locais e fazer a integração da aprendizagem automática (Forootan et al., 2022).

O Modelo de controlo preditivo (Neculoiu et al., 2016) é frequentemente utilizado para otimizar sistemas de edifícios utilizando a estimativa e previsão de ocupação (Sangogboye et al., 2017). Novas redes de sensores sem fios (Stamatescu et al., 2014), tais como sensores de CO₂ e infravermelhos, assim como infraestruturas existentes, tais como contadores inteligentes, sensores wi-fi e HVAC, fornecem dados para a deteção da presença humana.

Os autores Chitu et al., (Chitu et al., 2017), por exemplo, utilizaram uma rede de sensores infravermelhos para detetar a presença humana, que foi depois introduzida num método de *Markov model chain*. Alguns investigadores (Z. Chen et al., 2016) apresentaram uma *framework* de fusão utilizando um algoritmo de filtro de partículas com aumentos de 5-14% na estimativa da precisão entre muitas abordagens para mostrar as tendências da atividade humana dentro de escritórios de edifícios. Outro grupo de investigadores (Wang et al., 2018) propõe combinar tecnologias WiFi e Bluetooth de baixa energia para identificar níveis de ocupação de alta resolução utilizando uma mistura de *K-nearest neighbor* (K-NN) e *K-means clustering*. A ocupação real com 50% de humidade e 25°C de temperatura, relatam uma poupança de carga térmica de até 14,16%. Modelos de florestas aleatórias, que estão relacionados com modelos K-NN, foram utilizados e produziram resultados encorajadores para tarefas de ocupação (Candanedo et al., 2016).

Devido à sua capacidade de lidar com as propriedades não lineares dos edifícios inteligentes, os algoritmos genéticos (AG) são uma abordagem de busca heurística amplamente utilizada em modelos baseados em IA. Os AG podem resolver de forma competente tanto problemas de otimização sem constrangimentos como com restrições. Esta técnica é amplamente utilizada na programação de cargas residenciais num esquema de preços dinâmicos, com o objetivo de minimizar os custos totais de energia (Oladeji & Olakanmi, 2015). É também utilizada na determinação do consumo ótimo de energia para proporcionar condições térmicas confortáveis, selecionando a gama ótima de pontos de referência de temperatura interior (Reynolds et al., 2018). Com base na junção dos AG e do algoritmo de otimização baseado no ensino-aprendizagem, criaram uma estratégia de gestão inteligente de energia aplicando um programa *demand response* para programar a carga domiciliária com o objetivo de reduzir o custo da energia (Manzoor et al., 2017).

2.2.2 Aprendizagem não supervisionada

No paradigma da aprendizagem não supervisionada é fornecido também um conjunto de dados, apesar de estes serem meros exemplos e não propriamente os resultados. O número de classes em que os casos devem ser classificados é também desconhecido no pior dos cenários e a única informação fornecida é a proximidade dos exemplos. Estes algoritmos de aprendizagem não supervisionada são utilizados para identificar padrões e relações nos dados introduzidos sem a necessidade de supervisão explícita ou de dados identificados. Estes algoritmos têm numerosas aplicações em vários setores, incluindo reconhecimento de imagem e fala, processamento de linguagem natural e deteção de anomalias (A. Xiao et al., 2022).

Os algoritmos de aprendizagem não supervisionada foram impulsionados pelo desenvolvimento de métodos de aprendizagem profunda, que levaram a avanços em áreas como a modelação generativa, o *clustering* e redução de dimensionalidade (Y. Liu et al., 2023). Ao longo do tempo foram feitos muitos avanços nos algoritmos de aprendizagem não supervisionada.

Um dos algoritmos de aprendizagem não supervisionada são os *autoencoders* que são redes neuronais que são treinadas para reconstruir os dados de entrada, comprimindo-os numa representação de baixa dimensão. Têm sido utilizados para a redução da dimensionalidade, extração de características e modelação gerativa. As variações dos autoencoders incluem *denoising autoencoders*, *variational autoencoders* e *adversarial autoencoders* (Kingma & Welling, 2013).

As *generative adversarial networks* (GANs) são modelos de aprendizagem profunda que consistem em duas redes neuronais: um gerador e um discriminador. O gerador gera novas amostras que se assemelham aos dados de entrada, enquanto o discriminador tenta distinguir entre as amostras geradas e as amostras reais. As GANs têm sido utilizadas para geração de imagem e vídeo, aumento de dados e adaptação de domínios (Goodfellow et al., 2014).

Os mapas de auto-organização são um tipo de rede neuronal que utiliza a aprendizagem não supervisionada para criar uma representação de dados de baixa dimensão a partir de dados de alta dimensão. Têm sido utilizados para extração de características, detecção de anomalias e visualização (Hinton & Salakhutdinov, 2006).

Os algoritmos de *clustering* agrupam pontos de dados semelhantes com base nas suas características. Alguns algoritmos de *clustering* populares incluem k-means, *clustering* hierárquico e *clustering* espacial baseado em densidade de aplicações com ruído. Os algoritmos de *clustering* têm sido utilizados para segmentação de clientes, detecção de anomalias e segmentação de imagens (Alqahtani et al., 2021).

Nos últimos anos, a análise de *clusters* tem sofrido um desenvolvimento vigoroso. K-Means *clustering* é uma das técnicas de agrupamento mais populares e amplamente utilizadas. Esta técnica foi proposta pela primeira vez pelo MacQueen (MacQueen, 1967). Embora o k-means tenha sido proposto há mais de meio século e muitos métodos de agregação tenham sido propostos desde então, o k-means foi otimizado várias vezes e ainda é amplamente utilizado pelos cientistas de dados.

O algoritmo k-means visa n objetos de um conjunto de dados em grupos k (*clusters*) de uma forma que os objetos de cada grupo têm mais semelhanças do que os objetos dos outros grupos. Pondo por outras palavras, cada objeto é colocado no aglomerado com a média mais próxima. Na etapa inicial do processo de agrupamento, o k-means escolhe aleatoriamente k objetos do conjunto de dados e em seguida, realiza duas etapas repetitivas, atribui cada objeto do conjunto de dados ao conjunto mais próximo e após atribuir todos os objetos, revê o centro para os conjuntos com a média dos objetos (Shirkhorshidi et al., 2014). Esta técnica gera k *clusters* distintos com a maior distinção possível. O k ótimo leva à maior separação.

O processo do algoritmo k-means pode ser formulado nos seguintes passos:

1. Agrupar o conjunto de dados em subconjuntos k, enquanto o valor de k é pré-definido.
2. Escolhe aleatoriamente os pontos k como centros de *clusters*.
3. Atribuir o objeto do conjunto de dados ao *cluster* com o centro mais próximo de acordo com a função de distância euclidiana.
4. Determinar o centroide ou a média de todos os objetos em cada *cluster*.
5. Replicar o terceiro e quarto passo até que sejam atribuídos exatamente os mesmos objetos de cada *cluster* em rondas consecutivas

É necessário definir o número de *clusters*, ou seja, o valor de k, antes da execução do algoritmo K-means como um input fixo. Definir antecipadamente o número de *clusters* é um dos principais inconvenientes do K-means. Por exemplo, (El-Mandouh et al., 2019) afirmaram que estimar o número de *clusters* é um desafio crítico no processo de análise de *clusters*. Do mesmo modo,

(Laccetti et al., 2020) descreveu no que diz respeito aos atributos matemáticos de k-means, o resultado final do *cluster* depende fortemente de alguns parâmetros, tais como o centro inicial dos *clusters* e o número de *clusters*. Além disso, determinar antecipadamente o número adequado de *clusters* também não é viável para todos os tipos de aplicações, por exemplo, não é possível pré-definir o valor de k em ambientes dinâmicos onde os conjuntos de dados são alterados ao longo do tempo (Debelee et al., 2019). No total, sem uma estimativa ótima do valor de k, o k-means torna-se bastante restritivo na prática (Oliveira et al., 2017).

O k-means permitiu avanços consideráveis e aplicações na gestão energética. O *load profiling* é o processo de identificar padrões de uso de energia durante um período. O k-means pode ser usado para segmentar os clientes em diferentes perfis de carga com base nos seus padrões de utilização de energia. Isto ajuda os utilitários a conceber e implementar programas de conservação de energia específicos (Jeong et al., 2021). O k-means também pode ser utilizado para deteção de anomalias através da identificação de padrões anómalos de consumo de energia, o que pode ser indicativo de mau funcionamento de equipamentos ou outras questões. Isto ajuda os gestores das instalações a identificar e resolver problemas rapidamente, reduzindo o desperdício de energia e melhorando a fiabilidade do sistema (Budiarto et al., 2019). Este algoritmo também pode ser utilizado para a gestão de energia de edifícios, pode ser utilizado para identificar padrões de consumo de energia em edifícios, tais como ocupação, temperatura e níveis de iluminação. Isto ajuda os gestores de edifícios a otimizar o desempenho dos edifícios e a reduzir os custos de energia (Malatesta & Breadsell, 2022). A integração de energias renováveis também pode beneficiar do uso de k-means, podendo ajudar na identificação de locais ótimos para as fontes de energia renováveis, tais como a energia eólica e solar. Isto ajuda a melhorar a eficiência da geração da energia renovável e a reduzir a dependência dos combustíveis fósseis (Wu et al., 2022).

A identificação e reconhecimento de padrões no contexto de edifícios é um *feedback* necessário para criar edifícios inteligentes. Neste contexto, o objetivo é capacitar os sistemas com elementos de aprendizagem para tomar decisões. O desafio é o elemento detetado para prever o comportamento humano no edifício. A temperatura média diária no exterior é uma das variáveis com incidência no conforto humano devido à adaptação meteorológica dos utilizadores. Em (Pablo et al., 2017), foi analisado o consumo num escritório em relação à temperatura interna e à temperatura média diária externa através de técnicas de *clustering*. O *cluster* pode ser utilizado como uma previsão do consumo.

Os métodos de aprendizagem não supervisionada para extrair informação útil sobre tendências num edifício possuem muita documentação. D. Chen et al. (D. Chen et al., 2013) utilizam uma abordagem de *clustering* seguida por um limiar ao longo de três métricas: potência média, desvio padrão e intervalo de potência adquirido a partir de dados de contadores de eletricidade para investigar monitorização não intrusiva da ocupação. Já D'Oca & Hong (D'Oca & Hong, 2015) oferecem um paradigma de mineração que se baseia principalmente na indução de regras. Zhao et al. empregam a mineração de dados para aprender sobre o comportamento dos ocupantes dos edifícios (J. Zhao et al., 2014). Para extrair locais de alta utilização, Nguyen et al. (Nguyen et

al., 2013) empregam uma abordagem de *clustering* não paramétrico categórico para aprendizagem não supervisionada.

2.3 Edifícios Inteligentes e Ambientes Inteligentes

Este capítulo fornece uma visão geral do atual estado da arte em edifícios inteligentes e ambientes inteligentes. O capítulo abrange os últimos desenvolvimentos no campo dos edifícios inteligentes, incluindo a utilização de sensores, algoritmos de automação e a internet das coisas (IoT) para melhorar o desempenho dos edifícios e a eficiência energética. Além disso, o capítulo discute os potenciais benefícios e desafios associados à implementação dos ambientes inteligentes em edifícios inteligentes.

2.3.1 Edifícios Inteligentes

Os edifícios inteligentes são estruturas que utilizam várias tecnologias para melhorar a eficiência e sustentabilidade do seu funcionamento, manutenção e consumo de energia. Estes edifícios empregam uma gama de sistemas, incluindo sistemas de automação e controlo de edifícios, dispositivos IoT, inteligência artificial e algoritmos de aprendizagem automática para otimizar o consumo de energia, melhorar o conforto dos ocupantes e melhorar a qualidade do ar interior (Bashir & Gill, 2018). Diversos artigos de revisão sobre edifícios inteligentes já foram publicados a partir de várias perspetivas. Os artigos de revisão mais relevantes no terreno focam questões tais como tecnologias de *hardware*, monitorização, previsão, modelização, gestão de energia de edifícios, e aplicações de aprendizagem automática (Alawadi et al., 2020; Djenouri et al., 2019).

De forma a criar inovação e a impulsionar a tecnologia IoT, modelos de aprendizagem automática podem ser integrados em sistemas de IoT, permitindo o surgimento de soluções mais inteligentes. Aprendizagem automática pode ser integrada em sistemas de IoT para resolver muitos problemas ou até para fazer aparecer novas possibilidades. A IoT e os sistemas de automação e controlo de edifícios surgiram como componentes críticos dos edifícios inteligentes (Bashir & Gill, 2018). Os sistemas de automação e controlo de edifícios podem fornecer o controlo centralizado de vários sistemas de edifícios, tais como iluminação, aquecimento, ventilação e ar condicionado e segurança, enquanto os dispositivos IoT permitem a recolha de dados em tempo real que podem ser utilizados para vários fins, incluindo a otimização energética e a manutenção preditiva.

A inteligência artificial e a aprendizagem automática estão a tornar-se cada vez mais predominantes na tecnologia de edifícios inteligentes, permitindo aos edifícios aprenderem com o comportamento passado e ajustarem as suas operações em conformidade (Luo, 2022). Estas tecnologias são utilizadas para várias aplicações, incluindo manutenção preditiva, otimização energética e conforto dos ocupantes.

Há uma ênfase crescente na criação de edifícios que promovam a saúde e o bem-estar dos ocupantes, particularmente na sequência da pandemia do COVID-19 (Xiaoxiong Xie et al., 2022). Os projetistas e operadores de edifícios estão a incorporar características como a melhoria da qualidade do ar interior, controlos sem contacto e ventilação melhorada para mitigar a propagação de doenças infecciosas.

A utilização de fontes de energia renováveis, tais como energia solar e eólica, está a aumentar em edifícios inteligentes (Shakeri et al., 2020). Muitos edifícios estão a integrar fontes de energia renováveis nas suas operações, reduzindo a sua dependência de fontes de energia tradicionais e melhorando a sua sustentabilidade.

Os edifícios inteligentes são uma componente essencial do conceito mais amplo de cidade inteligente, que aproveita várias tecnologias para melhorar a qualidade de vida dos cidadãos (González-Lezcano et al., 2021). As cidades inteligentes utilizam uma gama de dispositivos e sistemas interligados para melhorar os transportes, a eficiência energética e a sustentabilidade global.

Ameaças e ataques feitos a infraestruturas de IoT estão a crescer. Sistemas de IoT podem sofrer de ataques e anomalias que podem causar falhas graves. O uso de modelos de aprendizagem automática pode ajudar a prever e a mitigar ataques e anomalias em sistemas de IoT. Com o uso de regressão logística, *support vector machine* (SVM), árvores de decisão, florestas aleatórias e redes neuronais artificiais (RNA) é possível detetar estas anomalias. (Hasan et al., 2019). Ainda no assunto de assegurar a segurança de sistemas de IoT, a aprendizagem automática pode ser usada num *gateway* de IoT para ajudar a assegurar o sistema inteiro. Em (Canedo & Skjellum, 2016) é proposta uma RNA em *gateways* para permitir a deteção de anomalias em dados enviados de dispositivos de ponta. IoT combinado com aprendizagem automática pode ser usado para autenticação, controlo de acesso, descarga segura e deteção de *malware* para proteger a privacidade dos dados, mas é preciso ter em conta alguns obstáculos quando se tenta implementar certas técnicas de segurança baseadas em aprendizagem automática, como por exemplo a comunicação e os custos gerais de computação, soluções de segurança de reserva e observação parcial do estado (Liang Xiao et al., 2018).

Outras das grandes preocupações relacionado com a segurança dos sistemas de IoT, é a existência de dispositivos não autorizados. Com o uso de modelos de aprendizagem automática supervisionados, é possível detetar dispositivos não autorizados, com a análise de dados de tráfego de rede, para detetar de forma exata estes dispositivos não autorizados. A utilização de classificadores multiclasse pode ser uma boa abordagem para a precisão da classificação, velocidade da deteção, capacidade de transporte dos classificadores e resiliência aos ciberataques (Meidan et al., 2017). A aprendizagem automática pode ser também usada para detetar ataques, prevenindo que o desempenho geral do sistema baixe. Para identificar dados envenenados, uma metodologia que usa informação contextual relacionado com a origem e a transformação de pontos de dados pode ser usado, permitindo a deteção efetiva e a mitigação do ataque (Baracaldo et al., 2018).

Modelos de deteção de intrusos para redes IoT para classificar o fluxo do tráfego usando aprendizagem profunda, nomeadamente redes neuronais *feed-forward* e classificação multiclasse podem ser utilizadas para detetar precocemente intrusos em sistemas IoT (Ge et al., 2019). Os algoritmos de aprendizagem também podem detetar dados de correio eletrónico não solicitado permitindo a categorização dos dados com o uso de pontuação de correio eletrónico não solicitado (Makkar et al., 2021).

A segurança é crítica em ambientes que usem dispositivos IoT, por isso com o uso do sistema de deteção de intrusos baseado em aprendizagem automática torna-se mais simples para detetar ameaças à segurança nestes ambientes. Estes sistemas detetam ataques de recusa de serviço, ataques *user-to-root* (U2R), ataques de sonda e ataques *remote-to-local* (R2L) (Otoum et al., 2022). De modo que seja possível classificar ataques de intrusos em sistemas de IoT, uma solução proposta em (Ibitoye et al., 2019) considerando uma rede neuronal *feed-forward* (RNF) conhecida como rede neuronal auto-normalizante foi considerada para resolver este problema.

O uso de dispositivos IoT juntos com inteligência artificial também podem trazer benefícios no domínio da medicina. A condição dos pacientes pode ser prevista com o uso de aprendizagem automática e os IoT podem ser utilizados para monitorizar o paciente e comunicar com o paciente sobre o seu estado de estresse (Pandey, 2017). Para tratar o cancro da pele que é uma das doenças mais comuns no mundo, (Rodrigues et al., 2020) propôs um modelo de doze *convolutional neural networks* com sete configurações diferentes de classificadores para detetar nevos comuns, nevos atípicos e melanomas, permitindo serem assistentes para os médicos em encontrar lesões na pele. Para tratar doenças de coração, (Devi & Kalaivani, 2019) um sistema de monitorização por eletrocardiograma ativado por IoT capaz de encontrar o intervalo frequência respiratória de um sinal de eletrocardiograma para capturar a variância do ritmo cardíaco, a solução proposta usa um processo de classificação para classificar a doença, permitindo a deteção de arritmias cardíacas recorrendo ao uso de diagnósticos atempados. A monitorização em tempo real de pacientes que recorrem ao uso de dispositivos IoT podem ter atrasos causados pela comunicação dos dados com a nuvem. Para ultrapassar estes atrasos, (Kavitha & Ravikumar, 2021) propôs uma solução com quatro módulos: IoT, pré-processamento dos dados, sensível ao contexto e tomada de decisão. Esta solução usa sensores IoT que foram desenvolvidos para monitorizar, seguir e sentir as atividades de pessoas mais velhas enquanto fornecem alarmes e notificações enviadas para os médicos com a condição inteira do paciente com pouco tempo de resposta.

Com o aumento da popularidade dos dispositivos IoT, implementar controlos inteligentes em edifícios para reduzir os consumos energéticos está a subir (L. Gomes, Sousa, et al., 2019). Em (X. Zhang et al., 2020), uma *framework* de aprendizagem *plug-and-play* é proposta onde o modelo térmico de cada zona térmica num edifício é automaticamente identificada sem uma configuração manual e o modelo térmico é capaz de aprender com as leituras de temperatura medidas pelos termostatos inteligentes baseados em IoT. Esta solução promissora é capaz de fornecer modelos térmicos de confiança para futuros controlos de clima de edifícios inteligentes. Também, para edifícios inteligentes, em (Alhajri et al., 2018), é proposto um sistema em tempo real capaz de detetar a localização dentro do edifício do utilizador e de

detetar o contexto do ambiente. O sistema usa dados sensoriais e posicionais para classificar, recorrendo ao uso de um modelo ponderado *k-nearest neighbor*, o tipo de ambiente interior que rodeia os utilizadores. Em (Mohammadi et al., 2018), é proposto um modelo de aprendizagem profunda por reforço semi-supervisionado para resolver o problema de localização interior através do uso da intensidade dos sinais de baixa energia Bluetooth. O uso de aprendizagem por reforço é uma boa abordagem para aplicações IoT visto que requer pouca supervisão por dar reações através de recompensas ao longo do tempo que vai aprendendo para escolher a melhor política dentro de muitas ações alternativas.

IoT e aprendizagem automática, permitem a previsão do tempo de vida útil restante para ajudar a manutenção das máquinas industriais. Em (Kanawaday & Sane, 2018) é proposto um modelo autoregressivo de previsão da média móvel integrada que recebe dados de vários sensores para prever as falhas e os defeitos de qualidade. O uso de aprendizagem automática prova ser um componente vital nos IoT, assim diminui o custo de manutenção e aumenta a eficiência geral do processo de manufatura.

2.3.2 Ambientes Inteligentes

Ambiente Inteligente (Aml) é um conceito que se refere a um ambiente que se adapta às necessidades e preferências dos seus utilizadores (Cook et al., 2009). Visa a criar um ambiente onde os utilizadores possam interagir sem problemas com a tecnologia, sem qualquer esforço consciente. O Aml utiliza várias tecnologias, tais como, sensores, inteligência artificial e aprendizagem automática para criar um ambiente que seja sensível ao contexto, antecipatório e responsivo (Al-Fuqaha et al., 2015).

Um dos aspetos chave da Aml é a sua capacidade de compreender e adaptar-se ao contexto do utilizador. Os investigadores estão a explorar novas formas de incorporar vários sensores em edifícios inteligentes, tais como câmaras, microfones e acelerómetros, para permitir ao sistema sentir o contexto do utilizador e adaptar-se às suas necessidades e preferências (J. Augusto & Mccullagh, 2007). O Aml poderia ter uma interação sem falhas entre o ser humano e a tecnologia. Estão a ser exploradas novas formas de criar uma interface mais natural e intuitiva, como o reconhecimento de voz e de gestos, para permitir aos utilizadores interagir com o sistema sem esforço (J. C. Augusto et al., 2010).

A inteligência artificial e a aprendizagem automática são componentes essenciais da Aml. Estas tecnologias permitem que o sistema aprenda com o comportamento do utilizador e se adapte às suas preferências ao longo do tempo. Estas tecnologias auxiliam na melhoria da capacidade do sistema antecipar e responder às necessidades do utilizador (Acampora et al., 2013).

Uma vez que a Aml depende fortemente da recolha de dados de vários sensores, a privacidade e a segurança são aspetos cruciais. Existem muitos esforços na descoberta de novas formas de assegurar que a privacidade do utilizador seja protegida, e que o sistema seja seguro (Dunne et al., 2021).

O conceito de edifícios inteligentes pode mudar a forma como interagimos com os edifícios e até com a nossa casa. Os edifícios deixarão de ser uma agregação de recursos estática e passarão a ser um recurso ativo que pode auxiliar os utilizadores. Tal, irá tornar possível a aplicação de várias soluções baseadas em ambientes inteligentes e dispositivos IoT, como por exemplo fazer plataformas com base no contexto para tornar o conforto interior cada vez melhor (Ghayvat et al., 2015). O sucesso de algumas destas plataformas, como por exemplo, a DoMAIns (*Domain-based modeling for Ambient Intelligence*) (Bonino & Corno, 2012), ou então a plataforma proposta por (Ramos et al., 2010) mostram que é possível utilizar e combinar múltiplos dispositivos de terceiros para chegar a uma solução orientada para poder utilizar modelos de ambientes inteligentes, considerando várias fases de comportamento inteligente (L. Gomes, Ramos, et al., 2019).

Através de dados ambientais recolhidos de sensores é possível definir contextos e preferências do utilizador, com recurso a um motor de decisão consciente (Meurer et al., 2019). Este motor é capaz de identificar relações importantes nos dados, permitindo que sejam tomadas decisões de controlo inteligentes, que sejam ajustadas as definições do ambiente de acordo com as preferências do utilizador e que sejam reduzidos os consumos energéticos no geral, aumentando a interação humano-tecnologia.

Contudo, podem advir algumas complicações quando os dados são insuficientes. Por exemplo, a deteção de intrusões, com base no contexto, pode ser realizada utilizando Aml e dispositivos IoT em ambientes industriais. No entanto, os resultados obtidos nestes ambientes não são os mais apropriados, uma vez que são utilizados números inadequados de dados nos estudos realizados, sendo este o maior problema encontrado em sistemas que utilizam Aml (Park et al., 2020).

Modelos de Aml também podem ser usados para a mobilidade inteligente no interior de edifícios, com recurso a IoTs numa *framework* de mapeamento de contexto escalável multicamadas, que permite a utilização de robots de assistência pessoal (De Silva et al., 2018).

Para ser possível alcançar a eficiência energética em edifícios inteligentes, pode ser usado um sistema híbrido inteligente que utiliza uma arquitetura *fog-based*. Este paradigma permite alocar as tarefas de computação entre vários dispositivos heterogéneos logicamente distribuídos por 3 camadas: a infraestrutura de deteção de limite (*edge*), a computação intermediária de recolha de dispositivos (*fog*) e o armazenamento remoto e a unidade de processamento (nuvem), combinando inteligência reativa e deliberativa, para fazer aprendizagem complexa e otimização (De Paola et al., 2020). Este sistema demonstra que é possível obter poupanças de energia e manter o utilizador satisfeito. Apesar disso, possui algumas limitações, nomeadamente o facto de ser inadequado para gerir cenários multiutilizadores, em que as necessidades e preferências individuais podem entrar em conflito e ainda de necessitar de recolher dados iniciais de treino.

Tendo em conta o elevado consumo energético por parte dos edifícios, a utilização de dispositivos IoT é bastante vantajosa, uma vez que permite implementar ações sustentáveis

nestes edifícios, para que haja um aumento da poupança energética. Isto é conseguido através da identificação de padrões de consumo e da correlação feita entre o consumo e o espaço que está a ser usado (Santos et al., 2018). O recurso a informação externa também é essencial, como, por exemplo, mapas locais e condições atmosféricas exteriores que permitem aumentar a poupança e a eficiência da energia.

Existem algumas *frameworks* que têm como objetivo melhorar a poupança energética dentro de edifícios ou casas inteligentes, tal como a ComfOnt. Esta tem como objetivo fornecer aos habitantes a possibilidade de terem conforto interior personalizado e de os ajudar nas suas atividades diárias que requerem aparelhos tecnológicos. Esta *framework* permite a representação do consumo energético dos aparelhos e o perfil energético de uma casa inteligente, ajudando assim a fomentar a poupança de energia (Spoladore et al., 2019). O uso de ontologias permite ainda a adição de novas métricas de conforto para a descrição de ambientes específicos. Contudo, uma das principais limitações é a modulação de diferentes recursos, nomeadamente dos dispositivos domésticos e das suas funcionalidades.

É possível que os *Heating, Ventilation, and Air Conditioning* (HVAC) possam aprender com os utilizadores, através de um sistema de aprendizagem baseado no *feedback* adquirido pelos dispositivos móveis dos utilizadores. Deste modo, torna-se possível a redução do consumo de energia, bem como o aumento do conforto do utilizador (Carreira et al., 2018). Isto demonstra que sistemas de Aml podem ser usados para controlar sistemas de gestão de energia, reduzindo o consumo energético e mantendo os níveis de conforto. Uma das grandes vantagens deste sistema é permitir que os ocupantes votem para influenciar o sistema a aumentar ou diminuir a temperatura, funcionando também apenas com dados históricos.

Existem várias soluções centradas no humano baseadas em contexto, sendo que uma das soluções segue *edge computing*, com o objetivo de promover a eficiência energética em edifícios de uso público. No entanto, esta solução necessita de uma arquitetura mais descentralizada para ir de encontro à incorporação de redes neuronais e modelos simples probabilísticos, sendo esta uma das suas principais limitações (Casado-Mansilla et al., 2018).

Diversas técnicas podem ser utilizadas para garantir a segurança dos dados nestes sistemas. Num sistema de monitorização que utiliza IoT pode ser usada uma sequência *keccak-chaotic*, sendo que esta apresenta três fases: recolher os dados em *real time*, encriptação do vídeo e assegurar o armazenamento em nuvem. Para recolher os dados são necessárias duas câmaras ESP32 e estes dados, por sua vez, são enviados para um *fog node* que grava os nós na nuvem (Ravikumar & Kavitha, 2021).

Com o intuito de melhorar as reuniões, o IoT pode ser utilizado juntamente com técnicas de Aml, através do uso de dispositivos que tenham acesso à internet. Estes permitem ao utilizador poupar tempo e dinheiro, podendo esta solução ser usada, por exemplo, em escolas e faculdades (J. Patel & Panchal, 2018). Com a adição de capacidades IoT nas salas de reuniões estas podem tornar-se em salas de reunião inteligentes e mais eficientes, diminuindo quer o

gasto energético, quer a ocupação de espaço. Porém, uma das limitações deste sistema é não possuir sensores que detetam presença na sala, apesar deste aspeto estar a ser trabalhado.

Para ajudar os utilizadores a poupar energia em casa de uma forma simples, o sistema IntelliHome, através do uso de técnicas de *big data* e de aprendizagem automática, faculta uma perspetiva dos hábitos de consumo de eletricidade de cada utilizador. Desta forma, os utilizadores envolvem-se num processo de poupança de energia através de informação em tempo real e de recomendações de poupança de energia (Paredes-Valverde et al., 2020). Porém, uma das limitações deste sistema é que o método de previsão, que está por detrás das recomendações, não foi concebido para lidar com séries cronológicas múltiplas, o que significa que apenas é feito a previsão global do edifício. Além disso, a aplicação móvel para auxílio deste sistema apenas está disponível para android.

Outra proposta dada por diferentes autores é a de desenhar uma estratégia de *feedback* para sistemas de monitorização de consumos energéticos baseados em IoT. Esta estratégia permite aumentar a atenção do utilizador e diminuir o consumo energético, dando sugestões personalizadas para participantes específicos poderem perceber qual o consumo de cada recurso e para estarem alertados da possível existência de consumos consideravelmente mais baixos que o esperado. Além disso, permite alertar para práticas erradas de poupança de energia, nomeadamente a prática de desligar os radiadores, que pode penalizar a temperatura do ar dentro de casa, diminuindo o conforto do utilizador. Um vez mais, a principal limitação deste sistema é a modelação dos dispositivos IoT (Dell'Isola et al., 2019).

