



Modelos inteligentes para a operação otimizada de sistemas AVAC em edifícios inteligentes

BRUNO EMANUEL SOARES RIBEIRO

julho de 2024

Modelos inteligentes para a operação otimizada de sistemas AVAC em edifícios inteligentes

Bruno Emanuel Soares Ribeiro

**Dissertação para obtenção do Grau de Mestre em
Engenharia Mecânica, Área de Especialização em
Energias**

Orientador: Luís Filipe de Oliveira Gomes, Investigador

Co-orientador: Zita Maria Almeida do Vale, Professora Coordenadora Principal

Supervisor: Bruno Alexandre Santos Mota, Estudante de Doutoramento

Júri:

Presidente:

Rui Filipe Neves de Araújo Rego, Professor Adjunto, Instituto Superior de Engenharia do Porto

Vogais:

Pedro Nuno Silva Faria, Investigador, Instituto Superior de Engenharia do Porto

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

Porto, junho 2024

Agradecimentos

Falar sobre gratidão e dissertação é pensar numa infinidade de momentos e sentimentos. É desejar agradecer a uma lista interminável de pessoas que, de diversas formas, contribuíram para a realização deste trabalho, e é querer guardar no coração uma coleção de memórias preciosas. Na impossibilidade de mencionar todos os nomes, resta-me, em poucas palavras, destacar algumas pessoas que foram essenciais nesta jornada intensa.

Ao Instituto Superior de Engenharia do Porto (ISEP), a minha profunda gratidão por me acolher ao longo destes dois anos que foram tão transformadores na minha vida. Obrigado por toda a formação proporcionada e por me permitir trabalhar com docentes excepcionais como o meu orientador, Doutor Luís Gomes. A sua orientação foi marcada pela assertividade, apoio incondicional e motivação constante, qualidades que foram cruciais para o desenvolvimento deste trabalho.

À minha coorientadora, Professora Doutora Zita Vale, expresso o meu sincero agradecimento pela oportunidade concedida. O seu conhecimento e experiência foram inestimáveis para a concretização deste projeto.

Ao meu supervisor, Mestre Bruno Mota, agradeço a incansável dedicação e a prontidão em esclarecer todas as minhas dúvidas e questões. A sua supervisão foi fundamental para superar os desafios encontrados ao longo deste percurso.

À minha família, especialmente aos meus pais e ao meu irmão, o meu mais profundo agradecimento. O vosso apoio incondicional, amor e compreensão foram pilares fundamentais não só nesta fase, mas em todo o meu percurso académico. À minha namorada, por estar sempre ao meu lado, pela coragem e compreensão, mesmo nos momentos mais difíceis, a minha eterna gratidão.

Aos meus amigos, que estiveram presentes em cada etapa deste caminho, oferecendo apoio, amizade e motivação, o meu sincero obrigado. A vossa companhia tornou esta jornada mais leve e agradável.

Agradeço também ao Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento (GECAD) por me fornecer os meios necessários para a execução desta dissertação. O suporte e os recursos disponibilizados foram essenciais para a realização deste trabalho.

Por fim, deixo um agradecimento especial a todas as pessoas que, de alguma forma, contribuíram para a concretização desta dissertação. Cada gesto de apoio e cada palavra de incentivo foram valiosos para alcançar este objetivo.

O meu mais sincero obrigado a todos!

Resumo

Desde o Acordo de Paris, adotado em 2015, diversas estratégias e metas climáticas ambiciosas têm sido estabelecidas, tanto a nível mundial como europeu, com o objetivo de alcançar a neutralidade carbónica a longo prazo. Esta pressão global impulsiona a adoção de medidas que promovam a descarbonização em todos os setores, sendo o setor energético um dos principais focos. Contudo, as emissões de CO₂ continuam a aumentar, com o setor energético a ser um dos principais responsáveis.

Nos tempos atuais, os sistemas de Aquecimento, Ventilação e Ar Condicionado (AVAC) assumem uma importância crucial no consumo energético dos edifícios. Esta relevância suscita a necessidade premente de racionalizar e otimizar os consumos energéticos associados a estes sistemas. A inteligência artificial surge como uma solução inovadora para o controlo inteligente e eficiente dos sistemas AVAC. Como tal, o presente estudo propõem-se a aplicar modelos baseados em inteligência artificial para o controlo de sistemas AVAC.

Dada a abrangência do tema da inteligência artificial, foi necessário delinear um percurso específico ao longo do desenvolvimento deste trabalho, culminando na escolha de três modelos de inteligência artificial: *random forest*, árvore de decisão e Redes Neurais *Feedforward* (FFNN). Estes modelos foram desenvolvidos e testados em *Jupyter Notebooks*, em *Python*. A alta fiabilidade desejada para os sistemas AVAC impõe a descoberta de métodos para tornar a sua gestão mais eficiente, assegurando simultaneamente o conforto dos ocupantes. Assim, esta dissertação tem como objetivo explorar e testar soluções para a gestão proativa e eficiente destes equipamentos.

Para testar e validar a aplicabilidade e eficiência dos modelos propostos, foram considerados três casos de estudo que permitem analisar o desempenho dos modelos de inteligência artificial com base em diferentes métricas, tipos de dados recolhidos e variáveis de conforto. Os resultados obtidos demonstram a capacidade dos modelos de inteligência artificial serem implementados em diversos contextos, mostrando-se eficazes na melhoria do conforto e na sustentabilidade das comunidades. Como prova disso, o modelo de árvore de decisão foi aplicado num edifício inteligente e foi capaz de proceder de forma automática e contínua à gestão inteligente e eficaz de um sistema AVAC.

Palavras-chave: AVAC, Eficiência Energética, Inteligência Artificial, *Random Forest*, Redes Neurais *Feedforward*, Árvore de Decisão

Abstract

Since the Paris Agreement, adopted in 2015, various ambitious climate strategies and goals have been established at both the global and European levels with the aim of achieving long-term carbon neutrality. This global pressure drives the adoption of measures that promote decarbonization across all sectors, with the energy sector being a primary focus. However, CO₂ emissions continue to rise, with the energy sector being one of the main contributors.

In current times, Heating, Ventilation, and Air Conditioning (HVAC) systems play a crucial role in the energy consumption of buildings. This significance highlights the urgent need to rationalize and optimize the energy consumption associated with these systems. Artificial intelligence emerges as an innovative solution for the intelligent and efficient control of HVAC systems. Therefore, this study aims to apply AI-based models for the control of HVAC systems.

Given the broad scope of artificial intelligence, it was necessary to outline a specific path throughout the development of this work, culminating in the selection of three AI models: Random Forest, Decision Tree, and Feedforward Neural Networks (FFNN). These models were developed and tested in Jupyter Notebooks using Python. The high reliability desired for HVAC systems imposes the discovery of methods to make their management more efficient while simultaneously ensuring occupant comfort. Thus, this dissertation aims to explore and test solutions for the proactive and efficient management of these systems.

To test and validate the applicability and efficiency of the proposed models, three case studies were considered, allowing for the analysis of AI model performance based on different metrics, types of collected data, and comfort variables. The results obtained demonstrate the capability of AI models to be implemented in various contexts, proving effective in enhancing comfort and the sustainability of communities. As evidence of this, the decision tree model was applied in an intelligent building and was able to autonomously and continuously manage an HVAC system in an intelligent and effective manner.

KEYWORDS: Artificial Intelligence, Decision Tree, Energy Efficiency, Feedforward Neural Networks, HVAC, Random Forest

Índice

1. Introdução.....	17
1.1. Contextualização	17
1.2. Objetivos	18
1.3. Estrutura do Documento.....	20
2. Revisão Bibliográfica	21
2.1. Edifícios Inteligentes	21
2.1.1. Demand Side Management	22
2.1.2. Nearly Zero-Energy Buildings.....	25
2.1.3. Sistemas de Automação e Controlo do Edifício (SACE)	27
2.2. Modelos de Inteligência Artificial e Machine Learning	28
2.3. Técnicas de ML Utilizadas nos Edifícios Inteligentes.....	31
2.3.1. Árvores de Decisão	31
2.3.2. <i>Random Forest</i>	32
2.3.3. Redes Neurais Artificiais	33
2.3.4. Lógica de Fuzzy (FL).....	33
2.4. Análise Crítica da Revisão Bibliográfica.....	36
3. Métodos e Aplicação.....	39
3.1. Descrição do Ambiente de Estudo e Contextualização.....	39
3.1.1. Bases de Dados Utilizadas.....	39
3.2. Desenvolvimento dos Modelos de IA.....	41
3.2.1. Configuração Inicial dos Modelos de IA.....	41
3.2.2. Estratégias de Treino	42
3.2.3. Critérios e Métricas de Avaliação	44
4. Resultados e Discussão	49
4.1. Caso de Estudo 1	49
4.1.1. Discussão e Resultados do Caso de Estudo 1	58
4.2. Caso de Estudo 2	59
4.2.1. Discussão e Resultados do Caso de Estudo 2	65
4.3. Caso de Estudo 3	65
4.3.1. Discussão e Resultados do Caso de Estudo 3	73
5. Conclusão	75
5.1. Conclusões finais.....	75
5.2. Limitações e trabalhos futuros.....	76

Índice de Figuras

Figura 1 - Ordem dos objetivos	19
Figura 2 - Edifício Inteligente [10]	22
Figura 3 -Abordagens do DSM	23
Figura 4 - Variação das tarifas nos diferentes <i>price-based DR programs</i> : (a) TOU; (b) RTP; (c) IBR [22].	25
Figura 5 - Cronologia da Legislação Nacional de Energia em Edifícios	26
Figura 6 - Definição do conceito NZEB [56].....	26
Figura 7 - Exemplos de aplicações num Edifício Inteligente [24].....	27
Figura 8 - Criação do modelo IA [57].....	28
Figura 9 - Tecnologias do ML (adaptada de [35]).....	30
Figura 10 - Classificação dos algoritmos de ML (adaptada de [35])	31
Figura 11 - Estrutura de uma árvore de decisão [58].	32
Figura 12 - Estrutura do random forest (adaptada de [43])	32
Figura 13 - Arquitetura do FFNN [60].....	33
Figura 14 - Arquitetura do FBNN [61]	34
Figura 15 - Diferenças entre a abordagem convencional e a abordagem Fuzzy (adaptada de [51]).....	35
Figura 16 - Passos para calcular um sistema baseado na lógica Fuzzy. [64].....	35
Figura 17 - Ordem de aplicação das estratégias de treino	42
Figura 18 - Matriz de Confusão	47
Figura 19 - Matriz de confusão: a) árvore de decisão com <i>oversampling</i> e <i>grid search</i> (cenário 1), b) árvore de decisão com <i>oversampling</i> e <i>grid search</i> (cenário 2) e c) árvore de decisão com <i>oversampling</i> e <i>grid search</i> (cenário 3).....	54
Figura 20 - Resultados das previsões do AC com dados reais – sala 103	56
Figura 21 - Resultados das previsões do AC com dados reais - sala 105	57
Figura 22 - Matriz de confusão: a) FFNN com <i>oversampling</i> e <i>grid search</i> (cenário 1), b) <i>Random forest</i> padrão (cenário 2) e c) árvore de decisão padrão (cenário 3)	64
Figura 23 - Matriz de confusão: a) FFNN padrão (cenário 1), b) FFNN padrão (cenário 2) e c) <i>Random Forest</i> padrão (cenário 3)	72

Lista de Tabelas

Tabela 1 - Aplicabilidade de algumas técnicas ML.....	38
Tabela 2 - Resultados teóricos obtidos para o caso de estudo 1.....	51
Tabela 3 - Resultados teóricos obtidos para o caso de estudo 2.....	61
Tabela 4 - Resultados teóricos obtidos para o caso de estudo 3.....	67

Acrónimos e Símbolos

Lista de Acrónimos

AG	Algoritmo Genético
ANN	<i>Artificial Neural Network</i>
AQS	Água Quente Sanitária
AVAC	Aquecimento, Ventilação e Ar Condicionado
CO ₂	Dióxido de Carbono
CPP	<i>Critical Peak Pricing</i>
DLC	<i>Direct Load Control</i>
DNN	<i>Deep Neural Network</i>
DR	<i>Demand Response</i>
DSM	<i>Demand Side Management</i>
EE	<i>Energy Efficiency</i>
EPBD	<i>Energy Performance of Buildings Directive</i>
FBNN	<i>Feed Back Neural Network</i>
FFNN	<i>Feed-forward Neural Network</i>
FL	<i>Fuzzy Logic</i>
FN	Falsos Negativos
FP	Falsos Positivos
GEE	Gases Efeito Estufa
HI	<i>Heat Index</i>
IA	Inteligência Artificial
IBR	<i>Inclining Block Rate</i>
IPCC	Painel Intergovernamental das Alterações Climáticas
ISEP	Instituto Superior de Engenharia do Porto
ML	<i>Machine Learning</i>
NLP	<i>Natural Language Processing</i>
NZEB	<i>Nearly-Zero Emission Buildings</i>
ONU	Organização das Nações Unidas
P.Porto	Instituto Politécnico do Porto
RTP	<i>Real Time Pricing</i>

SACE	Sistemas de Automação e Controlo do Edifício
SG	Redes Inteligentes de Energia
SMOTE	<i>Synthetic Minority Oversampling Technique</i>
SRI	Indicador de aptidão para tecnologias
SVM	<i>Support Vector Machine</i>
TOU	<i>Time Of Use</i>
UE	União Europeia
VR	Realidade Virtual

Lista de Símbolos

R	humidade	%
T	temperatura	°F

1. Introdução

Esta secção serve para situar o projeto no contexto adequado, destacando os objetivos principais almejados por este trabalho de dissertação. Simultaneamente, procura-se esclarecer as etapas que orientam a organização deste documento, proporcionando uma visão clara da estrutura adotada.

1.1. Contextualização

Nos dias de hoje, para ir de encontro com as metas de longo prazo definidas e implementadas no Acordo de Paris, muitos países estão a realçar a importância de diminuir as emissões de dióxido de carbono (CO₂) [1]. No entanto, de acordo com o Painel Intergovernamental das Alterações Climáticas (IPCC), desde o início da era industrial, tem sido observado um aumento constante nas emissões de CO₂ [2]. Estas emissões devem-se, principalmente, pela geração de energia através da queima de combustíveis fósseis, como carvão, petróleo e gás natural [3].

Segundo várias organizações científicas globais, tem-se observado um aumento sem precedentes na temperatura global do planeta, com o ano de 2016 destacando-se como o mais quente registado na era moderna [4]. Apesar dos impactos preocupantes do aquecimento global, existem indicações que sustentam a possibilidade de reverter ou, pelo menos, mitigar esses efeitos através da implementação de medidas imediatas [3]. Desta forma, para atender aos objetivos de diminuição das emissões de CO₂, torna-se imperativo implementar ações preventivas.

Na União Europeia (UE), os edifícios representam aproximadamente 30% do consumo total de energia e contribuem com 26% das emissões de gases de efeito estufa (GEE), estabelecendo-se como o setor dominante em termos de consumo energético e emissões de GEE na UE [5].

De acordo com as Organização das Nações Unidas (ONU) [6]:

“Mais de 50% da população total do planeta vive em áreas urbanas e é expectável que em 2050 seja atingido aproximadamente 75% da população.”¹

Dada a crescente densidade populacional nas áreas urbanas, torna-se essencial otimizar o desempenho energético dos edifícios. Neste âmbito, surgiram as Redes Inteligentes de Energia

¹ Esta definição em português, foi livremente traduzida pelo autor a partir do texto original em língua inglesa.

(SG), estas têm vindo a ganhar destaque ao longo dos últimos anos, pois, ao contrário das redes de energia convencionais, permitem a comunicação bidirecional e possibilitam a implementação de diversas soluções capazes de controlar os recursos energéticos [7][8].

Outro conceito que tem vindo a crescer significativamente são os edifícios de necessidades quase nulas de energia (NZEB). Estes são edifícios com um elevado desempenho energético, em que as necessidades de energia são cobertas por energias renováveis [9].

Dada a intrincada administração simultânea do consumo e produção de energia nos NZEB, é crucial aprimorar a eficiência energética dessas estruturas. Garantir que os NZEB possuam a capacidade de ajustar-se dinamicamente às demandas energéticas em constante mudança torna-se, portanto, uma prioridade essencial. Nesse contexto, a aplicação de técnicas de *Machine Learning* (ML) para a gestão de edifícios assume uma elevada importância [10].

De modo a colmatar este problema, esta dissertação propõe-se a desenvolver e aplicar dois modelos avançados de ML. Estes modelos serão cuidadosamente elaborados considerando o estado da arte, irão incorporar não apenas a expertise teórica, mas também uma abordagem prática ao serem implementados e testados utilizando conjuntos de dados provenientes de um edifício real, nomeadamente o GECAD, no ISEP. Ao enfrentar a complexidade da gestão eficiente do consumo e produção de energia em edifícios inteligentes, esta dissertação procura mitigar o problema e estabelecer uma nova perspetiva na otimização dos sistemas de Aquecimento, Ventilação e Ar condicionado (AVAC). A exploração aprofundada das técnicas de Inteligência Artificial (IA) permitirá uma adaptação dinâmica e proativa às variáveis ambientais, considerando um espectro amplo de condições e demandas.

A realização desta dissertação surge da conjugação de dois fatores principais: a minha experiência profissional na área de AVAC e o meu interesse crescente pela Inteligência Artificial. Embora não possuísse experiência prévia específica em IA, sempre tive uma grande curiosidade sobre este campo e o seu potencial transformador. Como trabalho na área do AVAC, constantemente deparo-me com desafios de otimização energética e eficiência operacional. A oportunidade de aplicar técnicas de IA na minha área de especialização apresentou-se como um desafio estimulante e uma oportunidade única para explorar soluções inovadoras.

1.2. Objetivos

Esta dissertação visa contribuir de forma significativa para o avanço dos sistemas AVAC, com especial enfoque em edifícios inteligentes. Diante do contexto crescente da urbanização e da transição para ambientes urbanos mais eficientes e sustentáveis, a otimização da operação dos sistemas AVAC torna-se crucial. Assim, o objetivo desta dissertação é a conceção, implementação e teste de modelos de IA que permitam o controlo inteligente, otimizado e eficiente de sistemas AVAC considerando o contexto e a aprendizagem contínua com os utilizadores.

Levantamento do estado da arte:

- Analisar de forma abrangente as pesquisas e avanços mais recentes relacionados a sistemas de AVAC em edifícios inteligentes. Este tópico visa fornecer uma base sólida

para o desenvolvimento dos modelos propostos, incorporando as mais recentes inovações e tendências identificadas na literatura especializada.

Desenvolvimento de modelos inteligentes e otimização energética:

- Conceber e implementar modelos inteligentes, fundamentados em técnicas avançadas de ML, para melhorar a gestão e controlo dos sistemas AVAC, mantendo o conforto térmico e a qualidade do ar interior.

Adaptação dinâmica:

- Desenvolver mecanismos de adaptação dinâmica dos sistemas AVAC às mudanças nas condições ambientais e de ocupação, promovendo uma resposta ágil e eficiente às demandas específicas de cada momento.

Utilização de sensores reais:

- Utilizar sensores para a coleta de dados em tempo real, para melhorar a precisão dos dados e facilitar a tomada de decisões.

Teste e validação do sistema num edifício inteligente:

- Aplicação dos modelos de IA num edifício real, para teste e análise dos mesmos.

Avaliação do desempenho:

- Realizar um conjunto de testes e análises teóricas para avaliar o desempenho de todos os modelos desenvolvidos.
- Analisar criticamente os resultados simulados para identificar os pontos fortes e fracos, e ajustar os modelos conforme necessário.

Contribuições para a literatura:

- Enriquecer o conhecimento acadêmico no domínio de AVAC em edifícios inteligentes, com a publicação dos resultados e descobertas em conferências e revistas especializadas.
- Fornecer contribuições tangíveis para a prática da engenharia, e incentivar a implementação de soluções mais inteligentes nos sistemas AVAC.

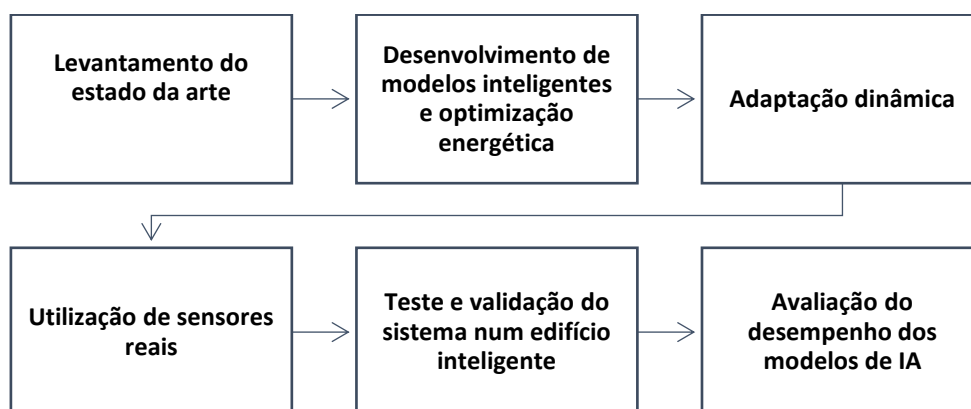


Figura 1 - Ordem dos objetivos

Ao alcançar os objetivos supramencionados, não só se procura enriquecer o conhecimento acadêmico no domínio de AVAC em edifícios inteligentes, mas também se procura fornecer contribuições tangíveis para a prática da engenharia, de forma a estimular a implementação de soluções mais inteligentes e sustentáveis, ver Figura 1.