A junção de dispositivos IoT com Aml é cada vez mais utilizada e contribui para soluções promissoras. O uso de microcontroladores para aplicações IoT baseadas em ambientes inteligentes é muito comum, visto que qualquer aparelho eletrónico é incompleto sem eles. Um estudo recente demonstrou que o Arduino e AVR consomem menos energia. Estes microcontroladores permitem, por exemplo, monitorizar a temperatura remotamente de forma mais simples, eficaz e sem grande consumo energético (Raj et al., 2019). A monitorização da temperatura remotamente torna possível o controlo da temperatura de áreas como Antártida e o triângulo das bermudas.

2.4 Conclusões do Capítulo

Este capítulo começou por descrever na secção 2.1, o conceito de internet das coisas. A IoT é um campo em rápido crescimento com numerosas aplicações potenciais, incluindo casas inteligentes, transportes, cuidados de saúde e automação industrial. Embora a IoT ofereça muitos benefícios, tais como maior eficiência e conveniência, também coloca desafios relacionados com a segurança, privacidade e gestão de dados. A abordagem destes desafios será crucial para o sucesso da IoT.

Na secção 2.2, o conceito de aprendizagem automática é descrito e toda a literatura atual é estudada. A integração da aprendizagem automática com a IoT em sistemas de energia tem

mostrado resultados promissores no aumento da eficiência energética, na redução de custos e na melhoria da fiabilidade do sistema. No entanto, desafios como a segurança dos dados, a interoperabilidade e a escalabilidade ainda precisam de ser enfrentados para se aproveitar totalmente o potencial desta tecnologia. Os modelos de aprendizagem automática permitem transformar os edifícios regulares em edifícios inteligentes, aplicando modelos de aprendizagem automática é possível fazer previsões, como por exemplo previsões de consumos energéticos e permite encontrar padrões através da análise dos dados.

Os edifícios inteligentes têm-se tornado cada vez mais populares devido ao seu potencial para melhorar a eficiência energética, o conforto dos ocupantes e o desempenho geral dos edifícios. A integração de várias tecnologias como a IoT, a aprendizagem automática e os sistemas de automação de edifícios tem permitido aos edifícios inteligentes alcançar estes objetivos. Contudo, ainda existem desafios relacionados com a interoperabilidade, privacidade de dados, e elevados custos de implementação, que requerem mais investigação e desenvolvimento. Na secção 2.3 é possível encontrar o atual estado de arte dos edifícios inteligentes e dos ambientes inteligentes.

Os ambientes inteligentes representam uma mudança de paradigma significativa na computação ao criar um ambiente computacional mais centrado no ser humano e intuitivo. A integração de várias tecnologias, tais como sensores e aprendizagem automática permitiu ao ambiente inteligente fornecer serviços personalizados e sensíveis ao contexto aos utilizadores. No entanto, os desafios relacionados com a privacidade dos dados, segurança e preocupações éticas ainda precisam de ser enfrentados para que se realize plenamente o potencial desta tecnologia. Na secção 2.3 são demonstradas diferentes soluções de ambientes inteligentes.

3 Métodos e Ferramentas

Este capítulo descreverá as diferentes ferramentas e métodos que foram utilizados no desenvolvimento do sistema proposto nesta dissertação. Além disso, são apresentados os desafios técnicos e sociais relacionados com o domínio do desenvolvimento.

3.1 Métodos

Nesta última subsecção são explorados os métodos e algoritmos escolhidos para o desenvolvimento do BAIS e as suas funcionalidades. Os tópicos abordados são o processamento paralelo, algoritmos de previsão para a previsão de consumos energéticos e de *clustering* para a identificação de contextos.

3.1.1 Processamento Paralelo

A monitorização dos dispositivos IoT é feito através do uso de *threads*, de modo que seja mais fácil e rápido efetuar a monitorização de diferentes dispositivos IoT em simultâneo, uma vez que uma *thread* é uma forma de um processo que se divide em várias tarefas, pelo que é possível executar outras funcionalidades do sistema enquanto as *threads* estão a correr e monitorizar os dispositivos IoT.

3.1.2 Aprendizagem Automática

A aprendizagem automática está cada vez mais a revolucionar o nosso mundo, porque a explosão de dados provocada pela digitalização em massa requer novas ferramentas para o processamento de dados.

O sistema permite ser feita previsão de energia. A previsão é uma técnica que utiliza dados históricos como inputs para fazer estimativas informadas que são preditivas na determinação

da direção de tendências futuras. O sistema permite a previsão por dispositivo IoT, com uma rotina de previsão é possível prever a potência ou a energia necessária para equilibrar a oferta e a procura de carga, que é obrigatória para o bom funcionamento da indústria elétrica. Pode ser classificado em termos de tempo como algumas horas, algumas semanas, até um ano ou mais de um ano. Estas *previsões* são efetuadas através do uso de aprendizagem automática. É possível prever a utilização dos dispositivos IoT, que irá prever se o utilizador irá utilizar um determinado recurso num determinado momento e a flexibilidade energética irá prever a flexibilidade das cargas dos IoT.

Para realizar uma previsão é possível utilizar diferentes métodos de aprendizagem automática como por exemplo, redes neurais artificiais, redes neurais de *long short-term-memory* (LSTM), *convolutional neural networks* (CNN), florestas aleatórias, redes neurais de regressão, regressão *k-nearest neighbors*, regressão de *support vector machines*, árvores de classificação e regressão (CART) e métodos ensemble.

Em muitos casos a interpretação e a explicação dos métodos de aprendizagem automática não são muito claros. Mas quando temos uma vasta quantidade de dados as técnicas de aprendizagem automática são o que melhor se adequa para as previsões. O processo de realização de uma previsão é bastante acessível, como pode ser visto na Figura 6. Em suma, técnicas de previsão de aprendizagem automática são altamente eficazes em aplicações pelo qual o objetivo é aprender de conjuntos de dados que tem muitas características e que a explicação do modelo não seja crítica.

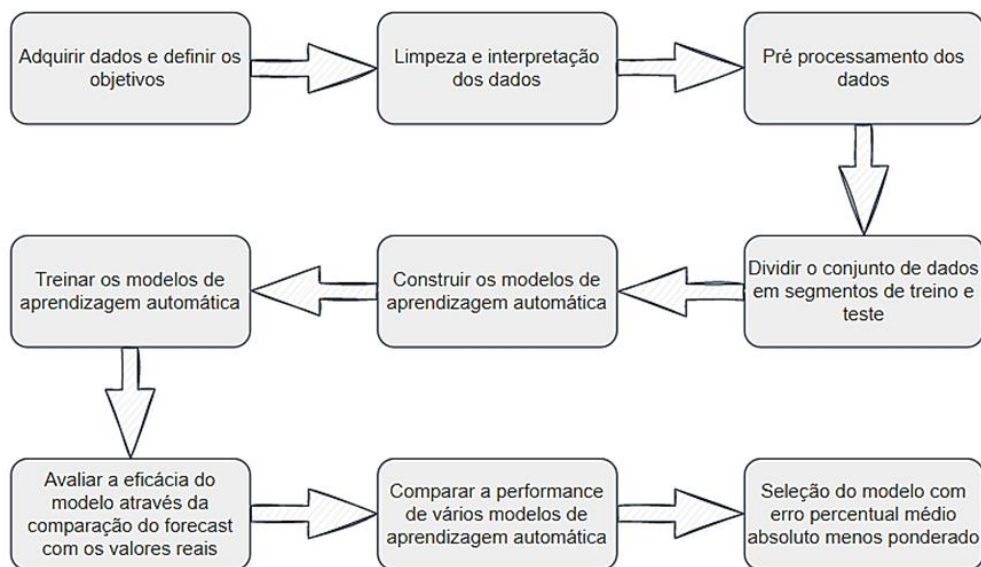


Figura 6 - Fluxo de execução de uma previsão

Os consumos energéticos podem ter muita informação escondida e essa informação pode ser utilizada para perceber diferentes contextos que possam estar a envolver o ambiente. Através dos consumos energéticos é possível identificar padrões, ou seja, níveis de energia que são habituais numa determinada hora, como meio de promover a sustentabilidade e eficiência

energética, pois irá analisar o melhor padrão caso a caso num esforço para estudar as melhores práticas, estabelecer objetivos e definir potenciais soluções para a conservação da energia. Para conseguir identificar os padrões podem ser utilizados algoritmos de *clustering*.

Os algoritmos de *clustering* são uma das técnicas mais importantes para a gestão de dados de grandes dados. Permite organizar as informações de uma base de dados grande para realizar uma análise mais precisa. A aplicação dos algoritmos de *clustering* é bastante ampla e combina com Python, que é a linguagem de programação utilizada para o desenvolvimento deste sistema. Inclusive existem já Bibliotecas de Python que disponibilizam módulos de *clustering* como por exemplo a Scikit.learn, por isso é que o Python é uma linguagem de programação muito utilizada para a criação de algoritmos. O *clustering* é uma técnica não supervisionada de aprendizagem automática que identifica padrões e características em comum entre as informações de maneira autônoma, realizada automaticamente por algoritmos de aprendizagem automática. Ou seja, os dados recolhidos vão ser divididos em grupos, chamados de *clusters*.

Existem dois principais tipos de *clustering*: os hierárquicos e os particionais. O método de *clustering* mais utilizado é o de divisão, é baseado na formação de *clusters* pela divisão em partes dos dados de uma base de dados, com base nas suas semelhanças, isto vai requerer que o programador especifique o número de *clusters* a serem gerados. O hierárquico baseia-se numa matriz de distância. Quando são fornecidos somente dados brutos, o algoritmo calcula automaticamente uma matriz de distância em segundo plano. Neste caso, o *clustering* baseia-se na junção entre os *clusters* mais próximos e que tenham mais semelhanças. Este processo vai-se repetindo até que todos os *clusters* sejam gerados.

O método mais utilizado no *clustering* é o k-means sendo o k o número de *clusters* que queremos que o nosso algoritmo tenha, a partir da definição do nosso k, são estabelecidos pontos chamados de centroides, esses centroides irão ser utilizados para calcular a distância euclidiana entre os objetos, o que dará origem aos nossos *clusters*.

Para além de proteger os dados, é vital saber como organizar os dados disponíveis e analisá-los atualmente, o grande volume de dados obtidos abre diversas possibilidades para o mundo dos negócios, isto é feito com o auxílio de dispositivos IoT e do armazenamento em nuvem, sendo possível recolher informações das mais variadas fontes. Com o *clustering*, pode ser delineado várias informações de mercado com base nos dados recolhidos. Tendências, preferências dos utilizadores, comportamentos, tudo isto pode ser agrupado em *clusters*, facilitando a análise de contexto e uma tomada de decisão mais assertiva.

3.1.3 Identificação de correlações nos dados

Fazer pequena introdução. As variáveis podem ser relacionadas por uma relação linear. Esta relação entre duas variáveis chama-se covariância. Uma covariância não é fácil de interpretar, mas se a covariância tiver o valor de zero indica que ambas as variáveis são completamente independentes. Devido à difícil interpretação da correlação na covariância é preferível utilizar

o coeficiente de correlação Pearson para ver a força da relação linear entre duas amostras de dados. No caso da correlação de Pearson o coeficiente irá retornar um valor entre -1 e 1 que representa o valor da correlação, sendo que 0 significa sem correlação. O valor deve ser interpretado, onde normalmente um valor abaixo de -0,5 ou acima de 0,5 indica uma correlação forte e valores abaixo desses valores sugerem uma correlação menos forte.

A correlação Spearman é feita para relacionar duas variáveis ou mais por uma relação não linear, de modo que a relação seja mais forte ou mais fraca em toda a distribuição das variáveis. Este teste de relação também pode ser usado se houver uma relação linear entre as variáveis, mas dará ligeiramente piores resultados. Uma relação linear entre as variáveis não é assumida, contudo uma relação monotónica é assumida neste tipo de correlações. Este é um nome matemático para uma relação crescente ou decrescente entre duas variáveis. Se não houver certeza da distribuição e possíveis relações entre duas variáveis, o coeficiente de correlação Spearman é uma boa ferramenta a utilizar. A função para calcular o coeficiente de correlação Spearman entre duas amostras de dados com o mesmo comprimento pode ser usada acedendo também à Biblioteca Pandas.

Visto que tanto a covariância e a correlação de Spearman não se enquadram nos objetivos do projeto, a correlação que será usada será a correlação de Pearson.

3.2 Ferramentas

Nesta primeira subsecção são apresentadas as ferramentas utilizadas no desenvolvimento do sistema proposto nesta dissertação. É descrita a construção do conjunto de dados, são descritas todas as bibliotecas utilizadas que permitem a implementação de algoritmos sofisticados, a ferramenta de acesso e partilha de dados também é apresentada. Por fim os protocolos de interligação de dispositivos IoT são descritos.

3.2.1 Conjunto de dados e construção de histórico

Para o sistema funcionar corretamente terá de ser alimentado por diferentes dados provenientes de dispositivos IoT. Porém, não é utilizado um conjunto de dados específico, uma vez que o próprio sistema recolhe os dados de um edifício verdadeiro.

A plataforma foi implementada num edifício que já tinha um *supervisory control and data acquisition system* (SCADA) com vários analisadores energéticos. O edifício de onde os dados estão a ser retirados é o edifício N do Instituto Superior de Engenharia do Porto (ISEP), que é o edifício onde foi realizado o teste e implementação deste trabalho de investigação.

Os dados recolhidos deste edifício são recolhidos em períodos de segundo a segundo e serão armazenados numa base de dados implementada em MongoDB de 5 em 5 segundos, que irá armazenar todos os dados retirados do edifício, formando assim o conjunto de dados necessário que o sistema precisará para conseguir realizar as suas funções. Na Tabela 5 estão

descritos todos os recursos que foram utilizados para criar o conjunto de dados necessários para o sistema funcionar corretamente.

Tabela 5 - Recursos energéticos monitorizados

Recurso	Controlo
Frigorifico	Não
Cilindro de água quente	Sim
Televisão	Sim
Ar Condicionado	Sim
Luzes	Sim
Micro-ondas	Sim
Monitores	Sim
Computadores	Sim
Cafeteira	Sim
Tomadas	Não
Máquina de Lavar a Loiça	Sim
Sensores de Temperatura	Não
Sensores de Movimento	Não
Sensores de Portas	Não
Sensores de CO ₂	Não
Sensores de Compostos Orgânicos Voláteis	Não
Sensores de Humidade	Não
Sensores de Luminosidade	Não

3.2.2 Ferramenta de acesso e partilha de dados

É utilizado um padrão da Internet para a criação de dados com assinatura opcional e criptografia cujo *payload* contém um JSON que afirma algum número de declarações. Este *Json Web Token* (JWT) irá permitir que o acesso aos dados seja controlado e que se mantenha a privacidade do utilizador.

JWT é um padrão aberto (RFC 7519) que define uma forma compacta e independente de transmitir informação em segurança entre partes. Esta informação pode ser verificada e confiada porque é assinada. Os JWT são assinados por uma chave secreta com o algoritmo de

código de autenticação de mensagem baseado em *hash* (HMAC). Embora o JWT possa ser encriptado para proporcionar confidencialidade, a solução desenvolvida está atualmente centrada nos *tokens* assinados. Os *tokens* assinados podem verificar a integridade das declarações neles contidas, enquanto os *tokens* encriptados escondem essas declarações. Tendo os *tokens* assinados, conseguimos garantir que apenas a pessoa com a chave secreta foi quem os assinou.

Geralmente, o JWT é utilizado para autorização. Após o *login* do utilizador, cada pedido incluirá um JWT, permitindo ao utilizador aceder a rotas, serviços e recursos que são disponibilizados pelo *token*. O JWT também pode ser utilizado para troca de informações, sendo uma boa solução para transmitir informações de forma segura. Uma vez que estes têm de ser assinados, é possível ter a certeza de que os remetentes são quem dizem ser. Além disso, como a assinatura é calculada utilizando o *header* e o *payload*, também é possível verificar se a informação foi adulterada. A estrutura de um JWT consiste em três partes separadas por pontos: *header*, *payload* e *signature*. O *header*, por sua vez, é composto por duas partes: o tipo de *token* e o algoritmo de assinatura utilizado. A *payload* contém as reivindicações, que são dados, praticamente quaisquer dados JSON, que o criador inclui no JWT. Por fim, para criar a assinatura, é necessário ter o *header* codificado, a *payload* codificada, a chave secreta, e o algoritmo especificado no *header*.

O JWT foi o mecanismo escolhido para desempenhar a função de encriptação dos dados porque tem várias vantagens em relação a outras tecnologias. JSON é menos verboso que a *extension markup language* (XML), quando codificado o seu tamanho é também menor, tornando o JWT mais compacto que a *security assertion markup language* (SAML). Isto torna o JWT uma boa escolha para ser transmitido em ambientes HTTP.

3.2.3 Bibliotecas utilizadas para a Interface Computacional

Toda a interface computacional foi desenvolvida em Python, por ser uma linguagem de programação versátil, ser fácil de programar, ser *open-source* e ter uma vasta quantidade de bibliotecas. Bibliotecas essas que serão uma mais-valia para o desenvolvimento desta dissertação.

O Flask é uma *micro framework web* que utiliza a linguagem Python para criar aplicações web. É poderoso, simples e rápido, sendo útil tanto para soluções de projetos pequenos como para aplicações robustas. O Flask é baseado no kit de ferramentas Werkzeug, *Web Server Gateway Interface* (WSGI) e na Biblioteca Jinja2. A WSGI é a especificação de uma interface comum entre servidores e aplicações web. O Werkzeug é uma das bases do Flask, um kit de ferramentas WSGI que implementa funções como pedidos, por exemplo. Já o Jinja2 é um sistema de *template web* que combina um modelo com uma fonte de dados específica para renderizar uma página web. A *framework* Flask é utilizada no desenvolvimento desta dissertação para ser possível desenvolver uma API RESTful, na qual os utilizadores podem solicitar o acesso aos dados utilizando o JWT.

O Pymongo é uma distribuição python que contém ferramentas para trabalhar com MongoDB, e é a forma recomendada para trabalhar com MongoDB a partir do Python. A base de dados utilizada para armazenar os dados recolhidos pelo BAIS, é uma base de dados NoSQL desenvolvida em MongoDB então para facilitar a ligação do Python com o MongoDB a Biblioteca Pymongo foi utilizada.

O módulo *threading* é um módulo que constrói interfaces de *threading* de nível superior no topo do módulo de nível inferior *_thread*, como vários módulos da dissertação são feitos recorrendo a *threads*, como a monitorização dos diferentes dispositivos IoT, este módulo será usado para facilitar essas tarefas.

A Biblioteca Schedule é programada em processo para trabalhos periódicos que utilizam o padrão do construtor para configuração. Esta Biblioteca permite executar funções em Python periodicamente em intervalos pré-determinados usando uma sintaxe simples. Esta Biblioteca de agendamento é utilizada para agendar uma tarefa a uma hora específica todos os dias ou num dia específico de uma semana. Basicamente a Biblioteca, combina a hora do sistema com a hora programada definida no código, quando a hora programada e a hora do sistema coincidirem a função da tarefa é chamada. Esta Biblioteca é utilizada para agendar a previsão do dia seguinte.

3.2.4 Framework da Interface Gráfica

A elaboração de uma interface gráfica do utilizador foi necessária para permitir ao utilizador visualizar os seus pedidos de forma organizada e simples. Para implementar a interface gráfica foi utilizada a *framework* JavaScript Vue.js que é focada no desenvolvimento de interfaces de utilizador. Vue é uma estrutura progressiva para construção de interfaces de utilizador. Esta foi concebida desde o início para ser gradualmente adotável, e pode facilmente escalar entre uma Biblioteca e uma estrutura, dependendo dos diferentes casos de utilização. Esta foca-se na renderização declarativa e na composição de componentes. Os componentes Vue estendem elementos HTML básicos. No Vue um componente é essencialmente uma instância do Vue com opções predefinidas. As rotas da interface gráfica estão conectadas às rotas da API REST, por conseguinte todos os dados que são mostrados na interface gráfica são obtidos através da API REST.

3.2.5 Bibliotecas de identificação de correlações entre dados

Fazer a modelação dos diferentes recursos pode ser uma tarefa difícil, por isso o sistema irá usar correlações para fazer a modelação dos recursos. Por exemplo, se for integrado um novo sensor de CO₂, vai ser identificado que um novo parâmetro terá de ser monitorizado, e depois disso o sistema vai começar a perceber quais os atuadores/recursos que causam um impacto no CO₂, se não houver correlação então o parâmetro não pode ser otimizado, se houver correlação, esse parâmetro pode ser otimizado. Pode ser útil na análise e modelação de dados

para melhor compreender as relações entre as variáveis. A relação entre duas variáveis é referida como a sua correlação.

A Biblioteca Pandas disponibiliza uma função *corr()* para calcular a correlação entre duas amostras de dados com o mesmo tamanho dando o coeficiente de correlação de Pearson, a utilização desta função irá retornar uma matriz das correlações. Para representar a matriz das correlações entre os dispositivos IoT, é utilizada a Biblioteca *seaborn* para fazer um mapa de temperatura da matriz de correlações para melhor compreensão e identificação das correlações.

3.2.6 Bibliotecas para a previsão de consumos energéticos

Para o desenvolvimento dos modelos de previsão de consumos energéticos o sistema usou a biblioteca Tensorflow e a sua API Keras e também a biblioteca *XGboost*, estas bibliotecas permitirão desenvolver modelos de previsão que permitem a previsão dos consumos energéticos.

Keras é uma API de aprendizagem profunda escrita em Python, que funciona em cima da plataforma de aprendizagem automática TensorFlow. Foi desenvolvido com o objetivo de permitir uma experiência rápida. Ser capaz de ir da ideia ao resultado o mais rápido possível é a chave para fazer uma boa investigação. É simples, mas não é simplista. O Keras reduz a carga cognitiva do desenvolvedor para o libertar para se concentrar nas partes do problema que realmente importam. Keras adota o princípio da divulgação progressiva da complexidade, os fluxos de trabalho simples devem ser rápidos e fáceis, enquanto os fluxos de trabalho arbitrariamente avançados devem ser possíveis através de um caminho claro que se baseia no que já se aprendeu. Proporciona um desempenho e escalabilidade de grande resistência à indústria.

TensorFlow é uma plataforma de aprendizagem automática de código aberto de ponta a ponta. Pode pensar-se nela como uma camada de infraestrutura para uma programação diferenciável. Combina algumas capacidades chave, entre elas a execução eficiente de operações de baixo nível de tensão no CPU, GPU ou TPU. A computação do gradiente de expressões diferenciáveis arbitrárias também é uma das capacidades do tensorflow. Tem a capacidade de fazer a computação em escala para muitos dispositivos, tais como *clusters* de centenas de GPUs. Por último consegue fazer a exportação de programas para tempos de execução externos, tais como servidores, navegadores, dispositivos móveis e embutidos.

O Keras permite aos engenheiros e investigadores tirar o máximo partido da escalabilidade e das capacidades de *cross-platform* do tensorflow, o keras pode ser executado em *Tensor Processing Unit* (TPU) ou em grandes grupos de GPUs e pode exportar os modelos keras para executar no browser ou num dispositivo móvel.

XGBoost é uma biblioteca de aprendizagem automática de código aberto que fornece uma implementação poderosa do algoritmo de *gradient boosting*. Foi concebido para ser altamente

eficiente, escalável e flexível, tornando-o uma das mais populares e amplamente utilizadas bibliotecas de aprendizagem automática do mundo.

No seu núcleo, XGBoost é um algoritmo de *ensemble learning* baseado em árvores de decisão que combina aprendizes fracos num forte. Funciona iterativamente através da adição de árvores de decisão ao conjunto, com cada árvore a tentar corrigir os erros cometidos pelas árvores anteriores.

Uma das principais vantagens do XGBoost é a sua rapidez e eficiência. É capaz de manusear grandes conjuntos de dados com um elevado número de características e pode funcionar numa única máquina ou num conjunto distribuído. XGBoost também inclui uma série de técnicas avançadas de otimização, tais como processamento paralelo, otimização de cache e divisão de blocos de colunas, que ajudam a acelerar o treino e a melhorar a precisão.

O XGBoost é implementado em Python e pode ser facilmente integrado com bibliotecas populares de análise de dados e aprendizagem automática, tais como NumPy, Pandas e Scikit-Learn. Também inclui uma série de características úteis, tais como paragem antecipada, validação cruzada e ferramentas de visualização de modelos, que o tornam fácil de usar e compreender.

Em geral, XGBoost é uma biblioteca de aprendizagem automática potente e flexível que é ideal para uma vasta gama de aplicações, incluindo regressão, classificação e problemas de ordenação. A sua velocidade, eficiência e escalabilidade fazem dela uma escolha popular para cientistas de dados e profissionais da aprendizagem automática em todo o mundo.

3.2.7 Bibliotecas para o *clustering*

Para o desenvolvimento do *clustering* para a identificação de contextos o sistema fez uso da biblioteca scikit-learn. Scikit-learn é uma biblioteca popular de aprendizagem automática para Python que fornece uma vasta gama de ferramentas para a construção e avaliação de modelos de aprendizagem automática. Uma das principais características de scikit-learn é o seu módulo de *clustering*, que inclui vários algoritmos, tais como k-means, *clustering* espacial baseado em densidade de aplicações com ruído e *clustering* hierárquico.

O algoritmo K-means é um dos mais populares algoritmos de *clustering* e é utilizado para dividir um conjunto de dados em K *clusters*, onde K é um parâmetro definido pelo utilizador. O algoritmo funciona através da inicialização aleatória dos centroides K, atribuindo cada ponto ao seu centroide mais próximo, recalculando o centroide de cada *cluster* e repetindo este processo até à convergência.

No Scikit-learn, o algoritmo k-means é implementado na classe `sklearn.cluster.KMeans`. Esta classe permite especificar vários parâmetros tais como o número de *clusters* (K), o método de inicialização, por exemplo, aleatório, k-means++ ou um método personalizado, o número máximo de iterações e a métrica de distância utilizada para medir a semelhança entre pontos.

No geral, Scikit-learn é uma poderosa biblioteca de aprendizagem automática para Python que fornece uma vasta gama de algoritmos de *clustering*, incluindo k-means. A classe `sklearn.cluster.KMeans` fornece uma interface simples e fácil de usar para agregação de dados usando o algoritmo k-means.

3.2.8 Protocolos de Interligação de dispositivos IoT heterogêneos

Um dos aspectos chave do sistema é a capacidade de trabalhar com múltiplos dispositivos IoT que podem ser ligados à estrutura utilizando os serviços de gestão de ligação. Estes serviços podem ser vistos como controladores de ligação para os quais os dispositivos IoT podem comunicar dados e informações. Esta secção enumerará alguns dos protocolos de comunicação, que serão desenvolvidos como conectores para a estrutura do sistema. No entanto, a arquitetura do sistema permite a integração futura de ligações adicionais sem comprometer ou limitar as funcionalidades da estrutura.

A integração de componentes de software e hardware de diferentes marcas e fabricantes pode ser muito desafiante e pode causar problemas quando diferentes marcas de hardware têm diferentes protocolos de comunicação entre os dispositivos. Para resolver este problema, podem ser implementados vários controladores de ligação onde os dispositivos podem ser ligados, e podemos utilizar vários protocolos de comunicação, tais como: HTTP, MQTT, Modbus/RTU, Modbus/TCP, TCP e UDP.

Hypertext Transfer Protocol (HTTP), é um protocolo que permite obter recursos, é a base de qualquer troca de dados na Web, e um protocolo cliente-servidor, o que significa que os pedidos são iniciados pelo destinatário, geralmente feitos através de um navegador da Web. Ao contrário de um fluxo de dados, o cliente e o servidor comunicam através de trocas de mensagens individuais. Não é o protocolo ideal para a integração de dispositivos IoT devido ao seu custo, enorme consumo de energia, e problemas de peso, mas ainda é utilizado devido à grande quantidade de dados que pode publicar.

Queueing Telemetry Transport (MQTT) é um protocolo de dados leve de IoT. Apresenta um modelo de mensagens editor-subscritor e permite um fluxo de dados simples entre diferentes dispositivos. A principal vantagem do MQTT é a sua arquitetura, a sua composição é básica e leve e pode proporcionar um baixo consumo de energia para dispositivos. Funciona em cima de um protocolo TCP/IP. Os protocolos de dados IoT são concebidos para se ligarem a redes de comunicação não fiáveis. Isto tornou-se uma necessidade no mundo IoT devido ao número crescente de objetos que apareceram na rede nos últimos anos. Apesar da ampla adaptação do MQTT, este não suporta uma representação de dados definida e um modo de gestão de dispositivos.

Modbus/RTU define uma forma de interpretação dos dados que são enviados e recebidos por um dispositivo, pelo que se trata de um protocolo de comunicação. O modelo de comunicação é do tipo mestre-escravo. Assim, um escravo não deve iniciar qualquer tipo de comunicação no ambiente físico até que tenha sido solicitado pelo mestre. Esta comunicação permite a ligação

de vários dispositivos ao mesmo tempo, um dos quais é o mestre, que coordena a comunicação, e os restantes são os escravos. É muito comum, quando se comunica com um PLC, utilizar Modbus/RTU.

Modbus/TCP é um protocolo simples e fácil de implementar, acaba por ser aplicado na maioria dos equipamentos industriais que utilizam alguma tecnologia de rede, é um protocolo aberto para que possa ser implementado livremente em qualquer equipamento. Para aplicar este protocolo em arquitetura no ambiente físico, Modbus tem um protocolo de comunicação TCP, uma das principais vantagens desta comunicação é a facilidade de implementação de infraestruturas, através de comutadores ou hubs industriais, a comunicação pode atingir velocidades muito elevadas. O protocolo pode integrar dispositivos instalados no terreno e permite a troca de informação entre eles sem restrições, ou seja, cada utilizador pode ligar-se diretamente aos servidores.

O *Transmission Control Protocol (TCP)* é o protocolo de comunicação mais comum utilizado na Internet, responsável por dividir a mensagem em datagramas, remontá-los, e retransmitir os datagramas perdidos. É orientado para a ligação, o que significa que os dados podem ser enviados bidireccionalmente uma vez estabelecida uma ligação. Inclui um sistema de verificação automática de erros para assegurar que cada pacote é entregue conforme solicitado. O Protocolo Internet (IP) é responsável pelo encaminhamento de datagramas, o que não é tarefa fácil na Internet, uma vez que a ligação pode querer que o datagrama atravesse várias redes até chegar ao seu destino. O TCP não só tem de entregar os datagramas ao destino, como também tem de controlar a que ligação pertence cada datagrama.

O *User Datagram Protocol (UDP)* é um protocolo de comunicação que tem como característica essencial a falta de fiabilidade. Isto significa que, ao utilizar este protocolo, é possível enviar datagramas de uma máquina para outra, mas sem qualquer garantia de que os dados enviados chegarão intactos e na ordem correta, ao contrário do TCP. UDP é um protocolo que não segue uma ligação, isto significa que não é necessário estabelecer comunicação, desta forma com UDP é possível enviar, através da mesma saída, dados para várias máquinas diferentes sem qualquer problema. O UDP torna-se um protocolo vantajoso quando se pretende lidar com serviços onde a velocidade é algo fundamental e a perda mínima de dados não é muito desvantajosa.

Com a utilização de todos estes protocolos é possível garantir a interoperabilidade do sistema. Independentemente do protocolo, um dispositivo IoT é modelado usando o mesmo modelo, o que permitirá a integração futura de novos controladores, a configuração dos dispositivos IoT também define a periodicidade de leitura.

3.3 Desafios Técnicos e Sociais

Nesta secção irão ser abordados os desafios técnicos e sociais quanto à proteção de dados, análise de segurança e aspetos éticos.

3.3.1 Proteção dos dados

A proteção de dados refere-se ao conjunto de medidas, políticas e práticas concebidas para salvaguardar a informação pessoal e assegurar a sua confidencialidade, integridade e disponibilidade. Com o rápido desenvolvimento das tecnologias digitais, a proteção de dados tornou-se uma questão crítica tanto para indivíduos, organizações como para governos. A quantidade crescente de dados pessoais recolhidos, processados e armazenados por sistemas digitais suscita preocupações quanto à privacidade, segurança e a potencial utilização indevida desta informação. Para enfrentar estes desafios, foram introduzidas várias leis, regulamentos e normas para proteger os dados pessoais e estabelecer diretrizes para a sua recolha, utilização e divulgação.

Em (Sovacool & Furszyfer Del Rio, 2020), foram relatadas trinta e uma entrevistas em que permitiram identificar alguns riscos e barreiras da tecnologia inteligente. Sendo que alguns deles são: privacidade, segurança e *hacking*, fiabilidade técnica, garantias, obsolescência, usabilidade, aceitação do utilizador, aprendizagem, elitismo, incumbência, barreiras ao mercado, erosão da democracia e incerteza, falta de partilha e dificuldade em rentabilizar os benefícios. No mesmo estudo foram feitas recomendações que devem ser abordadas em edifícios inteligentes. Sendo algumas delas: proteção do consumidor, privacidade e segurança de dados, restrições ou configuração para assegurar baixo consumo de energia ou baixo teor de carbono, regulamentos mais fortes para serviços de energia ou IoT, proporcionar investigação, inovação e aprendizagem, remover barreiras e encorajar a concorrência no mercado (Sovacool & Furszyfer Del Rio, 2020).

O sistema proposto nesta dissertação cumpre o Regulamento Geral sobre a Proteção de Dados (RGPD), ao permitir ao utilizador o controlo total dos seus dados. A união europeia apresentou em 2018 o RGPD que deu uma grande atualização ao regulamento sobre privacidade de dados publicado em 1995. Isto teve um grande impacto em como os dados são partilhados, processados e recolhidos (Voigt & von dem Bussche, 2017). O RGPD também foi implementado para ambientes IoT, utilizando controladores de dados e técnicas relacionadas que permitam aos utilizadores monitorizar os seus dados. Já foi desenvolvido um modelo para tornar os dispositivos responsáveis perante as exigências dos consumidores (Crabtree et al., 2018). O modelo corresponde às exigências do RGPD para melhorar a confidencialidade e a confiança do utilizador. (Loideain, 2019) examinou mecanismos para apoiar as consequências da proteção de dados dos utilizadores apresentadas pela utilização do IoT.

Os edifícios inteligentes são sistemas baseados em IoT onde são necessárias operações de dados sobre sensores e atuadores. Estes sensores podem envolver a monitorização do comportamento do utilizador dentro de um edifício, exigindo assim o cumprimento do RGPD. Os edifícios inteligentes têm incorporado equipamento de monitorização e controlo com potencial para monitorizar a atividade física de um utilizador (Luca Porrati et al., 2011), mas também para otimizar o uso de energia.

3.3.2 Análise de Segurança

A segurança e a privacidade dos edifícios inteligentes devem ser consideradas como uma prioridade e asseguradas nas soluções de edifícios inteligentes. As ameaças podem colocar o edifício e os utilizadores em perigo. De entre estas ameaças temos danos não intencionais causados por acidentes, danos e perdas em bens de tecnologia da informação (Paper et al., 2016). A utilização de dispositivos IoT também suscita preocupações, uma vez que a segurança de um único dispositivo pode comprometer todos os dispositivos e todo o sistema (Paper et al., 2016). Existem vários problemas de segurança significativos com os dispositivos IoT. Há pouca ou nenhuma autenticação em muitos dispositivos IoT. Um dispositivo IoT inseguro pode ser um portal para uma rede, onde os hackers podem utilizar o poder de processamento para disseminar *malware* e realizar ataques DDoS, mesmo que não haja muitos dados significativos guardados no próprio dispositivo. Pedir autenticação em várias etapas é uma forma de resolver o grande problema da fraca autenticação para a segurança da IoT. Embora seja mais simples para um dispositivo IoT utilizar a mesma rede que outros dispositivos do utilizador final, fazê-lo aumenta significativamente a vulnerabilidade da rede.

O dispositivo IoT pode ser utilizado por alguém para obter mais informação privada que é mantida na rede ou noutros dispositivos ligados. É aconselhável empregar redes diferentes, uma firewall ou um *gateway* de segurança para que qualquer falha do dispositivo seja contida nesse dispositivo específico. Quando se trata de normas de segurança dentro da Internet sem fios, há um pouco de liberdade para todos. Desta forma não existe uma norma global, pelo que cada empresa terá de criar os seus próprios procedimentos e regras. Devido à falta de normas, é significativamente mais difícil salvaguardar os dispositivos IoT e mais arriscado permitir a comunicação máquina a máquina. A frequente ausência de criptografia nas transmissões é uma das maiores preocupações para a segurança da Internet das Coisas não codificam os dados que transportam, o que torna possível aos intrusos da rede capturar palavras-passe e outros dados sensíveis enviados de e para o dispositivo.

Se os dispositivos são libertados no campo com um defeito que introduz vulnerabilidades, este é outro dos maiores perigos de segurança da internet das coisas. Os fabricantes devem ter a capacidade de lançar atualizações de *firmware*, a fim de mitigar estas preocupações de segurança, quer estas tenham origem no seu próprio código ou noutras fontes. O ideal seria que isto ocorresse remotamente, mas nem sempre isso é possível. Poderá ser necessário contactar fisicamente o dispositivo para emitir a atualização se a velocidade de transferência de dados de uma rede for demasiado lenta ou se tiver capacidades restritas de envio de mensagens.

A segurança física é essencial para impedir o acesso não autorizado a um dispositivo porque as aplicações de IoT são frequentemente remotas por natureza. Aqui, a utilização de peças resilientes e hardware especializado que torna os dados mais difíceis de aceder é benéfica. Os riscos de segurança já existem quando as comunicações são enviadas e recebidas através de dispositivos implantados remotamente. Embora a encriptação de mensagens seja um passo positivo, deve ser tomado mais cuidado quando se envia informação sensível através de redes

públicas. Para garantir que os dados nunca atravessem a internet aberta, é aconselhável empregar redes privadas para além das medidas de segurança atuais.

As transferências de dados dentro da rede devem ser encriptadas, a fim de transportar dados de e para os dispositivos em segurança. Embora a rede e a aplicação possam ser seguras, existem um espaço onde os dados podem ser interceptados. Outra forma de conseguir uma maior segurança, é poder isolar a conectividade da rede do dispositivo às suas funções primárias, mais seguro ele vai ser.

3.3.3 Aspetos Éticos

Ao desenvolver e implantar tecnologia de edifícios inteligentes, as considerações éticas devem ser cuidadosamente exploradas. (Chung et al., 2016) identificou sete questões éticas significativas: privacidade, consentimento informado, autonomia, intrusão, igualdade de acesso, redução do contacto humano, e usabilidade. A partilha de dados com pessoas e entidades não autorizadas, bem como a obtenção de dados não autorizados de utilizadores, pode causar preocupações em matéria de privacidade.

Três princípios devem orientar o consentimento informado: não maleficência, beneficência e autonomia (Beauchamp et al., 2019). A não maleficência declara que a solução de edifícios inteligentes não pode prejudicar os utilizadores e a beneficência deve especificar quais os benefícios que a solução proporcionará aos utilizadores.

A autonomia deve especificar a vontade do utilizador de aceitar a solução, bem como o seu direito de a recusar. A autonomia dos utilizadores é também vital em edifícios inteligentes, uma vez que permite aos indivíduos completar tarefas, assumir o controlo e designar quais as entidades que têm acesso aos seus dados.

O sistema desenvolvido nesta dissertação aborda a privacidade dos dados utilizando os JWT para proteger o utilizador, sendo que se o utilizador depois de acabar a contratualização quiser que os dados que foram recolhidos sejam revogados, todos os dados associados ao *token* desse utilizador serão apagados da base de dados e terá direito ao esquecimento dos dados e caso o utilizador tente aceder à plataforma com o *token* que foi revogado não irá conseguir aceder de novo aos dados do edifício.

3.4 Conclusões do capítulo

Este capítulo apresentou uma visão geral dos métodos, ferramentas e desafios técnicos e sociais envolvidos no desenvolvimento do sistema. Python foi a linguagem de programação escolhida, pois tem um grande número de bibliotecas de código aberto que podem ser utilizadas para melhorar o sistema. Os dados que foram usados no estudo, seguem as diretrizes do RGPD. Foram utilizadas várias bibliotecas e *frameworks*, tais como pandas, Vue.JS para a interface

gráfica, e vários protocolos de comunicação para dispositivos IoT. Os métodos utilizados incluíram a aprendizagem automática, algoritmos de previsão e *clustering* e a correlação de Pearson foi escolhida para o mecanismo de extração de conhecimento. Finalmente, foram discutidos desafios técnicos e sociais, tais como proteção de dados, segurança e considerações éticas. Este capítulo forneceu uma visão global dos vários componentes envolvidos no desenvolvimento do sistema, salientando a importância de uma consideração cuidadosa tanto dos aspectos técnicos como éticos.

4 *Building Ambient Intelligent System* (BAIS)

A *framework* proposta é chamada de *Building Ambient Intelligent System* (BAIS). Esta *framework* é baseada em dispositivos IoT heterogéneos e toma a segurança e privacidade em consideração. A arquitetura foi concebida para permitir a integração de dispositivos IoT heterogéneos com o propósito de permitir a implementação de um sistema de ambiente inteligente (Aml) a trabalhar em conjunto com um sistema de gestão de energia, mantendo o controlo de acesso aos dados do utilizador.

4.1 Arquitetura de Software

Nesta secção é descrita a arquitetura de software. É proposta uma *framework* baseada em dispositivos IoT para a gestão de edifícios suportada por modelos de ambientes inteligentes. Os conhecimentos adquiridos pelo sistema serão o resultado de uma análise de correlações tendo em conta o impacto que cada atuador tem no ambiente. Este método permite a construção autónoma de um modelo de conhecimento de um edifício que se adapta e evolui de cada vez que um IoT novo é adicionado à *framework*. O modelo de conhecimento construído pelo sistema terá informação valiosa relacionadas com o edifício e com os dispositivos IoT presentes e pode ser utilizada para aumentar a gestão inteligente dos recursos.

Utilizando dispositivos IoT, pretende-se recolher e monitorizar os dados de consumo de um edifício, mantendo ao mesmo tempo a privacidade dos dados de cada utilizador. De acordo com o pedido de cada requisitante, é feito um pedido HTTP considerando as permissões desse utilizador para proteger os dados de outros utilizadores e do edifício.

A arquitetura do software é composta por três diferentes camadas, tendo a camada de conectividade, que proporciona a ligação entre os componentes do sistema, tais como os dispositivos físicos, o *backend* e o *frontend*.

A Camada de *middleware*, onde está presente a integração de controladores para sensores e atuadores, a previsão de energia por dispositivos IoT, o armazenamento do consumo numa base de dados, o módulo do sistema de contextos, e finalmente, dentro desta camada, é também realizada a integração da gestão de energia. A camada de *middleware* está dividida em três modos de operação, gestão operação de dados históricos, operação de dados em tempo real e operação de dados futuros. Finalmente, a camada principal que tem componentes essenciais para o sistema funcionar, como o ficheiro de configuração escrito em JavaScript Object Notation (JSON), o gestor de tarefas, e a orquestração de *threads*. Na Figura 7 pode ser visto um diagrama que ilustra a arquitetura do software do sistema.

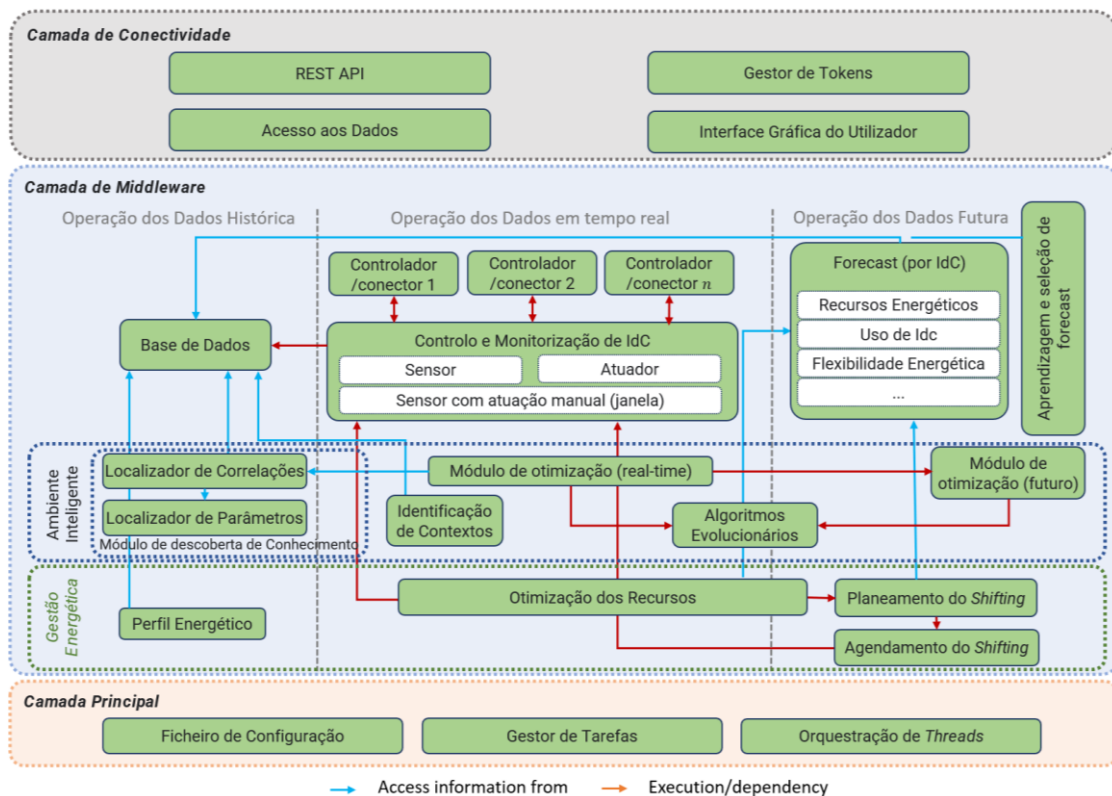


Figura 7 - Arquitetura de Software

O módulo de monitorização e controlo de IoT permite a recolha e monitorização das cargas de energia e de recursos de um edifício. No entanto, existe um problema com a integração de dispositivos IoT heterogéneos, ou seja, dispositivos de diferentes marcas e fabricantes, isto irá dificultar a comunicação entre dispositivos IoT, porque utilizam múltiplas tecnologias de comunicação com múltiplos protocolos, e não promovem a interoperabilidade e cooperação necessárias para implantar um sistema de gestão de energia em edifícios. A solução proposta resolve este problema porque implementou múltiplos controladores de ligação onde diferentes dispositivos IoT podem ser ligados uns aos outros.

4.1.1 Camada de Conectividade

A Camada de conectividade é onde o acesso aos dados é gerido, tentando sempre manter a privacidade e segurança dos dados. Nesta camada, está presente uma API REST, o gestor de *tokens*, e o módulo de notificações do utilizador. Todos estes módulos têm a função de gerir o acesso aos dados de uma forma segura.

A API REST gere os pedidos feitos pelo utilizador e protege-os utilizando JWT, as respostas a estes pedidos são dadas no módulo de notificações do utilizador para permitir a filtragem dos dados de acordo com as permissões e a privacidade. O módulo gestor de *tokens* verifica se o JWT é válido e está presente no pedido. Todo este mecanismo permite-nos ter a certeza de que quem faz o pedido é quem diz ser e através da forma como a assinatura foi calculada utilizando o cabeçalho e a *payload*, é possível verificar se a informação foi adulterada. A REST API permite fazer a ligação entre a interface computacional e a base de dados e para estabelecer também conexão entre a interface gráfica do utilizador e a interface computacional.

O módulo de interface gráfica do utilizador é a ponte entre o *middleware* e o utilizador, consiste na apresentação dos dados e das funcionalidades do sistema ao utilizador, para que ele tenha uma perceção visual de tudo que o sistema proporciona. Este módulo supervisiona a recolha de dados do *middleware* através da REST API e o seu processamento e análise no que diz respeito à privacidade dos dados utilizando o JWT. Este JWT é gerado a pedido do utilizador, para além disso é possível visualizar outras funcionalidades que o sistema proporciona, como por exemplo, a previsão de energia ou as correlações entre os diferentes dispositivos IoT.

4.1.2 Camada de *Middleware*

A camada de *middleware* está dividida em três modos de operação relacionados com o tempo de operação nos dados. A divisão é feita pela operação histórica dos dados, pela operação em tempo real dos dados e pela operação futura dos dados.

A operação histórica dos dados permite fazer uma gestão dos dados históricos, que permite ao sistema armazenar e aceder a dados que foram monitorizados no passado. Estes dados são armazenados numa base de dados NoSQL, implementada em MongoDB. No módulo do sistema de ambiente inteligente, nesta divisão, está presente o módulo de aquisição de conhecimento, onde a modelação dos dispositivos é feita através da própria inteligência do sistema. No módulo de aquisição de dados são encontradas as correlações entre os diferentes dispositivos IoT, porque para calcular as correlações é necessário ter acesso aos dados históricos dos consumos energéticos do edifício. Também presente nesta operação de dados, está o perfil energético do utilizador no módulo do sistema de gestão de energia. Tudo isto pode ser feito devido à existência de uma gestão de dados histórica.

A operação dos dados em tempo real permite o acesso aos dados em tempo real, e contém a monitorização e controlo dos dispositivos IoT e a sua integração através de múltiplos controladores de conexão. O módulo do sistema de ambiente inteligente, permite a

identificação de contextos em tempo real, também permite fazer a otimização no módulo de otimização, recorrendo ao uso de algoritmos evolucionários. No módulo de gestão de energia o sistema permite a otimização dos recursos, na gestão em tempo real dos dados.

A operação futura dos dados está encarregue de manipular os dados futuros do sistema, ou seja, serão os dados que resultarão das previsões realizadas pelo sistema. A operação futura dos dados inclui a realização da previsão dos dispositivos IoT e a seleção e aprendizagem dos melhores modelos de previsão a serem escolhidos para cada dispositivo IoT e contexto. No módulo do sistema de ambiente inteligente, é feita a otimização antecipada recorrendo ao uso de algoritmos evolucionários. No módulo de gestão de energia, pode ser feita a otimização de recursos, o planeamento do *shifting* dos recursos energéticos e fazer o agendamento da ação para materializar o *shifting* planeado. Assim, permitindo a manipulação de dados futuros.

Esta solução integra sensores e atuadores. Os sensores são basicamente dispositivos que têm a função de detetar e responder eficazmente a alguns estímulos. Existem vários tipos de sensores que respondem a diferentes estímulos, tais como calor, pressão, movimento, luz e outros. Após o sensor receber o estímulo, a sua função é emitir um sinal que pode ser convertido e interpretado por outros dispositivos.

Os atuadores são dispositivos que convertem energia em movimento. Pode também ser utilizado para aplicar uma força. Um atuador é normalmente um dispositivo mecânico que toma energia e a converte em movimento. Os atuadores são geralmente utilizados no fabrico e em aplicações industriais.

Os sensores com atuação do utilizador são aqueles sensores que necessitam de intervenção humana para funcionar, como por exemplo, uma janela, se o utilizador abrir a janela, o frio entrará e fará com que a temperatura ambiente desça.

A combinação entre sensores e atuadores é muito comum em sistemas de IoT, dando mais informação contextual relacionada com um recurso. Para integrar os dispositivos IoT, a solução proposta utiliza o conceito de controladores, mas este conceito não só realiza a integração dos dispositivos IoT como também permite uma camada de abstração entre os dispositivos IoT e a camada de *middleware*. Os dispositivos IoT são modelados de acordo com as suas capacidades sensoriais e de atuação. Portanto, de acordo com este tipo de modelação, todos os dispositivos são modelados da mesma forma, permitindo a manipulação de múltiplas fontes de dados sem a necessidade de reescrever o código. Isto também permite que novos dispositivos IoT sejam adicionados ao sistema sem a necessidade de atualizar o código. A periodicidade de leitura também pode ser definida pela configuração dos dispositivos IoT.

Outra característica do sistema é que pode armazenar os dados dos dispositivos IoT numa base de dados, onde todos esses dados serão armazenados, tornando possível fazer uma gestão histórica dos dados, permitindo o acesso aos dados lidos anteriormente, formando um histórico que poderá ser acedido e que poderá auxiliar em muitas tarefas a que o utilizador terá acesso.

O módulo de previsão permite a previsão de energia por dispositivo IoT, com uma rotina de previsão é possível prever a potência ou energia necessária para equilibrar a oferta e a procura de carga, o que é obrigatório para o bom funcionamento da indústria elétrica. Pode ser classificado em termos de tempo como algumas horas, algumas semanas até um ano ou mais do que um ano. Pode ser feita previsão de recursos energéticos, o que lhe permitirá equilibrar o consumo e a oferta, prevendo a potência e a energia de cada dispositivo de IoT individual. É possível fazer a previsão da utilização dos IoT, que irá prever se o utilizador utiliza um determinado recurso num determinado momento e o módulo da flexibilidade energética irá prever a flexibilidade dos IoT.

Também presente na camada de *middleware* está o módulo de gestão de energia, onde é possível fazer um perfil energético do utilizador presente na parte de operação dos dados históricos, que de acordo com o perfil de utilização de recursos de um utilizador irá prever os consumos em cada momento, de acordo com os dados previamente recolhidos. Por exemplo, se o utilizador gastar uma dada quantidade de energia numa quarta-feira, o perfil energético irá prever que na quarta-feira seguinte o consumo será o mesmo. No módulo de otimização de recursos, é possível, através da leitura do consumo, fazer uma otimização energética na parte de gestão de dados em tempo real e na parte de gestão futura, ou seja, é possível fazer uma previsão da otimização que pode ser feita no futuro. Este módulo de gestão de energia também permite fazer um planeamento de *shifting*, que consiste em poder programar cargas, por exemplo, definir que um recurso se ligará num determinado momento. O sistema pode programar futuras ações de *shifting*, dentro da programação de *shifting*, o que significa que pode agendar qual será o melhor momento para realizar o *shifting*, para aproveitar os momentos em que a energia tem um custo mais baixo.

Por fim o sistema também tem incorporado um sistema de ambiente inteligente, em que tem presente o módulo de descoberta do conhecimento, que irá fazer a descoberta de correlações e de parâmetros. Este módulo servirá para fazer a modelação dos dispositivos IoT, através de correlações, caso exista correlação entre dispositivos o parâmetro que os correlaciona será otimizado. Pode ser útil na análise e modelação de dados para melhor compreender as relações entre as variáveis. A relação entre duas variáveis é referida como a sua correlação. Depois desta modulação ser feita e de serem descobertas as correlações, vai ser realizado a otimização destes dispositivos IoT, utilizando algoritmos evolucionários, tanto em tempo real, como no futuro. O sistema também tem a funcionalidade de identificar contextos em tempo real, esta funcionalidade permite através de modelos de *clustering*, a identificação de contextos permitirá perceber qual o comportamento do utilizador relativamente aos consumos energéticos tendo em conta a temperatura ambiente do exterior.

4.1.3 Camada Principal

A Camada Principal tem três módulos que são importantes para o bom funcionamento do sistema. O ficheiro de configuração funciona como um ficheiro de configuração escrito em linguagem JavaScript Object Notation (JSON) que permite adicionar diferentes dispositivos IoT

sem a necessidade de alterar o código fundamental do sistema, facilitando assim a interoperabilidade dos dispositivos IoT, uma vez que são modelados dentro deste ficheiro de configuração.

A leitura dos dispositivos IoT é feita através de *threads*, para que seja mais fácil e rápido executar a monitorização de diferentes dispositivos IoT simultaneamente, uma vez que um *thread* é uma forma de processo que se divide em várias tarefas, pelo que é possível executar outras funcionalidades do sistema enquanto os *threads* estão a funcionar e monitorizar os dispositivos IoT, isto é feito no módulo de orquestração de *threads*.

O gestor de tarefas permite gerir as tarefas que serão executadas pelo sistema, tais como iniciar a monitorização dos dispositivos IoT, iniciar a gravação de dados na base de dados, iniciar a execução de *threads*, calcular a potência total do conjunto de dispositivos IoT diferentes e fazer o agendamento de algumas tarefas, como por exemplo, executar a previsão do dia seguinte todos os dias às 22 horas.

4.2 Integração dos IoT's Heterogéneos

Com o intuito de resolver um dos maiores problemas da integração dos dispositivos IoT, esta dissertação liga dispositivos IoT heterogéneos, divididos entre sensores e atuadores. A integração dos dispositivos IoT está presente na camada de *middleware*. Fazer aplicações desenvolvidas independentemente funcionarem bem em conjunto com os dados é o objetivo desta integração. No contexto da implementação de soluções IoT, a integração dos dispositivos IoT implica fazer a combinação de novos dispositivos e de dados IoT, juntamente com elementos de Tecnologias de Informação (TI), que funcionam eficazmente em conjunto. Para ligar e integrar dispositivos IoT, o BAIS emprega a noção de controladores. Os dispositivos são modelados para compreender se podem ou não agir, pelo que uma IoT pode ser representado com o mesmo modelo independentemente do protocolo, permitindo acrescentar mais fontes de dados sem ter de reescrever o código. A configuração dos dispositivos IoT também determina a periodicidade de leitura, contudo, os protocolos *Message Queuing Telemetry Transport* (MQTT) e *Advanced Message Queuing Protocol* (AMQP) não requerem intervalos de leitura porque os dados viajam do corretor para os clientes.

A integração dos dispositivos IoT é feita através de um ficheiro de configuração escrito em *JavaScript Object Notation* (JSON), em que todos os dispositivos IoT estão listados nesse ficheiro de configuração de igual forma tendo a mesma estrutura, como pode ser visto no exemplo abaixo. O código do sistema está desenvolvido para lidar dinamicamente com este ficheiro de forma que sempre que seja adicionado um dispositivo novo, não seja preciso fazer grandes alterações e apenas seja preciso adicionar o dispositivo a este ficheiro preenchendo os campos necessários relativos ao dispositivo que se pretende adicionar. Neste ficheiro está presente o uri e o método, porque é utilizado o protocolo HTTP para aceder aos dados dos diferentes IoT. Na Figura 8 está presente um exemplo de um dispositivo IoT modelado no ficheiro de configuração.

```

"resources" : {
  "_comment" : "reading period in seconds, resource response",
  "monitoring_period" : 1,
  "IoTs" : [
    {
      "name" : "Air Conditioner 101",
      "type" : "hvac",
      "uri" : "http://192.168.1.2:4000/api/resource/analyzer1",
      "method" : "GET",
      "values" : [
        {
          "type" : "power",
          "tag" : "Ph1_P",
          "data" : "DOUBLE"
        },
        {
          "type" : "voltage",
          "tag" : "Ph1_U",
          "data" : "DOUBLE"
        },
        {
          "type" : "current",
          "tag" : "Ph1_I",
          "data" : "DOUBLE"
        }
      ],
      "control" : {
        "type" : True
      },
      "store" : {
        "period" : 10,
        "type" : "avg"
      }
    }
  ]
}

```

Figura 8 - Código do ficheiro de configuração dos dispositivos IoT

Os diferentes dispositivos IoT serão representados da mesma forma que o exemplo exposto acima, sendo que todos os dispositivos ficarão dentro da chave *resources* cada dispositivo IoT terá que ser identificado com o nome, com o tipo que identificará que tipo de IoT é, o uri de acesso ao sistema SCADA para fazer a ligação ao analisador onde está presente o dispositivo IoT, o método que é o método que será utilizado na API RESTful, os valores que serão todos os valores que serão monitorizados pelo sistema, dentro dos valores estão divisões dos diferentes valores que vão ser monitorizados e cada divisão tem diferentes chaves, como por exemplo, o tipo de valor que será indicativo do que se está a monitorizar, a *tag* que indica qual a *tag* do valor que será utilizada no uri do analisador para identificar corretamente qual o valor que será monitorizado, e por último dentro dos valores o campo *data* indica qual o tipo de dados do valor recebido, se é inteiro ou decimal. Depois da chave valores, o ficheiro de configuração tem a chave de controlo que serve para indicar se o dispositivo IoT tem controlo ou não que definirá se é um atuador ou não. E por último, na última chave *store* é definida a periodicidade de armazenamento dos dados, definindo o período de gravação e o tipo de gravação. Como se pode visualizar o ficheiro é de fácil compreensão e de fácil preenchimento, tornando assim mais fácil a adição de novos dispositivos IoT.

4.3 Mecanismo de partilha e acesso aos dados

O controlo de partilha e acesso aos dados é uma das principais funcionalidades do sistema fazendo parte da camada de conectividade da arquitetura de software (Teixeira et al., 2021). O mecanismo de acesso aos dados baseia-se nos *json web tokens* (JWT) que são utilizados para gerir o acesso aos dados e assegurar a privacidade dos utilizadores. Para a partilha de dados o BAIS fornece uma API RESTful que permite que o utilizador aceda às diferentes funcionalidades disponibilizadas pelo sistema através das diferentes rotas disponibilizadas. O mecanismo de acesso aos dados também permite fazer a participação direta dos dispositivos IoT em programas de *demand response* (Teixeira et al., 2022).

4.3.1 JSON Web Tokens

As respostas dos pedidos da API RESTful são fornecidas de acordo com o JWT, se o JWT não estiver presente ou não estiver correto nenhuma resposta será enviada quando o pedido for feito. O JWT enviado no pedido também vai definir o conteúdo que será mostrado numa rota, por exemplo, a mesma rota pode fornecer o consumo de energia em tempo real do ar condicionado ou o consumo de energia agregado de vários dispositivos IoT.