1.3. Estrutura do Documento

A presente dissertação segue uma estrutura cuidadosamente delineada, guiando o leitor ao longo de cinco secções no domínio dos sistemas de AVAC em edifícios inteligentes. Ao adotar esta estrutura, procura-se não apenas comunicar os resultados da pesquisa, mas também proporcionar uma experiência de leitura envolvente e instrutiva.

Na primeira secção, é apresentada a base fundamental da dissertação, de forma a proporcionar uma introdução clara e contextualizada ao leitor. São exploradas as motivações por trás da escolha do tema, delineados os objetivos da pesquisa e, por fim, é descrita a estrutura do documento.

A segunda secção, Revisão Bibliográfica, apresenta a base teórica da dissertação abrangendo temas essenciais para a compreensão do panorama atual de edifícios inteligentes e sistemas AVAC. Desde a exploração de edifícios inteligentes até à análise de técnicas avançadas de ML, como árvores de decisão, *random forest*, redes neurais artificiais (ANN's), *SVM* e *Fuzzy Logic*.

A implementação de Técnicas de ML será a terceira secção. Esta adentra na parte prática da dissertação, onde são detalhadas as técnicas de ML selecionadas, a sua utilização no sistema AVAC do edifício do GECAD e o processo meticuloso para a sua implementação. Nesta secção são fornecidas perceções detalhadas sobre a aplicação das técnicas escolhidas.

A quarta secção, Resultados e Discussão, expõe detalhadamente os casos de estudo analisados e os resultados obtidos. Esta secção é dedicada a uma análise crítica e aprofundada dos dados recolhidos, com discussão das implicações dos resultados e avaliação da eficácia das técnicas de ML implementadas.

Na última secção, são apresentadas as conclusões decorrentes da pesquisa, realçando os pontos-chave e as descobertas feitas. Além disso, é apresentada uma ideia sobre os caminhos futuros, delineando possíveis extensões do presente trabalho.

2. Revisão Bibliográfica

Esta secção apresenta uma revisão abrangente da literatura que abarca desde os fundamentos dos edifícios inteligentes até as sofisticadas técnicas de ML aplicadas à gestão predial. Inicialmente, serão abordados os edifícios inteligentes, destacando conceitos como *demand side management* (DSM), *nearly zero-energy buildings* (NZEB) e sistemas de automação e controlo do edifício (SACE). Em seguida, serão abordados os temas da IA e ML, de forma a explorar as técnicas mais relevantes utilizadas nos edifícios inteligentes

2.1. Edifícios Inteligentes

Segundo a agência internacional de energia [5], as operações dos edifícios são responsáveis por 30% do consumo global de energia e por 26% das emissões globais relacionadas com a energia (sendo 8% emissões diretas nos edifícios e 18% emissões indiretas, provenientes da produção de eletricidade e calor utilizado nos edifícios) [5]. Esta estatística realça a importância de direcionar a nossa atenção para os edifícios, a fim de reduzir o seu impacto ambiental. Mais dados sobre esta temática foram encontrados. Os autores de [11], concluíram no seu estudo que 56,62% dos artigos revistos relativamente aos edifícios não residenciais, eram focados em AVAC. O conforto no interior de um edifício depende, normalmente, de três variáveis: qualidade do ar, conforto térmico e conforto visual. Sendo que duas das três variáveis depende dos sistemas AVAC e esses sistemas são os responsáveis pelo maior consumo de energia de um edifício, é importante o aperfeiçoamento na sua utilização.

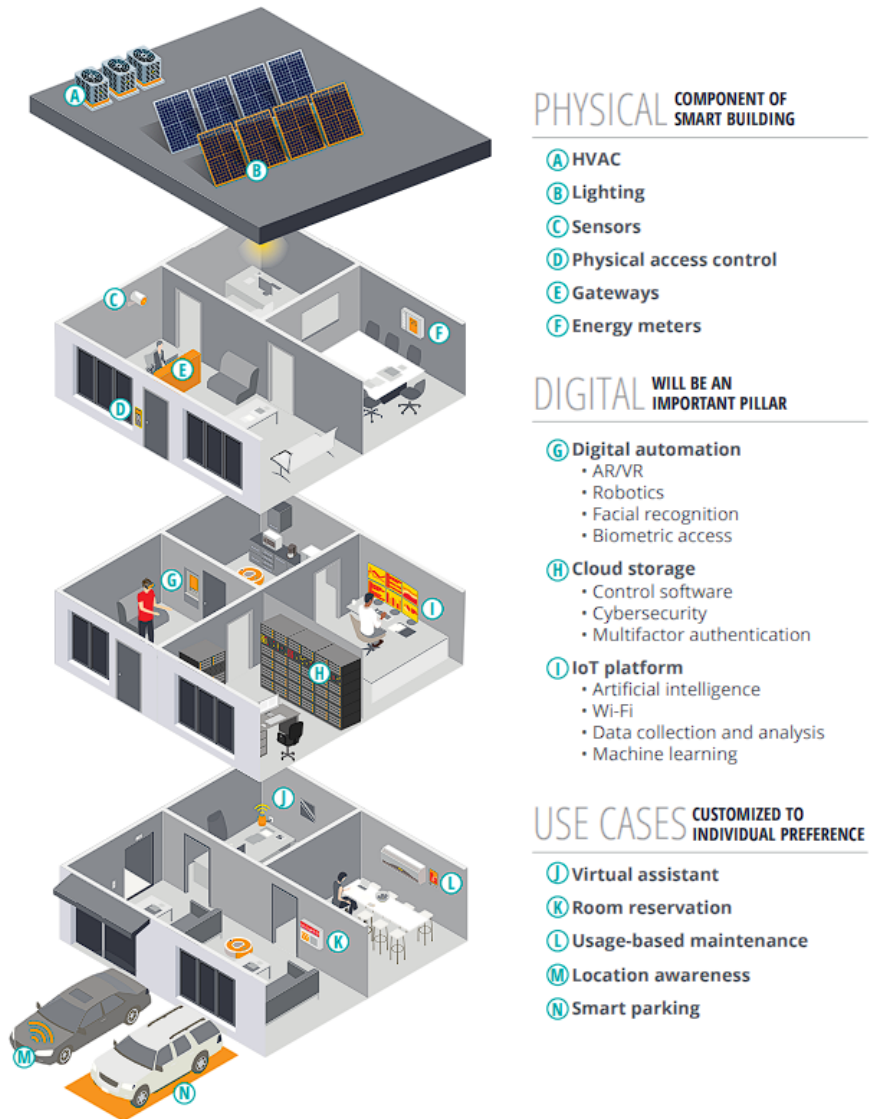
O conceito de Edifício Inteligente, segundo [12], é definido como:

“Edifícios inteligentes são estruturas conectadas digitalmente que combinam a otimização do edifício e a sua automação operacional com gestão inteligente dos espaços para melhorar a experiência do utilizador, aumentar a produtividade, reduzir custos e mitigar riscos físicos e de cyber segurança.”²

Pela definição apresentada, verifica-se que o conceito de Edifícios Inteligentes abrange uma grande variedade de tecnologias e conceitos que podem ser aplicadas de forma a controlar eficientemente os sistemas AVAC e os seus gastos de energia, ver Figura 2.

² Esta definição em português, foi livremente traduzida pelo autor a partir do texto original em língua inglesa.

Em 2010, perante o paradigma europeu da produção e consumo de energia, dependência energética, emissões de GEE e as alterações climáticas surgem os NZEB, ou seja, edifícios com necessidades quase nulas de energia [13]. Juntamente com esta iniciativa surgiram estratégias para incentivar ao utilizador à correta gestão e utilização de energia, denominadas de *Demand Side Management (DSM)*.



2.1.1. Figura 2 - Edifício Inteligente [10]Demand Side Management

De acordo com [14] o DSM pode ser descrito como:

“Uma iniciativa implementada pelas empresas de eletricidade para incentivar os consumidores a adotar procedimentos que sejam vantajosos para ambas as partes. Estes procedimentos incluem qualquer atividade que visa a alterar as formas de carga, influenciando o comportamento de consumo dos consumidores.”

Dependendo da forma como a gestão da procura é efetuada, o DSM tem dois conceitos principais: Demand Response (DR) e Energy Efficiency (EE), ver Figura 3 [11].

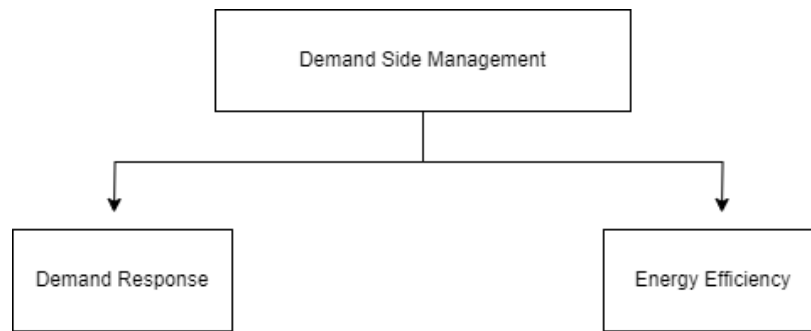


Figura 3 -Abordagens do DSM

O DR pode ser classificado em duas grandes categorias: *Incentive-based DR programs* e *Price-based DR programs* [14].

O *incentive-based DR program* consiste em fornecer recompensas financeiras ou outros incentivos aos participantes por reduzirem o seu consumo de eletricidade durante períodos de ponta [15]. Existem várias formas de implementar esta iniciativa baseada em incentivos, como por exemplo:

- **Direct Load Control (DLC):**

Os fornecedores de energia podem controlar remotamente alguns aparelhos específicos, como por exemplo, ar condicionados, aquecimento de água, entre outros, durante períodos de ponta. Os participantes concordam com esse controlo em troca de incentivos [15].

- **Serviço Interrompível/Redutível:**

Grandes clientes industriais ou comerciais concordam em reduzir a sua carga de consumo mediante pedido, em troca de tarifas reduzidas ou outros incentivos [15].

- **Programas de Licitação/Compra de Demanda:**

Os clientes oferecem-se para reduzir a carga de consumo em resposta à variação dos preços ou pedidos do fornecedor da rede, geralmente através de um processo de licitação onde especificam o preço pelo qual estão dispostos a reduzir o consumo [15].

Os *Price-based DR programs* não oferecem incentivos financeiros diretos, mas utilizam a variação dos preços para encorajar os clientes a modificar os seus padrões de consumo [16]. Existem várias formas de implementar esta iniciativa baseada em preços, consultar Figura 4.

- **Time of use (TOU):**

Nesta iniciativa o preço da eletricidade para os consumidores depende do tempo que a eletricidade é utilizada. Isto é, o dia é dividido em três intervalos designados por intervalos de ponta, intervalos de meio consumo e intervalo fora de ponta. Durante o intervalo de ponta os consumidores são alvos de um aumento do preço da eletricidade, de forma a incentivar o consumo da mesma durante os outros períodos e reduzir assim o intervalo de ponta [17].

- **Real time pricing (RTP):**

O RTP refere-se à alteração da tarifa de eletricidade a cada hora, conforme a variação do mercado da eletricidade [18]. Normalmente, a variação associada às tarifas de eletricidade deve ser comunicada aos consumidores até uma hora antes de existir a alteração [19]. A ideia principal desta medida é ajudar os consumidores finais a ajustar o seu consumo às horas de menor valor, sendo beneficiados economicamente. O RTP tem sido cada vez mais popular nos edifícios inteligentes, visto que, manualmente torna-se complicado ajustar o consumo da eletricidade a cada hora [20]. Segundo [20], que estudou vários casos no uso da medida, o RTP pode refletir a relação perfeita entre procura e demanda, no entanto, nos dias de hoje ainda não é prático devido à falta de infraestruturas inteligentes.

- **Critical peak pricing (CPP):**

O CPP é similar ao TOU, sendo que os preços de eletricidade apenas aumentam durante um número limitado de horas, ao contrário do TOU que varia todos os dias durante o período de ponta. Esta medida, normalmente, é imposta quando o sistema elétrico encontra-se severamente limitado, como por exemplo, nos períodos muito frios de inverno, ou muito quentes de verão. De forma a proteger a fiabilidade do sistema é necessário incentivar os consumidores a consumir menos eletricidade durante os períodos de ponta extremo, sendo então criado o CPP [20]. No entanto, o CPP não é uma solução eficaz para melhorar a eficiência no consumo de energia, reduzir o custo e reduzir o impacto das emissões de carbono, pois, apenas é implementado em alturas de elevado ponta, que pode apenas acontecer algumas vezes durante anos [20].

- **Inclining block rate (IBR):**

O IBR consiste em criar dois níveis de consumo, sendo ambos cobrados com valores muito distintos. No primeiro nível de consumo o preço é reduzido, sendo que quando é atingido um valor limite de consumo, este pode aumentar até 80% [21].

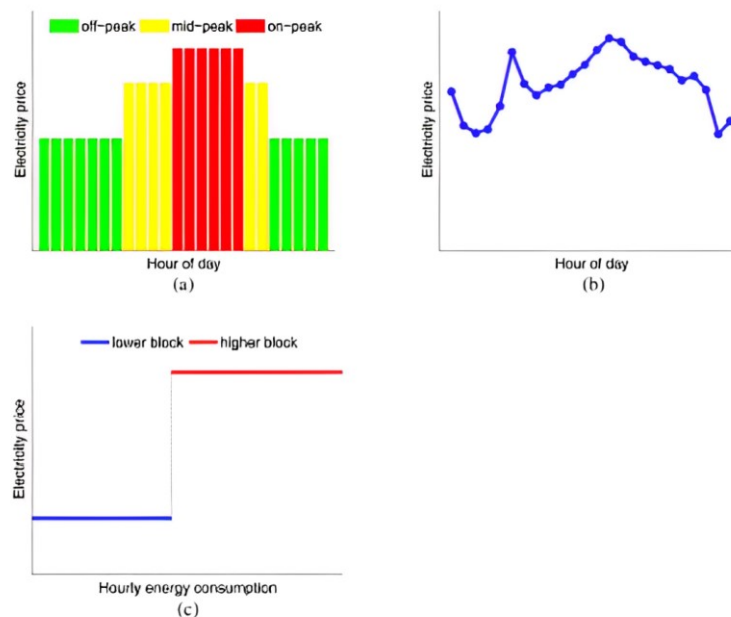


Figura 4 - Variação das tarifas nos diferentes *price-based DR programs*: (a) TOU; (b) RTP; (c) IBR [22].

2.1.2. Nearly Zero-Energy Buildings

O conceito NZEB provém do conceito base dos *Zero Energy Buildings* (ZEBs) que se fundamenta num balanço energético, no qual as necessidades energéticas do edifício são supridas por energia proveniente de fontes renováveis, ao longo de um período de tempo [23].

A UE tem vindo a concentrar-se nos NZEB para tentar responder de forma eficaz aos problemas que, particularmente nas últimas décadas, afetam o ambiente. O setor da construção é uma das principais fontes de poluição devido à quantidade de emissões que são emitidas para a atmosfera em resultado dos sistemas de aquecimento e arrefecimento dos edifícios [24].

A primeira indicação dos NZEB surgiu na diretiva da UE em 2010 [23] :

“a building that has a very high energy performance, ... The nearly zero or very low amount of energy required should be covered to a very significant extent by energy from renewable sources, including energy from renewable sources produced on-site or nearby”

Esta diretiva obrigou a implementação do modelo NZEB na Europa a partir de 31 de dezembro de 2018 para novos edifícios públicos. Os restantes edifícios apenas foram abrangidos pela diretiva a partir de 31 de dezembro de 2020 [23].

Em Portugal, a introdução destes dois conceitos obrigou à revisão da legislação existente, o que ocorreu através do DL nº 118/2013 [25], estabelecendo os requisitos mínimos de desempenho energético para os edifícios, sistemas técnicos e elementos construtivos com relevância do desempenho energético do edifício. Este Decreto foi, entretanto, revisto várias vezes, ajustando

os requisitos mínimos em função dos resultados dos cálculos dos níveis ótimos de rentabilidade, ver Figura 5.

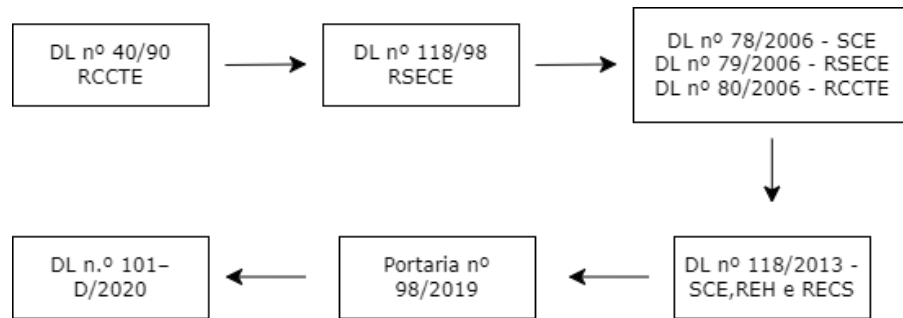


Figura 5 - Cronologia da Legislação Nacional de Energia em Edifícios

A legislação portuguesa não estabeleceu ainda um limite numérico em termos de necessidades de energia primária ou de emissões de gases com efeito de estufa, estabelecendo, contudo, um referencial para os requisitos mínimos dos elementos da envolvente do edifício e da eficiência dos sistemas [26].

Na Figura 6 é possível observar o conceito NZEB. No eixo horizontal está representado o consumo de energia de um edifício e no eixo vertical a produção de energia renovável. É possível constatar que para atingir o balanço energético (quase) nulo num edifício convencional, é necessário ter uma elevada produção de energia renovável. O principal objetivo do conceito NZEB, definido pela *energy performance of buildings directive 2010* (EPBD), passa por reduzir ao máximo as necessidades energéticas do edifício para que a produção de energia por fontes renováveis seja tanto menor quanto possível, de modo a alcançar um balanço nulo de energia [23].

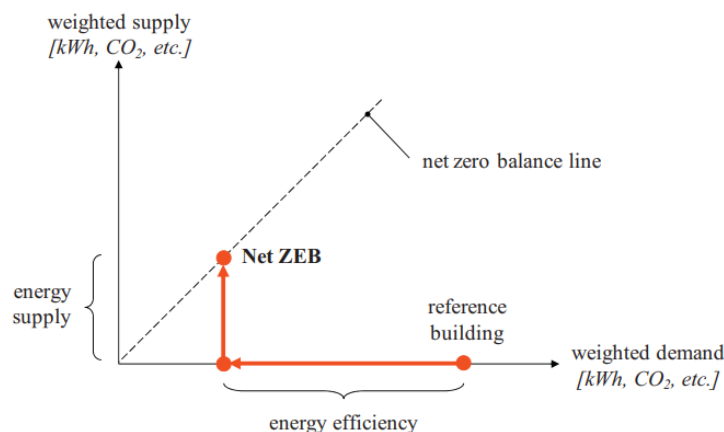


Figura 6 - Definição do conceito NZEB [56]

A eficiência no uso de energia e a incorporação de fontes renováveis são os principais pilares de um edifício NZEB. Para otimizar o consumo energético, é essencial aprimorar o isolamento térmico das estruturas e adotar sistemas eficazes de climatização e água quente sanitária (AQS).

2.1.3. Sistemas de Automação e Controlo do Edifício (SACE)

Em 2018, a EPBD foi revista com o objetivo de impulsionar a renovação dos edifícios na Europa. A nova diretiva visa a promover o uso de tecnologias em edifícios inteligentes por meio de um indicador de aptidão para tecnologias (SRI). O SRI avalia a capacidade de um edifício ajustar a sua operação de acordo com as necessidades dos ocupantes, visando otimizar a eficiência energética e o desempenho resultante [27].

Os SACE compreendem uma variedade de produtos, softwares e serviços de engenharia projetados para promover o funcionamento econômico, seguro e energeticamente eficiente do sistema técnico de um edifício. Isto é alcançado através de comandos automáticos e de uma gestão manual simplificada, contribuindo para a otimização do desempenho do edifício [28].

A Figura 7 mostra alguns exemplos dos equipamentos num edifício inteligente, tais como, sistemas AVAC, sistemas de iluminação, sensores de temperatura e de humidade, entre outros. O controlo centralizado destes elementos tende a promover a utilização eficiente da energia através do controlo inteligente dos mesmos [29].




Figura 7 - Exemplos de aplicações num Edifício Inteligente [24].