A gestão dos *tokens* é feita no módulo gestor de *tokens*, neste módulo é feita a validação e a verificação do *token*, como também a descodificação da informação do *token*. Assim que o *token* for colocado no pedido será verificado se está presente e se é um *token* válido, será verificado se a chave secreta vinda do *token* é igual à chave secreta definida no código fonte, de seguida será verificado se o *token* foi revogado, onde existirá uma ligação à base de dados onde estarão todos os *tokens* criados até ao momento e será verificado se o campo *revoke* do *token* está verdadeiro, se estiver verdadeiro significa que o *token* foi revogado e não poderá ser utilizado, ou seja, o utilizador não vai receber nenhuma resposta ao pedido realizado. Caso o token seja um *token* válido, vai ser feita a descodificação do *token*, toda a informação enviada no *payload* será descodificada, o *payload* contém informação como o nome do utilizador que fez a geração do *token*, a lista de recursos a que o utilizador terá acesso, o tipo de agregação de dados, o tipo de agregação temporal, o período de embargo e a data de expiração do *token*. Todos estes dados depois de descodificados serão enviados para o sistema para poder enviar os dados dos dispositivos IoT referentes ao utilizador que fez o pedido.

4.3.2 RESTful API

O sistema tem implementada uma API RESTful para a ligação com o utilizador, a API fornece várias rotas que terão todas as funcionalidades que o sistema dispõe. As rotas implementadas aparecem descritas na Tabela 6. Apenas a rota de geração do *token* não necessita de enviar um JWT. Todas as rotas restantes necessitam, uma vez que a resposta dependerá das permissões do utilizador. O método HTTP para a rota de geração do *token* é o POST porque os dados

precisam de ser enviados através de um formulário e os pedidos para as restantes rotas utilizarão o método GET.

Tabela 6 – Rotas disponíveis na API REST

Rota	Método
/generate_token	POST
/building/energy/historic	GET
/building/energy	GET
/building/forecast	GET
/building/correlations	GET
/building/tokens	GET

A rota */generate_token* irá permitir a criação do *token* ao utilizador, solicitando informações ao utilizador através de um formulário, permitindo assim ter informações necessárias sobre o utilizador e sobre os dados a que ele terá acesso para gerar o *token* com as devidas permissões. A rota */building/energy/historic* permite ao utilizador ver o histórico de consumos de um determinado período. A rota */building/energy* permite visualizar os dados de consumo em tempo real dos dispositivos IoT selecionados no formulário, caso o período de embargo seja superior a 0, os dados de consumo que serão mostrados nesta rota vão ter um atraso referente ao período de embargo colocado no formulário. A rota */building/forecast* exibe o forecast dos consumos energéticos para o dia seguinte descritos em períodos de uma hora. A api do sistema também tem presente uma rota que permite a visualização das correlações de uma determinada sala usando */building/correlations*, as correlações serão feitas com todos os dispositivos IoT presentes na sala associada ao utilizador. Por fim tem presente a rota */building/tokens* que permite visualizar a lista de *tokens* gerados anteriormente e permite fazer a revogação conforme a vontade do utilizador fazendo com que todos os dados associados àquele *token* não sejam mais visíveis, mantendo assim a privacidade do utilizador.

Para ilustrar a aquisição de dados e a atuação do utilizador nos dispositivos IoT num dado edifício, foi desenvolvido um diagrama de sequência representado na Figura 9. Este processo é ilustrado em forma de diagrama de sequência para melhor perceção de como funciona, tendo em consideração a segurança e a privacidade do utilizador.

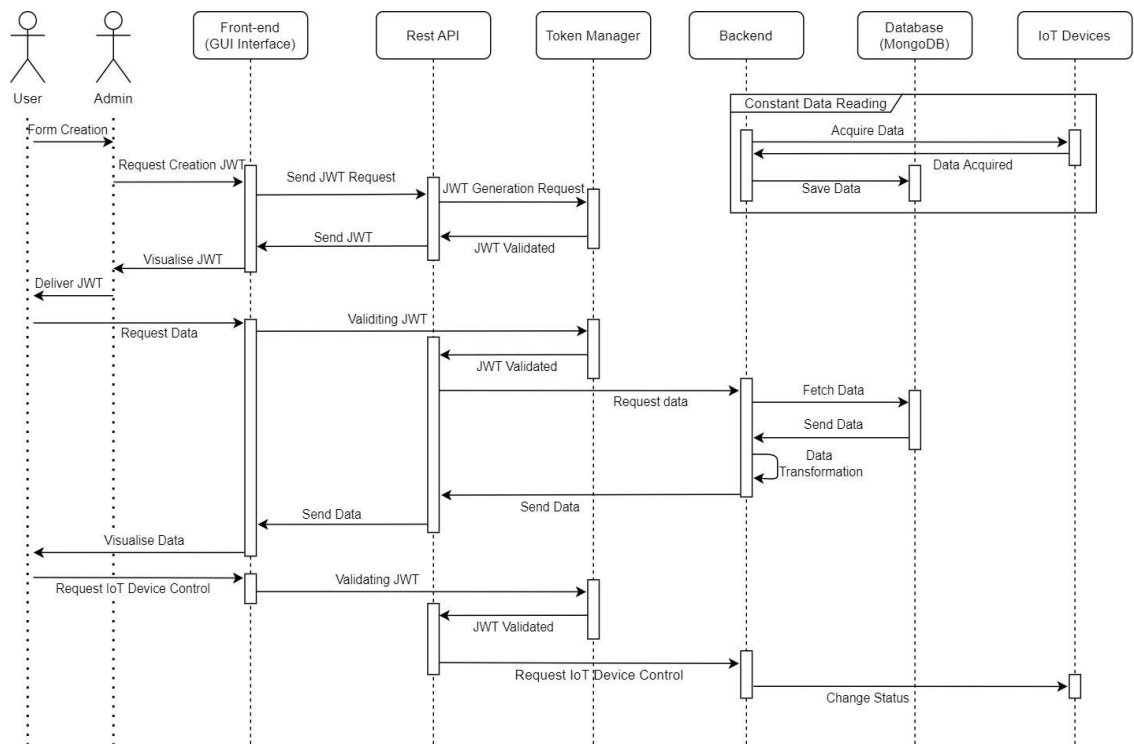


Figura 9 - Diagrama de Sequência do Processo de Aquisição dos Dados e Atuação do Utilizador

4.4 Extração de conhecimento

Este módulo de extração de conhecimento está presente na camada de *middleware*, no sistema de ambiente inteligente. Uma das principais características do sistema é que este pode fazer a modelação dos diferentes dispositivos IoT sem a necessidade de ter uma base de conhecimento ou ontologia, modelar dispositivos IoT pode ser difícil porque não há uma ontologia ou uma base de conhecimento que contenha todos os dispositivos de todas as marcas e todas as características.

Nos últimos anos, vários mecanismos de extração de conhecimento foram propostos para substituir ontologias e as bases de conhecimento nos ecossistemas da IoT. O mecanismo de extração de dados IoT sensível ao contexto extrai dados relevantes de dispositivos IoT, considerando o contexto em que os dados foram gerados. Isto pode incluir fatores tais como localização, tempo, preferências do utilizador, e condições ambientais (X. Chen & Hao, 2022). O mecanismo de extração de dados IoT baseado na semântica, extrai dados de dispositivos IoT utilizando tecnologias semânticas para compreender o significado dos dados. Esta abordagem é útil quando se lida com dispositivos de IoT heterogêneos que utilizam diferentes formatos de dados e ontologias (P. Gomes et al., 2019). O mecanismo de extração de dados IoT baseado em aprendizagem automática utiliza algoritmos de aprendizagem automática para aprender padrões nos dados da IoT e extrair dados relevantes com base nesses padrões (Lakshmana et al., 2022). O mecanismo *federated* de extração de dados IoT extrai dados de múltiplos dispositivos IoT de uma forma distribuída e descentralizada. Pode ajudar a superar alguns dos

desafios de escalabilidade e privacidade associados aos mecanismos centralizados de recuperação de dados IoT (Z. Han et al., 2022).

Estes mecanismos não dependem de uma base de conhecimentos centralizada, o que os torna mais escaláveis e tolerantes a falhas. São sensíveis ao contexto, o que melhora a precisão da extração de dados. Podem aprender com os dados e melhorar o seu desempenho ao longo do tempo. Por estas vantagens, esta dissertação irá apresentar uma solução para este problema recorrendo à extração de conhecimento inteligente através do uso de correlações e de linhas de tendência.

A função do módulo de extração de conhecimento é encontrar correlações sempre que um parâmetro novo for adicionado ao sistema, assim sempre que o sistema detetar um novo parâmetro, vai procurar atuadores ou recursos que tenham impacto nesse parâmetro, e verifica se existe correlação, se existir o atuador ou recurso poderá ser otimizado.

Esta modelação é feita desta forma para que o sistema consiga modelar-se de forma autónoma através da própria inteligência sempre que um IoT novo é adicionado ao sistema, sem ter conhecimento prévio de um modelo de conhecimento.

O sistema proposto nesta dissertação recorre ao uso de correlações de Pearson. É usado o coeficiente de correlação proveniente do cálculo das correlações, para ver o quão fortes são as relações lineares entre duas amostras de dados. O coeficiente vai retornar um valor entre -1 e 1 no qual representa o valor da correlação, sendo que 0 significa que não existe qualquer correlação. O valor deve ser interpretado, onde normalmente uma correlação perfeita é quando um valor está próximo de 1 ou de -1, uma correlação perfeita indica que quando uma variável aumenta, a outra variável aumenta também quando a correlação é positiva e se a correlação for negativa significa que uma variável está a aumentar e a outra a diminuir. Se o coef $\in [0,5..1]$ ou coef $\in [-1..-0,5]$, então pode ser dito que existe uma correlação forte. Se o coef $\in [0,3..0,5[$ ou coef $\in]-0,5..-0,3]$, então é considerada uma correlação média e se o valor é inferior a 0,29 ou superior a -0,29 é uma correlação fraca.

Para o mecanismo de extração de conhecimento funcionar corretamente, terão de ser usados dados históricos dos consumos energéticos dos dispositivos IoT que vão ser correlacionados, será necessário usar mais de 2 meses de dados para as correlações serem mais exatas e darem bons resultados.

Através da utilização da biblioteca pandas, é criado um *dataframe* com os dados em questão, com o método `corr()` disponibilizado pela mesma biblioteca é possível fazer as correlações entre os dispositivos IoT presentes nesse *dataframe*. Dentro do método `corr()` é possível especificar qual o tipo de correlação que se quer calcular, neste caso o escolhido foi a correlação de Pearson. Ao usar o método juntamente com o *dataframe* é possível obter os coeficientes de correlação entre os diferentes dispositivos IoT, todos estes coeficientes terão valores entre -1 e 1. Com os coeficientes obtidos é criada uma matriz de correlações. Para uma melhor visualização é desenhado um mapa de temperaturas com a matriz de correlações, tendo as

correlações mais relevantes cores diferentes, permitindo assim ao utilizador visualizar e identificar as correlações mais facilmente.

O principal objetivo seria extrair conhecimento através das correlações entre os diferentes dispositivos IoT. Uma das abordagens seria correlacionar o ar condicionado com os sensores de temperatura e o sistema perceber que o ar condicionado tinha impacto na temperatura ambiente da sala onde esse ar condicionado estaria instalado. Depois do tratamento dos dados, é feita a correlação entre os dois dispositivos IoT e é feita a análise dos coeficientes de correlação. Depois de uma análise detalhada verificou-se que os resultados não eram os esperados, porque quando o ar condicionado estava ligado para aquecer a correlação deveria ser positiva com o sensor de temperatura e quando o ar condicionado estava ligado para arrefecer a correlação deveria ser negativa e depois da análise dos coeficientes os sinais estavam invertidos. Chegou-se à conclusão de que esta não seria uma boa abordagem a seguir, porque depois de analisar os dados verificou-se que existiam algumas limitações nos dados.

Como forma de ultrapassar este contratempo foi pensada outra metodologia para fazer a extração de conhecimento. Utilizar linhas de tendência para perceber qual a mudança de estado das variáveis em análise. Por exemplo, no caso de correlacionar o ar condicionado com os sensores de temperatura, seria traçada a linha de tendência da temperatura dos 10 minutos antes do ar condicionado ligar, os 2 minutos após o ar condicionado ligar seriam descartados e seria traçada também a linha de tendência da temperatura dos 10 minutos após o ar condicionado ligar. Desta forma, será possível perceber se o ar condicionado tem influência na temperatura e desta forma extrair conhecimento e criar um mecanismo de extração de conhecimento.

4.5 Aprendizagem e Identificação de Contextos

Na camada *middleware* também está presente o módulo de identificação de contextos, a identificação de contextos é uma funcionalidade que cresce exponencialmente nos edifícios inteligentes, uma vez que para utilizar eficazmente todos os dados recolhidos pelos sensores é essencial compreender o contexto em que foram recolhidos. Num edifício inteligente, o contexto refere-se aos vários fatores que influenciam o comportamento dos sistemas, tais como padrões de ocupação, condições meteorológicas e preços de energia.

Ao identificar e analisar diferentes contextos, os gestores de edifícios podem obter conhecimentos valiosos. No caso da funcionalidade proposta nesta dissertação, é possível identificar contextos relativamente aos consumos energéticos tendo em conta as temperaturas meteorológicas do exterior.

Quando se trata de consumo de energia, a temperatura exterior é uma variável que pode ter um impacto significativo nos padrões de utilização de energia de um edifício. Podem ser identificados diferentes contextos diferentes contextos de utilização de energia que correspondem a diferentes temperaturas. Por exemplo, pode ser descoberto que nos dias em

que a temperatura exterior é inferior a um determinado limiar, o consumo de energia tende a ser mais elevado devido ao aumento das necessidades de aquecimento. Inversamente, nos dias em que a temperatura está acima de um determinado limiar, o consumo de energia pode ser menor devido a necessidades de arrefecimento. Ao identificar estes diferentes contextos, podem ser adquiridos conhecimentos sobre os fatores que influenciam o consumo de energia e desenvolver estratégias para otimizar a utilização de energia em diferentes condições. Esta informação pode ser utilizada para informar tomada de decisões em torno da gestão de energia.

O k-means é um algoritmo de aprendizagem automática que é utilizado nestes problemas de identificação de contextos dentro de um conjunto de dados, que podem ser definidos como diferentes conjuntos de condições ou circunstâncias que afetam o comportamento ou o resultado de um sistema.

Este sistema tem implementada a funcionalidade de identificação de contextos. Através do uso do algoritmo k-means, é possível determinar diferentes contextos. Para o uso deste algoritmo é necessário ter dados para fazer o treino e posteriormente fazer a previsão para o contexto a que os novos dados se adequam.

Inicialmente foi feita a recolha dos dados históricos gravados na base de dados desenvolvida para o sistema, de seguida foi feita uma análise e o pré processamento dos dados que foram utilizados para o treino deste modelo de *clustering*, no final do pré processamento dos dados, os dados foram agregados em períodos de 1 hora. Durante este processo foi feito também a normalização dos dados, a normalização é uma técnica de pré processamento comum para transformar os dados de entrada numa escala padrão. Faz o redimensionamento das características dos dados de entrada para assegurar que têm intervalos semelhantes e, por conseguinte, os algoritmos de ML, neste caso o algoritmo k-means poderá ser mais preciso. Neste caso os dados contêm intervalos muito diferentes, visto que se trata de dados de consumos energéticos, o que poderia enviesar os resultados, portanto foi utilizada a técnica de normalização *MinMaxScaler*.

Feito o pré processamento dos dados, o passo seguinte é determinar o número de *clusters* que serão utilizados pelo modelo k-means, para determinar este número foram usados dois métodos bastante comuns, o método *Elbow*, neste método, a soma das distâncias quadradas entre os pontos de dados e o seu centroide atribuído é traçada com diferentes valores de k. O ponto onde a mudança na soma das distâncias quadradas começa a nivelar ou a formar uma forma de cotovelo pode ser considerado como o número ótimo de *clusters*. O outro método utilizado foi o método *silhouette*, o coeficiente de *silhouette* mede a semelhança de um ponto de dados com o seu próprio *cluster* em comparação a outros *clusters*. A pontuação do *silhouette* para diferentes valores de k é calculada e o valor de k que maximiza a pontuação média é considerado o número ótimo de *clusters*.

Depois de determinar o número de *clusters*, com o conjunto de dados criado anteriormente onde estão presentes os dados dos consumos energéticos e da temperatura exterior é necessário fazer o treino do modelo de *clustering*. Com o treino vai ser possível atribuir cada

amostra a um *cluster*, que neste caso serão os diferentes contextos que serão identificados. O treino tem algumas definições específicas, como por exemplo, é utilizado o método `k-means++` que é o método utilizado para iniciar os centros dos *clusters*. Neste caso, o modelo utilizará este método que é uma variação da inicialização padrão de `k-means` que tende a ser mais eficaz. O parâmetro `max_iter` também foi iniciado a 300, este parâmetro especifica o número máximo de iterações que o algoritmo pode realizar para uma única execução. Se o modelo não convergir dentro deste número de iterações, vai parar e devolver o melhor resultado encontrado até ao momento. O parâmetro `n_init` foi iniciado a 10, este parâmetro especifica o número de vezes que o algoritmo será executado com diferentes sementes iniciais para a inicialização do centroide. Isto é feito para assegurar que se obtém o melhor resultado possível. Por fim, o parâmetro `random_state` foi definido a 0, este parâmetro especifica a semente geradora de números aleatórios, que assegura que o modelo produza os mesmos resultados de cada vez que é executado com as mesmas entradas. Isto é útil para fins de reprodutibilidade e de *debugging*.

Depois do treino é necessário dar nome aos diferentes contextos, para uma melhor interpretação do lado do utilizador. Este treino será repetido a cada semana através de uma tarefa agendada através do uso da biblioteca `schedule` e das `threads`.

A cada hora do dia, utilizando o modelo já treinado, é feita a previsão para as novas amostras presentes na base de dados e a essas amostras é atribuído um contexto. Esta tarefa é agendada para ser feita a cada hora certa do dia, como por exemplo, às 10 horas, 11 horas e por aí em diante. Toda a informação proveniente da previsão é guardada na base de dados, é adicionado o número do *cluster*, o contexto a que pertence, o consumo energético, a temperatura e a hora a que foi feita a previsão.

Desta forma é possível adquirir conhecimentos sobre como é que a temperatura exterior influencia o consumo de energia, esta informação pode ser utilizada para tomar decisões em termos de gestão energética.

4.6 Perfil Energético do Utilizador

Na camada de *middleware* no módulo de gestão de energia, o sistema dispõe da funcionalidade de traçar o perfil energético do utilizador. O perfil energético do utilizador envolve recolher e analisar dados relacionados com padrões de utilização de energia de um utilizador, tais como as horas do dia em que utilizam mais energia, os aparelhos ou dispositivos que mais usam, em que mês existe um maior consumo energético e tendo em conta a temperatura exterior. Com o perfil energético do utilizador é possível compreender padrões de utilização de energia, os utilizadores podem identificar áreas onde podem conservar energia, tais como desligar aparelhos quando não estão a ser utilizados ou ajustar o ar condicionado.

Os utilizadores podem também utilizar o perfil energético para identificar formas de poupar nas contas de energia, reduzindo o seu consumo global de energia ou deslocar o uso de energia

para horas de vazio quando as taxas são mais baixas. Com a redução do consumo de energia, os utilizadores podem ajudar a reduzir a pegada de carbono e contribuir para um futuro mais sustentável.

O perfil energético do utilizador pode ser utilizado para automatizar sistemas domésticos inteligentes, tais como desligar as luzes ou ajustar a temperatura com base nos padrões descobertos. Vários serviços podem utilizar o perfil energético para gerir períodos de pico de procura, encorajando os utilizadores a reduzir a sua utilização de energia durante períodos de alta procura.

Em geral, a definição do perfil energético do utilizador pode fornecer informações valiosas sobre os padrões de utilização de energia e ajuda os utilizadores a tomar decisões mais informadas sobre o seu consumo energético, promovendo a poupança de energia, conservação da energia e sustentabilidade.

O BAIS disponibiliza uma funcionalidade que traça o perfil energético do utilizador, através do cálculo da média dos consumos energéticos tendo em conta os dias do mês e também considerando contextos. Os dados utilizados para traçar o perfil do utilizador são recolhidos da base de dados onde estão os dados recolhidos pelo sistema. Os dados são pré processados e são retirados os *outliers*, porque há dias atípicos e pode haver problemas com o hardware que poderão tornar inviável o perfil traçado.

A funcionalidade do perfil energético do utilizador do BAIS permite através da utilização do cálculo da média do consumo energético traçar o perfil global do utilizador em cada hora de um dia ao longo de todos os dados apresentados. Este perfil é o mais simples que o sistema fornece e desta forma não há motivação para alterar comportamentos, visto que é uma representação mais genérica e por isso o sistema possibilita traçar perfis tendo em conta contextos concretos.

Um dos panoramas disponibilizados é o contexto semanal, que permite visualizar as diferenças do consumo energético durante uma semana de trabalho e do fim de semana. Outro panorama é o contexto mensal, que avalia mensalmente o perfil do utilizador, permitindo avaliar meses que são mais intensivos energeticamente. Para o último perfil tendo em conta um contexto específico o conjunto de dados teve que ser alterado e introduziram-se valores de temperatura exterior, que irão trazer uma visão diferente do perfil de consumo energético. É utilizada a média dos dias, tendo em conta o contexto térmico exterior, permitindo uma representação gráfica para diferentes intervalos de temperatura que foram identificados no conjunto de dados utilizado.

Com esta funcionalidade, o sistema permitirá informar o utilizador de estratégias de gestão de energia, como identificar áreas onde pode conservar energia ao compreender os diferentes padrões, pode também servir para prever os consumos energéticos e incentivar os utilizadores a deslocar a sua utilização de energia para horas do dia em que são cobrados preços diferentes.

4.7 Algoritmos de Previsão de consumos de energia elétrica

O sistema dispõe de um módulo de previsão na camada de middleware. Este módulo permite a previsão da energia agregando cada previsão energética dos dispositivos IoT. Será permitido ao utilizador fazer a previsão da energia para a próxima hora ou horas. Além disso, este módulo permite fazer a previsão do uso de IoT's, que prevê se um utilizador usa um determinado recurso a um dado momento e permite ainda a previsão da flexibilidade da energia do dispositivo IoT.

A funcionalidade de poder ser feita a previsão dos consumos energéticos, traz muitas vantagens para quem utiliza o sistema, como redução de custos, ao prever com previsão o consumo de energia, os edifícios podem ajustar o consumo de energia e podem planear em conformidade, o que pode levar a poupanças de custos a longo prazo.

Pode melhorar a eficiência energética, com um modelo de previsão, os edifícios podem identificar padrões e tendências no uso de energia, o que pode ajudar a otimizar o consumo energético e a melhorar a eficiência energética. Pode também melhorar a atribuição de recursos, pode ajudar os edifícios a alocar os seus recursos de forma mais eficaz e evitar desperdícios, tais como sobreprodução ou excesso de inventário. Ajuda também a reduzir a pegada de carbono e contribui para um futuro mais sustentável, permitindo um melhor planeamento e gestão dos recursos energéticos. Com tudo isto, é possível tomar decisões informadas sobre o uso e planeamento da energia, o que pode conduzir a melhores resultados e a um melhor desempenho.

Em geral, um modelo de previsão do consumo de energia pode proporcionar benefícios significativos às empresas, incluindo poupança de custos, melhor eficiência energética, melhor atribuição de recursos, melhor sustentabilidade e maior capacidade de tomada de decisões.

O sistema fornece a funcionalidade de poder fazer a previsão do consumo de energia através de 3 diferentes modelos de aprendizagem automática. Para estes modelos poderem funcionar corretamente é necessário terem acesso a um vasto conjunto de dados com os consumos energéticos referentes a um edifício. Primeiramente são recolhidos os dados históricos da base de dados do sistema, depois são retirados todos os *outliers*. Os dados são agregados em períodos de 1 hora para um melhor desempenho do modelo uma vez que o objetivo é ter-se a previsão do dia seguinte em períodos de 1 hora. De seguida aos dados são normalizados para transformar os dados numa escala padrão. Faz o redimensionamento das características dos dados de entrada para assegurar que têm intervalos semelhantes.

Os dados são então divididos em dados de treino, teste e validação. Como são dados de series temporais, os dados são divididos temporalmente, sendo que, os dados de teste são 2 semanas e os dados de validação também são 2 semanas. Os dados são preparados para serem utilizados nos modelos que requerem dados introduzidos sob a forma de sequências de um comprimento fixo, os dados são divididos em sequências mais pequenas de comprimento 3.

Os dados são transformados num formato de aprendizagem supervisionada adequado para treinar um modelo de aprendizagem automática. Os dados são reformulados em dois *arrays* que contêm as sequências de entrada, *X*, e as sequências de saída *Y*. Os *arrays* ficam com a forma de (amostras, número de *inputs*, 1) e (amostras, números de *outputs*), respetivamente.

A funcionalidade de previsão fornece três modelos, tais como, uma *convolutional neural network*, *Long Short-Term Memory (LSTM) neural network* e um método de aprendizagem *ensemble eXtreme Gradient Boosting (XGBoost)*. O principal motivo para a escolha destes três modelos foi a possibilidade de poder compará-los e perceber qual o melhor modelo para este problema.

O modelo de *convolutional neural network* é usado para uma tarefa de regressão, em que o objetivo é prever um valor de saída contínuo. Os dados de entrada devem ter uma forma de (amostras, *timesteps*, características), onde as amostras são o número de amostras no conjunto de dados, os *timesteps* são o número de etapas de tempo em cada sequência de amostras e as características são o número de características em cada *timestep*.

A arquitetura do modelo consiste nas seguintes camadas:

- camada inicial Conv1D, esta camada aplica uma operação de convolução 1D com 100 neurónios, um *kernel_size* de 2 e a função de ativação utilizada é a ReLU;
- camada *flatten*, esta camada alisa a saída da camada anterior num *array* 1D;
- camada *dense*, esta camada contém 100 neurónios com função de ativação ReLU;
- camada *dense*, esta é a camada de saída, com o número de neurónios igual à quantidade de horas que se quer prever.

O modelo é compilado com a função *mean squared error* (MSE) e com o otimizador *adam*. O treino decorre durante 2 épocas, ou seja, duas passagens por todo o conjunto de dados de treino, com um *batch size* de 6 amostras por *batch*. O parâmetro *verbose* controla a quantidade de informação sobre o treino. Neste caso, é definido como 2, o que significa que as mensagens do progresso de treino são impressas para cada época.

As *convolutional neural networks* (CNNs) são um tipo de rede neuronal que são particularmente adequadas para tarefas de reconhecimento e processamento de imagem. Contudo, também podem ser utilizadas para tarefas de previsão, especialmente quando se trata de dados de séries temporais. Uma das principais vantagens da utilização de CNNs para a previsão é a sua capacidade de extrair automaticamente características dos dados introduzidos. Isto é feito através da utilização de *convolutional filters*, que são aplicados aos dados de entrada para extrair padrões espaciais que são relevantes para a tarefa de previsão. Ao fazer isto, as CNNs podem identificar e aprender padrões e relações importantes entre as entradas e saídas, o que pode ajudar a melhorar a precisão da previsão. No entanto, é de notas que as CNNs nem sempre são a melhor escolha para tarefas de previsão. Em alguns casos, outros tipos de redes neuronais

como as redes *Long Short-Term Memory* (LSTM) podem ser mais adequadas, dependendo das características específicas dos dados e da tarefa de previsão.

O modelo de LSTM é definido para uma tarefa de regressão, onde o objetivo é o mesmo que o do modelo de CNN apresentado anteriormente. Os dados de entrada devem ter uma forma de (amostras, *timesteps*, características), onde as amostras são o número de amostras no conjunto de dados, os *timesteps* são o número de etapas de tempo em cada sequência de amostras e as características são o número de características em cada *timestep*.

A arquitetura do modelo consiste nas seguintes camadas:

- camada LSTM, esta camada tem três neurónios e utiliza a função de ativação ReLU, a forma de entrada é (número de *timesteps*, número de características);
- camada *dense*, esta camada tem 200 neurónios com ativação ReLU;
- camada *dense*, esta camada também tem 200 neurónios com ativação ReLU;
- camada *dense*, esta é a camada de saída, com o número de neurónios igual à quantidade de horas que se quer prever.

O modelo é compilado com a função de perda de *mean squared error* (MSE) e o otimizador *adam* com uma taxa de aprendizagem de 0.0005. O processo de treino decorre durante 60 épocas, ou seja, 60 passagens por todo o conjunto de dados de treino, com um *batch size* de 4 amostras por *batch*. O parâmetro *verbose* é definido a 1, o que significa que as mensagens de progresso serão impressas para cada época.

As LSTMs são um tipo de rede neuronal recorrente que são adequadas para tarefas de previsão, especialmente quando se trata de dados de séries temporais. Uma vantagem de usar LSTMs para previsão é a sua capacidade de capturar dependências a longo prazo nos dados de entrada. Ao contrário das redes neuronais tradicionais *feedforward* ou até mesmo de outros tipos de redes neuronais recorrentes, as LSTMs têm um mecanismo para recordar seletivamente ou esquecer informações ao longo do tempo. Isto permite-lhes captar padrões complexos nos dados introduzidos que podem ser difíceis de aprender por outros modelos. Outra vantagem das LSTMs é a sua capacidade de lidar com entradas sequenciais, ou seja, entradas que chegam ao longo do tempo. As LSTMs são concebidas para trabalhar com sequências de dados e têm um mecanismo para manter um estado interno que pode ser atualizado a cada *timestep*. Isto torna-as adequadas para tarefas como previsão de séries temporais, em que os dados de entrada são uma sequência de observações ao longo do tempo.

Em geral, as LSTMs são uma ferramenta poderosa para a previsão de séries temporais e são amplamente utilizadas numa variedade de aplicações, incluindo no setor energético. Contudo, como qualquer outra técnica, o seu desempenho depende das características específicas dos dados.

No modelo de XGBoost os dados foram divididos de forma diferente utilizando o *TimeSeriesSplit* da biblioteca *scikit-learn* para a validação cruzada. Divide-se o conjunto de dados em dois intervalos de tempo consecutivos, com um intervalo de 24 horas entre eles e usa cada intervalo como um conjunto de teste numa só dobra e o restante como o conjunto de treino. O parâmetro *test_size* define o tamanho do conjunto de testes, que neste caso é 24152, indicando o valor de 15 dias de dados em cada conjunto de teste.

De seguida, são adicionadas diferentes características adicionais relacionadas com a data ao conjunto de dados, tais como a hora, dia da semana, mês, ano, entre outras. Estas características ajudam na captura de padrões e sazonalidade dos dados e podem melhorar o desempenho do modelo de previsão.

Foi criada uma função para adicionar versões desfasadas do *totalpower* ao conjunto de dados. Especificamente adicionada três características desfasadas chamadas, *lag1*, *lag2*, *lag3*, que correspondem aos valores de *totalpower* 29, 58 e 87 dias atrás, respetivamente. Estas características podem fornecer informações úteis sobre tendências e sazonalidade nos dados e podem potencialmente melhorar a precisão do modelo de previsão. A adição de desfasamentos como características pode ser útil nas tarefas de previsão porque permite ao modelo incorporar observações passadas como input, o que pode melhorar a sua capacidade de capturar tendências e padrões nos dados. Ao adicionar desfasamentos, o modelo pode aprender a identificar dependências e correlações entre valores passados e atuais e utilizar esta informação para fazer melhores previsões para períodos futuros.

O modelo de XGBoost usa a classe *XGBRegressor* da biblioteca XGBoost que implementa um algoritmo de *gradient boosting* para problemas de regressão. Os parâmetros passados para o construtor foram:

- o *base_score* que é a pontuação inicial de previsão de todas as instâncias, definida a 0,5;
- o *booster* que é o tipo de *booster* a utilizar. Neste caso, o *booster* é o *gbtree*, que constrói árvores de decisão;
- o *n_estimators*, que é o número de árvores de decisão a construir. Neste caso, serão construídas 1000 árvores;
- o *early_stopping_rounds*, que é o número de rondas a esperar antes de parar o processo de treino, se a pontuação de validação não melhorar;
- o *objective* que é a função de perda a utilizar. Neste caso, o objetivo *reg:linear*, que é apropriado para problemas de regressão;
- o *max_depth* que é a profundidade máxima de cada árvore de decisão. Neste caso, cada árvore terá uma profundidade máxima de 3;

- o *learning_rate* que é a taxa de aprendizagem, a diminuição do tamanho utilizado evita o *overfitting*. Neste caso, é utilizada uma pequena taxa de aprendizagem de 0,01.

O objeto resultante, é uma instância da classe `XGBRegressor` que pode ser treinado e utilizado para fazer previsões. O XGBoost é particularmente útil para tarefas de previsão porque é um poderoso método de *ensemble learning*, que combina múltiplas árvores de decisão para fazer previsões. O XGBoost tem várias vantagens para tarefas de previsão, como alta precisão, pode alcançar alta precisão em comparação a outros algoritmos, graças á sua capacidade de lidar com relações complexas nos dados. Outra vantagem é o fornecimento de uma pontuação de importância de características para cada variável no conjunto de dados, o que pode ajudar a identificar os previsores mais importantes da previsão. O XGBoost utiliza regularização para evitar o *overfitting*, que é um problema comum em tarefas de previsão onde o modelo pode tornar-se demasiado complexo e não conseguir generalizar bem com novos dados. É concebido para lidar com grandes conjuntos de dados e pode ser executado em sistemas distribuídos para melhorar o desempenho.

Em geral, o XGBoost é um algoritmo poderoso e flexível que pode ser utilizado para uma vasta gama de tarefas de previsão e tornou-se uma escolha popular entre muitos cientistas de dados, profissionais de aprendizagem automática e em muitas competições de previsão no Kaggle.

As métricas de avaliação utilizadas para medir o desempenho dos modelos de previsão foram o *relative absolute error* (RAE) e *mean absolute percentage error* (MAPE). São métricas de avaliação normalmente utilizadas para medir o desempenho dos modelos de previsão.

O RAE mede a proporção da diferença entre os valores previstos e os valores reais em relação aos valores reais. É definido como a soma das diferenças absolutas entre os valores previstos e reais dividida pela soma das diferenças absolutas entre os valores reais e a sua média. O RAE pode ser expressa como uma percentagem multiplicando o resultado por 100. O RAE é útil para comparar o desempenho de diferentes modelos, pois é uma medida relativa e é menos sensível a valores aberrantes do que outras métricas, tais como o *mean squared error* (MSE). Um RAE mais baixa indica um melhor desempenho, com 0 indicando um ajuste perfeito.

O MAPE mede a diferença percentual absoluta média entre os valores previstos e os valores reais. É definido como a soma das diferenças absolutas entre os valores previstos e os reais dividida pela soma dos valores reais e multiplicada por 100. O MAPE é útil para medir a precisão das previsões em termos de erro percentual. Contudo, o MAPE tem uma limitação na medida em que não pode ser utilizada quando os valores reais são zero ou próximos de zero, uma vez que o erro percentual se torna indefinido. Além disso, o MAPE coloca mais peso em grandes erros, o que pode distorcer o resultado global.

Também para fazer uma avaliação dos modelos foi utilizado um diagrama de Taylor. Um diagrama de Taylor é uma técnica gráfica utilizada para avaliar o desempenho de múltiplos modelos em múltiplas métricas de avaliação em simultâneo. É um gráfico de coordenadas polares que exhibe o coeficiente de correlação, o *root mean square error* (RMSE) e o desvio

padrão da amplitude das observações. Cada modelo é representado por um ponto no diagrama e a distância entre o ponto e o ponto de referência representa a *root mean square deviation* (RMSD) entre o modelo e as observações.

As vantagens de utilizar um diagrama de Taylor para avaliar o desempenho destes modelos de previsão são:

- Permitir uma comparação visual de múltiplos modelos ao mesmo tempo, o que pode ser útil na identificação do modelo com melhor desempenho;
- Pode destacar os pontos fortes e fracos de cada modelo, assim como as semelhanças e diferenças entre eles;
- Fornece uma avaliação exaustiva do desempenho dos modelos, tendo em conta as múltiplas métricas de avaliação.

Em geral, um diagrama de Taylor pode ser uma ferramenta útil para avaliar o desempenho dos modelos de previsão, mas deve ser utilizado em combinação com outras métricas de avaliação para obter uma imagem mais completa da precisão e fiabilidade dos modelos. Na Figura 10 pode ver-se um exemplo de um diagrama de Taylor.

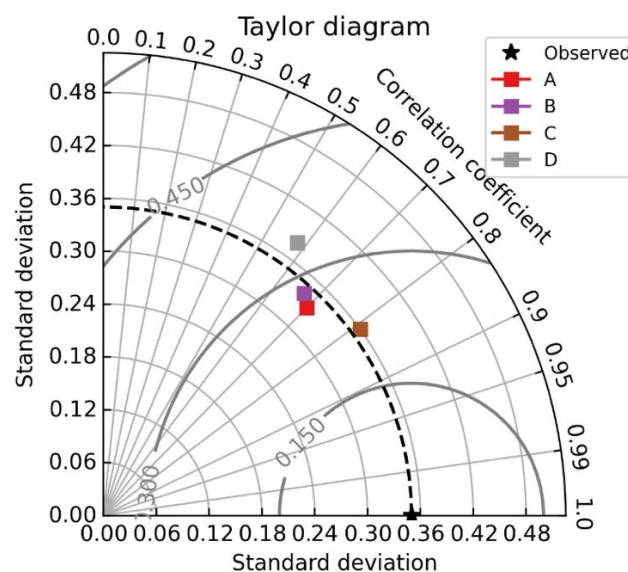


Figura 10 - Exemplo de um diagrama de Taylor

4.8 Interface gráfica do BAIS

A interface gráfica do BAIS foi desenvolvida com o intuito de facilitar a visualização e a manipulação dos dados por parte do utilizador, permitindo que tenha uma melhor gestão dos

consumos energéticos. A interface gráfica está conectada com a API REST, todas as rotas vão alimentar as diferentes páginas web presentes na interface.

A interface gráfica funcionará como um painel de controlo, e cada página web permitirá fazer cada uma das diferentes funcionalidades permitidas pelo sistema. Tais como preencher um formulário com os campos necessários para a geração do JWT, visualizar os dados dos consumos energéticos em tempo real, visualizar os dados históricos dos consumos energéticos dos dispositivos IoT associados ao utilizador, visualizar o mapa de temperatura relacionado com as correlações pedidas pelo utilizador, pode também visualizar um gráfico da previsão dos consumos energéticos do dia seguinte e por fim o utilizador poderá visualizar a lista de *tokens* com a possibilidade de revogar os *tokens*. Cada uma destas funções está associada a uma rota da interface gráfica que permite o acesso ao utilizador.

A página web para gerar o *token* pertence à rota */generate_token*, esta página web permite aceder ao formulário de geração do *token*. O formulário criado em *Vue.js* irá beneficiar o utilizador tornando a criação do *token* mais fácil e simples, sendo que este só necessitará de preencher alguns campos e através dos *inputs* dados nesses campos o *token* irá ser criado. Cada campo será enviado para o método de codificação do *payload* do JWT, tornando-se num documento JSON onde de seguida é codificado e passa a fazer parte da estrutura do JWT. Na Figura 11, encontra-se representado o formulário criado para a geração dos *tokens*, no qual se encontram os diferentes campos necessários para a sua criação.

Generation Token Form

NAME:
Nuno Teixeira

LIST OF RESOURCES:
Air Conditioner 101 X Air Conditioner 102 X Air Conditioner 103 X
Add Tag

DATA AGGREGATION:
 Individual
 Aggregated

TIME AGGREGATION:
 Real-Time
 5 Minutes
 15 Minutes
 60 Minutes

EMBARGO PERIOD:
0

EXPIRATION DATE:
2022-09-30 to 2022-10-14

Submit

eyJ0eXAiOiJKV1QiOiJhbnRpdG9mbyB1Zm9udGVudCIsImVudCI6ImN1bn0uIiwiaWF0IjoiMjAyMi00OS0zMCJ9.eyJ0eXAiOiJKV1QiOiJhbnRpdG9mbyB1Zm9udGVudCIsImVudCI6ImN1bn0uIiwiaWF0IjoiMjAyMi00OS0zMCJ9.eyJ0eXAiOiJKV1QiOiJhbnRpdG9mbyB1Zm9udGVudCIsImVudCI6ImN1bn0uIiwiaWF0IjoiMjAyMi00OS0zMCJ9

Copy Token

Figura 11 - Formulário de geração do JSON Web Token

Cada campo é imprescindível para a criação do *token*, sendo que todos os campos são de preenchimento obrigatório. O nome do utilizador é necessário para saber a quem é que o JWT foi atribuído e quem o solicitou. A lista de recursos permite saber a que IoT terá acesso para poder visualizar os consumos de cada recurso escolhido. Por exemplo, se forem selecionados o ar condicionado e o frigorífico, apenas serão mostrados os consumos destes dois recursos, enquanto que, se nesta lista de componentes selecionarmos o edifício, serão mostrados todos os recursos associados ao edifício. O tipo de agregação de dados fará com que os dados apareçam agregados da forma que o utilizador escolher, ou seja, se o utilizador quiser ver os dados agregados individualmente, será mostrado o consumo energético de cada IoT separadamente, e se apenas tiver acesso aos dados agregados dos recursos, será mostrado a soma do consumo energético de todos os recursos selecionados pelo utilizador. O tempo de agregação permite ao utilizador escolher como serão agregados os dados em termos de intervalo de tempo, o que significa que pode escolher ver os dados em tempo real, agregados em períodos de 5 minutos, de 15 minutos ou de 60 minutos. O período de embargo é um aspeto importante deste pedido, porque permitirá ao utilizador definir um atraso para a visualização dos dados que permitirá manter a privacidade e segurança do utilizador, uma vez que, através dos consumos energéticos é possível tirar várias conclusões sobre o utilizador, principalmente sobre a utilização de dispositivos IoT específicos, o que permitirá saber se o utilizador está presente ou não no seu local de trabalho ou em casa. O que este período de embargo faz é dar um atraso aos consumos para que quem quer que esteja a visualizar os dados não possa ver os consumos em tempo real, mantendo assim a segurança do utilizador, porque nunca vai estar a ver os dados dos consumos energéticos em tempo real.

E finalmente, a data de expiração do *token* é utilizada para definir um tempo de validade, é permitido selecionar o dia em que o *token* é solicitado e o dia em que o utilizador deixará de ter acesso ao *token*, de modo que, quando o tempo limite é atingido este já não seja válido, e o utilizador perca o acesso aos dados de consumo relativos àquele *token*.

A página web relativa à visualização dos consumos energéticos em tempo real está associado à rota */building/energy*. Esta página web apresenta um campo de preenchimento obrigatório onde será colocado o *token* de acesso aos dados para o utilizador poder visualizar os dados de consumo dos IoT associados ao seu *token*. Os dados são apresentados na forma de ficheiro JSON, numa caixa de texto sem a possibilidade de escrita, com a identificação do IoT. Esta página web apresenta dados diferentes de acordo com a permissão, tanto pode apresentar os dados de consumo de cada IoT referente ao utilizador como poderá apresentar a soma dos consumos dos IoTs. Na Figura 12 pode ser visualizada a página web *bulding energy*.

A página web *building historic* demonstra os dados dos consumos históricos e está associado à rota */building/historic*. Nesta página web pode visualizar-se uma caixa de texto de preenchimento obrigatório para apresentar o *token* de acesso aos dados, e depois do *token* ser inserido e validado, o utilizador terá acesso a um gráfico com os dados históricos dos consumos energéticos das últimas vinte e quatro horas, com a divisão por cores dos diferentes dispositivos associados ao utilizador.

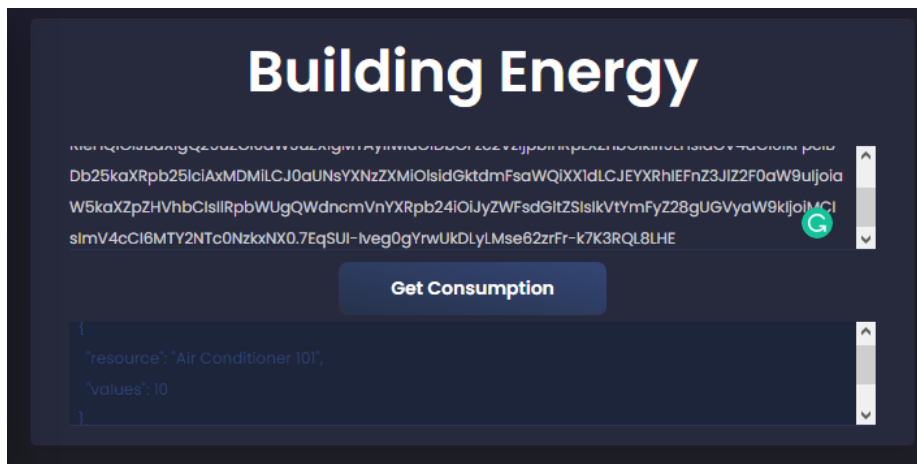


Figura 12 - Página Web *Building Energy*

Na Figura 13 é possível ver uma representação da página web referente ao histórico de consumos de alguns recursos. A interface gráfica tem também uma página web que contém a previsão energética do utilizador, a rota que está conectada a esta página web é */building/forecast*. Pode visualizar-se um campo de preenchimento obrigatório para usar o *token* de acesso aos dados, que dará acesso ao gráfico da previsão dos consumos energéticos do dia seguinte. Os dados de previsão são apresentados num gráfico de linhas em períodos de uma hora. Na Figura 14 é possível visualizar-se um exemplo do gráfico gerado pela página web da previsão.

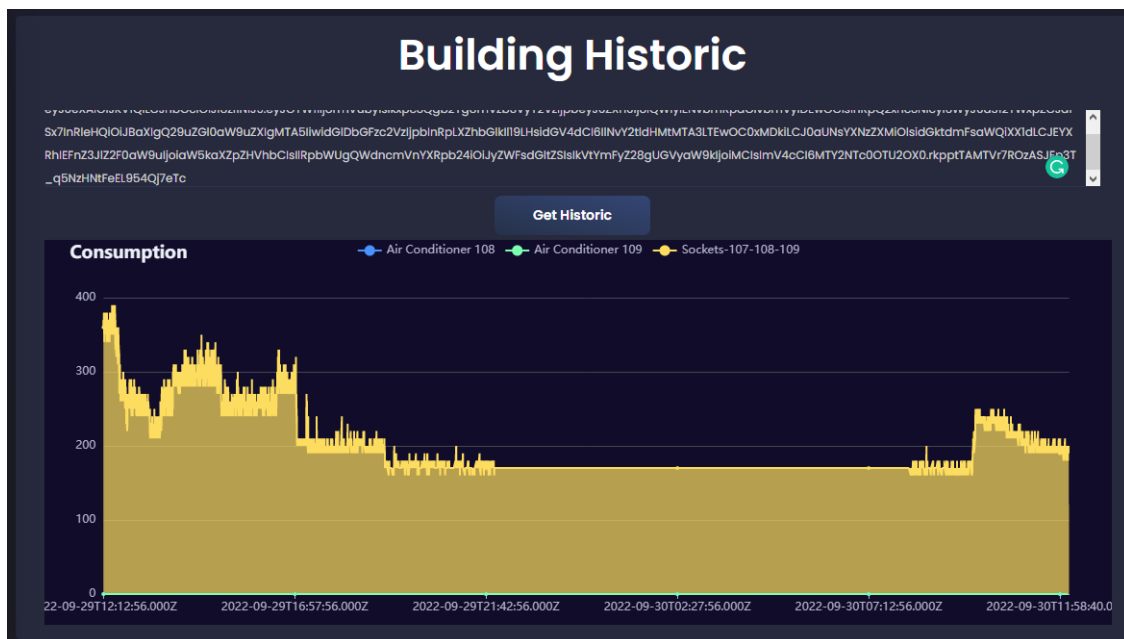


Figura 13 - Página Web *Building Historic*

As correlações calculadas pelo sistema, também podem ser visualizadas na interface gráfica, na página web relacionada com as correlações que está associada à `/building/correlations`. É apresentado o mapa de temperatura da matriz de coeficientes da correlação de Pearson relacionado com os sensores e atuadores presentes na sala a que o utilizador está associado, cada coeficiente é representado com cores diferentes para ser mais fácil detetar as correlações mais relevantes. Na figura 15 pode ver-se um exemplo de como são exibidas as correlações na página web.

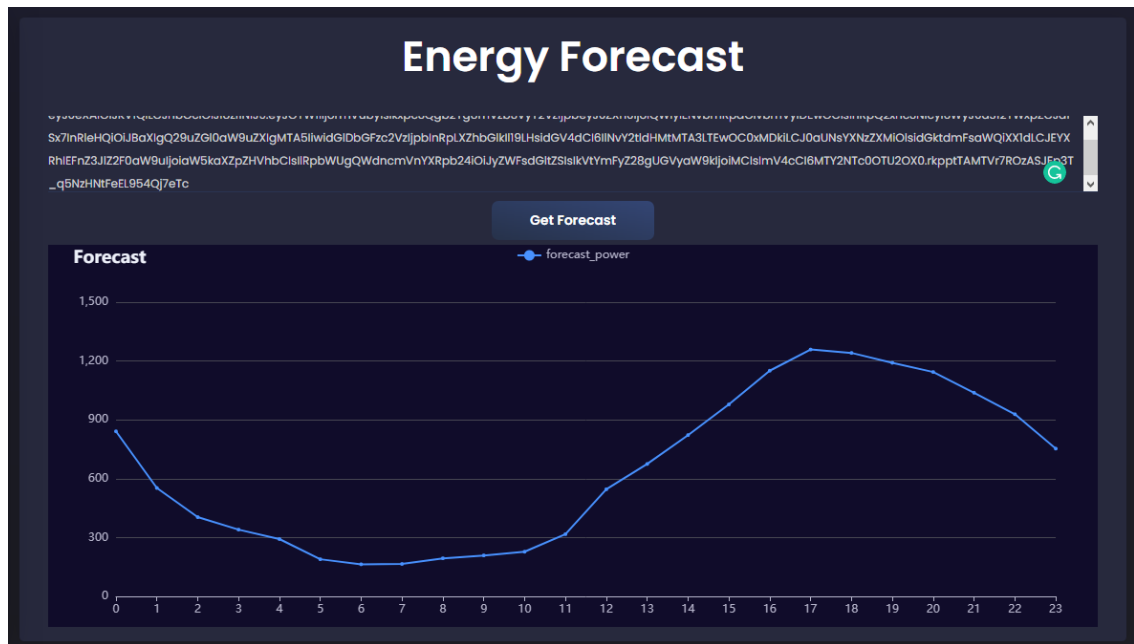


Figura 14 - Página Web *Energy Forecast*




Figura 15 - Página Web das Correlações

O BAIS também tem incorporado um módulo de gestão de energia que permitirá utilizar as diferentes funcionalidades propostas para melhorar a eficiência energética dos edifícios, aumentando assim a sua sustentabilidade.

Além disto, a linguagem de programação utilizada, Python, para desenvolver todo o sistema proposto é modular e extensível, permitindo a adição de novas funcionalidades que podem melhorar o funcionamento do sistema, tal como o facto do sistema ter um ficheiro de configuração que permitirá serem adicionados novos dispositivos IoT sem ser preciso a alteração do código base do sistema.

5 Casos de Estudo

Neste capítulo serão apresentados os casos de estudo propostos das funcionalidades integradas no sistema baseado em dispositivos IoT para testar e validar o sistema proposto. Serão apresentados casos de estudo que já foram apresentados anteriormente em publicações científicas. Neste capítulo vão ser testados quatro cenários onde a IoT está a ser aplicada, a integração dos IoTs e o mecanismo de acesso aos dados onde vai ser testada e avaliada a integração dos dispositivos IoT no sistema e o mecanismo de acesso aos dados criado. O perfil e a previsão de consumos energéticos onde vão ser testados os diferentes modelos de previsão desenvolvidos e também o perfil do utilizador que é traçado pelo sistema. Os contextos inteligentes onde vai ser testado o modelo de *clustering* desenvolvido no sistema para avaliar a capacidade de identificar os diferentes contextos de forma inteligente. E por último, irá ser examinada a participação direta dos dispositivos IoT em programas de *demand response*. Estes quatro casos de estudo ilustram as diversas aplicações que o sistema oferece. Através destes casos de estudo, serão analisadas as principais características e desafios de cada aplicação e serão fornecidas informações sobre a conceção e implementação de soluções de IoT em diferentes contextos.

5.1 Integração de IoTs e mecanismo de acesso a dados

Este caso de estudo pretende testar e avaliar a capacidade de integração dos diferentes dispositivos IoT de diferentes produtores e marcas no mesmo sistema. E é pretendido também com este caso de estudo avaliar o mecanismo de acesso aos dados que utiliza JWT, para perceber se é um mecanismo fiável para aceder aos dados sem haver a possibilidade de estes serem acedidos por terceiros. Este caso de estudo foi apresentado na seguinte publicação, apenas as imagens foram substituídas para a representação da interface gráfica do utilizador:

- **Nuno Teixeira**, Luis Gomes, and Zita Vale, "Data Access Mechanism to Allow Multiple Level Permissions in Energy Management Solutions Supported by IoT devices," 2021 IEEE International Conference on Environment and Electrical Engineering and 2021 IEEE

O mecanismo de acesso aos dados foi testado e validado com dados reais (relativos a um edifício de escritórios). O caso de estudo definido considera um edifício de co trabalho onde os espaços são subarrendados a vários utilizadores. No qual temos três tipos de entidades: o proprietário do edifício, o utilizador do edifício, e o operador da *microgrid*. Este caso de estudo irá analisar o potencial do sistema para a sua capacidade de manter a privacidade dos dados dos seus utilizadores. Desta forma, o utilizador de um escritório só pode aceder os dados agregados de consumo (15 minutos de agregação) da sala que aluga, o gestor da *microgrid* pode aceder aos dados agregados do edifício (15 minutos de agregação), e o proprietário do edifício pode aceder aos dados do edifício em tempo real.

A plataforma foi montada num edifício que já possuía um sistema de controlo de supervisão de dados (SCADA) com vários analisadores de energia. Cada local de trabalho contém sensores IoT que monitorizam a utilização de energia e estão ligados ao sistema SCADA e integrados na através de HTTP. O gestor do edifício é responsável pela geração do JWT, que será único para as entidades, ou seja, os utilizadores que alugam um local de trabalho, o operador da *microgrid* e o proprietário do edifício.

O *token* para o utilizador que vai alugar o escritório é gerado no momento do aluguer e durará o mesmo tempo que o contrato de aluguer, após o contrato de aluguer expirar, o utilizador já não tem acesso aos dados do escritório, e o *token* expira, dando a possibilidade ao utilizador de poder pedir para apagar todos os dados que foram recolhidos enquanto esteve presente no escritório em questão.

Como foi anteriormente referido, o proprietário do edifício tem acesso em tempo real aos dados do edifício, enquanto o outro só tem acesso aos dados agregados de 15 em 15 minutos. No que diz respeito à rota `"/building/energy"`, que fornece dados de consumo, o gestor do edifício tem acesso ao consumo detalhado por dispositivo, o utilizador que alugou um espaço de trabalho tem acesso ao consumo detalhado dos seus dispositivos, e o operador da *microgrid* tem acesso apenas ao consumo total do edifício. De acordo com a permissão do JWT, o percurso apenas devolve os valores mais recentes medidos, por exemplo, o gestor do edifício recebe dados em tempo real, enquanto as outras duas entidades recebem dados dos 15 minutos anteriores, sendo este um valor único.

As Figuras 17-19 mostram o resultado das leituras de três dispositivos IoT durante o período de três horas. A Figura 17 mostra os consumos dos dispositivos IoT lidos pelo proprietário do edifício, sendo que pode ser visualizado que os dados estão presentes em tempo real. A Figura 18 mostra os consumos dos dispositivos IoT vistos do ponto de vista de um utilizador de um escritório e estão agregados de 15 em 15 minutos.



Figura 17 - Dados energéticos lidos pelo proprietário do edifício

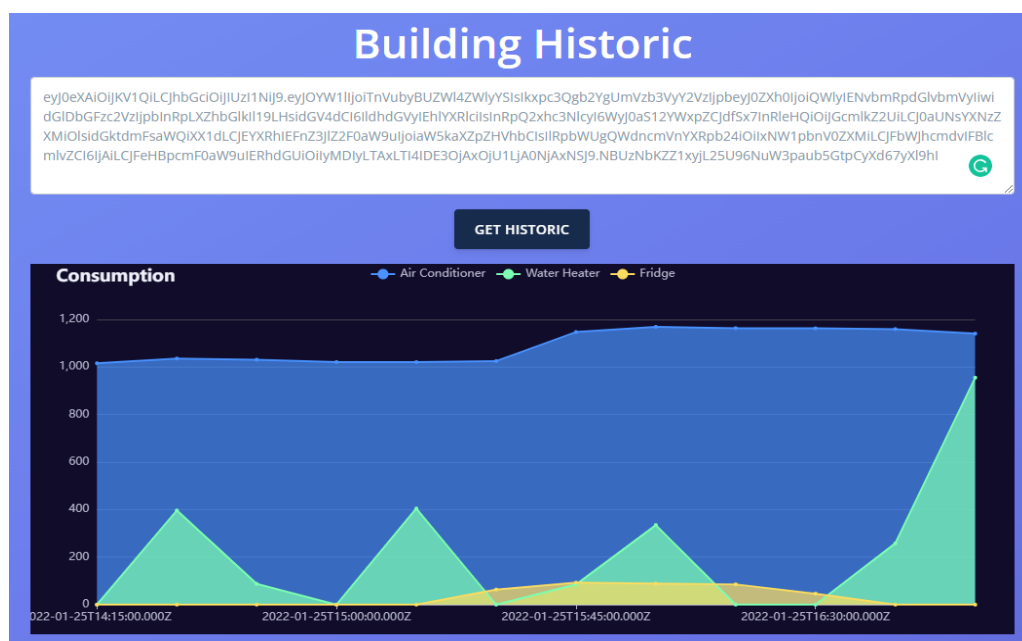


Figura 18 - Dados energéticos lidos pelo utilizador de um escritório

A Figura 19 mostra o consumo total dos dispositivos IoT agregados de 15 em 15 minutos que é visto pelo gestor da *microgrid*. Ao alterar o tipo de acesso aos dados, é possível partilhar diferentes pontos de vista com diferentes entidades numa comunidade. As figuras acima são uma saída direta da plataforma web desenvolvida. Contudo, todos os *tokens* podem ser utilizados numa API RESTful onde os dados são partilhados em documentos JSON. Os gráficos das Figuras 17, 18 e 19 foram criados utilizando a mesma rota (*/building/energy/historic*) mas com diferentes JWT, correspondendo às três entidades envolvidas neste caso de estudo. Desta

forma, é possível garantir a segurança dos dados, tanto para os utilizadores que alugam um escritório como para o edifício.

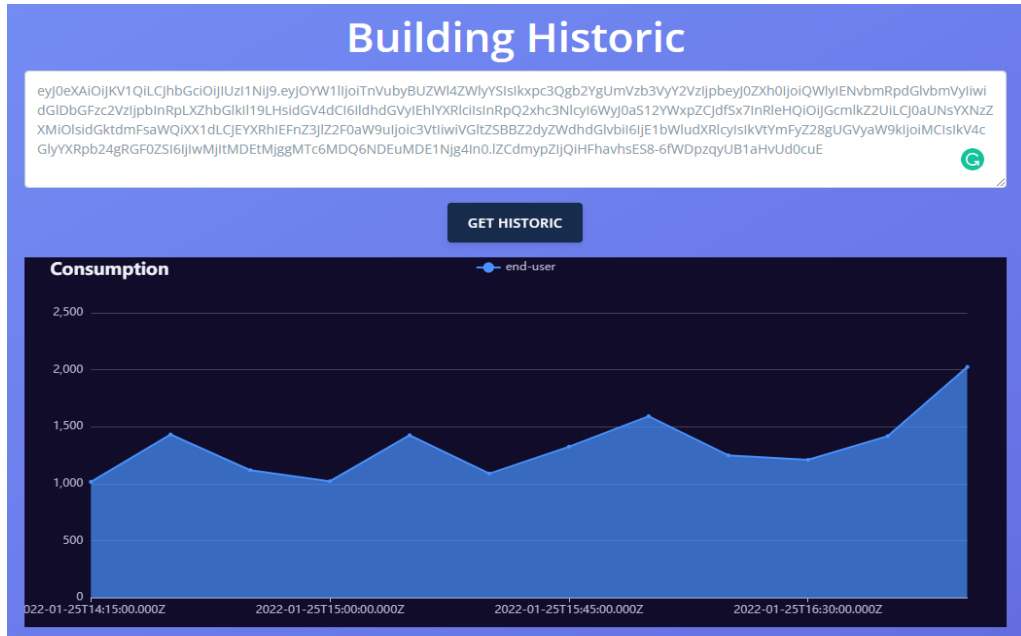


Figura 19 - Dados energéticos lidos pelo gestor da *microgrid*

5.2 Perfil e Previsão de consumos energéticos

Para este caso de estudo, o BAIS foi integrado num edifício de investigação do centro de investigação do autor (GECAD). Para este edifício de investigação foram implantados múltiplos dispositivos IoT que foram instalados com o objetivo principal de transformar o edifício num edifício inteligente capaz de ser monitorizado e controlado remotamente. O caso de estudo dará ênfase à capacidade do BAIS de fornecer previsões autónomas do consumo de energia do dia seguinte do edifício inteligente e de fornecer o perfil energético do utilizador. Os modelos de previsão permitirão a participação do edifício inteligente em programas de *demand response*.