A comunicação contínua entre os sensores e controladores de um edifício, assim como a interação entre os medidores de energia, unidades geradoras de energia renovável e unidades de armazenamento, gera conjuntos extensos e heterogêneos de dados. Esses conjuntos de dados exigem abordagens cada vez mais automatizadas e adaptáveis para o processamento de informações e a tomada de decisões em tempo real. As técnicas de IA e ML demonstram capacidades comprovadas para aprender a partir de conjuntos de dados heterogêneos [30].

2.2. Modelos de Inteligência Artificial e Machine Learning

A IA surgiu na década de 1950, com o trabalho desenvolvido por diversos investigadores, sendo definida por [31] em 1956 como:

“A ciência e engenharia para construir máquinas inteligentes, em especial programas de computador inteligentes”

Desde então, a IA desenvolveu-se em diversas subáreas, tais como [32]:

- *Knowledge representation* - Representação de conhecimento;
- *Machine Learning* - Aprendizagem de máquinas;
- *Automated Reasoning* - Raciocínio Automatizado;
- *Natural Language Processing (NLP)* – Processamento de linguagem natural;

De acordo com [33], o impacto da IA no planeta resulta de três fenómenos principais: o elevado crescimento de recolha de dados (*Big Data*), o aumento exponencial da capacidade de processamento e o desenvolvimento de algoritmos sofisticados para a análise dos dados (por exemplo, *Deep Learning*).

A integração de tecnologias contemporâneas, como sensores, 5G, realidade virtual (VR) redes de comunicação, computação na *Cloud*, transmissão sem fio e dispositivos inteligentes, nos SACE tem resultando numa rápida implementação de modelos analíticos nesses domínios [34]. Por exemplo, mediante o histórico de consumo de energia dos edifícios, os modelos de IA podem permitir prever as tendências futuras do consumo de energia nessas estruturas. Este processo de aprendizagem compreende, normalmente, quatro etapas principais [35]:

- 1 - Recolha de dados (*Data Collection*);
- 2 - Pré-processamento de dados (*data preprocessing*);
- 3 - Treino dos modelos (*Model Training*);
- 4 - Testes dos modelos (*Model Testing*)

Na Figura 8 é possível ter uma melhor percepção do funcionamento de um modelo IA.

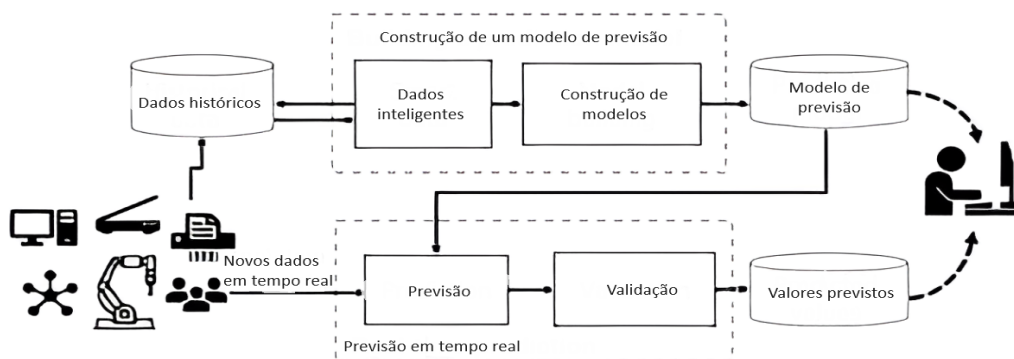


Figura 8 - Criação do modelo IA [57]

Segundo [36], o conceito de ML pode ser descrito como “várias técnicas estatísticas que permitem aos computadores aprender com a experiência sem serem explicitamente programados”. As técnicas de ML permitem determinar relações não lineares, através da previsão a partir de um conjunto de dados para aprendizagem (Aprendizagem supervisionada), ou sem qualquer conjunto de dados para aprendizagem (Aprendizagem não supervisionada), ou até mesmo na sequência de decisões num sistema incerto (Aprendizagem por reforço) [37].

A aprendizagem supervisionada consiste no treino do ML com uma grande base de dados para a previsão de objetivos para amostras nunca vistas. Este tipo de aprendizagem deverá permitir ao algoritmo reproduzir uma função com menor erro, comparando com a realidade [37]. Este método é maioritariamente utilizado para tarefas de classificação e regressão [38].

A aprendizagem é considerada não supervisionada, quando não existem classes identificadas nos dados de entrada, isto é, ao contrário da aprendizagem supervisionada, onde o modelo é treinado com dados de entrada e saída rotulados, na aprendizagem não supervisionada, o algoritmo procura padrões e estruturas subjacentes nos dados de forma autónoma [39]. Esta técnica tem vindo a receber especial atenção nas análises energéticas dos edifícios, devido aos ambientes dinâmicos, onde as condições operacionais e as características do edifício variam ao longo do tempo [37].

Por fim, a aprendizagem por reforço (*Reinforcement learning*) consiste num algoritmo tomar decisões sequenciais e receber um *feedback* em forma de recompensas ou penalidades. O objetivo do algoritmo é aprender a tomar decisões que maximizem a recompensa total ao longo do tempo, por tentativa e erro [40].

A Figura 9 apresenta os três tipos de tecnologias associadas ao ML.

As técnicas ML podem ser categorizadas como *shallow learning* e *deep learning*. De acordo com [40]:

“Os modelos de *shallow learning* são modelos com camadas simples, enquanto os modelos de *deep learning* são modelos com camadas complexas ou múltiplas. “

A Figura 10 representa as diferentes técnicas de ML e as tecnologias associadas.

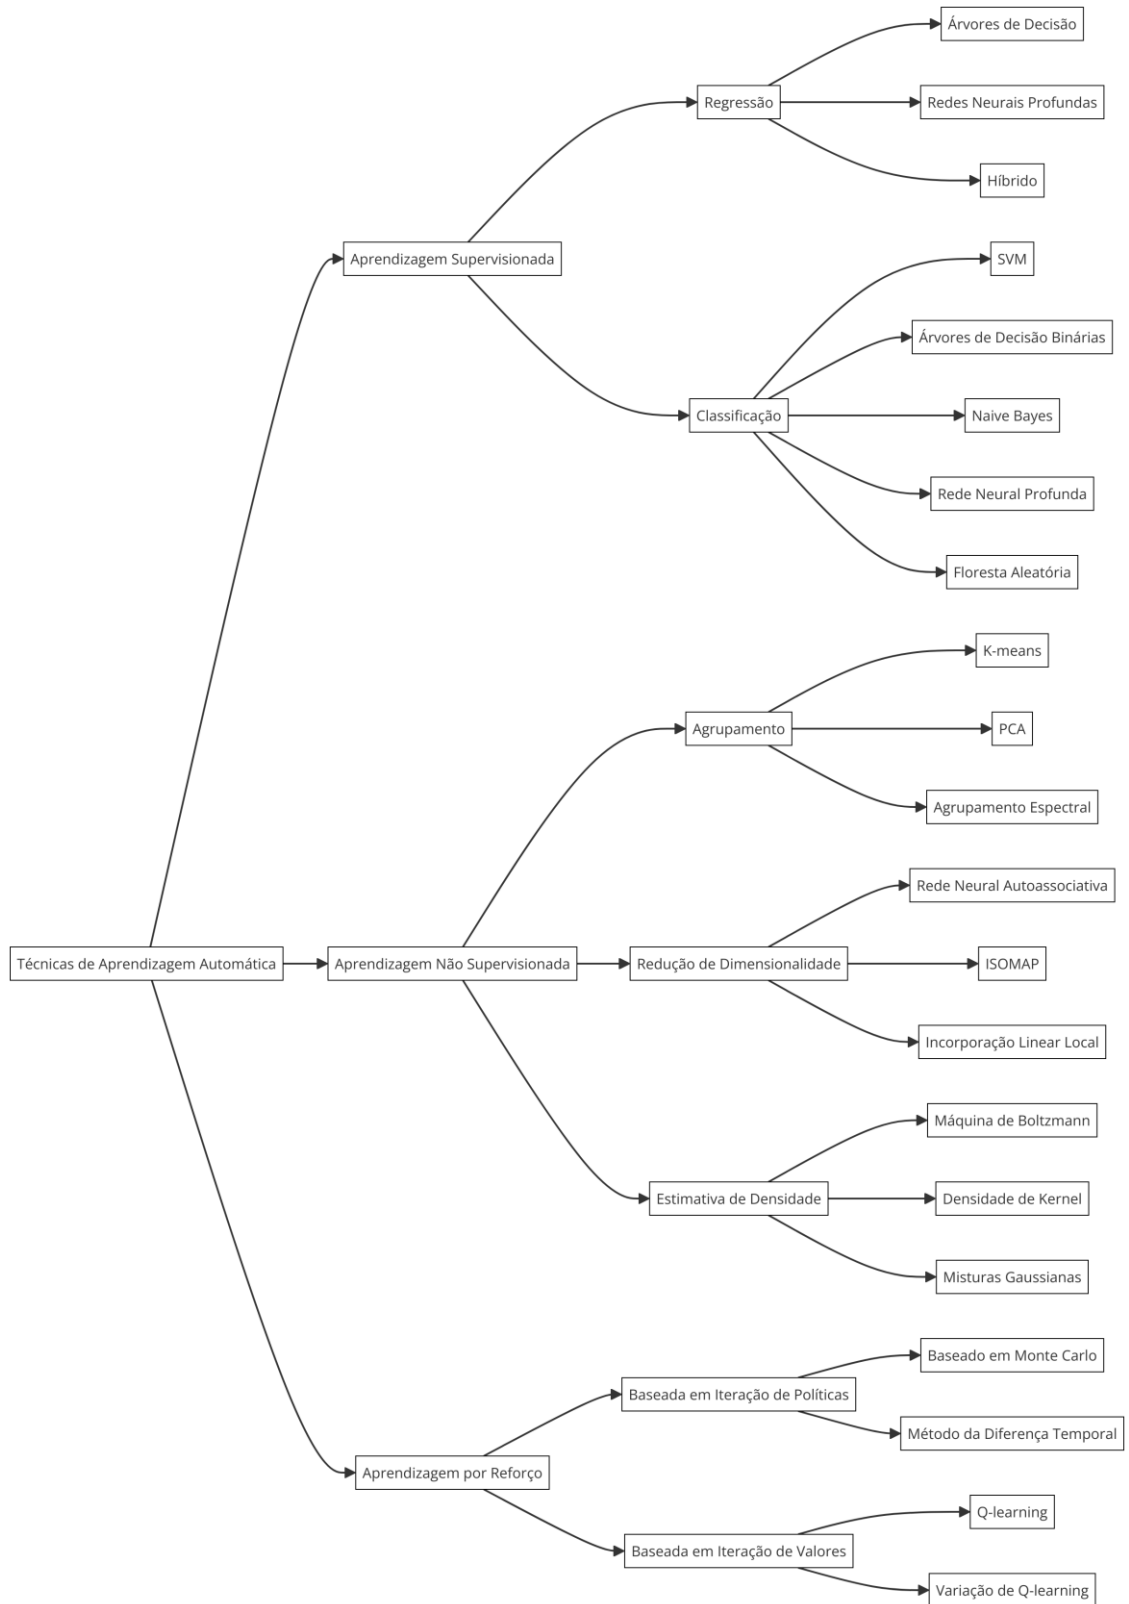


Figura 9 - Tecnologias do ML (adaptada de [35])

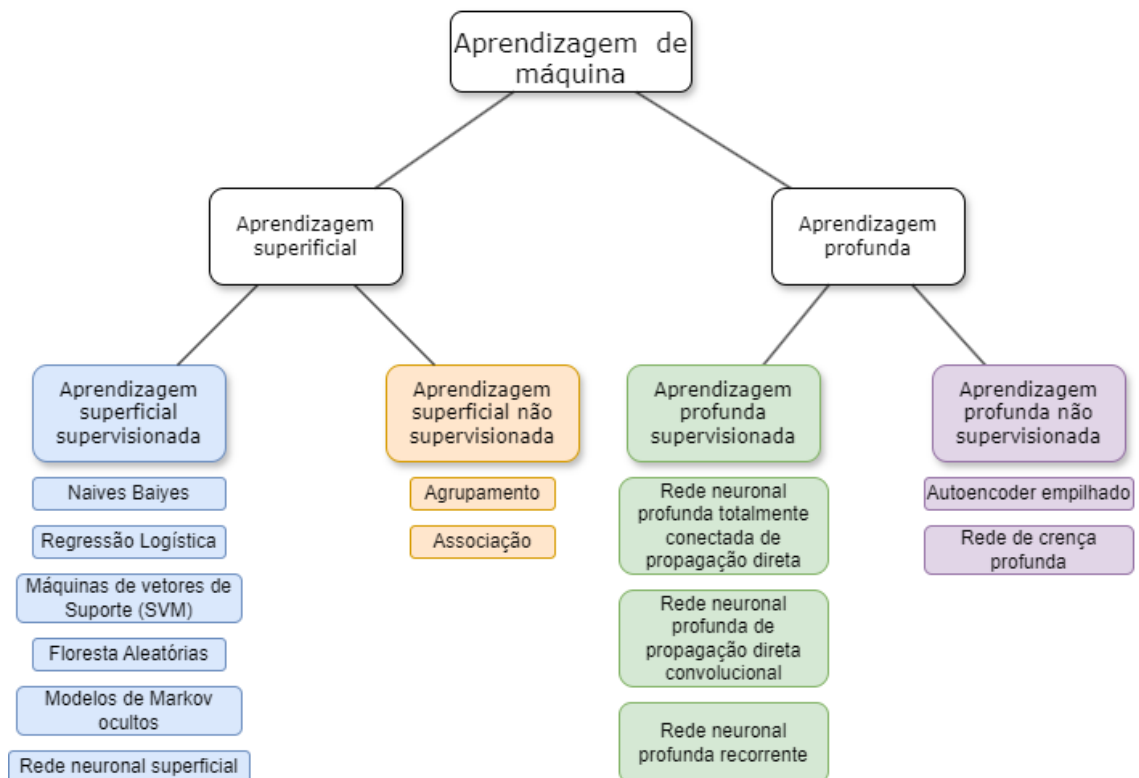


Figura 10 - Classificação dos algoritmos de ML (adaptada de [35])

2.3. Técnicas de ML Utilizadas nos Edifícios Inteligentes

Este capítulo irá proporcionar uma visão abrangente sobre as diversas técnicas de ML que são mais utilizadas em contextos de edifícios inteligentes e desempenham um papel crucial na gestão eficiente dos sistemas AVAC. As técnicas abordadas serão as árvores de decisão, o *random forest*, a *artificial neural network* e por fim a *fuzzy logic*.

2.3.1. Árvores de Decisão

As árvores de decisão funcionam de uma forma semelhante a uma árvore, onde cada nó interno representa uma decisão com base num atributo específico, cada ramificação representa uma possível escolha para esse atributo, e cada folha representa o resultado da decisão. O processo de construção de uma árvore de decisão envolve a divisão recursiva dos dados em subconjuntos com base nos atributos mais relevantes [41].

Uma árvore de decisão possui a seguinte estrutura típica [42]:

- Nós raiz (*Root Node*), conjunto de origem;
- Nós de decisão (*Decision Node*), decisão do conjunto de origem;
- Nós folha (*Leaf Node*), são rotulados com valores ou com intervalos.

A Figura 11 representa de uma forma clara a estrutura de uma árvore de decisão.

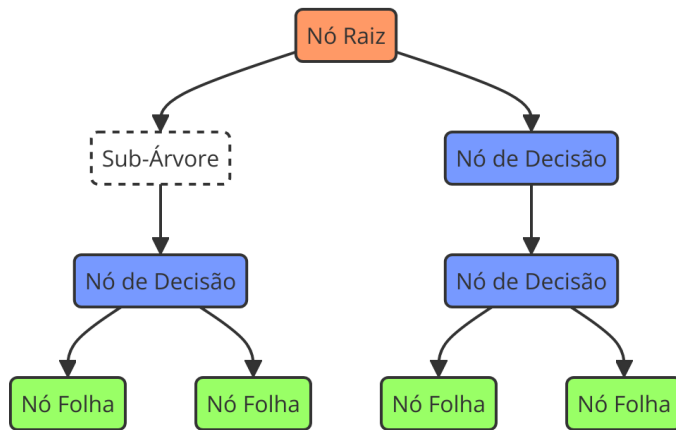


Figura 11 - Estrutura de uma árvore de decisão [58].

2.3.2. *Random Forest*

O *random forest* resume-se a um conjunto de árvores de decisão. Em grande medida, se uma árvore de decisão é boa, então um conjunto de árvores de decisão provavelmente apresenta resultados melhores [41].

A principal vantagem desta técnica de ML é a forma como cria a aleatoriedade a partir de um conjunto de dados padrão. Existem alguns métodos para aumentar ou diminuir a aleatoriedade do *random forest*, por exemplo, o *Bagging* consiste em criar árvores diferentes treinando-as, assim, com dados diferentes [41].

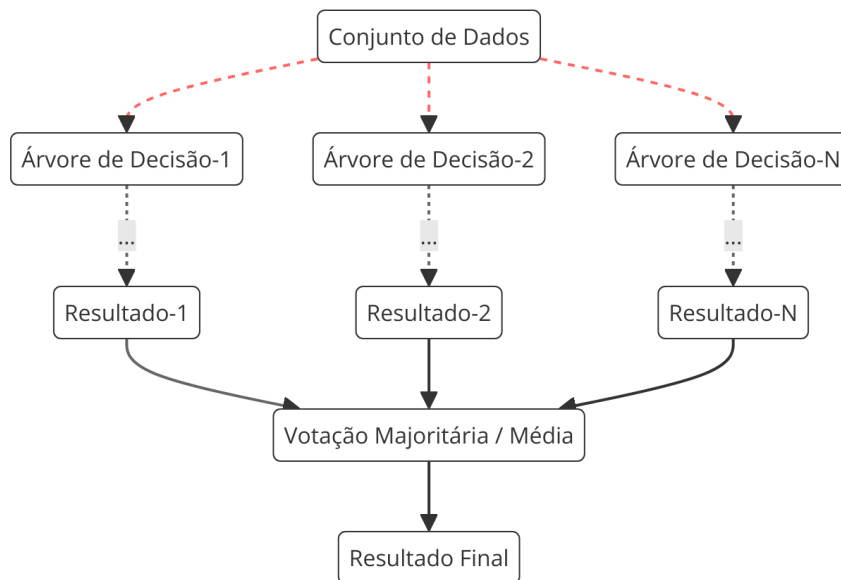


Figura 12 - Estrutura do random forest (adaptada de [43])

No processo de construção da *random forest*, os dados são escolhidos de forma aleatória em cada nó de cada árvore de decisão, ver Figura 12. Em seguida, é aplicada a medida de impureza de Gini (*Gini Impurity*), que avalia a probabilidade de uma classificação estar incorreta. Este

cálculo é realizado apenas no conjunto de dados considerado, identificando o dado “melhor” (aquela com a menor impureza de Gini). A abordagem *random forest*, é amplamente utilizada na construção de sistemas energéticos, pois esta destaca-se na previsão do consumo de energia em intervalos de horários [41].

2.3.3. Redes Neurais Artificiais

De acordo com [44], as ANNs podem ser definidas como,

“As funções dos neurónios do cérebro são reproduzidas por grandes conjuntos de algoritmos que representam as redes neuronais artificiais. Estas são capazes de estabelecer relações entre variáveis não lineares altamente anómalas e produzir resultados sofisticados, precisos e fiáveis para problemas complexos através da aprendizagem e do treino.”

Existem essencialmente dois tipos de ANNs: o *Feed-Forward Neural Network* (FFNN) e o *FeedBack Neural Network* (FBNN). O FFNN consiste numa conexão de várias camadas de em que a cada de saída não cria ligações de retorno, isto é, funciona como um fluxo unidirecional, Figura 13. Em contrapartida o FBNN permite a criação de um ciclo em que as informações erradas são reenviadas para a alteração iterativa dos valores até que o erro não possa ser melhorado, Figura 14 [44].




Figura 13 - Arquitetura do FFNN [60]

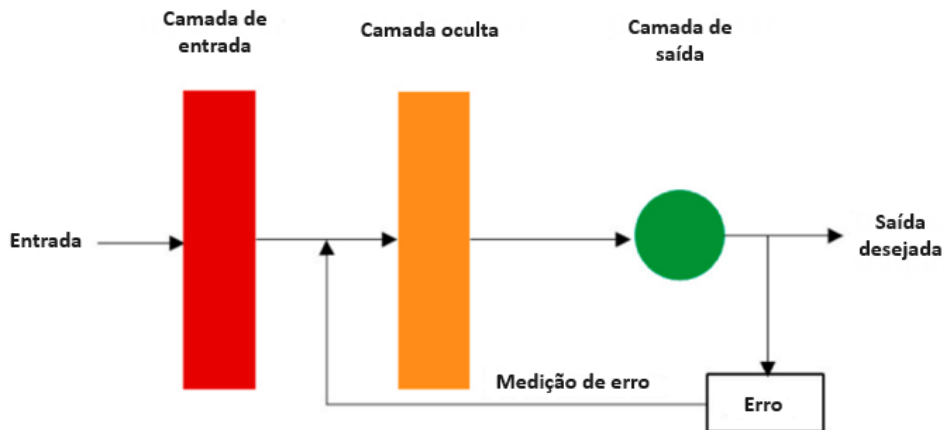


Figura 14 - Arquitetura do FBNN [61]

Quando a ANN contem várias camadas passa a ser denominado de *Deep Neural Network* (DNN). A medida que são adicionados mais dados a DNN tende a ter cada vez melhor desempenho, no entanto isso faz com que sejam requeridos um elevado número de dados e um elevado poder computacional [44].