O perfil energético do utilizador utiliza dados históricos para poder ser traçado o perfil com base em experiências anteriores. O perfil energético do utilizador é calculado através do cálculo da média dos consumos energéticos tendo em conta os dias do mês e também considerando contextos.

Os modelos de previsão do dia seguinte utilizam dados históricos para fazer o treino necessário para determinar o consumo de energia para o dia seguinte. Estes modelos de previsão serão executados todos os dias, à hora 22, para prever o consumo energético para o dia seguinte. Esta previsão também pode ser partilhada com o operador da comunidade através de um JWT criado anteriormente.

Todos os dados monitorizados pelo sistema serão guardados na base de dados do sistema usando um período de armazenamento de 5 segundos. As *previsões* serão treinadas novamente quando necessário para utilizar os dados históricos mais recentes que foram recolhidos e o cálculo do perfil energético do utilizador será feito novamente para utilizar os dados mais recentes.

O perfil energético do utilizador pode ser utilizado para ajudar na previsão dos consumos energéticos, através do perfil do utilizador é possível verificar tendências e através dessas tendências é possível prever qual vai ser o consumo energético aquando das mesmas circunstâncias a que o utilizador estava sujeito quando foi calculado o seu perfil energético.

As Figuras 20-23 mostram os diferentes perfis energéticos traçados tendo em conta diferentes contextos. Na Figura 20 é possível visualizar o perfil energético global do utilizador, na Figura 21 pode ver-se o perfil energético considerando o contexto semanal, na Figura 22 é apresentado o perfil energético considerando o contexto mensal e por fim na Figura 23 está representado o perfil energético considerando o contexto térmico.




Figura 20 - Perfil energético global do utilizador




Figura 21 - Perfil energético considerando o contexto semanal




Figura 22 - Perfil energético considerando o contexto mensal




Figura 23 - Perfil energético considerando o contexto térmico

Através da análise dos diferentes perfis energéticos é possível verificar muitas tendências, como por exemplo, o utilizador do edifício utiliza o edifício sempre entre as 9 horas da manhã e as 18 horas da tarde. O edifício ao fim de semana não é utilizado. É possível ver que em agosto o consumo é mais baixo, o que indicará que poderá ser o mês de férias das pessoas que utilizam o edifício e que quando a temperatura é mais elevada ou mais baixa os consumos energéticos são mais elevados. Com os diferentes contextos extraídos do perfil energético é possível fazer uma previsão do consumo energético perante as condições a que o perfil foi calculado.

Para a previsão energética utilizando modelos de aprendizagem automática, foram usados 3 diferentes modelos de previsão, uma *convolutional neural network* (CNN), *Long Short-Term Memory* (LSTM) neural network e um método de aprendizagem *ensemble*, o *extreme Gradient Boosting* (XGBoost). O principal motivo para a escolha destes três modelos foi a possibilidade de poder compará-los e perceber qual o melhor modelo para este problema. No modelo de XGBoost o tratamento dos dados foi feito de forma diferente.

A Figura 24 mostra o resultado das previsões dos consumos energéticos do dia seguinte dos três diferentes modelos referidos anteriormente e do perfil energético semanal. A Figura mostra a previsão dos consumos energéticos do dia seguinte calculado pelo modelo CNN, a previsão dos consumos energéticos do dia seguinte calculado pelo modelo LSTM e a previsão dos consumos energéticos do dia seguinte calculado pelo modelo XGBoost, juntamente com os dados de consumo reais.

As previsões mostram que os consumos energéticos são um pouco elevados durante os períodos em que ninguém está no edifício, mas isto deve-se ao facto do edifício inteligente ter servidores de computadores a funcionar nos seus escritórios.

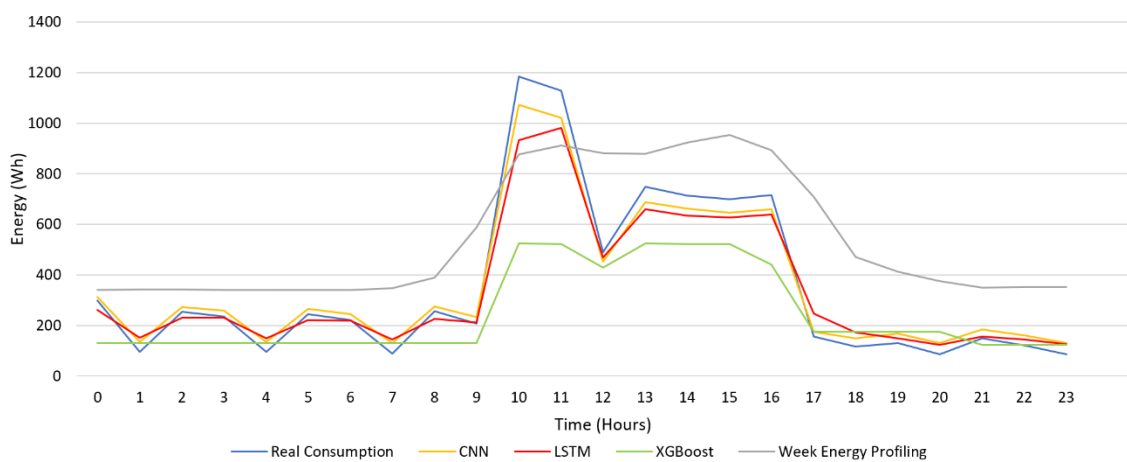


Figura 24 - Previsão dos diferentes modelos e do perfil energético para o consumo do dia seguinte vs valor real

Como se pode visualizar através da análise do gráfico os melhores modelos foram a CNN e a LSTM e o pior foi o XGBoost. Esta não é a melhor forma de avaliar os diferentes modelos. Para avaliar os diferentes modelos foram usadas duas métricas de avaliação, o *relative absolute error* (RAE), o *mean absolute percentage error* (MAPE) e a *root mean square deviation* (RMSD). Na Tabela 7 pode visualizar-se o RAE o MAPE e a RMSD de cada modelo.

Tabela 7 - Métricas de avaliação dos modelos de previsão

Métrica de avaliação	CNN	LSTM	XGBoost	Energy Profiling
RAE	0,2671	0,2982	0,6764	1,1890
MAPE	0,3290	0,3033	0,4687	0,5431
RMSD	175,3135	200,0484	502,8156	551,6318

Ainda para avaliar os diferentes modelos foi usado o diagrama de Taylor, que é uma técnica gráfica que utiliza múltiplas métricas de avaliação em simultâneo, para calcular as métricas foi usado um conjunto de dados que contém 55 dias do conjunto de dados total. É um gráfico de coordenadas polares que exhibe o coeficiente de correlação, o *root mean square error* (RMSE) e

o desvio padrão da amplitude das observações. Cada modelo é representado por um ponto no diagrama e a distância entre o ponto e o ponto de referência representa a RMSD entre o modelo e as observações. Na Figura 25 é possível visualizar-se o gráfico de Taylor com os dados não normalizados dos diferentes modelos de previsão.

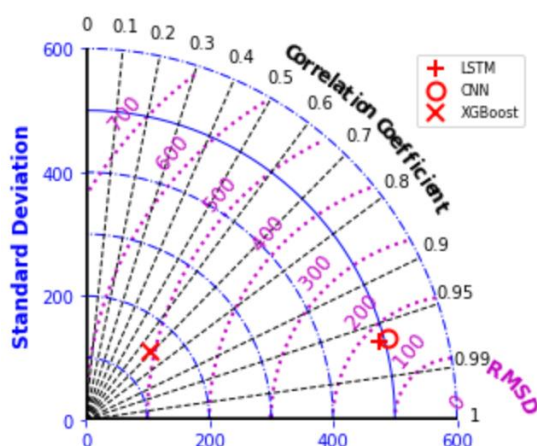


Figura 25 - Gráfico de Taylor dos diferentes modelos de previsão

Através da análise das diferentes metodologias de avaliação dos diferentes modelos, pode concluir-se que para este problema a LSTM e a CNN tiveram melhores resultados que o XGBoost. O XGBoost não teve os melhores resultados devido a não ter dados suficientes, visto que é um modelo que foi feito para lidar com um grande conjunto de dados.

Os modelos de previsão em comparação ao perfil energético do utilizador mostram uma maior eficácia na previsão dos consumos energéticos visto que ficam muito perto do que é o consumo energético real e o perfil energético apenas dá a média do consumo energético para aquele contexto, o que não permite ter um valor de previsão tão preciso

5.3 Contextos Inteligentes

O BAIS foi incorporado nas instalações do centro de investigação do autor (GECAD) para este caso de estudo. O centro de investigação tem muitos dispositivos IoT instalados no seu interior com o objetivo principal de o tornar num edifício inteligente que pode ser monitorizado e controlado remotamente. O edifício inteligente tem uma sala de reuniões e oito escritórios. A fim de avaliar esta solução, foi inserido um sensor de temperatura no exterior para obter informações sobre a temperatura ambiente. Uma primeira versão destes desenvolvimentos, usando correlações, foi apresentada na seguinte publicação:

- **Nuno Teixeira**, Luis Gomes, and Zita Vale, “Knowledge Retrieval Mechanism for Smart Buildings Based On IoT Devices Data,” aceite e apresentado em “The 9th International Conference on Energy and Environment Research” (ICEER 2022) e indicado para publicação em livro na Springer.

O caso de estudo dará ênfase à capacidade do BAIS de ajudar a perceber o que está a acontecer no meio ambiente em que está inserido, para que desta forma se consiga uma melhor gestão energética do edifício. Podendo ajudar na diminuição do consumo energético, na deteção de anomalias, pois tudo que saia do que é esperado pode ser indicação de um problema ou de um risco. Para esta finalidade o BAIS incorpora o conceito de identificação de contextos, fazendo uso do algoritmo k-means para determinar os diferentes contextos presentes nos dados recolhidos. Todos os dados utilizados neste caso de estudo são dados reais relativos ao cento de investigação anteriormente referido.

O modelo de k-means desenvolvido é treinado sempre que haja quantidade suficiente de novos dados que justifique um novo treino do modelo para os resultados das previsões serem o mais precisos possível. Inicialmente os dados são pré processados e são retirados todos os *outliers* que prejudiquem o treino do modelo e é feita a junção da temperatura exterior e dos consumos energéticos no mesmo conjunto de dados.

O k-means precisa que seja determinado o número de *clusters* que serão utilizados pelo modelo, para determinar este número foram usados dois métodos bastante comuns, o método *Elbow* e o método *silhouette*. Depois de analisar os resultados obtidos pelos dois métodos, foi concluído que o número ótimo de *clusters* para os dados em questão era 4, uma vez que no método *Elbow* as distâncias quadradas começam a nivelar no número 4 e no método *silhouette* a pontuação mais alta foi o do número 4 com uma pontuação de 0.5275. Na Figura 26 é possível visualizar o gráfico utilizado para determinar o número de *clusters* do modelo k-means utilizado no sistema.

Com o número de *clusters* definido, pode passar-se para o treino do modelo, utilizando o conjunto de dados criado anteriormente onde estão presentes os dados dos consumos energéticos e da temperatura exterior. Com o treino vai ser possível atribuir cada amostra a um *cluster*, que neste caso serão os diferentes contextos que serão identificados. Na Figura 27 pode ser visto um gráfico onde estão presentes os diferentes *clusters* identificados a cores diferentes para mostrar a sua divisão após o treino do modelo.

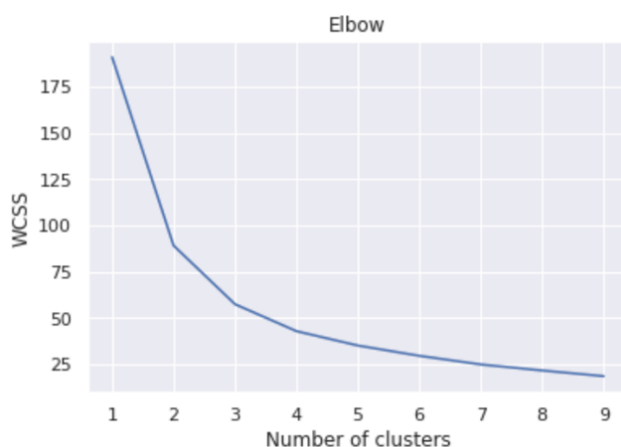


Figura 26 - Método Elbow para determinar o número de *clusters*

Para uma melhor percepção dos diferentes contextos identificados é necessário dar nomes aos contextos. Os nomes dos contextos são:

- a roxo, temperatura baixa, consumo baixo;
- a verde, temperatura alta, consumo baixo;
- a azul, consumo alto;
- a vermelho, consumo atípico.

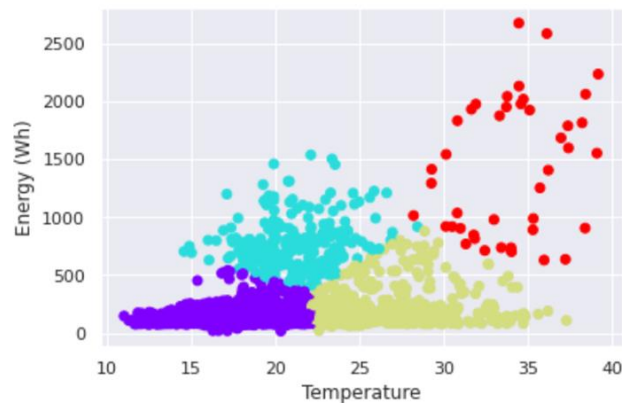


Figura 27 - Gráfico dos diferentes *clusters* identificados pelo modelo

Depois de efetuado o treino do modelo, o modelo permite realizar previsões sobre novas amostras, o que indicará qual o contexto em que são inseridas, estas previsões são feitas através de uma tarefa agendada, que será executada a cada hora do dia, o sistema agrega todos os dados recolhidos referentes àquela hora e após isso irá fazer a previsão. Na Figura 28 está presente um dia inteiro de dados recolhidos de consumos energéticos e da temperatura exterior e está identificado sempre que um novo contexto é descoberto nos novos dados.

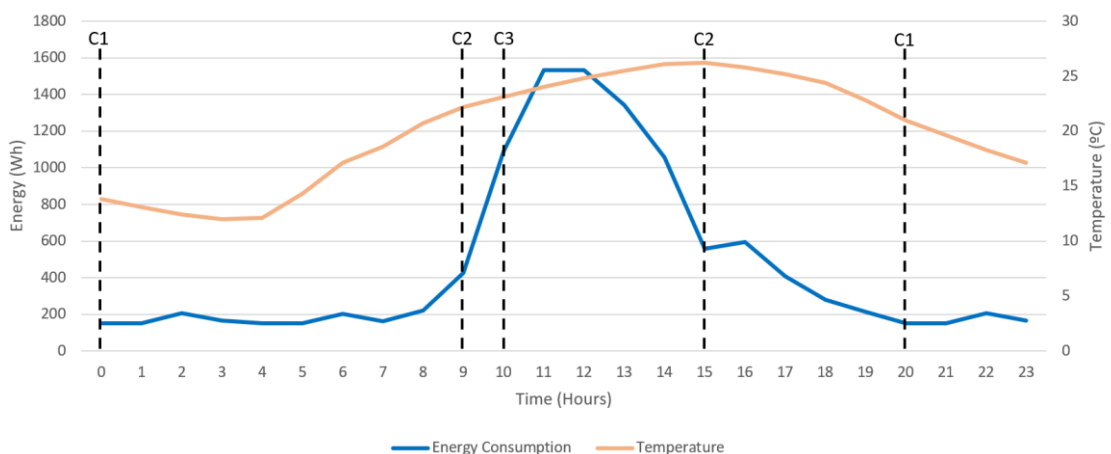


Figura 28 - Gráfico de um dia inteiro de identificação de contextos

A Tabela 8 faz a descrição dos diferentes contextos identificados durante um dia, para uma melhor percepção do que foi identificado após as previsões realizadas pelo BAIS. Estão presentes

os diferentes id's, a descrição dos contextos para se perceber melhor o que está a acontecer e a hora de ativação.

Tabela 8 - Tabela descritiva dos contextos identificados

Id	Descrição	Hora de ativação
C1	Temperatura baixa, consumo baixo	00:00
C2	Temperatura alta, consumo baixo	09:00
C3	Consumo alto	10:00
C2	Temperatura alta, consumo baixo	15:00
C1	Temperatura baixa, consumo baixo	20:00

Num edifício inteligente, o contexto refere-se aos vários fatores que influenciam o comportamento dos sistemas, neste caso os padrões de consumo tendo em conta a temperatura exterior. Ao identificar e analisar diferentes contextos, é possível obter conhecimentos valiosos. Este caso de estudo permite adquirir conhecimentos sobre como é que os consumos energéticos são influenciados pela temperatura exterior.

5.4 Participação direta de dispositivos IoT em programas de *demand response*

Este caso de estudo surge para examinar a capacidade da participação direta dos dispositivos IoT em programas de *demand response*. O caso de estudo foi apresentado na seguinte publicação:

- **Nuno Teixeira**, Ruben Barreto, Luis Gomes, Pedro Faria, and Zita Vale, "A Trustworthy Building Energy Management System to Enable Direct IoT Devices' Participation in Demand Response Programs," *Electronics*, 2022, doi: 10.3390/electronics11060897

O caso de estudo que será apresentado consiste numa comunidade de energia de 50 edifícios, onde um deles é um edifício público e os outros são residências. O edifício público, junto com algumas residências tem um painel fotovoltaico instalado. Estes edifícios são constituídos por dispositivos IoT que permitem a monitorização, em períodos de 15 minutos, da geração fotovoltaica e o consumo de vários tipos de aparelhos. Nesta comunidade de energia, o número médio de aparelhos conectados a dispositivos IoT são 2 por edifício, onde esses aparelhos durante o evento de *demand response* (DR), podem fornecer flexibilidade pela redução ou pelo *shifting*. Os aparelhos que fornecem flexibilidade pela redução estão limitados a reduzir o consumo inteiro. No caso de aparelhos que fornecem flexibilidade pelo *shifting*, se participarem no evento de DR tem de indicar, em avanço, os períodos e a quantidade de energia para a qual

irão fazer o shift do seu consumo. Pela obtenção da previsão do dia seguinte dos recursos energéticos da comunidade de energia, é verificado que 3 períodos podem ser corrigidos.

Os aparelhos utilizados neste estudo de caso são listados abaixo, onde o tipo de aparelho, o respetivo tipo de flexibilidade que pode proporcionar, a quantidade total do respetivo aparelho na comunidade de energia e a quantidade dos aparelhos que podem proporcionar flexibilidade durante o evento DR são destacados:

- Ar Condicionado (Flexibilidade: *shifting*; Quantidade total: 16; Quantidade de eventos DR: 9);
- Máquina de lavar a loiça (Flexibilidade: *shifting*; Quantidade total: 11; Quantidade de eventos DR: 6);
- Secador (Flexibilidade: *shifting*; Quantidade total: 11; Quantidade de eventos DR: 3);
- Iluminação (Flexibilidade: redução; Quantidade total: 10; Quantidade de eventos DR: 10);
- Frigorífico (Flexibilidade: *shifting*; Quantidade total: 13; Quantidade de eventos DR: 13);
- Máquina de lavar (Flexibilidade: *shifting*; Quantidade total: 14; Quantidade de eventos DR: 9);
- Cilindro (Flexibilidade: *shifting*; Quantidade total: 25; Quantidade de eventos DR: 9).

Relativamente ao acesso aos dados, o sistema proposto nesta dissertação permite que sejam criados *tokens* de acesso aos dados que estão associados a um dispositivo IoT, os dados de cada dispositivo IoT são apresentados num documento JSON. O código abaixo contém a resposta dos dados pedidos em JSON que mostra como os dados são enviados do utilizador final/ dispositivo IoT que contém a previsão da flexibilidade para o evento de DR, a previsão da redução, a previsão do *shifting* e as diferentes distribuições de *shifting*. No documento JSON apresentado pode ser visto os dados da máquina de lavar.

```
{
  "Máquina de Lavar" : {
    "Flexibilidade" : "366 W",
    "Shifting" : "366 W",
    "Redução" : "0",
    "Distribuições de Shifting" : {"2h" : "122 W", "4h" : "122 W", "16h" : "122 W"}
  }
}
```

O gráfico da Figura 29 mostra o planeamento do *shifting* dos dispositivos IoT que têm flexibilidade durante o evento. Contudo, o utilizador final é proprietário de mais dispositivos IoT, mas nem todos estão representados no gráfico, uma vez que não têm flexibilidade durante o evento DR. O período respetivo onde o evento DR é aplicado é o período das 11:00 da manhã, onde é necessária uma redução no consumo da comunidade de energia em cerca de 1,55 kWh.




Figura 29 - Distribuições de *shifting* para o evento de *demand response* às 11 horas

Numa comunidade energética o edifício inteligente necessita de ter o BAIS instalado para ter todas as funcionalidades necessárias. Para que o edifício participe numa comunidade de energia necessita de partilhar dados de consumo, quer em tempo real, quer em dados históricos. Uma vez que a partilha com o operador da comunidade acontece frequentemente, para esta partilha o BAIS permite a criação de *tokens* para partilhar os dados com a segurança necessária para evitar fugas de informação pessoal. Este *token* é fornecido ao operador da comunidade e só terá acesso à soma total dos IoTs no edifício agregado em 15 minutos. Para realizar o evento de DR, o BAIS permite fazer a previsão das flexibilidades e da energia para ajudar nas correções necessárias durante o evento de DR.

5.5 Conclusões do Capítulo

Todos os casos de estudo apresentados e integrados no sistema proposto demonstraram resultados positivos em termos de partilha e acesso aos dados e no auxílio da tomada de decisão na gestão de energia como um sistema de ambiente inteligente.

O caso de estudo da integração dos dispositivos IoT e do mecanismo de acesso aos dados foi o maior teste à funcionalidade de partilha de dados, no qual foi proposto uma API REST que utiliza *Json Web Tokens* para validar se a pessoa que está a pedir acesso aos dados é quem diz ser. O mecanismo mostrou ter bons resultados permitindo que várias pessoas possam aceder à mesma rota e ter resultados diferentes devido ao *token* ser diferente.

No caso de estudo relacionado com o perfil e previsão de consumos energéticos, os modelos de previsão propostos mostraram ter bons resultados à exceção do modelo XGBoost que mostrou ter resultados piores. Através do perfil energético do utilizador e dos modelos de previsão é possível que o utilizador consiga prever os consumos energéticos futuros e que possa desenvolver estratégias de gestão de energia que ajudem a melhorar a eficiência energética do edifício onde o BAIS está instalado.

No caso de estudo dos contextos inteligentes, o modelo proposto tornou possível a identificação inteligente de contextos utilizando duas variáveis, os consumos energéticos e a temperatura exterior. Fazendo com que seja possível ao utilizador adquirir conhecimentos valiosos para tomar decisões acertadas em termos de gestão energética.

No caso de estudo da participação direta de dispositivos IoT em programas de *demand response*, esta participação foi possível através da aplicação do mecanismo de acesso aos dados, que demonstrou ser um mecanismo fiável para a partilha de dados que estão associados a um dispositivo IoT.

Em conclusão, os casos de estudo foram capazes de testar cada uma das funcionalidades propostas que foram integradas no sistema, bem como o sistema como um todo, particularmente em termos de partilha de dados, interoperabilidade e como um mecanismo de ajuda em estratégias de gestão de energia.

6 Conclusões

Este capítulo centrar-se-á nas principais conclusões retiradas da investigação. Além disso, serão descritos os objetivos alcançados. São feitas também várias propostas de funcionalidades e capacidades para uma integração futura, a fim de contribuir para uma evolução constante do sistema.

6.1 Conclusões Principais

Com a conclusão do trabalho descrito, é possível concluir que todos os objetivos foram alcançados. Durante o desenvolvimento da dissertação, surgiram obstáculos e dificuldades inesperadas que exigiram o replaneamento de certas opções a fim de alcançar os melhores resultados, contudo, os resultados cumprem os objetivos inicialmente definidos.

A primeira tarefa a ser realizada nesta dissertação foi investigar profundamente o estado de arte da internet das coisas, de aprendizagem automática e de edifícios inteligentes e ambiente inteligentes, especialmente quando aplicados ao domínio de gestão energética, para identificar as principais lacunas da literatura, alcançando assim o O1 (Investigar o atual estado de arte dos ambientes inteligentes em geral, a sua aplicação nos diferentes domínios e dos diferentes componentes que compõem essas soluções, como, os dispositivos IoT e aprendizagem automática) definido na secção 1.2. O estado da arte encontra-se descrito na secção 2.

O sistema proposto baseado em IoT apresenta um avanço na literatura atual preenchendo as lacunas identificadas, permitindo a interoperabilidade dos dispositivos IoT, sendo possível ter diferentes dispositivos de diferentes marcas presentes no sistema, indo ao encontro do O2 (Conceber uma solução, para edifícios inteligentes, que permita a integração de dispositivos IoT heterogéneos, ultrapassando o problema de interoperabilidade). A solução concebida, desenvolvida e testada, denominada BAIS, permite que seja feita a monitorização e controlo dos diferentes dispositivos IoT de diferentes marcas e com diferentes protocolos, como descrito

na secção 4.1 e 4.2. Todos os dados monitorizados são gravados numa base de dados em MongoDB, alcançando o O2.

A inovação mais significativa está relacionada com a arquitetura do sistema e das suas funcionalidades. As funcionalidades propostas têm um grande impacto no funcionamento do sistema e trazem muitas vantagens para os seus utilizadores. O mecanismo de acesso aos dados, descrito na secção 4.3, permite que a partilha dos dados seja controlada e que não permita o acesso aos dados por terceiros, atingindo o O3 (Conceber e implementar um mecanismo de acesso aos dados para assegurar a privacidade dos dados dos utilizadores, respeitando o atual Regulamento Geral sobre a Proteção de Dados (RGPD) nacional e europeu).

O mecanismo de descoberta de conhecimento através de correlações preenche uma grande lacuna na literatura que é o facto de ontologias e bases de conhecimento não conseguirem modelar todos os dispositivos IoT presentes no mercado. A funcionalidade de identificar contextos, permite ao utilizador abordar estratégias de gestão de energia consoante os contextos que são identificados. A funcionalidade de traçar o perfil energético do utilizador adquirir conhecimentos valiosos sobre o consumo energético tendo em conta diferentes contextos permitindo assim ter uma melhor gestão energética e até mesmo prever os consumos futuros. A funcionalidade de previsão permite ao utilizador prever os consumos energéticos futuros dando a possibilidade de ajustar os consumos em conformidade permitindo assim reduzir os custos energéticos. A conceção, desenvolvimento, teste e validação destas funcionalidades, descritas nas secções 4.4, 4.5, 4.6 e 4.7, contribuem para o O4 (Conceber e implementar um modelo para descoberta de conhecimento e identificação de contextos através do uso de técnicas de *clustering*) e O5 (Conceber e implementar modelos preditivos contextuais de consumo de energia elétrica).

No sistema BAIS está integrada uma interface gráfica, concebida e desenvolvida nesta dissertação, que permite a utilização mais intuitiva do sistema. Esta interface integra as funcionalidades do sistema, tais como, a criação do *token* de acesso aos dados a visualização da previsão, acesso aos dados em tempo real e históricos dos dispositivos associados ao utilizador que está a usar a interface gráfica, visualizar as correlações referentes aos atuadores e sensores presentes na sua sala e tem acesso à lista de *tokens* que foram criados. O desenvolvimento e integração da interface gráfica, descrita na secção 4.8 responde ao O6 (Conceber e implementar uma interface gráfica para o(s) utilizador(es) visualizar(em) todas as funcionalidades que o sistema tem disponível).

Para testar e avaliar a utilização do sistema, foram desenvolvidos múltiplos casos de estudo, nos quais foram testadas as diferentes funcionalidades do sistema. Os casos de estudo concebidos demonstraram a validação de toda a solução. Os resultados demonstraram a possibilidade de os utilizadores poderem adotar estratégias de gestão de energia, através da utilização dos contextos inteligentes e do perfil e previsão de consumos energéticos. Também demonstraram que o sistema permite o acesso e partilha de dados com a devida privacidade, permitindo a partilha de dados que estão associados a um dispositivo IoT para poder participar em programas de *demand response*. Os casos de estudo, presentes na secção 5, contribuíram

para o alcançar dos objetivos O7 (Testar as funcionalidades de integração dos IoT, monitorização e acesso aos dados propostas num contexto de edifício inteligente) e O8 (Testar o sistema proposto baseado em IoT e todos as suas funcionalidades como uma solução de ambiente inteligente para edifícios inteligentes). Através do resultado dos testes realizados, pode-se concluir que as funcionalidades desenvolvidas ajudam numa melhor gestão energética do edifício, sendo que a utilização do sistema poderá ser vantajosa para os utilizadores. Com isto os edifícios podem conduzir a melhorias significativas no seu desempenho através da utilização do BAIS.

6.2 Trabalho Futuro

O trabalho proposto provou o valor na realização de todos os objetivos inicialmente definidos. Apesar disso há alguns ajustes e atualizações possíveis que podem ser feitos para melhorar o BAIS. A integração do mecanismo de descoberta de conhecimentos mostrou ser uma boa forma de modelar os diferentes dispositivos IoT presentes num edifício, tornando assim o uso de ontologias ou de uma base de conhecimento dispensável. A utilização de correlações foi uma boa abordagem, contudo os resultados obtidos não foram de encontro ao que era pretendido. Para ultrapassar este problema foi iniciada a implementação de uma nova metodologia de extração de conhecimento, que faz uso de linhas de tendência para visualizar de que forma o estado das variáveis muda perante a atuação no meio ambiente. É pretendido continuar a investigação neste sentido.

Em relação à partilha de dados é também pretendido continuar a investigação no sentido de aprender mais sobre *macaroons*. Os *macaroons* são um tipo de *token* de acesso que proporciona uma forma flexível e segura de conceder e verificar a autorização de acesso aos dados. A principal vantagem dos *macaroons* é que permitem a delegação de direitos de acesso, o que significa que o titular original do *token* pode transmitir alguns ou todos os seus direitos de acesso a terceiros, sem lhes dar pleno acesso aos dados. Isto é conseguido através da utilização de advertências, que são condições adicionais que devem ser cumpridas para que o *token* seja válido. Outra vantagem dos *macaroons* é que podem ser utilizados de forma descentralizada, sem dependerem de um servidor de autenticação centralizado. Isto torna-os particularmente úteis em redes *peer-to-peer*, onde pode não haver uma autoridade centralizada que possa emitir e verificar os *tokens* de acesso. Globalmente, os *macaroons* proporcionam uma forma flexível e segura de conceder e verificar o acesso aos dados, com a capacidade de delegar direitos de acesso e trabalhar de forma descentralizada.

Referências

- Abdul Rahman, A. F., Daud, M., & Mohamad, M. Z. (2016). Securing sensor to cloud ecosystem using Internet of Things (IoT) security framework. *ACM International Conference Proceeding Series, 22-23-March-2016*. <https://doi.org/10.1145/2896387.2906198>
- Acampora, G., Cook, D. J., Rashidi, P., & Vasilakos, A. V. (2013). A survey on ambient intelligence in healthcare. *Proceedings of the IEEE, 101(12)*, 2470–2494. <https://doi.org/10.1109/JPROC.2013.2262913>
- Aduda, K. O., Labeodan, T., Zeiler, W., & Boxem, G. (2017). Demand side flexibility coordination in office buildings: A framework and case study application. *Sustainable Cities and Society, 29*, 139–158. <https://doi.org/10.1016/J.SCS.2016.12.008>
- Ahmad, T., & Zhang, D. (2021). Using the internet of things in smart energy systems and networks. *Sustainable Cities and Society, 68*, 102783. <https://doi.org/10.1016/J.SCS.2021.102783>
- Al-Fuqaha, A., Guizani, M., Mohammadi, M., Aledhari, M., & Ayyash, M. (2015). Internet of Things: A Survey on Enabling Technologies, Protocols, and Applications. *IEEE Communications Surveys and Tutorials, 17(4)*, 2347–2376. <https://doi.org/10.1109/COMST.2015.2444095>
- Al-Sarawi, S., Anbar, M., Alieyan, K., & Alzubaidi, M. (2017). Internet of Things (IoT) communication protocols: Review. *ICIT 2017 - 8th International Conference on Information Technology, Proceedings*, 685–690. <https://doi.org/10.1109/ICITECH.2017.8079928>
- Al Dakheel, J., Del Pero, C., Aste, N., & Leonforte, F. (2020). Smart buildings features and key performance indicators: A review. *Sustainable Cities and Society, 61*, 102328. <https://doi.org/10.1016/J.SCS.2020.102328>
- Alanne, K., & Sierla, S. (2022). An overview of machine learning applications for smart buildings. *Sustainable Cities and Society, 76*, 103445. <https://doi.org/10.1016/J.SCS.2021.103445>
- Alawadi, S., Mera, D., Manuel Fernández-Delgado, ·, Fahed Alkhabbas, ·, Carl, ·, Olsson, M.,

- Davidsson, · Paul, & Alawadi, S. (n.d.). *A comparison of machine learning algorithms for forecasting indoor temperature in smart buildings*. <https://doi.org/10.1007/s12667-020-00376-x>
- Alhajri, M. I., Ali, N. T., & Shubair, R. M. (2018). Classification of Indoor Environments for IoT Applications: A Machine Learning Approach. *IEEE Antennas and Wireless Propagation Letters*, 17(12), 2164–2168. <https://doi.org/10.1109/LAWP.2018.2869548>
- Alqahtani, A., Ali, M., Xie, X., & Jones, M. W. (2021). Deep Time-Series Clustering: A Review. *Electronics* 2021, Vol. 10, Page 3001, 10(23), 3001. <https://doi.org/10.3390/ELECTRONICS10233001>
- Alquthami, T., & Meliopoulos, A. P. S. (2018). Smart House Management and Control Without Customer Inconvenience. *IEEE Transactions on Smart Grid*, 9(4), 2553–2562. <https://doi.org/10.1109/TSG.2016.2614708>
- Alrashdi, I., Alqazzaz, A., Aloufi, E., Alharthi, R., Zohdy, M., & Ming, H. (2019). AD-IoT: Anomaly detection of IoT cyberattacks in smart city using machine learning. *2019 IEEE 9th Annual Computing and Communication Workshop and Conference, CCWC 2019*, 305–310. <https://doi.org/10.1109/CCWC.2019.8666450>
- Alzubaidi, L., Zhang, J., Humaidi, A. J., Al-Dujaili, A., Duan, Y., Al-Shamma, O., Santamaría, J., Fadhel, M. A., Al-Amidie, M., & Farhan, L. (2021). Review of deep learning: concepts, CNN architectures, challenges, applications, future directions. *Journal of Big Data* 2021 8:1, 8(1), 1–74. <https://doi.org/10.1186/S40537-021-00444-8>
- Amanullah, M. A., Habeeb, R. A. A., Nasaruddin, F. H., Gani, A., Ahmed, E., Nainar, A. S. M., Akim, N. M., & Imran, M. (2020). Deep learning and big data technologies for IoT security. *Computer Communications*, 151, 495–517. <https://doi.org/10.1016/J.COMCOM.2020.01.016>
- Ande, R., Adebisi, B., Hammoudeh, M., & Saleem, J. (2020). Internet of Things: Evolution and technologies from a security perspective. *Sustainable Cities and Society*, 54, 101728. <https://doi.org/10.1016/J.SCS.2019.101728>
- Arens, E., Federspiel, C. C., Wang, D., & Huizenga, C. (2005). How ambient intelligence will improve habitability and energy efficiency in buildings. *Ambient Intelligence*, 63–80. https://doi.org/10.1007/3-540-27139-2_5/COVER
- Aruul Mozhi Varman, S., Baskaran, A. R., Aravindh, S., & Prabhu, E. (2018). Deep Learning and IoT for Smart Agriculture Using WSN. *2017 IEEE International Conference on Computational Intelligence and Computing Research, ICCIC 2017*. <https://doi.org/10.1109/ICCIC.2017.8524140>
- Atzori, L., Iera, A., & Morabito, G. (2010). The Internet of Things: A survey. *Computer Networks*, 54(15), 2787–2805. <https://doi.org/10.1016/J.COMNET.2010.05.010>
- Augusto, J. C., Nakashima, H., & Aghajan, H. (2010). Ambient Intelligence and Smart Environments: A State of the Art. *Handbook of Ambient Intelligence and Smart Environments*, 3–31. https://doi.org/10.1007/978-0-387-93808-0_1

- Augusto, J., & Mccullagh, P. (2007). Ambient Intelligence: Concepts and applications. *Computer Science and Information Systems*, 4(1), 1–27. <https://doi.org/10.2298/CSIS0701001A>
- Aurélien Géron. (2019). Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: concepts, tools, and techniques to build intelligent systems. *O'Reilly Media*, 851. <https://www.oreilly.com/library/view/hands-on-machine-learning/9781492032632/>
- Ayodele, T. O., & Ayodele, T. O. (2010). Types of Machine Learning Algorithms. *New Advances in Machine Learning*. <https://doi.org/10.5772/9385>
- Baracaldo, N., Chen, B., Ludwig, H., Safavi, A., & Zhang, R. (2018). Detecting poisoning attacks on machine learning in IoT environments. *Proceedings - 2018 IEEE International Congress on Internet of Things, ICIOT 2018 - Part of the 2018 IEEE World Congress on Services*, 57–64. <https://doi.org/10.1109/ICIOT.2018.00015>
- Barbierato, L., Estebarsari, A., Pons, E., Pau, M., Salassa, F., Ghirardi, M., & Patti, E. (2019). A Distributed IoT Infrastructure to Test and Deploy Real-Time Demand Response in Smart Grids. *IEEE Internet of Things Journal*, 6(1), 1136–1146. <https://doi.org/10.1109/JIOT.2018.2867511>
- Bashir, M. R., & Gill, A. Q. (2018). IoT enabled smart buildings: A systematic review. *2017 Intelligent Systems Conference, IntelliSys 2017, 2018-Janua*, 151–159. <https://doi.org/10.1109/INTELLISYS.2017.8324283>
- Beauchamp, T. L., Childress, J. F., Vaughn, L., & Pierce, J. (2019). *Principles of Biomedical Ethics Eighth Edition*. 65.
- Bedi, G., Venayagamoorthy, G. K., Singh, R., Brooks, R. R., & Wang, K. C. (2018). Review of Internet of Things (IoT) in Electric Power and Energy Systems. *IEEE Internet of Things Journal*, 5(2), 847–870. <https://doi.org/10.1109/JIOT.2018.2802704>
- Bonino, D., & Corno, F. (2012). DoMAInS: Domain-based modeling for Ambient Intelligence. *Pervasive and Mobile Computing*, 8(4), 614–628. <https://doi.org/10.1016/J.PMCJ.2011.10.009>
- Bu, F., & Wang, X. (2019). A smart agriculture IoT system based on deep reinforcement learning. *Future Generation Computer Systems*, 99, 500–507. <https://doi.org/10.1016/J.FUTURE.2019.04.041>
- Budiarto, E. H., Erna Permanasari, A., & Fauziati, S. (2019). Unsupervised anomaly detection using K-Means, local outlier factor and one class SVM. *Proceedings - 2019 5th International Conference on Science and Technology, ICST 2019*. <https://doi.org/10.1109/ICST47872.2019.9166366>
- Candanedo, L. M., & Feldheim, V. (2016). Accurate occupancy detection of an office room from light, temperature, humidity and CO2 measurements using statistical learning models. *Energy and Buildings*, 112, 28–39. <https://doi.org/10.1016/J.ENBUILD.2015.11.071>
- Canedo, J., & Skjellum, A. (2016). Using machine learning to secure IoT systems. *2016 14th Annual Conference on Privacy, Security and Trust, PST 2016*, 219–222. <https://doi.org/10.1109/PST.2016.7906930>

- Carreira, P., Costa, A. A., Mansur, V., & Arsénio, A. (2018). Can HVAC really learn from users? A simulation-based study on the effectiveness of voting for comfort and energy use optimization. *Sustainable Cities and Society*, 41, 275–285. <https://doi.org/10.1016/J.SCS.2018.05.043>
- Caruana, R., & Niculescu-Mizil, A. (2006). An empirical comparison of supervised learning algorithms. *ACM International Conference Proceeding Series*, 148, 161–168. <https://doi.org/10.1145/1143844.1143865>
- Casado-Mansilla, Di., Moschos, I., Kamara-Esteban, O., Tsolakis, A. C., Borges, C. E., Krinidis, S., Irizar-Arrieta, A., Konstantinos, K., Pijoan, A., Tzovaras, Di., & Lopez-De-Ipina, Di. (2018). A Human-Centric Context-Aware IoT Framework for Enhancing Energy Efficiency in Buildings of Public Use. *IEEE Access*, 6, 31444–31456. <https://doi.org/10.1109/ACCESS.2018.2837141>
- Casado-Vara, R., Vale, Z., Prieto, J., & Corchado, J. M. (2018). Fault-Tolerant Temperature Control Algorithm for IoT Networks in Smart Buildings. *Energies* 2018, Vol. 11, Page 3430, 11(12), 3430. <https://doi.org/10.3390/EN1123430>
- Cerruela García, G., Luque Ruiz, I., & Gómez-Nieto, M. (2016). State of the Art, Trends and Future of Bluetooth Low Energy, Near Field Communication and Visible Light Communication in the Development of Smart Cities. *Sensors (Basel, Switzerland)*, 16(11). <https://doi.org/10.3390/S16111968>
- Chen, D., Barker, S., Subbaswamy, A., Irwin, D., & Shenoy, P. (2013). Non-intrusive occupancy monitoring using smart meters. *BuildSys 2013 - Proceedings of the 5th ACM Workshop on Embedded Systems For Energy-Efficient Buildings*. <https://doi.org/10.1145/2528282.2528294>
- Chen, M., Wan, J., & Li, F. (2012). Machine-to-machine communications: Architectures, standards and applications. *KSII Transactions on Internet and Information Systems*, 6(2), 480–497. <https://doi.org/10.3837/TIIS.2012.02.002>
- Chen, X., & Hao, Q. (2022). Research on Internet of Things Context-Aware Information Fusion Technology for Smart Libraries. *Scientific Programming*, 2022. <https://doi.org/10.1155/2022/5282932>
- Chen, Z., Masood, M. K., & Soh, Y. C. (2016). A fusion framework for occupancy estimation in office buildings based on environmental sensor data. *Energy and Buildings*, 133, 790–798. <https://doi.org/10.1016/J.ENBUILD.2016.10.030>
- Chitu, C., Khadem, M. I., & Sgarciu, V. (2017). Predictive modeling of occupancy patterns in smart buildings. *Proceedings of the 2017 IEEE 9th International Conference on Intelligent Data Acquisition and Advanced Computing Systems: Technology and Applications, IDAACS 2017*, 2, 622–627. <https://doi.org/10.1109/IDAACS.2017.8095167>
- Chung, J., Demiris, G., & Thompson, H. J. (2016). Ethical Considerations Regarding the Use of Smart Home Technologies for Older Adults: An Integrative Review. *Annual Review of Nursing Research*, 34, 155–181. <https://doi.org/10.1891/0739-6686.34.155>
- Ciabattoni, L., Grisostomi, M., Ippoliti, G., & Longhi, S. (2013). Neural networks based home

- energy management system in residential PV scenario. *Conference Record of the IEEE Photovoltaic Specialists Conference*, 1721–1726. <https://doi.org/10.1109/PVSC.2013.6744476>
- Cook, D. J., Augusto, J. C., & Jakkula, V. R. (2009). Ambient intelligence: Technologies, applications, and opportunities. *Pervasive and Mobile Computing*, 5(4), 277–298. <https://doi.org/10.1016/J.PMCJ.2009.04.001>
- Correa-Florez, C. A., Michiorri, A., & Kariniotakis, G. (2018). Robust optimization for day-ahead market participation of smart-home aggregators. *Applied Energy*, 229, 433–445. <https://doi.org/10.1016/J.APENERGY.2018.07.120>
- Crabtree, A., Lodge, T., Colley, J., Greenhalgh, C., Glover, K., Haddadi, H., Amar, Y., Mortier, R., Li, Q., Moore, J., Wang, L., Yadav, P., Zhao, J., Brown, A., Urquhart, L., & McAuley, D. (2018). Building accountability into the Internet of Things: the IoT Databox model. *Journal of Reliable Intelligent Environments*, 4(1), 39–55. <https://doi.org/10.1007/S40860-018-0054-5>
- D'Agostino, D., Zangheri, P., & Castellazzi, L. (2017). Towards Nearly Zero Energy Buildings in Europe: A Focus on Retrofit in Non-Residential Buildings. *Energies 2017, Vol. 10, Page 117*, 10(1), 117. <https://doi.org/10.3390/EN10010117>
- D'Oca, S., & Hong, T. (2015). Occupancy schedules learning process through a data mining framework. *Energy and Buildings*, 88, 395–408. <https://doi.org/10.1016/J.ENBUILD.2014.11.065>
- Daissaoui, A., Boulmakoul, A., Karim, L., & Lbath, A. (2020). IoT and Big Data Analytics for Smart Buildings: A Survey. *Procedia Computer Science*, 170, 161–168. <https://doi.org/10.1016/J.PROCS.2020.03.021>
- De Paola, A., Ferraro, P., Lo Re, G., Morana, M., & Ortolani, M. (2020). A fog-based hybrid intelligent system for energy saving in smart buildings. *Journal of Ambient Intelligence and Humanized Computing*, 11(7), 2793–2807. <https://doi.org/10.1007/S12652-019-01375-2/FIGURES/8>
- De Silva, V., Roche, J., Shi, X., & Kondo, A. (2018). IoT driven ambient intelligence architecture for indoor intelligent mobility. *Proceedings - IEEE 16th International Conference on Dependable, Autonomic and Secure Computing, IEEE 16th International Conference on Pervasive Intelligence and Computing, IEEE 4th International Conference on Big Data Intelligence and Computing and IEEE 3*, 451–456. <https://doi.org/10.1109/DASC/PiCom/DataCom/CyberSciTec.2018.00090>
- Debelee, T. G., Schwenker, F., Rahimeto, S., & Yohannes, D. (2019). Evaluation of modified adaptive k-means segmentation algorithm. *Computational Visual Media*, 5(4), 347–361. <https://doi.org/10.1007/S41095-019-0151-2/METRICS>
- Dell'Isola, M., Ficco, G., Canale, L., Palella, B. I., & Puglisi, G. (2019). An IoT Integrated Tool to Enhance User Awareness on Energy Consumption in Residential Buildings. *Atmosphere 2019, Vol. 10, Page 743*, 10(12), 743. <https://doi.org/10.3390/ATMOS10120743>
- Devi, R. L., & Kalaivani, V. (2019). Machine learning and IoT-based cardiac arrhythmia diagnosis

- using statistical and dynamic features of ECG. *The Journal of Supercomputing* 2019 76:9, 76(9), 6533–6544. <https://doi.org/10.1007/S11227-019-02873-Y>
- Ding, X., Xiong, G., Hu, B., Xie, L., & Zhou, S. (2013). Environment monitoring and early warning system of facility agriculture based on heterogeneous wireless networks. *Proceedings of 2013 IEEE International Conference on Service Operations and Logistics, and Informatics, SOLI 2013*, 307–310. <https://doi.org/10.1109/SOLI.2013.6611431>
- Djenouri, D., Laidi, R., Djenouri, Y., & Balasingham, I. (2019). Machine Learning for Smart Building Applications. *ACM Computing Surveys (CSUR)*, 52(2). <https://doi.org/10.1145/3311950>
- Dunne, R., Morris, T., & Harper, S. (2021). A survey of ambient intelligence. *ACM Computing Surveys*, 54(4). <https://doi.org/10.1145/3447242>
- Ejaz, W., Naeem, M., Shahid, A., Anpalagan, A., & Jo, M. (2017). Efficient Energy Management for the Internet of Things in Smart Cities. *IEEE Communications Magazine*, 55(1), 84–91. <https://doi.org/10.1109/MCOM.2017.1600218CM>
- El-Mandouh, A. M., Mahmoud, H. A., Abd-Elmegid, L. A., & Haggag, M. H. (2019). Optimized K-Means Clustering Model based on Gap Statistic. *International Journal of Advanced Computer Science and Applications*, 10(1), 183–188. <https://doi.org/10.14569/IJACSA.2019.0100124>
- Erdinc, O., Paterakis, N. G., Mendes, T. D. P., Bakirtzis, A. G., & Catalão, J. P. S. (2015). Smart Household Operation Considering Bi-Directional EV and ESS Utilization by Real-Time Pricing-Based DR. *IEEE Transactions on Smart Grid*, 6(3), 1281–1291. <https://doi.org/10.1109/TSG.2014.2352650>
- Falahi, M., Lotfifard, S., Ehsani, M., & Butler-Purry, K. (2013). Dynamic model predictive-based energy management of dg integrated distribution systems. *IEEE Transactions on Power Delivery*, 28(4), 2217–2227. <https://doi.org/10.1109/TPWRD.2013.2274664>
- FathyAtlam, H., Attiya, G., & El-Fishawy, N. (2013). Comparative Study on CBIR based on Color Feature. *International Journal of Computer Applications*, 78(16), 9–15. <https://doi.org/10.5120/13605-1387>
- Forootan, M. M., Larki, I., Zahedi, R., & Ahmadi, A. (2022). Machine Learning and Deep Learning in Energy Systems: A Review. *Sustainability* 2022, Vol. 14, Page 4832, 14(8), 4832. <https://doi.org/10.3390/SU14084832>
- Ge, M., Fu, X., Syed, N., Baig, Z., Teo, G., & Robles-Kelly, A. (2019). Deep learning-based intrusion detection for IoT networks. *Proceedings of IEEE Pacific Rim International Symposium on Dependable Computing, PRDC, 2019-December*, 256–265. <https://doi.org/10.1109/PRDC47002.2019.00056>
- Ghayvat, H., Liu, J., Mukhopadhyay, S. C., & Gui, X. (2015). Wellness Sensor Networks: A Proposal and Implementation for Smart Home for Assisted Living. *IEEE Sensors Journal*, 15(12), 7341–7348. <https://doi.org/10.1109/JSEN.2015.2475626>
- Gochhayat, S. P., Kaliyar, P., Conti, M., Tiwari, P., Prasath, V. B. S., Gupta, D., & Khanna, A. (2019).

- LISA: Lightweight context-aware IoT service architecture. *Journal of Cleaner Production*, 212, 1345–1356. <https://doi.org/10.1016/J.JCLEPRO.2018.12.096>
- Gomes, L., Ramos, C., Jozi, A., Serra, B., Paiva, L., & Vale, Z. (2019). IoH: A Platform for the Intelligence of Home with a Context Awareness and Ambient Intelligence Approach. *Future Internet 2019*, Vol. 11, Page 58, 11(3), 58. <https://doi.org/10.3390/FI11030058>
- Gomes, L., Sousa, F., Pinto, T., & Vale, Z. (2019). A Residential House Comparative Case Study Using Market Available Smart Plugs and EnAPlugs with Shared Knowledge. *Energies 2019*, Vol. 12, Page 1647, 12(9), 1647. <https://doi.org/10.3390/EN12091647>
- Gomes, L., Spínola, J., Vale, Z., & Corchado, J. M. (2019). Agent-based architecture for demand side management using real-time resources' priorities and a deterministic optimization algorithm. *Journal of Cleaner Production*, 241, 118154. <https://doi.org/10.1016/J.JCLEPRO.2019.118154>
- Gomes, L., Vale, Z. A., & Corchado, J. M. (2020a). Multi-Agent Microgrid Management System for Single-Board Computers: A Case Study on Peer-to-Peer Energy Trading. *IEEE Access*, 8, 64169–64183. <https://doi.org/10.1109/ACCESS.2020.2985254>
- Gomes, L., Vale, Z., & Corchado, J. M. (2020b). Microgrid management system based on a multi-agent approach: An office building pilot. *Measurement*, 154, 107427. <https://doi.org/10.1016/J.MEASUREMENT.2019.107427>
- Gomes, P., Cavalcante, E., Batista, T., Taconet, C., Conan, D., Chabridon, S., Delicato, F. C., & Pires, P. F. (2019). A semantic-based discovery service for the Internet of Things. *Journal of Internet Services and Applications*, 10(1), 1–14. <https://doi.org/10.1186/S13174-019-0109-8/FIGURES/10>
- González-Lezcano, A., Nocera, F., Caponetto, R. G., Anastasiadou, M., Santos, V., & Dias, M. S. (2021). Machine Learning Techniques Focusing on the Energy Performance of Buildings: A Dimensions and Methods Analysis. *Buildings 2022*, Vol. 12, Page 28, 12(1), 28. <https://doi.org/10.3390/BUILDINGS12010028>
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014). Generative Adversarial Networks. *Communications of the ACM*, 63(11), 139–144. <https://doi.org/10.48550/arxiv.1406.2661>
- Gordić, D., Babić, M., Jovičić, N., Šušteršič, V., Končalović, D., & Jelić, D. (2010). Development of energy management system – Case study of Serbian car manufacturer. *Energy Conversion and Management*, 51(12), 2783–2790. <https://doi.org/10.1016/J.ENCONMAN.2010.06.014>
- Guo, Z., Zhang, Z., & Li, W. (2012). Establishment of Intelligent Identification Management Platform in Railway Logistics System by Means of the Internet of Things. *Procedia Engineering*, 29, 726–730. <https://doi.org/10.1016/J.PROENG.2012.01.031>
- Han, M., May, R., Zhang, X., Wang, X., Pan, S., Yan, D., Jin, Y., & Xu, L. (2019). A review of reinforcement learning methodologies for controlling occupant comfort in buildings. *Sustainable Cities and Society*, 51, 101748. <https://doi.org/10.1016/J.SCS.2019.101748>

- Han, Z., Zhou, L., Ge, C., Li, J., & Liu, Z. (2022). Robust privacy-preserving federated learning framework for IoT devices. *International Journal of Intelligent Systems*, 37(11), 9655–9673. <https://doi.org/10.1002/INT.22993>
- Hasan, M., Islam, M. M., Zarif, M. I. I., & Hashem, M. M. A. (2019). Attack and anomaly detection in IoT sensors in IoT sites using machine learning approaches. *Internet of Things*, 7, 100059. <https://doi.org/10.1016/J.IOT.2019.100059>
- Hazra, A., Adhikari, M., Amgoth, T., & Srirama, S. N. (2021). A Comprehensive Survey on Interoperability for IIoT: Taxonomy, Standards, and Future Directions. *ACM Computing Surveys (CSUR)*, 55(1). <https://doi.org/10.1145/3485130>
- Heo, S., Park, W. K., & Lee, I. (2017). Energy management based on communication of smart plugs and inverter for smart home systems. *International Conference on Information and Communication Technology Convergence: ICT Convergence Technologies Leading the Fourth Industrial Revolution, ICTC 2017, 2017-December*, 810–812. <https://doi.org/10.1109/ICTC.2017.8190788>
- Hinton, G. E., & Salakhutdinov, R. R. (2006). Reducing the dimensionality of data with neural networks. *Science*, 313(5786), 504–507. https://doi.org/10.1126/SCIENCE.1127647/SUPPL_FILE/HINTON.SOM.PDF
- Ibitoye, O., Shafiq, O., & Matrawy, A. (2019). Analyzing Adversarial Attacks against Deep Learning for Intrusion Detection in IoT Networks. *Undefined*. <https://doi.org/10.1109/GLOBECOM38437.2019.9014337>
- Ibrahim, M., Elgamri, A., Babiker, S., & Mohamed, A. (2015). Internet of things based smart environmental monitoring using the Raspberry-Pi computer. *2015 5th International Conference on Digital Information Processing and Communications, ICDIPC 2015*, 159–164. <https://doi.org/10.1109/ICDIPC.2015.7323023>
- Internet of things : the new government to business platform - a review of opportunities, practices, and challenges.* (n.d.). Retrieved February 28, 2023, from <https://documentos.bancomundial.org/es/publication/documents-reports/documentdetail/610081509689089303/internet-of-things-the-new-government-to-business-platform-a-review-of-opportunities-practices-and-challenges>
- Islam, M. J., Wu, Q. M. J., Ahmadi, M., & Sid-Ahmed, M. A. (2008). *Investigating the Performance of Naive- Bayes Classifiers and K- Nearest Neighbor Classifiers*. 1541–1546. <https://doi.org/10.1109/ICCIT.2007.148>
- Jeong, H. C., Jang, M., Kim, T., & Joo, S. K. (2021). Clustering of Load Profiles of Residential Customers Using Extreme Points and Demographic Characteristics. *Electronics 2021, Vol. 10, Page 290, 10(3)*, 290. <https://doi.org/10.3390/ELECTRONICS10030290>
- Joo, I. Y., & Choi, D. H. (2017). Distributed Optimization Framework for Energy Management of Multiple Smart Homes with Distributed Energy Resources. *IEEE Access*, 5, 15551–15560. <https://doi.org/10.1109/ACCESS.2017.2734911>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/SCIENCE.AAA8415>

- K R, P., & N C, N. (2017). A Collective Study of Machine Learning (ML) Algorithms with Big Data Analytics (BDA) for Healthcare Analytics (HcA). *International Journal of Computer Trends and Technology*, 47(3), 149–155. <https://doi.org/10.14445/22312803/IJCTT-V47P121>
- Kalmeshwar, M., & K S, A. P. D. N. P. (2017). Internet Of Things: Architecture, Issues and Applications. *International Journal of Engineering Research and Applications*, 07(06), 85–88. <https://doi.org/10.9790/9622-0706048588>
- Kanawaday, A., & Sane, A. (2018). Machine learning for predictive maintenance of industrial machines using IoT sensor data. *Proceedings of the IEEE International Conference on Software Engineering and Service Sciences, ICSESS, 2017-November*, 87–90. <https://doi.org/10.1109/ICSESS.2017.8342870>
- Kavitha, D., & Ravikumar, S. (2021). IOT and context-aware learning-based optimal neural network model for real-time health monitoring. *Transactions on Emerging Telecommunications Technologies*, 32(1), e4132. <https://doi.org/10.1002/ETT.4132>
- Khakifirooz, M., Fathi, M., Ampatzidis, Y., & Pardalos, P. M. (2020). Ambient-Intelligent Decision Support System (Am-IDSS) for Smart Manufacturing. *Encyclopedia of Organizational Knowledge, Administration, and Technology*, 2338–2351. <https://doi.org/10.4018/978-1-7998-3473-1.CH161>
- Khan, Z. A. (2018). Using energy-efficient trust management to protect IoT networks for smart cities. *Sustainable Cities and Society*, 40, 1–15. <https://doi.org/10.1016/J.SCS.2018.03.026>
- Kingma, D. P., & Welling, M. (2013). Auto-Encoding Variational Bayes. *2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings*. <https://doi.org/10.48550/arxiv.1312.6114>
- Kotsiantis, S. B., Zaharakis, I. D., & Pintelas, P. E. (2006). Machine learning: A review of classification and combining techniques. *Artificial Intelligence Review*, 26(3), 159–190. <https://doi.org/10.1007/S10462-007-9052-3/METRICS>
- Kuncheva, L. I. (2006). *On the optimality of Naïve Naïve Bayes with dependent binary features*. <https://doi.org/10.1016/j.patrec.2005.12.001>
- Kuzlu, M., Pipattanasomporn, M., & Rahman, S. (2016). Review of communication technologies for smart homes/building applications. *Proceedings of the 2015 IEEE Innovative Smart Grid Technologies - Asia, ISGT ASIA 2015*. <https://doi.org/10.1109/ISGT-ASIA.2015.7437036>
- Laccetti, G., Lapegna, M., Mele, V., Romano, D., & Szustak, L. (2020). Performance enhancement of a dynamic K-means algorithm through a parallel adaptive strategy on multicore CPUs. *Journal of Parallel and Distributed Computing*, 145, 34–41. <https://doi.org/10.1016/J.JPDC.2020.06.010>
- Lakshmana, K., Kaluri, R., Gundluru, N., Alzamil, Z. S., Rajput, D. S., Khan, A. A., Haq, M. A., & Alhussen, A. (2022). A Review on Deep Learning Techniques for IoT Data. *Electronics 2022, Vol. 11, Page 1604*, 11(10), 1604. <https://doi.org/10.3390/ELECTRONICS11101604>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature 2015 521:7553*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>

- Lee, I. (2019). The Internet of Things for enterprises: An ecosystem, architecture, and IoT service business model. *Internet of Things*, 7, 100078. <https://doi.org/10.1016/J.IOT.2019.100078>
- Lin, S. W., Ying, K. C., Chen, S. C., & Lee, Z. J. (2008). Particle swarm optimization for parameter determination and feature selection of support vector machines. *Expert Systems with Applications*, 35(4), 1817–1824. <https://doi.org/10.1016/J.ESWA.2007.08.088>
- Liu, H. ;, Liang, J. ;, Liu, Y. ;, Wu, H. A., Liu, H., Liang, J., Liu, Y., & Wu, H. (2023). A Review of Data-Driven Building Energy Prediction. *Buildings 2023*, Vol. 13, Page 532, 13(2), 532. <https://doi.org/10.3390/BUILDINGS13020532>
- Liu, X., Yamamoto, R., & Suk, S. (2014). A survey analysis of energy saving activities of industrial companies in Hyogo, Japan. *Journal of Cleaner Production*, 66, 288–300. <https://doi.org/10.1016/J.JCLEPRO.2013.10.011>
- Liu, Y., Zhou, Y., Yang, K., & Wang, X. (2023). Unsupervised Deep Learning for IoT Time Series. *IEEE Internet of Things Journal*, 1–1. <https://doi.org/10.1109/JIOT.2023.3243391>
- Loideain, N. N. (2019). A port in the data-sharing storm: the GDPR and the Internet of things. <https://doi.org/10.1080/23738871.2019.1635176>, 4(2), 178–196. <https://doi.org/10.1080/23738871.2019.1635176>
- Lorena, A. C., Jacintho, L. F. O., Siqueira, M. F., Giovanni, R. De, Lohmann, L. G., De Carvalho, A. C. P. L. F., & Yamamoto, M. (2011). Comparing machine learning classifiers in potential distribution modelling. *Expert Systems with Applications*, 38(5), 5268–5275. <https://doi.org/10.1016/J.ESWA.2010.10.031>
- Luna, A. C., Diaz, N. L., Graells, M., Vasquez, J. C., & Guerrero, J. M. (2016). Cooperative energy management for a cluster of households prosumers. *IEEE Transactions on Consumer Electronics*, 62(3), 235–242. <https://doi.org/10.1109/TCE.2016.7613189>
- Luo, J. (2022). A Bibliometric Review on Artificial Intelligence for Smart Buildings. *Sustainability 2022*, Vol. 14, Page 10230, 14(16), 10230. <https://doi.org/10.3390/SU141610230>
- MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. <https://doi.org/10.1080/01621459608839001>, 5.1, 281–298. <https://projecteuclid.org/ebooks/berkeley-symposium-on-mathematical-statistics-and-probability/Proceedings-of-the-Fifth-Berkeley-Symposium-on-Mathematical-Statistics-and/chapter/Some-methods-for-classification-and-analysis-of-multivariate-observations/bsmsp/1200512992>
- Makkar, A., Garg, S., Kumar, N., Hossain, M. S., Ghoneim, A., & Alrashoud, M. (2021). An Efficient Spam Detection Technique for IoT Devices Using Machine Learning. *IEEE Transactions on Industrial Informatics*, 17(2), 903–912. <https://doi.org/10.1109/TII.2020.2968927>
- Malatesta, T., & Breadsell, J. K. (2022). Identifying Home System of Practices for Energy Use with K-Means Clustering Techniques. *Sustainability (Switzerland)*, 14(15). <https://doi.org/10.3390/su14159017>
- Manzoor, A., Javaid, N., Ullah, I., Abdul, W., Almogren, A., & Alamri, A. (2017). An Intelligent Hybrid Heuristic Scheme for Smart Metering based Demand Side Management in Smart Homes. *Energies 2017*, Vol. 10, Page 1258, 10(9), 1258.