2.3.4. Lógica de Fuzzy (FL)

A FL é um ramo da lógica que lida com a incerteza e a imprecisão, em contraste com a lógica clássica, que opera sob o princípio do terceiro excluído, onde uma proposição é verdadeira ou falsa, sem meio-termo. A lógica fuzzy sugere uma abordagem para lidar com situações em que a fronteira entre as categorias de verdadeiro e falso não é clara [45].

No dia-a-dia, ao utilizar a linguagem natural para transmitir conhecimentos e informações existe uma elevada imprecisão e ambiguidade, como por exemplo:

- Classificar os pacientes como depressivos;
- Classificar as pessoas em função da sua idade, como por exemplo, idosas.

Nos exemplos supramencionados os termos “depressivos” e “idosas” são termos *fuzzy*, isto é, são termos que não podem ser definidos com exatidão. Contudo, enquanto seres humanos, atribuímos significado a esses termos e usamo-los para tomar decisões [46].

Desta forma, criou-se uma linguagem matemática flexível capaz de caracterizar e inferir relações imprecisas à semelhança da linguagem/comunicação humana[47].

A título ilustrativo, na Figura 15 são apresentadas as comparações de estatura entre duas pessoas, tanto numa abordagem convencional como numa abordagem baseada em FL.

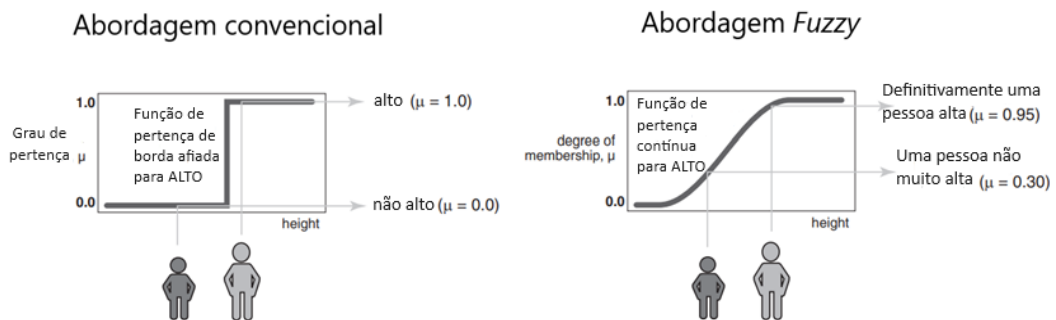


Figura 15 - Diferenças entre a abordagem convencional e a abordagem Fuzzy (adaptada de [51]).

Na abordagem convencional, a determinação da altura de uma pessoa resume-se a um estado binário, isto é, “a pessoa é baixa” ou “a pessoa é alta”. No entanto, ao adotar uma abordagem *Fuzzy*, é viável mensurar a incerteza associada à altura da pessoa, considerando o contexto do universo de pessoas ao seu redor. Assim, a FL pode ser integrada em inúmeros contextos, como por exemplo, no ajuste da temperatura de conforto num dado sistema de ar condicionado de um espaço [48].

Na Figura 16, são delineados os passos cruciais para calcular um sistema baseado na lógica *Fuzzy*.

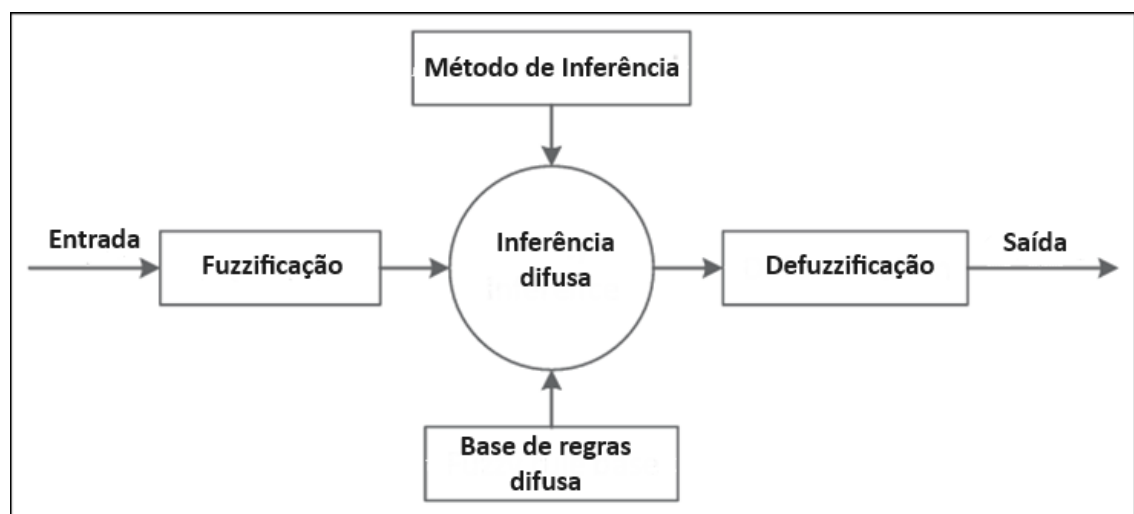


Figura 16 - Passos para calcular um sistema baseado na lógica Fuzzy. [64]

Para uma compreensão mais aprofundada, é fundamental desmistificar cada um desses passos. Como foi referido anteriormente, ao contrário da lógica tradicional, que opera com valores nítidos (verdadeiros ou falsos), a lógica *Fuzzy* permite a representação de informações que possuem graus de pertinência ou imprecisão [45].

Quando aplicamos a fuzzificação a dados precisos, geralmente expressos como números reais, estamos a reconhecer que esses dados podem ter particularidades e variações que não podem ser completamente descritas por um único valor exato. Em vez de forçar uma categorização rígida, a fuzzificação transforma esses valores precisos em conjuntos *fuzzy* [49].

1º Passo – Fuzzificação

Se a temperatura ambiente tiver o valor preciso de 25°C, a fuzzificação pode converter esse valor num conjunto *fuzzy* que representa a pertinência desse valor em graus de “frio”, “morno” e “quente”. Assim, a fuzzificação incorpora a ideia de que 25°C não corresponde simplesmente a “quente” ou “frio”, mas pode ter diferentes graus de pertinência a essas categorias.

2º Passo – Contribuições das regras de inferência *Fuzzy*

As regras de inferência *fuzzy* descrevem as relações lógicas entre as variáveis *fuzzy* do sistema. As regras são do tipo se-então [48]:

Se x é A , então y é B .

Essencialmente, as regras de inferência *fuzzy* atuam como diretrizes para a tomada de decisões. Estas descrevem condições e relações entre as variáveis *fuzzy*, de forma a determinar como é que essas variáveis interagem para produzir uma saída *fuzzy* [50].

Um aspeto crucial é a atribuição de contribuições às regras, indicando a importância relativa de cada uma no processo de tomada de decisão *fuzzy*. Essas contribuições refletem o impacto que cada regra tem na saída final do sistema. Isto é, diferentes regras podem contribuir de forma distinta, dependendo de seus graus de ativação. Estes graus de ativação são determinados com base na pertinência das variáveis de entrada [50].

3º Passo – Desfuzzificação

Esta etapa é essencial para converter a saída *fuzzy* num valor real e compreensível [48].

Segundo [46], existem vários processos de desfuzzificação, sendo os mais utilizados os abaixo apresentados:

- *Centroid (or center-of-gravity) defuzzification*
- *Mean-of-maxima defuzzification.*
- *Center-of-area defuzzification.*

O método *Center-of-area* é o mais utilizado, pois garante a simplicidade computacional sem que isso afete as conclusões provenientes dos estudos efetuados [48].

2.4. Análise Crítica da Revisão Bibliográfica

Neste capítulo, propõe-se uma análise crítica da revisão bibliográfica realizada, com foco na aplicabilidade das técnicas de ML no contexto dos sistemas de AVAC em edifícios inteligentes. Através da revisão, foram identificadas várias técnicas de ML, cada uma com suas vantagens, limitações e aplicações específicas.

As árvores de decisão são descritas na literatura como uma técnica de fácil interpretação e rápida de treinar. No entanto, apresentam limitações significativas em dados complexos e uma tendência ao *overfitting*, especialmente em árvores mais profundas. A sua aplicabilidade em sistemas AVAC é destacada na monitorização de condições operacionais e previsão de falhas,

proporcionando uma abordagem inicial simples e eficiente para problemas menos complexos. A técnica de *random forest*, uma extensão das árvores de decisão, destaca-se pela alta precisão e pela redução do *overfitting* através da combinação de múltiplas árvores. Esta técnica, embora exija mais recursos computacionais, é excelente na identificação de padrões complexos em dados de sensores e na seleção de características significativas para a detecção de falhas em sistemas AVAC. Comparada com as árvores de decisão, a *random forest* obtém uma precisão superior, sendo mais adequada para cenários com maior complexidade de dados.

As ANNs são ideais para lidar com grandes volumes de dados e variáveis de entrada, sendo capazes de aprender a partir de exemplos e resistir a ruídos nos dados. Na gestão de sistemas AVAC, as ANNs são vistas como uma boa solução para a previsão do consumo de energia tendo em conta a adaptação às condições ambientais e de ocupação. Em comparação com as SVM, as ANNs oferecem uma flexibilidade superior na modelagem de relações não lineares complexas. A FL é valorizada pela sua capacidade de lidar com incertezas e imprecisões, permitindo a modelagem de processos complexos sem necessidade de um modelo exato. Esta técnica é particularmente útil na descrição linguística do conforto térmico e na gestão de sistemas AVAC não lineares. Contudo, a implementação da FL pode ser complexa e a precisão do ajuste é normalmente baixa. Comparada com as ANNs e SVM, a FL oferece uma abordagem complementar, sendo mais adequada para situações onde a imprecisão e a linguística desempenham um papel crucial.

As SVM são reconhecidas pela sua capacidade de generalização e pela eficácia em tarefas de classificação com conjuntos de dados pequenos. Com a utilização de técnicas de *kernel*, as SVM podem lidar com dados não linearmente separáveis, oferecendo uma precisão elevada na detecção e diagnóstico de falhas em sistemas AVAC. Em comparação com a *random forest*, as SVM são mais eficientes em cenários com dados limitados, enquanto a *random forest* destaca-se em contextos com grandes volumes de dados. A revisão bibliográfica evidencia que cada técnica de ML possui características distintas que as tornam mais ou menos adequadas para diferentes aspetos da gestão de sistemas AVAC em edifícios inteligentes. As ANNs e *random forest* destacam-se pela capacidade de lidar com grandes volumes de dados e prever consumos energéticos com alta precisão, enquanto a FL oferece uma abordagem eficaz para a gestão de incertezas e variáveis linguísticas. A Tabela 1, sintetiza a aplicabilidade das técnicas de ML discutidas, as suas vantagens, limitações e aplicabilidade em serviços de energia e conforto.

Tabela 1 - Aplicabilidade de algumas técnicas ML

Técnica ML	Vantagens	Limitações	Aplicabilidade em serviços de energia e conforto
Árvore de Decisão [51]	<ul style="list-style-type: none"> ▪Fácil de Interpretar; ▪Rápida de treinar; 	<ul style="list-style-type: none"> ▪Apresenta baixa precisão em dados complexos; ▪A árvore profunda tem tendência a apresentar <i>overfitting</i>. 	<ul style="list-style-type: none"> ▪Monitorização de condições operacionais do sistema de AVAC. ▪Previsão de falhas dos sistemas de AVAC.
Random Forest [52]	<ul style="list-style-type: none"> ▪Alta precisão; ▪O <i>overfitting</i> é reduzido pela combinação de várias árvores de decisão; 	<ul style="list-style-type: none"> ▪Requer mais recursos computacionais; 	<ul style="list-style-type: none"> ▪Excelente na identificação de padrões complexos em dados de sensores; ▪Aplicável na seleção de características significativas para deteção de falhas em AVAC.
Artificial Neural Networks [53]	<ul style="list-style-type: none"> ▪Consegue lidar com um número elevado de variáveis de entrada; ▪Consegue lidar com grandes bases de dados; ▪Resistência ao "ruído" e aos dados ilegíveis; ▪Possibilidade de aprender a partir de exemplos. 	<ul style="list-style-type: none"> ▪Falta de um método sistemático para definir a melhor topologia da rede e o número de neurónios a colocar nas camadas ocultas; ▪Dificuldade na escolha dos valores iniciais dos pesos da rede; ▪Problema de sobre aprendizagem à custa da generalização. 	<ul style="list-style-type: none"> ▪Os métodos ANN são considerados mais fiáveis para a previsão do consumo de energia em sistemas de AVAC; ▪As ANN podem ser utilizadas para definir a noção de conforto térmico; ▪As ANN podem ser utilizadas para calcular o momento ideal para iniciar o aquecimento após um período de desocupação;
Fuzzy Logic [53]	<ul style="list-style-type: none"> ▪Não existe necessidade de modelação; ▪Capacidade de aplicar conhecimentos linguísticos do operador do processo; ▪Experiência em sistemas a afinar com comportamento complexo (altamente não linear e difícil de modelar); ▪Capacidade de gerir a incerteza e a imprecisão, e a capacidade de modelizar mecanismos de raciocínio e de tomada de decisão humana. 	<ul style="list-style-type: none"> ▪ Só podem utilizar um número limitado de entradas, uma vez que o aumento do número de funções de filiação e regras de inferência fuzzy torna o sistema mais complexo de resolver; ▪Falta de orientações precisas para a conceção de um ambiente (escolha das quantidades a medir, determinação de fuzzificação, inferências e defuzzificação); ▪A implementação do conhecimento do operador é muitas vezes difícil; ▪A precisão do ajustamento é normalmente baixa; 	<ul style="list-style-type: none"> ▪A lógica difusa pode exprimir o conforto térmico de uma forma linguística e, portanto, pode descrever conforto térmico em vez de descrever os níveis de temperatura ou humidade resultando numa maior eficiência; ▪Os métodos de FL são adequados para sistemas não lineares, por exemplo, sistemas AVAC. São capazes de aproximar uniformemente uma função não linear com qualquer grau de exatidão e permitem, também, um funcionamento rápido.

3. Métodos e Aplicação

Este capítulo descreve detalhadamente a metodologia adotada e a aplicação prática dos modelos de IA no controlo de sistemas de AVAC em edifícios inteligentes. Este capítulo é estruturado em várias secções que abrangem desde a descrição do ambiente de estudo e a contextualização do problema até a apresentação dos dados utilizados, o desenvolvimento dos modelos de IA e as estratégias de treino adotadas. Também se discutem os critérios e métricas de avaliação aplicados para validar a eficácia dos modelos.

3.1. Descrição do Ambiente de Estudo e Contextualização

Este subcapítulo fornece uma visão detalhada do ambiente de estudo, contextualizando a importância da integração da IA na gestão de sistemas de AVAC em edifícios inteligentes. A preparação dos dados envolveu processos de limpeza e transformação para garantir a sua integridade. Foram criadas variáveis críticas, como o índice de calor e a ocupação, para registar aspetos essenciais do conforto térmico e da presença humana, fundamentais para a gestão eficiente dos sistemas AVAC.

3.1.1. Bases de Dados Utilizadas

A investigação realizada nesta dissertação fundamenta-se em bases de dados providenciadas pelo ISEP, mais especificamente do edifício GECAD, dedicado ao estudo e desenvolvimento em IA. As bases de dados contêm registos detalhados obtidos de várias salas, ao longo de todo o ano de 2022, com atualizações a cada 5 minutos. Estes dados incluem várias métricas ambientais e operacionais críticas, como a temperatura exterior e interior, a humidade relativa, a intensidade de luz e o estado operacional do sistema de ar condicionado, detalhado como -1 (ligado em modo de aquecimento), 0 (desligado) e 1 (ligado em modo de arrefecimento).

Dada a extensiva periodicidade da coleta e a natureza real dos ambientes monitorizados, a base de dados apresentou entradas com valores “NULL”, indicativos de períodos de interrupção como falhas de energia ou falhas no sistema de registo. A primeira etapa na preparação dos dados envolveu a remoção dessas entradas, essencial para evitar distorções na análise e no treino dos modelos de IA. Esta limpeza garante a integridade dos dados que servem de base para a modelagem subsequente.

Após a limpeza inicial, procedeu-se à transformação dos dados para formatos mais adequados para análise. Uma etapa crítica foi a criação de novas variáveis derivadas dos dados brutos para

capturar aspetos relevantes que os modelos de IA poderiam não discernir diretamente. Essas variáveis são: o índice de calor e a ocupação.

A análise do Índice de Calor (HI) assume uma importância primordial em estudos relacionados ao conforto térmico em ambientes internos. Esta métrica é crucial porque sintetiza dois dos mais significativos fatores ambientais que afetam o conforto humano: a temperatura e a humidade. A compreensão de como esses fatores interagem para influenciar a percepção térmica dos ocupantes permite aos sistemas de gestão de edifícios inteligentes otimizar as suas respostas. A equação usada para a determinação do HI foi a seguinte [54]:

$$\begin{aligned} HI = & -42.379 + 2.04901523T + 10.14333127R - 0.22475541TR \\ & - 6.83783 \times 10^{-3}T^2 - 5.481717 \times 10^{-2}R^2 \\ & + 1.22874 \times 10^{-3}T^2R + 8.5282 \times 10^{-4}TR^2 \\ & - 1.99 \times 10^{-6}T^2R^2 \end{aligned} \quad (1)$$

onde T representa a temperatura ambiente em graus Fahrenheit e R a Humidade relativa em percentagem.

Esta equação complexa considera a interação entre temperatura e humidade de uma forma que simula com precisão a sensação térmica real experimentada pelos ocupantes. Assumindo condições de vestuário padrão e taxas de atividade metabólica definidas, o modelo ajusta as variações de percepção do calor humano conforme as mudanças na humidade e temperatura ambiente. Além disso, incorpora uma série de outros fatores biomecânicos e ambientais que influenciam a transferência de calor e humidade através da pele e do vestuário. A aplicação desta variável nos modelos de IA permite uma gestão mais precisa e eficiente dos sistemas AVAC, ao adaptar as respostas dos sistemas em tempo real às condições dinâmicas dentro de um edifício. Por conseguinte, o HI serve não apenas como uma ferramenta para manter o conforto, mas também como um meio para realizar uma operação energética mais sustentável e responsiva, alinhada aos princípios de edifícios inteligentes e automatizados.

A variável “ocupação” desempenha um papel crucial no comportamento dos sistemas de AVAC em edifícios inteligentes, servindo como um indicador fundamental para a ativação e regulação desses sistemas baseado na presença humana. Esta variável foi derivada da análise da intensidade de luz registada nas salas monitorizadas.

Para implementar esta abordagem, estabeleceu-se um limiar de luminosidade, determinado a partir do valor mínimo registado durante a coleta de dados. Qualquer leitura de iluminação que superasse esse limiar era interpretado como um sinal de ocupação da sala, sendo então codificada como “1” (presença). Por outro lado, leituras que não ultrapassassem esse limiar eram consideradas indicativas de uma sala vazia, sendo codificadas como “0” (ausência). Essa categorização é particularmente vantajosa porque permite uma resposta rápida e eficaz dos sistemas de climatização, que podem ser ajustados automaticamente para economizar energia quando ninguém está presente, ou para garantir o conforto térmico quando detetada a presença de ocupantes. Além disso, a adoção de um indicador binário de ocupação elimina a necessidade de modelos mais complexos para interpretar os dados de luminosidade, o que poderia introduzir incertezas adicionais nos modelos de IA.

As variáveis das bases de dados utilizadas na investigação são as seguintes:

- **Temperatura exterior:** Mede a temperatura ambiente fora do edifício;
- **Temperatura dos espaços em estudo:** Refere-se à temperatura registada no interior do espaço monitorizado;
- **Humidade dos espaços em estudo:** Mede a humidade relativa dentro das salas monitorizadas;
- **HI nos espaços em estudo:** HI calculado para os espaços interiores, através da temperatura e humidade;
- **Ocupação:** Indicador binário (0 ou 1) da presença humana nas salas monitorizadas;
- **Estado do ar condicionado:** Indica o estado operacional do sistema de ar condicionado, com valores -1 (aquecimento), 0 (desligado) e 1 (arrefecimento).

3.2. Desenvolvimento dos Modelos de IA

Neste subcapítulo, é explorado o desenvolvimento dos modelos de IA aplicados ao controlo de sistemas de AVAC em edifícios inteligentes. O objetivo é proporcionar uma compreensão detalhada das metodologias e técnicas aplicadas para configurar, treinar e avaliar os modelos, de forma a garantir a sua eficácia no conforto. A estrutura deste subcapítulo está organizada em três secções principais, a configuração inicial dos modelos de IA, as estratégias de treino adotadas e os critérios e métricas de avaliação utilizadas.