<https://doi.org/10.3390/EN10091258>

- Mashima, D., & Chen, W. P. (2016). Residential demand response system framework leveraging IoT devices. *2016 IEEE International Conference on Smart Grid Communications, SmartGridComm* 2016, 514–520. <https://doi.org/10.1109/SMARTGRIDCOMM.2016.7778813>
- Mehmood, M. U., Chun, D., Zeeshan, Han, H., Jeon, G., & Chen, K. (2019). A review of the applications of artificial intelligence and big data to buildings for energy-efficiency and a comfortable indoor living environment. *Energy and Buildings*, 202, 109383. <https://doi.org/10.1016/J.ENBUILD.2019.109383>
- Mehra, N., & Gupta, S. (2013). *Survey on Multiclass Classification Methods*.
- Meidan, Y., Bohadana, M., Shabtai, A., Ochoa, M., Tippenhauer, N. O., Guarnizo, J. D., & Elovici, Y. (2017). *Detection of Unauthorized IoT Devices Using Machine Learning Techniques*. <http://arxiv.org/abs/1709.04647>
- Menard, S. (2014). Logistic Regression: From Introductory to Advanced Concepts and Applications. *Logistic Regression: From Introductory to Advanced Concepts and Applications*. <https://doi.org/10.4135/9781483348964>
- Meurer, R. S., Fröhlich, A. A., & Hübner, J. F. (2019). Ambient Intelligence for the Internet of Things Through Context-Awareness. *Proceedings - IEEE International Symposium on Rapid System Prototyping, RSP*, 2018-October, 83–89. <https://doi.org/10.1109/RSP.2018.8631989>
- Miceli, R. (2013). *Energy Management and Smart Grids*. 6, 2262–2290. <https://doi.org/10.3390/en6042262>
- Minaee, S., Kalchbrenner, N., Cambria, E., Nikzad, N., Chenaghlu, M., & Gao, J. (2020). *Deep Learning Based Text Classification: A Comprehensive Review*. <https://doi.org/10.48550/arxiv.2004.03705>
- Mirnaghi, M. S., & Haghghat, F. (2020). Fault detection and diagnosis of large-scale HVAC systems in buildings using data-driven methods: A comprehensive review. *Energy and Buildings*, 229, 110492. <https://doi.org/10.1016/J.ENBUILD.2020.110492>
- Mocnej, J., Seah, W. K. G., Pekar, A., & Zolotova, I. (2018). Decentralised IoT Architecture for Efficient Resources Utilisation. *IFAC-PapersOnLine*, 51(6), 168–173. <https://doi.org/10.1016/J.IFACOL.2018.07.148>
- Mohamad Noor, M. binti, & Hassan, W. H. (2019). Current research on Internet of Things (IoT) security: A survey. *Computer Networks*, 148, 283–294. <https://doi.org/10.1016/J.COMNET.2018.11.025>
- Mohammadi, M., Al-Fuqaha, A., Guizani, M., & Oh, J. S. (2018). Semisupervised Deep Reinforcement Learning in Support of IoT and Smart City Services. *IEEE Internet of Things Journal*, 5(2), 624–635. <https://doi.org/10.1109/JIOT.2017.2712560>
- Motlagh, N. H., Mohammadrezaei, M., Hunt, J., & Zakeri, B. (2020). Internet of Things (IoT) and

- the Energy Sector. *Energies* 2020, Vol. 13, Page 494, 13(2), 494. <https://doi.org/10.3390/EN13020494>
- Muniswamaiah, M., Agerwala, T., & Tappert, C. C. (2020). Green computing for Internet of Things. *Proceedings - 2020 7th IEEE International Conference on Cyber Security and Cloud Computing and 2020 6th IEEE International Conference on Edge Computing and Scalable Cloud, CSCloud-EdgeCom 2020*, 182–185. <https://doi.org/10.1109/CSCLOUD-EDGECom49738.2020.00039>
- Musbah, H., Ali, G., Aly, H. H., & Little, T. A. (2022). Energy management using multi-criteria decision making and machine learning classification algorithms for intelligent system. *Electric Power Systems Research*, 203, 107645. <https://doi.org/10.1016/J.EPSR.2021.107645>
- Musbah, H., Aly, H. H., & Little, T. A. (2021). Energy management of hybrid energy system sources based on machine learning classification algorithms. *Electric Power Systems Research*, 199, 107436. <https://doi.org/10.1016/J.EPSR.2021.107436>
- Naperville Smart Meter Awareness v. City of Naperville, No. 16-3766 (7th Cir. 2018) :: Justia.* (n.d.). Retrieved September 29, 2022, from <https://law.justia.com/cases/federal/appellate-courts/ca7/16-3766/16-3766-2018-08-16.html>
- Neculoiu, G., Dache, V., Stamatescu, G., & Sgarciu, V. (2016). Model Predictive Control applied for building thermal control. *Joint International Conference - ACEMP 2015: Aegean Conference on Electrical Machines and Power Electronics, OPTIM 2015: Optimization of Electrical and Electronic Equipment and ELECTROMOTION 2015: International Symposium on Advanced Electromechanical Moti*, 363–368. <https://doi.org/10.1109/OPTIM.2015.7427008>
- Neocleous, C., & Schizas, C. (2002). Artificial neural network learning: A comparative review. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2308, 300–313. https://doi.org/10.1007/3-540-46014-4_27/COVER
- Neves, D., Pina, A., & Silva, C. A. (2015). Demand response modeling: A comparison between tools. *Applied Energy*, 146, 288–297. <https://doi.org/10.1016/J.APENERGY.2015.02.057>
- Ng, E. Y. K., & Lim, J. T. (2022). Machine Learning on Fault Diagnosis in Wind Turbines. *Fluids* 2022, Vol. 7, Page 371, 7(12), 371. <https://doi.org/10.3390/FLUIDS7120371>
- Nguyen, N. T., Zheng, R., & Han, Z. (2013). UMLI: An unsupervised mobile locations extraction approach with incomplete data. *IEEE Wireless Communications and Networking Conference, WCNC*, 2119–2124. <https://doi.org/10.1109/WCNC.2013.6554890>
- Niu, W., Zhang, X., Du, X., Zhao, L., Cao, R., & Guizani, M. (2020). A deep learning based static taint analysis approach for IoT software vulnerability location. *Measurement*, 152, 107139. <https://doi.org/10.1016/J.MEASUREMENT.2019.107139>
- Noura, M., Atiquzzaman, M., & Gaedke, M. (2019). Interoperability in Internet of Things: Taxonomies and Open Challenges. *Mobile Networks and Applications*, 24(3), 796–809.

<https://doi.org/10.1007/S11036-018-1089-9/FIGURES/5>

- Oladeji, O., & Olakanmi, O. O. (2015). A genetic algorithm approach to energy consumption scheduling under demand response. *IEEE International Conference on Adaptive Science and Technology, ICAST, 2015-January*. <https://doi.org/10.1109/ICASTECH.2014.7068096>
- Oliveira, G. V., Coutinho, F. P., Campello, R. J. G. B., & Naldi, M. C. (2017). Improving k-means through distributed scalable metaheuristics. *Neurocomputing, 246*, 45–57. <https://doi.org/10.1016/J.NEUCOM.2016.07.074>
- Orsi, E., & Nesmachnow, S. (2017). Smart home energy planning using IoT and the cloud. *2017 IEEE URUCON, URUCON 2017, 2017-December*, 1–4. <https://doi.org/10.1109/URUCON.2017.8171843>
- Otoum, Y., Liu, D., & Nayak, A. (2022). DL-IDS: a deep learning–based intrusion detection framework for securing IoT. *Transactions on Emerging Telecommunications Technologies, 33*(3), e3803. <https://doi.org/10.1002/ETT.3803>
- Pablo, A.-R., José, G.-M., Luis, O.-G., Pablo, C.-A., & Jesús, M.-S. (2017). Identification of Patterns of Consumption through the Daily Mean Outdoor Temperature. *World Journal of Engineering and Technology, 05*(03), 20–28. <https://doi.org/10.4236/WJET.2017.53B003>
- Pandey, P. S. (2017). Machine Learning and IoT for prediction and detection of stress. *Proceedings of the 2017 17th International Conference on Computational Science and Its Applications, ICCSA 2017*. <https://doi.org/10.1109/ICCSA.2017.8000018>
- Paper, W., Gustafson, P., Lillis, D., Becker, B. A., Sullivan, T. O., Scanlon, M., Devices, Y., Control, L., Ultrasound, U., EU DG Connect, Elinor Keshet, Findings, K., Cédric Lévy-Bencheton, Eleni Darra, Guillaume Tétu, Guillaume Dufay, Mouhannad Alattar, Roshan, R., Ray, A. K., ... Internet, T. (2016). Security Call to Action. In *Internet of Things* (Vol. 153, Issue November). <https://www.enisa.europa.eu/publications/security-resilience-good-practices>
- Paredes-Valverde, M. A., Alor-Hernández, G., García-Alcaráz, J. L., Salas-Zárate, M. del P., Colombo-Mendoza, L. O., & Sánchez-Cervantes, J. L. (2020). IntelliHome: An internet of things-based system for electrical energy saving in smart home environment. *Computational Intelligence, 36*(1), 203–224. <https://doi.org/10.1111/COIN.12252>
- Park, S. T., Li, G., & Hong, J. C. (2020). A study on smart factory-based ambient intelligence context-aware intrusion detection system using machine learning. *Journal of Ambient Intelligence and Humanized Computing, 11*(4), 1405–1412. <https://doi.org/10.1007/S12652-018-0998-6/FIGURES/3>
- Patel, J., & Panchal, G. (2018). An IoT-Based Portable Smart Meeting Space with Real-Time Room Occupancy. *Lecture Notes in Networks and Systems, 19*, 35–42. https://doi.org/10.1007/978-981-10-5523-2_4
- Patel, K. K., & Patel, S. M. (2016). *Internet of Things-IOT: Definition , Characteristics , Architecture , Enabling Technologies , Application & Future Challenges*.
- Patil, S. S., & Thorat, S. A. (2016). Early detection of grapes diseases using machine learning and IoT. *Proceedings - 2016 2nd International Conference on Cognitive Computing and*

- Information Processing, CCIP 2016*. <https://doi.org/10.1109/CCIP.2016.7802887>
- Pătru, I. I., Carabaş, M., Bărbulescu, M., & Gheorghe, L. (2016). Smart home IoT system. *Networking in Education and Research: RoEduNet International Conference 15th Edition, RoEduNet 2016 - Proceedings*. <https://doi.org/10.1109/ROEDUNET.2016.7753232>
- Pawar, P., TarunKumar, M., & Vittal K., P. (2020). An IoT based Intelligent Smart Energy Management System with accurate forecasting and load strategy for renewable generation. *Measurement*, *152*, 107187. <https://doi.org/10.1016/J.MEASUREMENT.2019.107187>
- Pernkopf, F. (2005). Bayesian network classifiers versus selective k-NN classifier. *Pattern Recognition*, *38*(1), 1–10. <https://doi.org/10.1016/J.PATCOG.2004.05.012>
- Qinghe, Z., Wen, X., Boyan, H., Jong, W., & Junlong, F. (2022). Optimised extreme gradient boosting model for short term electric load demand forecasting of regional grid system. *Scientific Reports 2022 12:1*, *12*(1), 1–12. <https://doi.org/10.1038/s41598-022-22024-3>
- Radhakrishnan, G., & Gopalakrishnan, V. (2020). Applications of internet of things (IOT) to improve the stability of a grid connected power system using interline power flow controller. *Microprocessors and Microsystems*, *76*, 103038. <https://doi.org/10.1016/J.MICPRO.2020.103038>
- Raj, B., Singh, J., Vishvakarma, S. K., & Chouhan, S. S. (2019). *IoT-Based Ambient Intelligence Microcontroller for Remote Temperature Monitoring*. 177–200. https://doi.org/10.1007/978-3-030-04173-1_8
- Rajagukguk, R. A., Ramadhan, R. A. A., & Lee, H. J. (2020). A Review on Deep Learning Models for Forecasting Time Series Data of Solar Irradiance and Photovoltaic Power. *Energies 2020, Vol. 13, Page 6623*, *13*(24), 6623. <https://doi.org/10.3390/EN13246623>
- Ramos, C., Augusto, J. C., & Shapiro, D. (2008). Ambient intelligencethe next step for artificial intelligence. *IEEE Intelligent Systems*, *23*(2), 15–18. <https://doi.org/10.1109/MIS.2008.19>
- Ramos, C., Marreiros, G., Santos, R., & Freitas, C. F. (2010). Smart Offices and Intelligent Decision Rooms. *Handbook of Ambient Intelligence and Smart Environments*, 851–880. https://doi.org/10.1007/978-0-387-93808-0_32
- Ravikumar, S., & Kavitha, D. (2021). IoT based home monitoring system with secure data storage by Keccak–Chaotic sequence in cloud server. *Journal of Ambient Intelligence and Humanized Computing*, *12*(7), 7475–7487. <https://doi.org/10.1007/S12652-020-02424-X/FIGURES/9>
- Reynolds, J., Rezgui, Y., Kwan, A., & Piriou, S. (2018). A zone-level, building energy optimisation combining an artificial neural network, a genetic algorithm, and model predictive control. *Energy*, *151*, 729–739. <https://doi.org/10.1016/J.ENERGY.2018.03.113>
- Risteska Stojkoska, B. L., & Trivodaliev, K. V. (2017). A review of Internet of Things for smart home: Challenges and solutions. *Journal of Cleaner Production*, *140*, 1454–1464. <https://doi.org/10.1016/J.JCLEPRO.2016.10.006>

- Robnik-Šikonja, M. (2004). Improving random forests. *Lecture Notes in Artificial Intelligence (Subseries of Lecture Notes in Computer Science)*, 3201, 359–370. https://doi.org/10.1007/978-3-540-30115-8_34/COVER
- Rodrigues, D. de A., Ivo, R. F., Satapathy, S. C., Wang, S., Hemanth, J., & Filho, P. P. R. (2020). A new approach for classification skin lesion based on transfer learning, deep learning, and IoT system. *Pattern Recognition Letters*, 136, 8–15. <https://doi.org/10.1016/J.PATREC.2020.05.019>
- Runge, J., & Zmeureanu, R. (2021). A Review of Deep Learning Techniques for Forecasting Energy Use in Buildings. *Energies 2021, Vol. 14, Page 608, 14(3)*, 608. <https://doi.org/10.3390/EN14030608>
- Saini, L., Meena, C. S., Raj, B. P., Agarwal, N., & Kumar, A. (2021). Net Zero Energy Consumption building in India: An overview and initiative toward sustainable future. <https://doi.org/10.1080/15435075.2021.1948417>, 19(5), 544–561. <https://doi.org/10.1080/15435075.2021.1948417>
- Samie, F., Bauer, L., & Henkel, J. (2016). IoT technologies for embedded computing: A survey. *2016 International Conference on Hardware/Software Codesign and System Synthesis, CODES+ISSS 2016*. <https://doi.org/10.1145/2968456.2974004>
- Sangogboye, F. C., Arendt, K., Singh, A., Veje, C. T., Kjærgaard, M. B., & Jørgensen, B. N. (2017). Performance comparison of occupancy count estimation and prediction with common versus dedicated sensors for building model predictive control. *Building Simulation*, 10(6), 829–843. <https://doi.org/10.1007/S12273-017-0397-5>
- Santos, C., Ferreira, J. C., Rato, V., & Resende, R. (2018). Public Building Energy Efficiency - An IoT Approach. *Advances in Intelligent Systems and Computing*, 806, 65–72. https://doi.org/10.1007/978-3-030-01746-0_8
- Semmelmann, L., Henni, S., & Weinhardt, C. (2022). Load forecasting for energy communities: a novel LSTM-XGBoost hybrid model based on smart meter data. *Energy Informatics*, 5, 15–16. <https://doi.org/10.1186/s42162-022-00212-9>
- Shakeri, M., Pasupuleti, J., Amin, N., Rokonzaman, M., Low, F. W., Yaw, C. T., Asim, N., Samsudin, N. A., Tiong, S. K., Hen, C. K., & Lai, C. W. (2020). An Overview of the Building Energy Management System Considering the Demand Response Programs, Smart Strategies and Smart Grid. *Energies 2020, Vol. 13, Page 3299, 13(13)*, 3299. <https://doi.org/10.3390/EN13133299>
- Sharma, H., & Kumar, S. (2016). A Survey on Decision Tree Algorithms of Classification in Data Mining. *International Journal of Science and Research (IJSR)*, 5(4), 2094–2097. <https://doi.org/10.21275/V5I4.NOV162954>
- Sharma, V., Song, F., You, I., & Atiquzzaman, M. (2017). Energy efficient device discovery for reliable communication in 5G-based IoT and BSNs using unmanned aerial vehicles. *Journal of Network and Computer Applications*, 97, 79–95. <https://doi.org/10.1016/J.JNCA.2017.08.013>
- Shi, Q., Liu, C., & Xiao, C. (2022). Machine learning in building energy management: A critical

- review and future directions. *Frontiers of Engineering Management 2022 9:2, 9(2)*, 239–256. <https://doi.org/10.1007/S42524-021-0181-1>
- Shih, C.-S., Chou, J.-J., Reijers, N., & Kuo, T.-W. (2016). Designing CPS/IoT applications for smart buildings and cities. *IET Cyber-Physical Systems: Theory & Applications*, 1(1), 3–12. <https://doi.org/10.1049/IET-CPS.2016.0025>
- Shirkhorshidi, A. S., Aghabozorgi, S., Wah, T. Y., & Herawan, T. (2014). Big data clustering: A review. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8583 LNCS(PART 5), 707–720. https://doi.org/10.1007/978-3-319-09156-3_49/COVER
- Shrouf, F., & Miragliotta, G. (2015). Energy management based on Internet of Things: Practices and framework for adoption in production management. *Journal of Cleaner Production*, 100, 235–246. <https://doi.org/10.1016/J.JCLEPRO.2015.03.055>
- Singh, D., Tripathi, G., & Jara, A. J. (2014). A survey of Internet-of-Things: Future vision, architecture, challenges and services. *2014 IEEE World Forum on Internet of Things, WF-IoT 2014*, 287–292. <https://doi.org/10.1109/WF-IOT.2014.6803174>
- SMART RETAIL SOLUTION: CONVERT CUSTOMER INSIGHTS INTO DOLLARS. (2017). <http://www.vmware.com/go/patents>.
- Sovacool, B. K., & Furszyfer Del Rio, D. D. (2020). Smart home technologies in Europe: A critical review of concepts, benefits, risks and policies. *Renewable and Sustainable Energy Reviews*, 120. <https://doi.org/10.1016/J.RSER.2019.109663>
- Spoladore, D., Mahroo, A., Trombetta, A., & Sacco, M. (2019). ComfOnt: A Semantic Framework for Indoor Comfort and Energy Saving In Smart Homes. *Electronics 2019, Vol. 8, Page 1449*, 8(12), 1449. <https://doi.org/10.3390/ELECTRONICS8121449>
- Stamatescu, G., Chițu, C., Vasile, C., Stamatescu, I., Popescu, D., & Sgârțiu, V. (2014). Analytical and experimental sensor node energy modeling in ambient monitoring. *Proceedings of the 2014 9th IEEE Conference on Industrial Electronics and Applications, ICIEA 2014*, 1615–1620. <https://doi.org/10.1109/ICIEA.2014.6931426>
- System for monitoring the physical activity of a user, a portable medium and a method for monitoring*. (2011).
- Teixeira, N., Barreto, R., Gomes, L., Faria, P., & Vale, Z. (2022). A Trustworthy Building Energy Management System to Enable Direct IoT Devices’s Participation in Demand Response Programs. *Electronics 2022, Vol. 11, Page 897*, 11(6), 897. <https://doi.org/10.3390/ELECTRONICS11060897>
- Teixeira, N., Gomes, L., & Vale, Z. (2021). Data Access Mechanism to Allow Multiple Level Permissions in Energy Management Solutions Supported by IoT devices. *21st IEEE International Conference on Environment and Electrical Engineering and 2021 5th IEEE Industrial and Commercial Power System Europe, IEEEIC / I and CPS Europe 2021 - Proceedings*. <https://doi.org/10.1109/IEEEIC/ICPSEUROPE51590.2021.9584750>
- Terroso-Saenz, F., González-Vidal, A., Ramallo-González, A. P., & Skarmeta, A. F. (2019). An open

- IoT platform for the management and analysis of energy data. *Future Generation Computer Systems*, 92, 1066–1079. <https://doi.org/10.1016/J.FUTURE.2017.08.046>
- The little-known story of the first IoT device - Industrious*. (n.d.). Retrieved September 29, 2022, from <https://www.ibm.com/blogs/industries/little-known-story-first-iot-device/>
- Verlinde, P., Maître, G., & Mayoraz, E. (1998). Decision fusion using a multi-linear classifier. *1st International Conference on Multisource-Multisensor Data Fusion*. <https://infoscience.epfl.ch/record/82489>
- Voigt & von dem Bussche. (2017). The EU General Data Protection Regulation - Chapter 5: Rights of Data Subjects. *The EU General Data Protection Regulation*, 4, 141–187. <https://bigbrotherwatch.org.uk/wp-content/uploads/2017/10/The-GDPR-1.pdf>
- Vujović, V., & Maksimović, M. (2015). Raspberry Pi as a Sensor Web node for home automation. *Computers & Electrical Engineering*, 44, 153–171. <https://doi.org/10.1016/J.COMPELECENG.2015.01.019>
- Wang, W., Xu, X., Wei, H. H., Ren, B., & Chen, J. (2018). Modeling occupancy distribution in large building spaces for HVAC energy efficiency. *Energy Procedia*, 152, 1230–1235. <https://doi.org/10.1016/J.EGYPRO.2018.09.174>
- Wearable Technology Market Size, Share & Trends Analysis Report By Product (Head & Eyewear, Wristwear), By Application (Consumer Electronics, Healthcare), By Region (Asia Pacific, Europe), And Segment Forecasts, 2023 - 2030*. (n.d.). Retrieved March 1, 2023, from <https://www.researchandmarkets.com/reports/5124989/wearable-technology-market-size-share-and-trends>
- Wei, M., Hong, S. H., & Alam, M. (2016). An IoT-based energy-management platform for industrial facilities. *Applied Energy*, 164, 607–619. <https://doi.org/10.1016/J.APENERGY.2015.11.107>
- Wu, M., He, Q., Liu, Y., Zhang, Z., Shi, Z., & He, Y. (2022). Machine Learning Techniques for Decarbonizing and Managing Renewable Energy Grids. *Sustainability*, 14(21), 13939. <https://doi.org/10.3390/su142113939>
- Xhemali, D., Hinde, C. J., & Stone, R. G. (2009). Naïve Bayes vs. Decision Trees vs. Neural Networks in the Classification of Training Web Pages. *IJCSI International Journal of Computer Science Issues*, 4(1).
- Xiao, A., Huang, J., Guan, D., Zhang, X., & Lu, S. (2022). *Unsupervised Point Cloud Representation Learning with Deep Neural Networks: A Survey*. <http://arxiv.org/abs/2202.13589>
- Xiao, Liang, Wan, X., Lu, X., Zhang, Y., & Wu, D. (2018). IoT Security Techniques Based on Machine Learning: How Do IoT Devices Use AI to Enhance Security? *IEEE Signal Processing Magazine*, 35(5), 41–49. <https://doi.org/10.1109/MSP.2018.2825478>
- Xiao, Ling, Dong, Y., & Dong, Y. (2018). An improved combination approach based on Adaboost algorithm for wind speed time series forecasting. *Energy Conversion and Management*, 160, 273–288. <https://doi.org/10.1016/J.ENCONMAN.2018.01.038>

- Xie, Xiang, Lu, Q., Herrera, M., Yu, Q., Parlikad, A. K., & Schooling, J. M. (2021). Does historical data still count? Exploring the applicability of smart building applications in the post-pandemic period. *Sustainable Cities and Society*, 69, 102804. <https://doi.org/10.1016/J.SCS.2021.102804>
- Xie, Xiaoxiong, Ramakrishna, S., & Manganelli, M. (2022). Smart Building Technologies in Response to COVID-19. *Energies*, 15(15), 1–23. <https://doi.org/10.3390/en15155488>
- Xu, L. Da, He, W., & Li, S. (2014). Internet of things in industries: A survey. *IEEE Transactions on Industrial Informatics*, 10(4), 2233–2243. <https://doi.org/10.1109/TII.2014.2300753>
- Yared, R., & Abulrazak, B. (2018). Adaptable Context-Aware Cooking-Safe System. *IEEE Transactions on Services Computing*, 11(2), 236–248. <https://doi.org/10.1109/TSC.2017.2662941>
- Yoon, S. G., Choi, Y. J., Park, J. K., & Bahk, S. (2016). Stackelberg-Game-Based Demand Response for At-Home Electric Vehicle Charging. *IEEE Transactions on Vehicular Technology*, 65(6), 4172–4184. <https://doi.org/10.1109/TVT.2015.2440471>
- Zanella, A., Bui, N., Castellani, A., Vangelista, L., & Zorzi, M. (2014). Internet of things for smart cities. *IEEE Internet of Things Journal*, 1(1), 22–32. <https://doi.org/10.1109/JIOT.2014.2306328>
- Zantalis, F., Koulouras, G., Karabetsos, S., & Kandris, D. (2019). A Review of Machine Learning and IoT in Smart Transportation. *Future Internet 2019*, Vol. 11, Page 94, 11(4), 94. <https://doi.org/10.3390/FI11040094>
- Zendehboudi, A., Baseer, M. A., & Saidur, R. (2018). Application of support vector machine models for forecasting solar and wind energy resources: A review. *Journal of Cleaner Production*, 199, 272–285. <https://doi.org/10.1016/J.JCLEPRO.2018.07.164>
- Zhang, H., Seal, S., Wu, D., Bouffard, F., & Boulet, B. (2022). Building Energy Management With Reinforcement Learning and Model Predictive Control: A Survey. *IEEE Access*, 10, 27853–27862. <https://doi.org/10.1109/ACCESS.2022.3156581>
- Zhang, X., Pipattanasomporn, M., Chen, T., & Rahman, S. (2020). An IoT-Based Thermal Model Learning Framework for Smart Buildings. *IEEE Internet of Things Journal*, 7(1), 518–527. <https://doi.org/10.1109/JIOT.2019.2951106>
- Zhao, J., Lasternas, B., Lam, K. P., Yun, R., & Loftness, V. (2014). Occupant behavior and schedule modeling for building energy simulation through office appliance power consumption data mining. *Energy and Buildings*, 82, 341–355. <https://doi.org/10.1016/J.ENBUILD.2014.07.033>
- Zhao, Y., Zhang, C., Zhang, Y., Wang, Z., & Li, J. (2020). A review of data mining technologies in building energy systems: Load prediction, pattern identification, fault detection and diagnosis. *Energy and Built Environment*, 1(2), 149–164. <https://doi.org/10.1016/J.ENBENV.2019.11.003>