3.2.1. Configuração Inicial dos Modelos de IA

Como referido anteriormente, a configuração inicial dos modelos de IA para o controlo dos sistemas AVAC em edifícios inteligentes envolveu uma meticulosa preparação e processamento de dados registados de ambientes monitorizados em tempo real. Embora todos os modelos de IA discutidos tenham sido abordados e explicados detalhadamente na revisão bibliográfica da dissertação, aqui será feita uma breve descrição dos modelos utilizados neste estudo específico, utilizando dados ambientais como temperatura interna e externa, humidade, HI e ocupação.

As Árvores de Decisão utilizam uma abordagem de segmentação binária dos dados, onde cada divisão representa uma “decisão” baseada em valores de atributos. Este modelo é ideal para situações onde a clareza do processo de decisão é crucial, como no ajuste dos parâmetros de sistemas AVAC com base em critérios ambientais específicos [55].

Aprofundando a técnica da árvore de decisão, o modelo *random forest* integra múltiplas árvores para melhorar a confiabilidade e a precisão das previsões. A diversidade entre as árvores do modelo reduz o risco de *overfitting*, fazendo deste uma boa escolha para prever o comportamento complexo dos sistemas AVAC em diferentes condições ambientais [56].

As redes neuronais *feedforward*, compostas por camadas de neurónios que processam sinais numa única direção (da entrada para a saída), são capazes de treinar relações complexas e não lineares. A sua aplicação em sistemas AVAC permite a adaptação inteligente às mudanças contínuas no ambiente interno e externo [57].




Figura 17 - Ordem de aplicação das estratégias de treino

Para este desenvolvimento, foi utilizado o *jupyter notebook* e a linguagem *python*. *Python* foi escolhido devido à sua versatilidade, vasta gama de bibliotecas especializadas (como *scikit-learn* para ML, *pandas* para manipulação de dados e *matplotlib* para visualização), e uma comunidade ativa que contribui para um desenvolvimento rápido e eficiente. O *jupyter notebook*, por sua vez, proporciona um ambiente interativo que facilita a prototipagem e a análise exploratória dos dados, permitindo a execução de código em células separadas e a visualização instantânea dos resultados.

3.2.2. Estratégias de Treino

Para garantir a eficácia e eficiência dos sistemas de AVAC em edifícios inteligentes, é essencial adotar estratégias de treino de modelos de IA que reflitam com precisão as condições operacionais reais e otimizem o desempenho do sistema. Neste contexto, devem ser utilizadas diferentes abordagens de treino para desenvolver modelos com bom desempenho capazes de adaptar a variáveis ambientais complexas. A seguir, ir-se-á explorar três estratégias principais de treino empregadas neste estudo: o uso de dados originais, a aplicação de técnicas de *oversampling* e *undersampling* e a otimização de hiperparâmetros via *grid search*. Cada uma destas estratégias contribui de forma significativa para o desenvolvimento de sistemas AVAC mais inteligentes e responsivos, ver Figura 17.

Dados originais:

Esta estratégia implica o uso de dados obtidos diretamente de sensores e sistemas sem qualquer forma de manipulação prévia, como o balanceamento de classes.

Ao utilizar dados não modificados, os modelos de IA podem capturar e refletir fielmente a verdadeira dinâmica e variabilidade dos sistemas de AVAC. Esta fidelidade é crucial, pois os sistemas de controlo de climatização devem responder precisamente às condições reais para maximizar o conforto e minimizar o consumo de energia. Modelos treinados com dados originais são capazes de identificar padrões e tendências que são inerentemente naturais ao

ambiente, incluindo variações diurnas e sazonais nas condições de temperatura e humidade, essenciais para a programação eficiente e o controlo dos sistemas AVAC.

No entanto, o uso de dados originais não está isento de desafios. Frequentemente, esses dados podem estar desbalanceados, indicando que certos estados operacionais, como o sistema de AVAC estar desligado, podem ocorrer mais frequentemente do que outros estados, como ligado em modo de aquecimento ou em modo de arrefecimento. Este desequilíbrio pode induzir os modelos de IA a desenvolver uma tendência, onde tendem a prever predominantemente a classe maioritária.

Oversampling:

Durante a análise inicial da base de dados, foi constatada uma disparidade significativa na frequência dos estados do sistema AVAC: existiam 101 371 registos do ar condicionado desligado, 7 044 registos do ar condicionado ligado em aquecimento, e apenas 2 374 registos do ar condicionado ligado em arrefecimento. Esta grande diferença indicou claramente a necessidade de implementar uma estratégia que equilibrasse as classes para melhorar a capacidade do modelo de prever os estados menos frequentes.

Para enfrentar este desafio da distribuição desigual das classes nos dados de sistemas AVAC, foi aplicada a técnica SMOTE (*Synthetic Minority Over-sampling Technique*) de *oversampling*.

A técnica SMOTE cria exemplos sintéticos da classe minoritária ao invés de simplesmente replicar os existentes. Esta abordagem contribui para aumentar a generalidade do modelo, pois os dados sintéticos gerados expandem a região de decisão da classe minoritária, facilitando a aprendizagem e a generalização a partir de uma representação mais equilibrada das classes. A utilização do SMOTE é benéfica para mitigar o problema de *overfitting* que os modelos de ML frequentemente enfrentam quando treinados em conjuntos de dados desbalanceados. Ao equilibrar as classes, os modelos têm uma maior probabilidade de aprender características distintas de cada classe, em vez de meramente prever a classe maioritária.

Contudo, é importante notar que o *oversampling* com SMOTE, embora eficaz no balanceamento de classes, pode ter algumas limitações. A geração de dados sintéticos pode, por vezes, introduzir ruído, especialmente se os pontos de dados da classe minoritária forem atípicos. Isso significa que, embora o modelo possa apresentar uma boa performance nos dados de treino, pode não se traduzir numa aplicação real tão eficaz, uma vez que os dados introduzidos não são reais.

Para a implementação do SMOTE, foi utilizada a biblioteca de python *imbalanced-learn*. Esta biblioteca é amplamente reconhecida pela sua eficácia no tratamento de problemas de balanceamento de classes em conjuntos de dados [58].

Undersampling:

Ao contrário do *oversampling* que cria dados sintéticos da classe minoritária, o *undersampling* reduz a quantidade de dados da classe maioritária, equilibrando assim o conjunto de dados. Ao reduzir o número de exemplos da classe mais frequente, é possível criar um conjunto de dados mais equilibrado, que pode ajudar a melhorar a precisão do modelo na previsão das classes minoritárias.

O *undersampling* oferece a vantagem de simplificar o conjunto de dados ao eliminar a redundância de exemplos da classe majoritária. Esta abordagem é particularmente eficaz quando se procura reduzir o tempo de treino do modelo e melhorar a sua capacidade de generalização, evitando que o modelo se concentre excessivamente na classe majoritária. Contudo, a redução do número de exemplos da classe majoritária pode levar à perda de informação relevante, o que pode comprometer a capacidade do modelo de capturar a complexidade dos dados. Além disso, o *undersampling* pode aumentar a variabilidade nos dados de treino.

Para a implementação do *undersampling*, foi utilizada, novamente, a biblioteca *python imbalanced-learn*, que oferece ferramentas para realizar esta técnica de forma eficiente [58].

Grid Search:

A otimização dos hiperparâmetros é uma etapa crítica no desenvolvimento de modelos de IA. Para isso, foi usado o método de *grid search*, uma técnica que permite uma procura exaustiva através de um conjunto específico de hiperparâmetros, testando sistematicamente várias combinações para determinar quais proporcionam o melhor desempenho do modelo.

No processo de *grid search*, cada combinação de parâmetros é avaliada e validada contra um conjunto de dados de validação cruzada, o que permite uma comparação direta entre diferentes configurações. Por exemplo, para as Árvores de Decisão, variáveis como a profundidade máxima da árvore, o critério de divisão e o número mínimo de amostras por folha são meticulosamente ajustadas para otimizar o desempenho do modelo. De forma similar, para o modelo de *random forest*, parâmetros como o número de árvores na floresta, e a profundidade máxima das árvores são ajustados. O ajuste destes parâmetros pode ajudar a melhorar significativamente a precisão e o desempenho do modelo, permitindo que lide melhor com as variações e as características intrínsecas dos dados de sistemas AVAC.

O uso do *grid search* garante que a seleção dos hiperparâmetros seja tanto sistemática quanto abrangente, eliminando a arbitrariedade na escolha dos parâmetros e aumentando a confiabilidade dos resultados.

A eficácia do *grid search*, contudo, depende da gama de valores considerados para cada hiperparâmetro e da quantidade de dados disponíveis para o treino e validação.

Para a implementação do *grid search*, foi utilizada a biblioteca *python scikit-learn*, que oferece ferramentas robustas para a otimização de hiperparâmetros [59].

3.2.3. Critérios e Métricas de Avaliação

Para garantir que os modelos de IA aplicados operem com eficácia, é crucial avaliar o seu desempenho utilizando várias métricas estatísticas. Estas métricas fornecem informações detalhadas sobre diferentes aspetos do desempenho dos modelos, desde a precisão geral até à capacidade de identificar corretamente estados específicos do sistema. Neste subcapítulo serão discutidas as principais métricas de avaliação utilizadas para analisar a eficiência dos modelos desenvolvidos, incluindo a exatidão, precisão, *recall*, *f1-score* e as pontuações de

validação cruzada. Adicionalmente, será abordada a matriz de confusão como uma ferramenta essencial para visualizar o desempenho do modelo.

Exatidão:

A exatidão é uma das métricas mais importantes para avaliar o desempenho de modelos de IA. Esta métrica é definida como a proporção de previsões corretas, incluindo tanto verdadeiros positivos quanto verdadeiros negativos, em relação ao total de casos testados. Por outras palavras, a exatidão mede o grau de conformidade entre as previsões do modelo e os estados reais observados do sistema.

No contexto de sistemas AVAC, onde a eficiência operacional e o conforto são cruciais, a exatidão de um modelo de IA indica a sua capacidade de executar decisões corretas sobre quando e como ativar ou ajustar os sistemas de climatização. Uma alta exatidão significa que o modelo pode efetivamente discernir entre os diferentes estados de necessidade de aquecimento, arrefecimento ou manutenção da temperatura, minimizando assim operações desnecessárias. Para uma melhor perceção a exatidão pode ser calculada da seguinte forma:

$$\text{exatidão} = \frac{\text{Número de previsões corretas}}{\text{Total de previsões feitas}} \quad (2)$$

A elevada exatidão é desejável, pois indica que o modelo é confiável, fazendo com que a gestão do sistema AVAC seja mais eficiente.

Apesar de ser uma métrica intuitiva e amplamente utilizada, a exatidão pode não ser suficiente por si só para fornecer uma imagem completa da performance de um modelo, especialmente em contextos com classes desbalanceadas, como é frequentemente em sistemas AVAC. Por exemplo, se um sistema raramente necessita de aquecimento, um modelo que sempre prevê “não aquecer” pode ter uma exatidão aparentemente alta, mas seria inútil na prática. Portanto, a exatidão deve ser complementada com outras métricas, como precisão, *recall* e *f1-score*, para uma avaliação mais completa da capacidade do modelo.

Precisão e Recall:

A precisão é uma métrica que mede a exatidão das previsões positivas feitas pelo modelo. Em termos técnicos, é a proporção de verdadeiros positivos (previsões corretas da classe positiva) em relação ao total de casos classificados como positivos (soma de verdadeiros positivos e falsos positivos). No contexto dos sistemas AVAC, uma alta precisão significa que o sistema minimiza o número de vezes que ativa inapropriadamente o aquecimento ou arrefecimento. Por exemplo, um sistema de AVAC com alta precisão só ativa o aquecimento quando é absolutamente necessário, com base nos dados de temperatura e outras condições ambientais.

O *recall*, também conhecido como sensibilidade, mede a capacidade do modelo de detetar todas as classes relevantes de um estado específico. É calculado como a proporção de verdadeiros positivos em relação ao número total de casos que realmente pertencem à classe positiva (soma de verdadeiros positivos e falsos negativos). Um *recall* elevado num sistema de AVAC significa que o sistema é eficaz em identificar quando é necessário ativar o aquecimento

ou arrefecimento para manter o conforto ambiental, garantindo que todas as necessidades de climatização sejam atendidas.

Embora tanto a precisão quanto o *recall* sejam importantes, muitas vezes há um meio-termo entre estas duas métricas. Maximizar a precisão pode resultar num menor *recall*, e vice-versa. Por exemplo, um sistema AVAC que é excessivamente cauteloso e só ativa o aquecimento em condições extremas pode ter alta precisão (poucas ativações desnecessárias), mas baixo *recall* (muitas situações onde o aquecimento era necessário não foram atendidas). Como tal, é essencial encontrar um equilíbrio adequado entre precisão e o *recall* de forma a otimizar o desempenho geral do sistema.

F1-Score:

Esta métrica fornece um equilíbrio entre a precisão e o *recall*, duas métricas essenciais que, quando consideradas isoladamente, podem não fornecer uma visão completa da eficácia do modelo. O *f1-score* é a média harmónica de precisão e *recall*, oferecendo um compromisso entre as duas. É calculado pela seguinte equação:

$$F1 = 2 \times \left(\frac{\text{precisão} \times \text{recall}}{\text{precisão} + \text{recall}} \right) \quad (3)$$

Esta métrica é especialmente valiosa porque compensa desequilíbrios significativos entre precisão e *recall*. Por exemplo, um modelo que prevê sempre a classe mais comum pode ter uma alta precisão, mas o seu *recall*, por consequência, seria extremamente baixo indicando uma eficácia limitada. Da mesma forma, um modelo que prevê sempre a ocorrência de uma condição rara (como a necessidade de aquecimento num clima predominantemente quente) pode ter um alto *recall*, mas baixa precisão. O *f1-score* ajuda a mitigar esses problemas ao fornecer uma visão mais abrangente do desempenho do modelo.

Pontuações de Validação Cruzada:

Esta técnica de validação é particularmente útil para verificar a eficácia de um modelo em condições variáveis, assegurando que o desempenho observado não é meramente circunstancial ou limitado aos dados específicos utilizados durante o treino. Normalmente as pontuações de validação cruzada são efetuadas através do método *k-fold*.

Na validação cruzada *k-fold*, o conjunto de dados é dividido aleatoriamente em "k" subconjuntos (ou *folds*) de aproximadamente igual tamanho. O modelo é então treinado "k" vezes, cada vez utilizando "k-1" *folds* para treino e o *fold* restante para teste. Este processo é repetido para cada *fold*, permitindo que cada segmento dos dados seja utilizado tanto para treino como para teste. Este método é amplamente reconhecido pela sua capacidade de fornecer uma avaliação mais abrangente e menos enviesada do desempenho do modelo.

A principal vantagem da validação cruzada *k-fold* é a sua capacidade de minimizar os efeitos do acaso na divisão dos dados de treino e teste, proporcionando uma visão mais precisa e estável da capacidade do modelo de se adaptar a novos dados. Além disso, ao usar todos os dados disponíveis para treino e teste, maximiza-se a eficiência do uso dos dados, um aspeto crucial quando as amostras são limitadas.

Matriz de Confusão

A matriz de confusão é organizada em formato de tabela, onde cada coluna da matriz representa as instâncias numa classe prevista pelo modelo, e cada linha representa as instâncias numa classe real. As entradas na diagonal principal da matriz representam o número de previsões corretas (verdadeiros positivos e verdadeiros negativos) para cada classe, o que é ideal para uma rápida visualização da eficiência do modelo em classificar cada categoria corretamente. A Figura 18 ilustra uma matriz de confusão.

		Valor Predito	
		Sim	Não
Real	Sim	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Não	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Figura 18 - Matriz de Confusão

As células fora da diagonal principal mostram os erros de classificação:

- Falsos Positivos (FP): Estas são situações onde o modelo prevê incorretamente a presença de uma condição (por exemplo, prevê que o sistema de AVAC precisa ser ligado quando na realidade não é necessário).
- Falsos Negativos (FN): Estas ocorrem quando o modelo falha em identificar uma condição existente (por exemplo, não aciona o AVAC quando deveria).

Estes erros são críticos para sistemas AVAC, pois os FP podem levar a um desperdício de energia, enquanto os FN podem resultar em desconforto para os ocupantes do edifício.

Para este problema específico, as métricas de precisão, *recall* e a matriz de confusão foram priorizadas. A precisão é crucial para minimizar ativações desnecessárias do sistema de AVAC, enquanto o *recall* garante que todas as necessidades de climatização sejam atendidas. A matriz de confusão proporciona uma visualização detalhada dos erros de classificação, ajudando a identificar onde é que o modelo pode ser melhorado

4. Resultados e Discussão

Este capítulo dedica-se à apresentação e discussão dos resultados obtidos através da aplicação de diferentes modelos de IA no controlo do sistema de ar condicionado do edifício GECAD do ISEP. Este capítulo está estruturado em três casos de estudo distintos, cada um com o objetivo de explorar e validar a eficácia dos modelos propostos em diferentes contextos e cenários específicos. No caso de estudo 1, os modelos de IA foram treinados e testados com dados de salas individuais (103, 102, 105). Este estudo teve como objetivo avaliar o desempenho dos modelos em ambientes específicos, utilizando variáveis como temperatura, humidade, HI e ocupação.

O caso de estudo 2 analisou o desempenho dos modelos quando treinados com dados agrupados de várias salas, divididas em três zonas distintas. Este estudo teve como objetivo entender se uma maior quantidade de dados de diferentes salas poderia melhorar a generalização e o desempenho dos modelos. Trabalhos anteriores no GECAD também exploraram a previsão de produção de energia com a utilização de redes neurais artificiais, o que contribui para a compreensão de como modelos baseados em IA podem ser aprimorados ao incorporar uma maior quantidade de dados e variáveis ambientais, como mostrado em [60].

No caso de estudo 3, foram introduzidas duas alterações principais: a remoção da variável de humidade e a conversão de variáveis de temperatura de valores quantitativos para qualitativos. Utilizando os mesmos dados das salas do caso de estudo 1, este estudo teve como objetivo avaliar se a simplificação dos dados e a transformação das variáveis resultariam num melhor desempenho dos modelos na previsão do estado do sistema de ar condicionado. Este enfoque simplificado segue a linha de trabalhos desenvolvidos no GECAD, como o estudo sobre a definição de tarifas de resposta à demanda em tempo real utilizando árvores de decisão, que demonstrou a eficácia de métodos de classificação na gestão de redes elétricas inteligentes e na otimização do consumo energético [61].

4.1. Caso de Estudo 1

O presente capítulo tem como objetivo apresentar e discutir os resultados obtidos a partir da aplicação dos diferentes modelos de IA, descritos na secção 2.3, no controlo do sistema de ar condicionado do edifício GECAD do ISEP. A principal meta da implementação destes modelos consistiu na promoção de um ambiente confortável, através do ajuste automático do sistema de ar condicionado conforme as variáveis ambientais e a ocupação dos espaços. Para uma exploração detalhada do desempenho dos modelos propostos, definiram-se três cenários

distintos dentro deste caso de estudo. Cada cenário envolveu o treino e teste dos modelos de IA utilizando dados específicos de diferentes salas.

No primeiro cenário, o foco do estudo foi para a sala 102. Inicialmente, a base de dados desta sala também continha 103 949 registos. A fim de equilibrar as classes e melhorar a previsão dos estados menos frequentes, aplicou-se a técnica SMOTE, que resultou numa expansão da base de dados para 304 113 registos. Para este cenário, a escolha de modelos de IA recaiu sobre a árvore de decisão, *random forest* e FFNN. Cada um destes modelos foi implementado e avaliado para analisar as suas capacidades e limitações no contexto específico da sala 102.

O segundo cenário foi desenvolvido com os dados da sala 103, que contempla uma unidade interior de ar condicionado e possui quatro postos de trabalho não fixos. Antes da aplicação da técnica de *oversampling*, a base de dados original continha 103 949 registos. Para balancear as classes e melhorar a capacidade dos modelos de IA prever os estados menos frequentes, foi utilizada a técnica SMOTE. Após a aplicação do *oversampling*, a base de dados expandiu-se para 307 437 registos. Para abordar este cenário, selecionaram-se novamente os três modelos de IA do cenário anterior: árvore de decisão, *random forest* e FFNN. Cada um destes modelos foi aplicado e analisado detalhadamente para explorar as suas capacidades e limitações específicas no contexto da sala 103. Adicionalmente, a discussão foi enriquecida com detalhes sobre a implementação prática destes modelos na sala 103, de forma a proporcionar uma perspetiva aplicada que complementa a teoria subjacente aos algoritmos de IA. Este enfoque prático é crucial para validar a funcionalidade dos modelos no ambiente real.

No terceiro cenário, a análise estendeu-se à sala 105. A base de dados inicial para esta sala foi constituída por 103 949 registos. Para mitigar o desequilíbrio nas classes e melhorar a capacidade de previsão dos estados menos frequentes, a técnica de *oversampling* SMOTE foi novamente aplicada, expandindo a base de dados para um total de 307 734 registos. Mantendo a consistência metodológica, optou-se pela aplicação dos modelos de IA: árvore de decisão, *random forest* e FFNN.

Para cada um dos cenários, seguiu-se um processo metódico. Inicialmente, os dados recolhidos foram limpos para remover valores nulos e preparar as variáveis de entrada, incluindo a criação do HI e a variável de ocupação. Em seguida, os modelos árvore de decisão, *random forest* e FFNN foram treinados com os dados específicos de cada sala. O desempenho dos modelos foi avaliado utilizando métricas como exatidão, precisão, *recall*, *f1-score* e média das pontuações de validação cruzada. Além do treino padrão, os modelos foram submetidos a técnicas de *oversampling* para balanceamento de classes e a otimização dos hiperparâmetros foi realizada através do *grid search*.

A apresentação consolidada dos resultados dos três cenários para o caso de estudo 1 é detalhada na Tabela 2, que inclui as métricas de desempenho para cada modelo de IA nas três salas analisadas. Esta abordagem permite uma comparação direta e uma análise mais abrangente das capacidades dos modelos de IA em diferentes ambientes dentro do mesmo edifício.

Tabela 2 - Resultados teóricos obtidos para o caso de estudo 1

<i>Cenário</i>	<i>Métricas de avaliação</i>	<i>Árvore de Decisão</i>	<i>Árvore de Decisão - com oversampling</i>	<i>Árvore de Decisão - com oversampling (Grid Search)</i>	<i>Random Forest</i>	<i>Random Forest - com oversampling</i>	<i>Random Forest - com oversampling (Grid Search)</i>	<i>Redes Neurais Feedforward</i>	<i>Redes Neurais Feedforward - com oversampling</i>	<i>Redes Neurais Feedforward - com oversampling (Grid Search)</i>
1	Exatidão	98,980%	99,484%	99,629%	99,220%	99,563%	99,558%	97,628%	90,605%	91,613%
	Precisão	98,989%	99,484%	99,632%	99,166%	99,565%	99,560%	95,998%	45,003%	91,684%
	<i>Recall</i>	98,980%	99,484%	99,629%	99,220%	99,563%	99,565%	97,638%	41,915%	91,613%
	<i>F1-Score</i>	98,984%	99,483%	99,629%	99,168%	99,563%	99,565%	96,538%	31,515%	91,602%
	Média das pontuações de Validação Cruzada	94,652%	97,406%	97,561%	95,848 %	97,913%	97,955%	96,927%	97,447%	97,490%
2	Exatidão	98,884%	99,082%	99,948%	99,201%	99,382%	99,388%	98,576%	78,732%	79,675%
	Precisão	98,862%	99,082%	99,948%	99,125%	99,382%	99,388%	97,172%	11,060%	79,215%
	<i>Recall</i>	98,884%	99,082%	99,948%	99,201%	99,382%	99,388%	98,576%	33,256%	79,537%
	<i>F1-Score</i>	98,872%	99,082%	99,948%	99,113%	99,381%	99,388%	97,869%	16,599%	79,224%
	Média das pontuações de Validação Cruzada	89,056%	90,674%	90,735%	91,872%	90,885%	90,943%	98,585%	98,580%	98,581%
3	Exatidão	99,013%	99,507%	99,982%	99,235%	99,575%	99,584%	98,691%	91,798%	91,982%
	Precisão	98,969%	99,507%	99,982%	99,157%	99,576%	99,585%	97,886%	78,039%	91,982%
	<i>Recall</i>	99,013%	99,507%	99,982%	99,235%	99,575%	99,584%	98,672%	37,529%	91,851%
	<i>F1-Score</i>	98,989%	99,507%	99,982%	99,167%	99,575%	99,584%	98,082%	24,950%	91,785%
	Média das pontuações de Validação Cruzada	94,831%	98,082%	98,155%	96,952 %	98,563 %	98,603%	98,690%	98,697%	98,352%

A análise dos resultados obtidos no cenário 1 revela conclusões valiosas sobre o desempenho dos modelos de IA aplicados no controlo do sistema de ar condicionado da sala 102.

A árvore de decisão, na sua configuração básica, apresentou uma alta exatidão. No entanto, os modelos aprimorados com *oversampling* e otimização de hiperparâmetros via *grid search* demonstraram um desempenho superior. Os resultados indicam que a aplicação da técnica de *oversampling*, especialmente quando combinada com a otimização de hiperparâmetros via *grid search*, melhora substancialmente o desempenho do modelo das árvores de decisão em todos os aspetos avaliados. Assim, pode concluir-se que a utilização do *oversampling* e a otimização de hiperparâmetros via *grid search* são estratégias eficazes para aprimorar o desempenho dos modelos de árvore de decisão em diferentes contextos.

O modelo de *random forest*, sem técnicas de *oversampling*, apresentou um desempenho notável, refletindo a eficiência do modelo na classificação dos diferentes estados do ar condicionado. Contudo, a ausência de *oversampling* pode resultar numa leve tendência a favor das classes majoritárias, o que limita a capacidade do modelo lidar com classes menos frequentes. A aplicação do *oversampling* melhora o balanceamento das classes, como é possível comprovar pelos aumentos nas métricas de desempenho, sugerindo que o modelo consegue lidar melhor com as classes minoritárias, obtendo um desempenho mais equilibrado. A combinação de *oversampling* com a otimização via *grid search* resultou no melhor desempenho entre as três configurações testadas. A otimização dos hiperparâmetros ajusta o modelo de forma a maximizar a precisão e minimizar os erros de classificação.

As FFNN, inicialmente, sem *oversampling*, alcançaram bons resultados nas métricas estudadas, indicando um bom desempenho do modelo na ausência de técnicas de *oversampling*. No entanto, a aplicação do *oversampling* resultou numa queda substancial no desempenho. Isto explica-se pela introdução de dados sintéticos, sem a devida otimização, que aumentou a variabilidade do modelo e comprometeu a sua eficácia. A combinação do *oversampling* com a otimização de hiperparâmetros resultou numa melhoria no desempenho, embora não tenha alcançado os níveis observados sem *oversampling*.

Comparando os resultados do cenário 1 com os do cenário 2, algumas diferenças notáveis emergem. No cenário 1, a FFNN sem *oversampling* apresentou uma exatidão ligeiramente inferior em comparação com a do cenário 2, mas ainda assim muito robusta. A aplicação de *oversampling* no cenário 2 resultou numa queda ainda mais drástica no desempenho do que no cenário 1, o que indica que a variabilidade introduzida pelos dados sintéticos afetou de forma mais severa o modelo na sala 103. Por outro lado, a combinação de *oversampling* e *grid search* no cenário 1 resultou numa performance superior à observada no cenário 2, sugerindo que a otimização dos hiperparâmetros foi mais eficaz em mitigar os efeitos negativos do *oversampling* na sala 102. Estas diferenças podem ser atribuídas a variações nas características dos dados entre as duas salas.

No cenário 3, os resultados indicam uma melhoria consistente no desempenho dos modelos com a aplicação de *oversampling* e *grid search*. A árvore de decisão beneficiou significativamente dessas técnicas, resultando em aumentos nas métricas avaliadas. O modelo de *random forest*, mesmo na configuração base, apresentou um desempenho robusto, mas a

aplicação de *oversampling* e a otimização via *grid search* proporcionaram um ajuste mais refinado dos parâmetros, melhorando ainda mais as métricas de desempenho e mostrando uma capacidade aprimorada para lidar com classes menos representadas. Para as FFNN, o cenário inicial sem *oversampling* apresentou um desempenho sólido, mas a aplicação de *oversampling* sem otimização levou a uma degradação significativa do desempenho. No entanto, quando combinado com a otimização via *grid search*, o modelo mostrou uma recuperação considerável, equilibrando melhor as métricas avaliadas.

Esta análise demonstra a importância das técnicas avançadas como o *oversampling* e otimização de hiperparâmetros para melhorar o desempenho de modelos de IA em aplicações práticas, proporcionando um controle mais preciso e eficiente dos sistemas de ar condicionado.

Após a análise dos resultados obtidos no caso de estudo 1, é igualmente importante considerar as matrizes de confusão dos melhores modelos de cada cenário para uma compreensão mais detalhada das previsões do modelo. Na seguinte Figura 19, serão apresentadas as matrizes de confusão para os três cenários testados, cada uma correspondente aos modelos que obtiveram o melhor desempenho, as restantes serão apresentadas no APÊNDICE A.

Conforme observado na Tabela 2, o melhor desempenho no cenário 1 foi alcançado pela árvore de decisão com *oversampling* e otimização via *grid search*. Este modelo não apenas melhorou significativamente as métricas de desempenho, mas também apresentou uma precisão quase perfeita. No cenário 2, o mesmo modelo com *oversampling* e *grid search* também demonstrou o melhor desempenho, replicando os excelentes resultados obtidos no primeiro cenário. Similarmente, no cenário 3, a árvore de decisão com *oversampling* e *grid search* manteve-se como a melhor abordagem, confirmando a sua eficácia consistente.

As matrizes de confusão apresentadas na Figura 19 reforçam as observações feitas anteriormente na análise das métricas de desempenho. Em todos os cenários, o modelo de IA demonstrou resultados excelentes, confirmando a eficácia das técnicas de *oversampling* e otimização por *grid search*.

A matriz de confusão da Figura 19.a), referente ao cenário 1, mostra que o modelo acertou a grande maioria das previsões, com um número pequeno de erros, principalmente na classe “desligado”. A matriz de confusão da Figura 19.b), também destaca a precisão elevada do modelo, com apenas alguns erros dispersos nas classes testadas.

No entanto, é na matriz de confusão da Figura 19.c), que o desempenho do modelo se destaca. Nesta matriz, o modelo conseguiu prever corretamente quase todas as classes, errando apenas 9 vezes na previsão da classe “desligado” e uma única vez na classe de “arrefecimento”. Este nível de precisão é notável e demonstra que o modelo está extremamente bem calibrado, especialmente após a aplicação do *oversampling* e da otimização de hiperparâmetros.

Resultados e Discussão

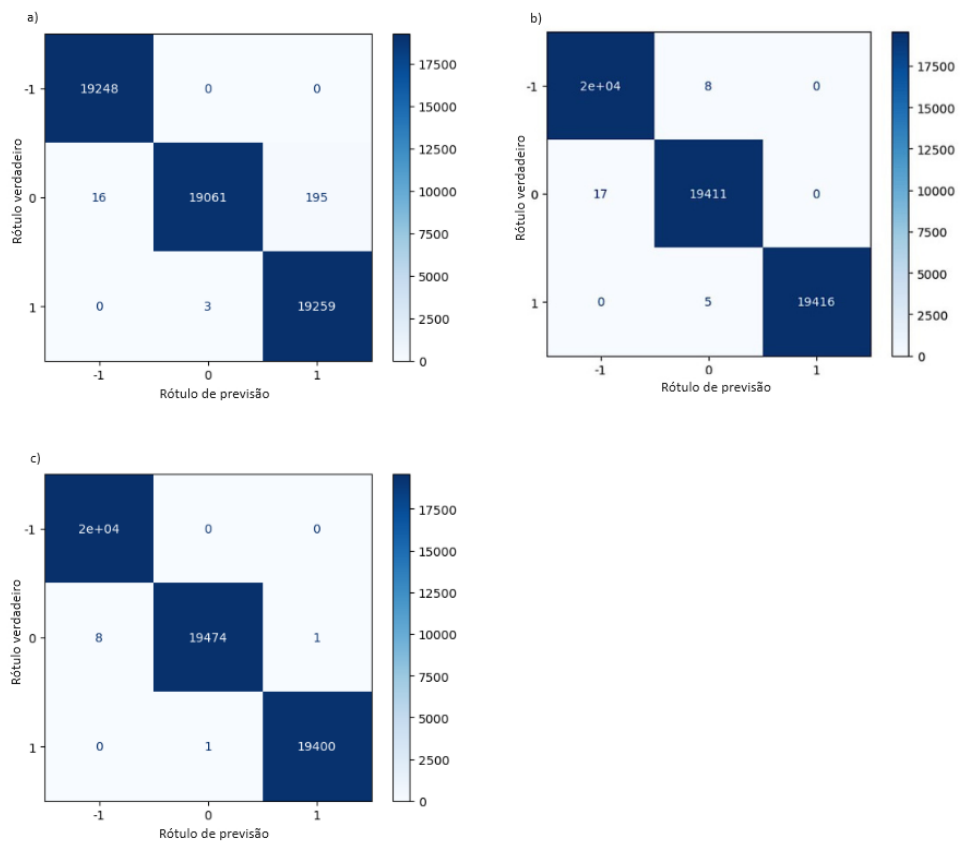


Figura 19 - Matriz de confusão: a) árvore de decisão com *oversampling* e *grid search* (cenário 1), b) árvore de decisão com *oversampling* e *grid search* (cenário 2) e c) árvore de decisão com *oversampling* e *grid search* (cenário 3)

Desempenho em Edifício Real

Considerando que os melhores resultados teóricos foram obtidos com o modelo de árvore de decisão, utilizando a técnica de *oversampling* e a otimização de hiperparâmetros via *grid search*, este foi o modelo selecionado para a aplicação prática no edifício real, na sala 103. No entanto, os resultados obtidos não foram os esperados. Observou-se uma tendência do modelo para ligar o AC quando não havia ocupantes na divisão e para ligar e desligar, frequentemente, em resposta a pequenas variações na temperatura ou humidade. Este comportamento pode ser atribuído a vários fatores, entre os quais:

- **Introdução de exemplos sintéticos pelo *oversampling*** - A técnica de SMOTE cria exemplos sintéticos para balancear as classes. Embora esta abordagem melhore o desempenho do modelo em dados de treino, os exemplos gerados podem não representar fielmente os casos reais. Assim, quando o modelo é aplicado a dados reais, pode comportar-se de forma inadequada.
- **Excesso de ajuste devido à otimização via *grid search*** - A otimização dos hiperparâmetros através do *grid search* ajusta o modelo para obter a melhor performance nos dados de treino. Contudo, isto pode levar a um *overfitting*, onde o

modelo torna-se demasiado específico aos dados de treino, perdendo a capacidade de generalizar adequadamente para novos dados. Esta falta de generalização pode resultar num desempenho deficiente quando o modelo é aplicado em ambiente real, onde as condições variam.

- **Sensibilidade das árvores de decisão a pequenas variações nos dados** -As árvores de decisão são notoriamente suscetíveis a pequenas variações nos dados, que podem resultar em mudanças significativas nas previsões. Este fenómeno pode explicar o comportamento instável observado, como ligar e desligar o AC em resposta a pequenas mudanças na temperatura ou humidade. A sensibilidade do modelo a pequenas variações nos dados de entrada pode ser acentuada pelo treino com dados não representativos.

De forma a obter uma nova perspetiva sobre o comportamento do modelo, foram registados dados das variáveis de entrada durante um dia inteiro no edifício do ISEP. Estes dados foram aplicados ao modelo para prever, em código, os estados do AC. Os resultados melhoraram ligeiramente, pois o modelo só ligava o AC quando havia pessoas na sala, ao contrário do que ocorria no ambiente real. Esta diferença pode ser explicada por vários fatores. Os dados em tempo real podem conter ruídos ou *outliers* que não estavam presentes nos dados históricos. Estes ruídos podem surgir devido a falhas nos sensores, erros de comunicação ou interferências ambientais, levando o modelo a tomar decisões incorretas, como ligar o ar condicionado sem necessidade. Além disso, há uma diferença significativa entre dados históricos e dados em tempo real. Os dados históricos são estáticos e representam uma captura contínua do ambiente, enquanto os dados em tempo real estão em constante atualização. A frequência de atualização dos dados em tempo real pode influenciar o desempenho do modelo, especialmente se este for sensível a pequenas variações nas condições ambientais.

O gráfico representado na Figura 20 mostra o resultado da previsão feita pelo modelo com os registos de um dia. Esta análise ilustra a aplicação prática do modelo e os desafios encontrados na transição dos dados teóricos para o ambiente real, destacando a importância de considerar fatores como a qualidade dos dados e a robustez do modelo ao lidar com dados em tempo real.

Observa-se um padrão de liga/desliga contínuo, especialmente durante a manhã, quando há variações significativas na ocupação (linha azul) e nas temperaturas (linha amarela). Este comportamento está alinhado com a crítica ao modelo, que sugere uma sensibilidade excessiva a pequenas variações nas entradas, resultando num controlo instável do ar condicionado. O acionamento frequente pode ser atribuído à criação dos exemplos sintéticos durante o *oversampling*, que pode não refletir fielmente as condições reais.

Resultados e Discussão

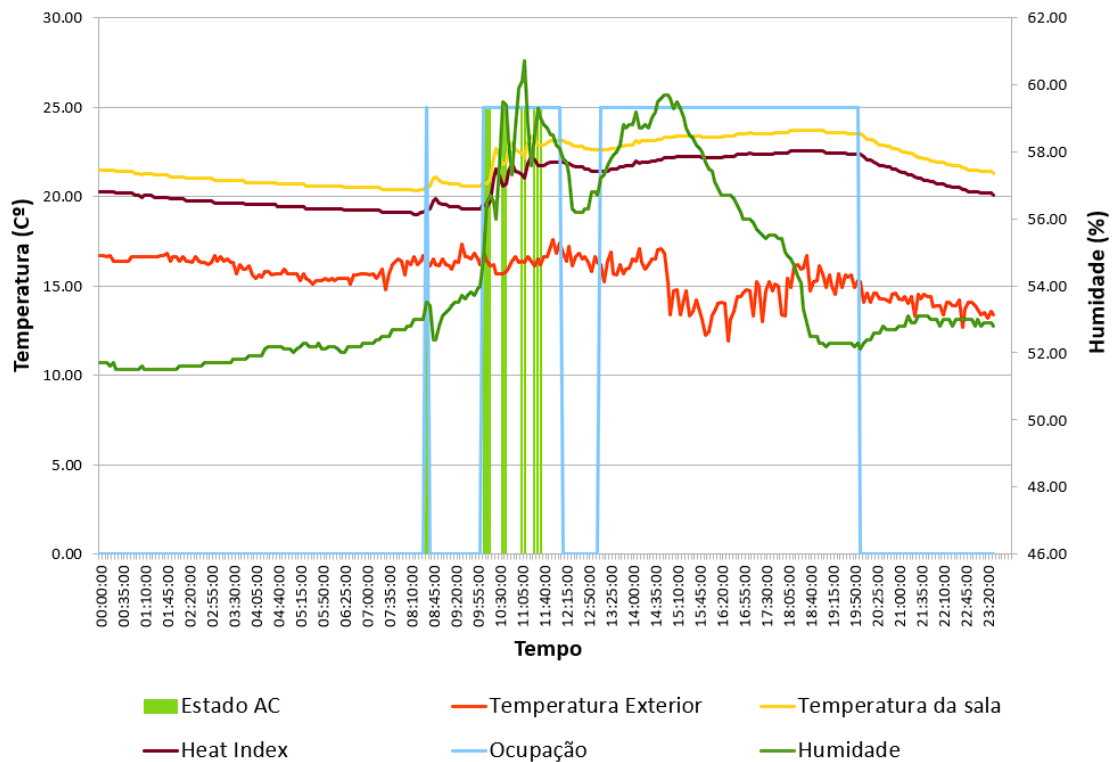


Figura 20 - Resultados das previsões do AC com dados reais – sala 103

A temperatura externa (linha laranja) e da sala (linha amarela) apresentam variações ao longo do dia. O índice de calor segue uma tendência similar à temperatura da sala, o que é esperado, dado que este índice leva em consideração a temperatura sentida pelos ocupantes. No entanto, as frequentes mudanças no estado do ar condicionado não parecem estabilizar significativamente a temperatura da sala, o que indica um possível problema de ajuste do modelo, que pode estar com *overfitting*.

A ocupação (linha azul) mostra períodos definidos de presença de pessoas na sala, principalmente entre 10:00 e 20:00. Durante estes períodos, o ar condicionado deveria, teoricamente, operar de maneira mais estável para manter o conforto térmico. Contudo, o comportamento errático do sistema sugere que o modelo não está a gerir adequadamente a variável de ocupação. No entanto, na aplicação real o modelo tinha tendência de ligar o ar condicionado mesmo não tendo ninguém na sala, enquanto neste estudo teórico o modelo apenas ligou em períodos de ocupação da sala. A humidade (linha verde-escuro) também mostra algumas flutuações, mas estas flutuações não parecem correlacionar-se diretamente com o ar condicionado.

A aplicação prática do modelo de árvore de decisão otimizado revelou várias limitações. A introdução de exemplos sintéticos pelo *oversampling*, apesar de eficaz no balanceamento das classes durante o treino, pode introduzir exemplos que não representam corretamente as condições reais, resultando em decisões inadequadas quando aplicado em ambiente real. Além disso, o excesso de ajuste pelo *grid search* pode ter levado a um *overfitting*, onde o modelo está

muito ajustado aos dados de treino e falha em generalizar para novas condições, especialmente aquelas dinâmicas encontradas em tempo real. As árvores de decisão são notoriamente sensíveis a pequenas variações nos dados de entrada, resultando num comportamento instável do ar condicionado, como observado com os frequentes liga/desliga em resposta a pequenas mudanças nas variáveis monitorizadas.

Como o melhor desempenho teórico do modelo foi no cenário 3, foi aplicada a mesma lógica neste cenário. Embora não tenha sido realizada a implementação direta do modelo no edifício real, foram registados dados de um dia inteiro da sala 105. Esses dados foram então integrados ao código do modelo para testar sua performance com novas entradas. Esta abordagem permitiu uma avaliação prática da capacidade do modelo em condições reais.

Os resultados das previsões geradas pelo modelo utilizando os novos dados estão representados na Figura 21.




Figura 21 - Resultados das previsões do AC com dados reais - sala 105

Ao analisar a figura, observa-se que o modelo previu que o ar condicionado deveria permanecer desligado durante todo o dia, o que é uma previsão inesperada, considerando as variações de temperatura e ocupação ao longo do período. Existem alguns possíveis motivos para esta anomalia na previsão:

- **Insuficiência de dados representativos:** É possível que os dados utilizados para treinar o modelo não incluíssem uma variedade suficiente de cenários em que o ar condicionado estivesse ligado. Se o conjunto de dados de treino fosse predominantemente composto de períodos em que o ar condicionado estava

desligado, o modelo pode ter aprendido que esta é a condição "normal" ou esperada, levando a previsões erradas

- **Oversampling:** Embora o *oversampling* e o *grid search* tenham melhorado o desempenho do modelo nos dados de treinamento, pode haver casos em que o *oversampling* introduziu um desvio no modelo, levando-o a subestimar a necessidade de ativar o ar condicionado. Este balanceamento artificial pode ter tido um impacto negativo na sensibilidade do modelo a mudanças nas condições ambientais e de ocupação.
- **Parâmetros e Hiperparâmetros:** A otimização dos hiperparâmetros por *grid search* é eficaz, mas ainda depende da qualidade e representatividade dos dados de treino. Se os parâmetros otimizados não refletirem bem a realidade operacional do edifício, as previsões podem ser imprecisas.

4.1.1. Discussão e Resultados do Caso de Estudo 1

A principal meta foi promover um ambiente confortável e eficiente, ajustando automaticamente o sistema de ar condicionado conforme as variáveis ambientais e a ocupação dos espaços. Para isso, foram definidos e executados três cenários com o intuito de explorar detalhadamente o desempenho dos modelos propostos. A análise dos resultados dos três cenários revela um padrão consistente na eficácia das técnicas aplicadas. Em todos os cenários, a combinação de *oversampling* com otimização *grid search* proporcionou uma melhoria significativa no desempenho dos modelos, destacando-se particularmente a árvore de decisão. Este modelo, quando aprimorado com as técnicas mencionadas, apresentou a maior precisão e capacidade de generalização, evidenciando um desempenho superior na previsão correta dos diferentes estados do ar condicionado. As melhorias observadas com o uso do *oversampling* e otimização foram evidentes através das métricas de exatidão, precisão, *recall* e *f1-score*, bem como nas matrizes de confusão que mostraram uma redução significativa nos erros de classificação.

No entanto, ao comparar os três cenários, emergem algumas nuances importantes. A sala 103 apresentou resultados iniciais ligeiramente superiores, possivelmente devido a uma melhor representatividade dos dados de treino. A sala 102, apesar de um desempenho inicial robusto, mostrou uma recuperação mais acentuada do desempenho com a aplicação das técnicas de *oversampling* e otimização. A sala 105, embora tenha seguido o mesmo padrão de melhorias, destacou-se pela precisão quase perfeita na previsão de todas as classes quando otimizada, indicando uma maior sensibilidade às técnicas aplicadas. Apesar das melhorias teóricas observadas, a transição para o ambiente real revelou desafios significativos. A aplicação prática na sala 105, utilizando dados de um dia inteiro, indicou que o modelo previu que o ar condicionado deveria permanecer desligado durante todo o período, uma previsão inesperada considerando as variações de temperatura e ocupação.

Essa observação prática destaca a complexidade e os desafios na implementação de modelos de IA em ambientes reais. Enquanto os modelos demonstram alta eficiência e precisão em contextos teóricos e controlados, a aplicação em tempo real requer uma robustez adicional

para lidar com variações e ruídos nos dados que não são facilmente capturados nos dados de treino. Este estudo enfatiza a importância de um contínuo processo de revisão e ajuste dos modelos para garantir sua aplicabilidade e eficácia em cenários operacionais dinâmicos.

4.2. Caso de Estudo 2

Este capítulo procura apresentar e discutir os resultados obtidos a partir da aplicação dos modelos de IA árvore de decisão, *random forest* e FFNN no controlo do sistema de ar condicionado em diferentes zonas do edifício GECAD do ISEP. Ao contrário do caso de estudo 1, onde os modelos foram treinados com dados de salas individuais, o presente caso de estudo explora o desempenho dos modelos treinados com dados agrupados de várias salas. Desta forma, é possível avaliar se uma maior quantidade de dados pode melhorar o desempenho e a capacidade de generalização dos modelos.

Para este estudo, foram definidos três cenários distintos, representando diferentes zonas do edifício. No primeiro cenário, os modelos foram treinados com dados das salas 101, 102 e 103, constituindo a zona 1. A base de dados original desta zona contém 105 046 registos para cada sala, abrangendo um ano completo de recolha de dados. Para enfrentar o desafio do desbalanceamento de classes, aplicaram-se técnicas de *oversampling* e *undersampling*, elevando o número total de registos para 210 552 por sala. Este cenário permite avaliar o comportamento dos modelos ao controlar um sistema de ar condicionado centralizado para estas três salas. Os modelos de IA aplicados foram treinados com este conjunto de dados equilibrado.

O segundo cenário focou-se nas salas 105 e 106, formando a zona 2. A base de dados original desta zona também contém 105 046 registos para cada sala, abrangendo um ano completo de recolha de dados. As técnicas de *oversampling* e *undersampling* resultaram num aumento do número total de registos para 251 799 por sala. O propósito deste cenário é investigar se os modelos mantêm o seu desempenho quando aplicados a uma configuração diferente de salas. Finalmente, o terceiro cenário abrangeu as salas 107, 108 e 109, que representam a zona 3. A base de dados original desta zona contém 105 046 registos para cada sala, correspondendo a um ano completo de recolha de dados. Aplicaram-se técnicas de *oversampling* e *undersampling*, o que resultou num aumento significativo do número total de registos para 251 667 por sala. Este cenário teve como objetivo testar a robustez dos modelos em mais um conjunto de salas, ampliando ainda mais a diversidade dos dados utilizados para treino. Os mesmos modelos de IA foram utilizados para avaliar a eficácia dos modelos na previsão do estado do sistema de ar condicionado, com particular atenção à capacidade de prever corretamente os diferentes estados do ar condicionado com base no conjunto de dados balanceado e não balanceado.

Em todos os cenários, os dados foram recolhidos ao longo de um ano completo, proporcionando uma base sólida e abrangente para o treino dos modelos. Similarmente ao caso de estudo 1, os dados passaram por um processo de limpeza, de forma a eliminar valores nulos e incoerentes, e de preparação das variáveis de entrada, incluindo a criação do HI e da variável de ocupação. Este processo assegurou a qualidade dos dados utilizados. Além do treino padrão,

Resultados e Discussão

foram aplicadas técnicas de *oversampling* e *undersampling* simultaneamente para o balanceamento de classes, com o objetivo de evitar o *overfitting* e explorar diferentes abordagens de balanceamento. O *oversampling* aumenta a quantidade de amostras na classe minoritária (aquecimento e arrefecimento), enquanto o *undersampling* reduz a quantidade de amostras na classe majoritária (desligado).

A otimização dos hiperparâmetros foi realizada através de *grid search*. Neste caso de estudo, a otimização dos hiperparâmetros foi abordada de forma distinta, testando-se diferentes intervalos de valores para cada parâmetro, comparativamente ao caso de estudo 1. Esta abordagem visa explorar um espectro mais amplo de configurações, na tentativa de encontrar as combinações de parâmetros que proporcionam o melhor desempenho para os modelos.

A Tabela 3 apresenta os resultados obtidos para os três cenários deste caso de estudo, permitindo uma comparação direta do desempenho dos modelos em diferentes zonas do edifício.

Tabela 3 - Resultados teóricos obtidos para o caso de estudo 2

<i>Cenário</i>	<i>Métricas de avaliação</i>	<i>Árvore de Decisão</i>	<i>Árvore de Decisão - com oversampling</i>	<i>Árvore de Decisão - com oversampling (Grid Search)</i>	<i>Random Forest</i>	<i>Random Forest - com oversampling</i>	<i>Random Forest - com oversampling (Grid Search)</i>	<i>Redes Neurais Feedforward</i>	<i>Redes Neurais Feedforward - com oversampling</i>	<i>Redes Neurais Feedforward - com oversampling (Grid Search)</i>
1	Exatidão	97,320%	97,439%	97,496%	98,310%	98,523%	98,491%	90,785%	88,648%	98,524%
	Precisão	97,317%	97,532%	97,564%	98,305%	98,505%	98,541%	90,265%	87,708%	98,575%
	<i>Recall</i>	97,320%	97,439%	97,496%	98,310%	98,520%	98,491%	90,785%	88,648%	98,524%
	<i>F1-Score</i>	97,318%	97,470%	97,521%	98,304%	98,512%	98,505%	89,790%	85,883%	98,539%
	Média das pontuações de Validação Cruzada	68,104%	68,104%	71,653%	72,757%	72,755%	72,557%	89,965%	88,559%	72,757%
2	Exatidão	99,919%	99,871%	99,871%	99,942%	99,900%	99,881%	99,885%	99,885%	99,885%
	Precisão	99,909%	99,906%	99,901%	99,909%	99,910%	99,902%	99,771%	99,771%	99,771%
	<i>Recall</i>	99,919%	99,871%	99,871%	99,942%	99,950%	99,881%	99,885%	99,885%	99,885%
	<i>F1-Score</i>	99,913%	99,885%	99,884%	99,924%	99,924%	99,889%	99,828%	99,828%	99,828%
	Média das pontuações de Validação Cruzada	99,480%	98,480%	98,480%	99,664%	99,664%	99,666%	99,879%	99,879%	99,879%
3	Exatidão	99,995%	99,966%	99,966%	99,985%	99,985%	99,985%	99,861%	99,861%	99,861%
	Precisão	99,990%	99,972%	99,972%	99,986%	99,986%	99,986%	99,724%	99,724%	99,724%
	<i>Recall</i>	99,995%	99,966%	99,966%	99,985%	99,985%	99,985%	99,861%	99,861%	99,861%
	<i>F1-Score</i>	99,992%	99,968%	99,968%	99,985%	99,985%	99,985%	99,793%	99,793%	99,793%
	Média das pontuações de Validação Cruzada	99,840%	99,190%	99,190%	99,888%	99,888%	99,828%	99,832%	99,832%	99,831%

Para a árvore de decisão no cenário 1, o modelo padrão mostrou uma elevada precisão e boa capacidade de identificar corretamente os estados positivos e negativos do sistema de ar condicionado. No entanto, houve variações no desempenho quando o modelo foi aplicado a diferentes subconjuntos de dados. A técnica de *oversampling* e *undersampling* melhorou ligeiramente o desempenho do modelo, mas não alterou significativamente. A otimização dos hiperparâmetros através do *grid search* resultou nos melhores desempenhos, proporcionando uma boa capacidade de previsão e maior confiabilidade em novos conjuntos de dados.

O modelo *random forest* no cenário 1 apresentou uma exatidão elevada e consistência nas previsões, com precisão e *recall* altos, refletidos num *f1-score* consistente. A introdução de técnicas de *oversampling* e *undersampling* melhorou ligeiramente a exatidão, precisão e *recall*, sem comprometer a estabilidade do modelo. No entanto, a combinação dessas técnicas com a otimização dos hiperparâmetros não trouxe os melhores resultados esperados, sugerindo que a maior complexidade introduzida pode ter aumentado a sensibilidade do modelo às variações nos dados.

Para o modelo FFNN no cenário 1, o desempenho inicial foi bom, com alta exatidão e estabilidade. No entanto, a introdução de técnicas de *oversampling* e *undersampling* reduziu a exatidão e a consistência das previsões, possivelmente devido à introdução de maior variabilidade e ruído nos dados. A combinação dessas técnicas com a otimização dos hiperparâmetros resultou em melhorias substanciais, destacando-se como a abordagem mais eficaz neste cenário.

No cenário 2, a árvore de decisão padrão revelou uma exatidão notavelmente alta, com boas métricas de precisão, *recall* e *f1-score*. A aplicação de técnicas de *oversampling* e *undersampling* resultou numa ligeira redução no desempenho, indicando que a complexidade adicional introduzida afetou negativamente a estabilidade do modelo. A otimização dos hiperparâmetros não trouxe melhorias significativas, mantendo-se as métricas de desempenho praticamente inalteradas.

O modelo *random forest* no cenário 2 também apresentou alta exatidão e consistência. A introdução de técnicas de *oversampling* e *undersampling* melhorou ligeiramente as métricas de desempenho, mas a combinação com a otimização dos hiperparâmetros não trouxe benefícios adicionais. Comparado com a zona 1, as melhorias observadas foram marginais e não comprometeram a estabilidade dos modelos.

O modelo FFNN no cenário 2 manteve uma exatidão extremamente alta, próxima dos 100%, com técnicas de *oversampling* e *undersampling* que não alteraram significativamente o desempenho. A aplicação combinada de técnicas de balanceamento e otimização dos hiperparâmetros resultou em métricas de desempenho idênticas às obtidas anteriormente, o que indica adaptabilidade inicial eficaz do modelo aos dados.

No cenário 3, os resultados dos modelos de árvore de decisão foram quase perfeitos, com métricas próximas dos 100%. A introdução de técnicas de *oversampling* e *undersampling* resultou numa ligeira descida nos resultados, devido à introdução de variabilidade adicional pelos dados sintéticos. A otimização dos hiperparâmetros não trouxe melhorias adicionais, reforçando a hipótese de que o modelo inicial já estava suficientemente otimizado. Este

desempenho extremamente alto levanta preocupações sobre o potencial *overfitting*, onde o modelo pode estar a sobreajustar-se aos dados de treino, falhando em generalizar para novos dados.

Os resultados do modelo *random forest* no cenário 3 também foram excelentes, com métricas elevadas que se mantiveram praticamente iguais após a introdução de técnicas de balanceamento e otimização dos hiperparâmetros. Esta constância nos resultados, aliada a uma ligeira descida na média das pontuações de validação cruzada, sugere a possibilidade de *overfitting*, onde o modelo captura padrões específicos dos dados de treino que não se traduzem em melhorias com dados sintéticos.

Finalmente, os modelos FFNN no cenário 3 apresentaram resultados idênticos em todas as abordagens testadas, indicando um possível *overfitting*. A falta de variação nas métricas após a introdução de técnicas de *oversampling*, *undersampling* e otimização dos hiperparâmetros reforça a hipótese de sobreajuste aos dados de treino.

Após esta análise dos resultados obtidos no caso de estudo 2, torna-se crucial examinar as matrizes de confusão dos modelos que apresentaram o melhor desempenho em cada cenário. A Figura 22 ilustra essas matrizes de confusão para os três cenários testados, permitindo uma visão mais aprofundada da eficácia das previsões dos modelos. As restantes matrizes de confusão, encontram-se no APÊNDICE B.

Como indicado na Tabela 3, no cenário 1, o modelo FFNN combinado com técnicas de *oversampling* e otimização por *grid search* demonstrou o desempenho mais robusto, alcançando métricas de precisão bastante elevadas. No cenário 2, o modelo *random forest*, na sua configuração padrão, destacou-se como o mais eficaz, ao apresentar excelentes resultados que confirmam a sua capacidade de generalização. Já no cenário 3, a árvore de decisão na sua forma padrão foi a abordagem que obteve os melhores resultados.

Para uma análise mais aprofundada, na Figura 22, são apresentadas as matrizes de confusão com o melhor desempenho em cada um dos cenários.

Na matriz de confusão da Figura 22.a), observa-se que, embora existam muitos erros, o modelo também teve um número significativo de acertos. Mesmo nas classes minoritárias (aquecimento e arrefecimento), o modelo apresentou um desempenho razoável. A classe “desligado” teve a maior parte das previsões corretas, enquanto as classes minoritárias apresentaram mais erros, possivelmente devido ao ruído introduzido no modelo durante o balanceamento das classes. Esse ruído pode ter dificultado a correta identificação das classes menos frequentes, mas, no geral, o modelo manteve um bom desempenho global.

A matriz de confusão da Figura 22.b) mostra o desempenho do modelo *random forest* na sua forma padrão no cenário 2. Aqui, é evidente a presença de *overfitting*. O modelo acertou todas as previsões da classe maioritária “desligado”, mas teve um desempenho significativamente inferior nas classes minoritárias “aquecimento” e “arrefecimento”. Esta discrepância deve-se à baixa quantidade de dados dessas classes na base de dados original, refletindo o facto de que os utilizadores daquela zona utilizaram muito pouco o ar condicionado para aquecimento ou arrefecimento. Assim, o modelo, ao ser treinado num conjunto de dados desequilibrado,

Resultados e Discussão

apresentou excelentes resultados na classe mais comum, mas falhou em generalizar para as classes menos frequentes.

A matriz de confusão da Figura 22.c), apresenta um fenômeno similar de *overfitting*. O modelo previu corretamente quase todas as previsões da classe maioritária, mas praticamente ignorou as classes minoritárias, prevendo-as apenas uma vez. Esta falta de previsões para as classes minoritárias indica que o modelo está excessivamente ajustado aos dados de treino, não conseguindo generalizar bem quando confrontado com novos dados.

O problema observado indica que os modelos têm dificuldades em lidar com classes desequilibradas. Para mitigar este problema, poderiam ser aplicadas técnicas adicionais, como o uso de métodos híbridos que combinem vários modelos para melhorar a generalização, ou técnicas de *data augmentation* específicas para IA, que criem mais exemplos sintéticos das classes minoritárias. No entanto, devido a limitações de tempo e recursos durante a realização deste estudo, não foi possível implementar e testar todas essas técnicas. Futuras pesquisas poderiam explorar essas abordagens para melhorar o desempenho dos modelos e reduzir o *overfitting*, de forma a garantir uma melhor capacidade na generalização e previsões mais precisas para todas as classes.

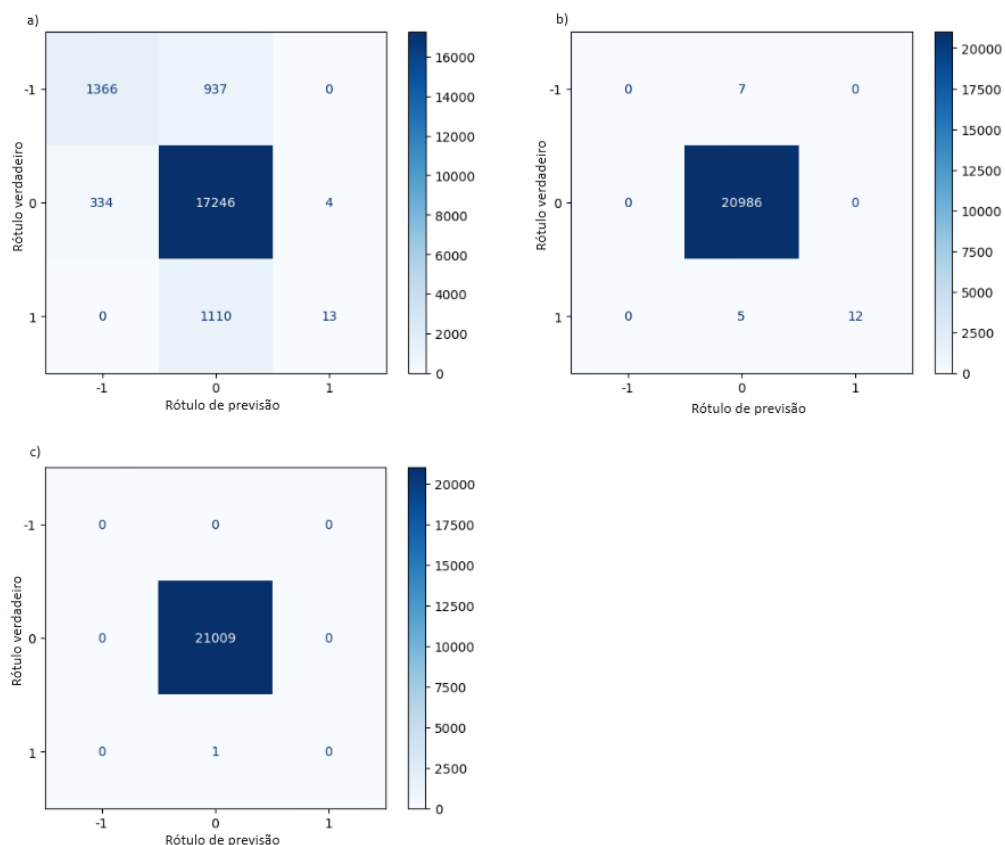


Figura 22 - Matriz de confusão: a) FFNN com *oversampling* e *grid search* (cenário 1), b) *Random forest* padrão (cenário 2) e c) árvore de decisão padrão (cenário 3)

4.2.1. Discussão e Resultados do Caso de Estudo 2

Nos três cenários considerados (zona 1, zona 2 e zona 3), os modelos de Árvores de Decisão, *random forest* e FFNN foram aplicados e avaliados. Em geral, os resultados demonstraram que todos os modelos apresentaram uma elevada precisão e capacidade de previsão, com algumas variações conforme a técnica de balanceamento de classes e a otimização dos hiperparâmetros.

Para a Zona 1, composta pelas salas 101, 102 e 103, os modelos demonstraram um desempenho consistente e elevado. A introdução de técnicas de *oversampling* e *undersampling*, seguida da otimização dos hiperparâmetros através do *grid search*, melhorou ligeiramente a capacidade de previsão das classes minoritárias. No entanto, a variação não foi substancial, indicando que os modelos já possuíam um bom desempenho com os dados originais.

Na Zona 2, que incluiu as salas 105 e 106, os modelos de Árvores de Decisão e *random forest* mantiveram uma elevada exatidão, precisão e *recall*. Contudo, as técnicas de *oversampling* e *undersampling* não trouxeram melhorias significativas, e os resultados permaneceram bastante constantes. As FFNN apresentaram um desempenho excepcional, mas revelaram sinais de *overfitting*, com resultados inalterados mesmo após a aplicação das técnicas de balanceamento e otimização dos hiperparâmetros. Esta constância sugere que o modelo estava demasiado ajustado aos dados de treino originais, limitando a sua capacidade de generalização.

Por fim, na Zona 3, composta pelas salas 107, 108 e 109, os modelos de *random forest* e FFNN também demonstraram um desempenho consistentemente alto. No entanto, a ausência de variação nos resultados após a aplicação das técnicas de *oversampling* e *undersampling*, bem como a otimização dos hiperparâmetros, reforça a hipótese de *overfitting*. Este comportamento indica que os modelos estavam excessivamente ajustados aos padrões específicos dos dados de treino.

Em suma, os resultados deste caso de estudo destacam a eficácia geral dos modelos de IA na previsão do estado do sistema de ar condicionado em diferentes zonas do edifício. Embora a aplicação de técnicas de *oversampling*, *undersampling* e *grid search* tenha demonstrado melhorias limitadas em algumas classes, a consistência dos resultados revela a necessidade de uma maior variabilidade nos dados de treino para evitar *overfitting* e melhorar a capacidade de generalização dos modelos. A análise detalhada das matrizes de confusão e das métricas de desempenho forneceu uma visão clara das capacidades e limitações de cada abordagem, sublinhando a importância de um conjunto de dados diversificado e representativo para o desenvolvimento de modelos eficientes.

4.3. Caso de Estudo 3

Este capítulo apresenta e discute os resultados obtidos a partir da aplicação dos modelos de IA árvore de decisão, *random forest* e FFNN no controlo do sistema de ar condicionado do edifício GECAD do ISEP, com a utilização de uma abordagem distinta dos casos de estudo anteriores. Neste terceiro caso de estudo, foram introduzidas duas alterações principais com o objetivo de simplificar os modelos e melhorar o seu desempenho. Inicialmente, a variável de humidade foi removida da base de dados, uma vez que já se encontra contemplada na equação do HI. Esta

simplificação tem como objetivo reduzir o ruído nos dados e permitir que os modelos de IA aprendam de forma mais eficiente. Em segundo lugar, as variáveis de temperatura - temperatura exterior, temperatura interior e HI - foram convertidas de valores quantitativos para qualitativos. Para esta conversão, foram definidos três intervalos: temperaturas abaixo de 18°C foram classificadas como “frio”, temperaturas entre 18°C e 24°C como “confortável” e temperaturas acima de 24°C como “quente”. Com esta definição, os dados foram transformados em representações qualitativas, como exemplificado por um valor de 16°C convertido para [1, 0, 0] (totalmente frio), 19°C para [0.3, 0.7, 0] (predominantemente confortável), 22°C para [0, 1, 0] (totalmente confortável) e 25°C para [0, 0.7, 0.3] (predominantemente quente).

Os dados utilizados neste novo estudo foram os mesmos do caso de estudo 1, uma vez que no global apresentaram melhores resultados e menos tendência de *overfitting* em comparação com os dados do caso de estudo 2. Foram utilizadas as bases de dados das salas 102, 103 e 105. Além do treino padrão, foram aplicadas técnicas de balanceamento de classes, como o *oversampling*. Adicionalmente, a otimização dos hiperparâmetros foi realizada através do *grid search*. O objetivo principal deste caso de estudo é avaliar a eficácia dos modelos de IA na previsão do estado do sistema de ar condicionado, utilizando as variáveis transformadas e os dados simplificados. A análise detalhada dos resultados obtidos permitirá identificar os pontos fortes e as limitações de cada abordagem.

No cenário 1, a análise incide sobre a sala 102, equipada com uma unidade interior de ar condicionado. A base de dados original desta sala continha um total de 103 949 registos. Para melhorar a capacidade dos modelos de IA em prever estados menos frequentes e balancear as classes, aplicou-se a técnica SMOTE de *oversampling*, o que resultou na expansão da base de dados para 304 113 registos. Cada um dos modelos foi treinado e testado com os dados da sala 102, permitindo uma avaliação abrangente das suas capacidades e limitações. A performance dos modelos foi medida através de várias métricas de desempenho, incluindo exatidão, precisão, *recall* e *f1-score*.

O cenário 2 incide sobre a sala 103. Inicialmente, a base de dados original desta sala continha 103 949 registos. De forma a melhorar a capacidade dos modelos de IA em prever estados menos frequentes e balancear as classes, aplicou-se a técnica SMOTE de *oversampling*, o que resultou na expansão da base de dados para 307 437 registos

No cenário 3, o foco da análise recai sobre a sala 105, igualmente equipada com uma unidade interior de ar condicionado. A base de dados original desta sala contabilizava 103 949 registos. Para melhorar a capacidade dos modelos de IA em prever estados menos frequentes e assegurar o balanceamento das classes, aplicou-se a técnica SMOTE de *oversampling*, expandindo assim a base de dados para 307 734 registos.

A análise dos resultados obtidos permitirá verificar se a simplificação dos dados e a transformação das variáveis contribuíram para um melhor desempenho dos modelos comparativamente aos casos de estudo anteriores, ver Tabela 4.

Tabela 4 - Resultados teóricos obtidos para o caso de estudo 3

<i>Cenário</i>	<i>Métricas de avaliação</i>	<i>Árvore de Decisão</i>	<i>Árvore de Decisão - com oversampling</i>	<i>Árvore de Decisão - com oversampling (Grid Search)</i>	<i>Random Forest</i>	<i>Random Forest - com oversampling</i>	<i>Random Forest - com oversampling (Grid Search)</i>	<i>Redes Neurais Feedforward</i>	<i>Redes Neurais Feedforward - com oversampling</i>	<i>Redes Neurais Feedforward - com oversampling (Grid Search)</i>
1	Exatidão	98,658%	89,706%	89,624%	98,763%	89,778%	89,778%	98,725%	91,556%	91,588%
	Precisão	98,017%	98,424%	98,392%	98,094%	98,489%	98,482%	97,947%	46,097%	91,675%
	<i>Recall</i>	98,658%	89,706%	89,624%	98,763%	89,778%	89,778%	98,749%	47,882%	91,361%
	<i>F1-Score</i>	98,305%	93,610%	93,548%	98,371%	93,678%	93,674%	98,240%	38,943%	91,251%
	Média das pontuações de Validação Cruzada	97,876%	97,876%	97,978%	98,148%	98,148%	98,341%	98,798%	98,803%	91,716%
2	Exatidão	98,451%	90,259%	70,251%	98,542%	70,278%	70,259%	98,576%	79,937%	79,547%
	Precisão	97,406%	97,792%	97,808%	97,570%	97,800%	97,804%	97,333%	44,692%	80,784%
	<i>Recall</i>	98,451%	70,259%	70,250%	98,542%	70,278%	70,259%	98,590%	36,797%	79,470%
	<i>F1-Score</i>	97,885%	91,299%	81,298%	97,931%	81,318%	81,304%	97,917%	23,452%	78,458%
	Média das pontuações de Validação Cruzada	95,845%	95,845%	95,794%	96,454%	96,454%	96,657%	98,607%	98,581%	79,506%
3	Exatidão	97,739%	90,731%	90,731%	98,037%	90,933%	90,933%	97,808%	90,427%	90,021%
	Precisão	96,992%	97,429%	97,429%	97,388%	97,531%	97,531%	96,451%	45,835%	90,198%
	<i>Recall</i>	97,739%	90,732%	90,731%	98,037%	90,933%	90,933%	97,830%	45,084%	89,558%
	<i>F1-Score</i>	97,277%	93,686%	93,686%	97,460%	93,844%	93,844%	96,994%	35,644%	89,350%
	Média das pontuações de Validação Cruzada	93,176%	93,176%	93,176%	93,675%	93,675%	93,675%	97,748%	97,780%	90,203%

A análise dos resultados obtidos com os diferentes modelos de IA - árvore de decisão, *random forest* e FFNN - revela várias nuances no desempenho dos mesmos, especialmente quando se aplicam técnicas de balanceamento de classes e otimização de hiperparâmetros.

Para o modelo de árvore de decisão no cenário 1, observou-se um desempenho inicial bastante positivo no modelo padrão, sem balanceamento de classes ou otimização de hiperparâmetros. No entanto, é importante salientar que, embora as métricas apresentem valores elevados, não é devemos confiar exclusivamente nestes resultados sem uma análise complementar da matriz de confusão. Esta análise é crucial para verificar se o modelo está a obter bons resultados apenas para a classe majoritária, ignorando as classes minoritárias. Com a aplicação de técnicas de balanceamento de classes, observa-se uma ligeira diminuição no desempenho do modelo, particularmente nas métricas de exatidão, *recall* e *f1-score*. Esta descida, contudo, não é significativa e o modelo continua a apresentar bons resultados. A técnica de *oversampling* procura aumentar a diversidade de previsões do modelo, forçando-o a considerar todas as classes de forma mais equitativa. Esta abordagem resulta numa ligeira redução nas métricas de desempenho, mas proporciona um modelo mais equilibrado. A aplicação do *grid search*, destinada a otimizar os hiperparâmetros do modelo, não teve um impacto significativo no desempenho da árvore de decisão. Os resultados permanecem praticamente inalterados, o que indica que o modelo já estava próximo do seu desempenho ótimo nas configurações padrão.

No cenário 2, o modelo padrão de árvore de decisão apresentou resultados bastante apelativos, com uma exatidão, precisão, *recall* e *f1-score* elevados. No entanto, como já vimos anteriormente, não se pode confiar apenas nestes resultados, pois a base de dados original pode estar desbalanceada, favorecendo a classe majoritária. Quando foram aplicadas as técnicas de balanceamento, notou-se uma descida acentuada no *recall*. Esta queda significativa pode ser explicada pela introdução de dados sintéticos através do *oversampling*, que embora ajudem a balancear as classes, podem também introduzir ruído e exemplos que não representam fielmente a distribuição real dos dados. Este ruído adicional dificulta a capacidade do modelo de generalizar corretamente, resultando numa menor sensibilidade para a classe minoritária. A exatidão e o *f1-score* também sofreram uma queda, embora menos acentuada. A exatidão diminui porque o modelo agora é confrontado com um conjunto de dados mais complexo e diversificado, que inclui exemplos sintéticos das classes minoritárias. Esta complexidade adicional pode levar o modelo a cometer mais erros. Com a aplicação da otimização dos hiperparâmetros através do *grid search*, os resultados mantêm-se muito semelhantes aos obtidos com o modelo balanceado sem otimização. O *recall* continua baixo, o que indica que a capacidade do modelo em identificar corretamente os dados da classe minoritária não melhorou. Isto pode ser explicado devido ao facto de os intervalos de hiperparâmetros testados não serem suficientemente abrangentes ou adequados para capturar a melhor configuração possível do modelo, limitados pelas restrições de tempo e recursos computacionais disponíveis.

No cenário 3, a árvore de decisão, sem técnicas de *oversampling* e *grid search*, manteve um desempenho muito positivo. Este comportamento é consistente com o observado noutros modelos, onde a presença de uma classe predominante faz com que o modelo apresente bons resultados ao prever essa classe específica. Com a aplicação do balanceamento de classes,

observa-se uma diminuição nas métricas de exatidão, *recall* e *f1-score*. Esta diminuição pode ser explicada pelo facto do modelo estar agora a ser treinado com uma distribuição de dados mais equilibrada. A adaptação a esta nova distribuição requer que o modelo ajuste os seus parâmetros internos para prever todas as classes de forma mais equitativa, o que pode resultar numa redução das previsões corretas. Este ajuste faz com que o modelo perca a vantagem de prever maioritariamente a classe predominante, refletindo uma queda no desempenho global. Interessantemente, a precisão aumenta ligeiramente em comparação com o modelo anterior. Esta melhoria pode ser atribuída ao facto do modelo, ao ser forçado a considerar todas as classes de forma mais equilibrada, tornar-se mais “cuidadoso” nas suas previsões positivas. Isto resulta numa maior proporção de previsões corretas entre as previsões que o modelo classifica como positivas, elevando assim a precisão. A média das pontuações de validação cruzada mantém-se inalterada, o que sugere que, apesar das mudanças na distribuição dos dados de treino, o modelo consegue manter uma consistência global no seu desempenho. Esta estabilidade pode indicar que o modelo tem uma boa capacidade de generalização, mesmo quando ajustado para considerar uma distribuição de dados mais equilibrada. A otimização de hiperparâmetros, através do *grid search*, não teve qualquer influência significativa nos resultados do modelo, visto que os resultados permanecem exatamente iguais.

Para o modelo random forest no cenário 1, o desempenho inicial foi positivo, mas os resultados devem ser interpretados com cautela devido ao desequilíbrio nos dados. Quando aplicada a técnica de *oversampling*, observa-se uma descida na exatidão e no *f1-score*. Esta diminuição pode ser explicada pela alteração na distribuição das classes no conjunto de treino, que força o modelo a considerar igualmente as classes minoritárias. Com esta redistribuição, a capacidade do modelo em manter previsões precisas sofre uma ligeira redução. Apesar da descida nas métricas mencionadas, as outras métricas mantêm-se praticamente inalteradas, o que é um bom indicador. Isto indica que o modelo *random forest*, mesmo após o balanceamento dos dados, continua a apresentar bons resultados. A aplicação do *grid search*, destinada a otimizar os hiperparâmetros do modelo, não resultou em melhorias significativas no desempenho do *random forest*. Esta falta de impacto significativo pode ser atribuída à vasta gama de configurações possíveis de hiperparâmetros para este modelo, como o número de árvores ou a profundidade das mesmas. A definição tão ampla de opções torna-se um desafio computacional significativo, limitando a capacidade de avaliar todas as hipóteses possíveis dentro do *grid search*.

No cenário 2, o modelo random forest sem técnicas de balanceamento de classes e sem otimização de hiperparâmetros parecem bastante promissores. O modelo demonstra um bom desempenho na previsão dos estados do ar condicionado, com elevados valores de exatidão, precisão, *recall* e *f1-score*. No entanto, é fundamental verificar a matriz de confusão correspondente para garantir que o modelo não está a obter bons resultados apenas para a classe maioritária. Quando aplicada a técnica de *oversampling* para balancear as classes, observa-se uma descida abrupta nos valores de exatidão, *recall* e *f1-score*. Este fenómeno pode ser explicado pelo facto de que o *oversampling* altera a distribuição das classes no conjunto de treino o que elimina a tendência inicial do modelo para a classe maioritária. Com a nova distribuição, o modelo enfrenta mais desafios para prever corretamente todas as classes, o que

resulta numa diminuição da exatidão e do *recall*. No entanto, a precisão mantém-se alta, sugerindo que as previsões positivas continuam a ser, em grande parte, corretas. A média das pontuações de validação cruzada mantém-se constante porque o modelo continua a ser consistente nos seus resultados, apesar da mudança na distribuição das classes. A aplicação da otimização de hiperparâmetros através do *grid search*, juntamente com o *oversampling*, não parece trazer melhorias significativas ao modelo. Os resultados obtidos são praticamente idênticos aos do modelo com apenas *oversampling*. Isto indica que a otimização de hiperparâmetros, neste caso específico, não contribui de forma relevante para o desempenho do modelo.

No cenário 3, o random forest também apresentou um desempenho inicial muito positivo. Com a aplicação da técnica de *oversampling*, o modelo continua a apresentar bons resultados, embora se observe uma ligeira descida nas métricas de exatidão, *recall* e *f1-score*. Este comportamento é esperado, uma vez que o *oversampling* introduz novas classes minoritárias, equilibrando a distribuição dos dados. A precisão do modelo, no entanto, aumentou ligeiramente. Este aumento pode ser explicado pelo facto de que o modelo tornou-se mais rigoroso nas previsões positivas, resultando numa maior proporção de previsões corretas entre as previsões classificadas como positivas. A pontuação média de validação cruzada manteve-se inalterada, o que indica uma consistência no desempenho do modelo, mesmo após a introdução de dados sintéticos. A aplicação do *grid search* para a otimização dos hiperparâmetros não teve qualquer impacto significativo no desempenho do modelo. Os resultados permanecem praticamente iguais aos obtidos apenas com o *oversampling*, o que indica que as configurações iniciais dos hiperparâmetros já estavam próximas do ótimo. Esta observação mostra que, dentro das métricas que foram otimizadas, as definições iniciais proporcionaram o melhor desempenho possível.

Para o modelo de FFNN no cenário 1, o modelo revela um desempenho inicial excelente na sua forma padrão, sem a aplicação de técnicas de balanceamento e de otimização. Este comportamento é recorrente em todos os modelos analisados, dado que a presença de uma classe maioritária faz com que o modelo tenda a obter bons resultados ao prever essa classe específica. No entanto, quando se aplica o balanceamento na base de dados, os resultados das FFNN descem abruptamente, com exceção da exatidão e da média das pontuações de validação cruzada, que se mantêm praticamente inalteradas. A exatidão e a média das pontuações de validação cruzada permanecem quase iguais mesmo após o balanceamento porque estas métricas são calculadas de forma a considerar o desempenho global do modelo, sem ponderar a distribuição das classes. Por outro lado, métricas como precisão, *recall* e *f1-score* são mais sensíveis às especificidades da previsão correta de cada classe. A descida significativa destas métricas após o balanceamento reflete a dificuldade do modelo em prever corretamente as classes que anteriormente eram minoritárias. O modelo, que antes apenas previa a classe dominante, agora enfrenta o desafio de ajustar os seus parâmetros internos para tratar todas as classes de forma equitativa, o que inicialmente resulta num desempenho inferior. Para tentar melhorar os resultados obtidos após o balanceamento, foi aplicado o *grid search* para otimização dos hiperparâmetros. Com esta abordagem, os resultados voltaram a melhorar

significativamente, indicando que o modelo conseguiu adaptar-se melhor à nova distribuição de dados.

No cenário 2, o modelo FFNN apresenta um bom desempenho na previsão dos estados do ar condicionado. Quando aplicado o balanceamento de classes, à semelhança do que foi observado com o modelo *random forest*, verifica-se uma descida abrupta nos valores de exatidão, *recall* e *f1-score*, acompanhada também por uma diminuição significativa na precisão. Esta diferença na precisão, em comparação com o *random forest*, pode ser explicada pela natureza das FFNN. Ao realizar o *oversampling*, são introduzidos novos dados sintéticos das classes minoritárias no conjunto de treino. As redes neurais, sendo modelos altamente parametrizados e sensíveis às alterações no conjunto de dados de treino, podem sofrer uma diminuição na precisão devido ao aumento da variabilidade introduzida por estes novos dados. Assim, o modelo tem maior dificuldade em fazer previsões precisas, dado que a sua capacidade de generalização é afetada pelo balanceamento artificial dos dados. A aplicação conjunta do balanceamento de classes e da otimização dos hiperparâmetros, através do *grid search*, resulta numa melhoria acentuada dos resultados. Este comportamento indica que, neste caso, a técnica de *grid search* teve um impacto bastante positivo no desempenho das FFNN. Embora o desempenho ainda não atinja os níveis observados inicialmente sem balanceamento, os resultados melhoram significativamente. Esta melhoria indica que o modelo, ao ser otimizado, consegue ajustar-se melhor às novas distribuições de dados impostas pelo balanceamento de classes. Assim, apesar do desempenho geral ainda ser inferior ao do modelo padrão, esta abordagem equilibrada permite ao modelo fazer previsões mais precisas para todas as classes, evitando a tendência para a classe maioritária.

Por fim, no cenário 3 o modelo padrão apresenta métricas de desempenho elevadas, mas isto deve-se ao *overfitting* que o modelo faz à classe maioritária, “desligado”. Este comportamento indica que, embora as métricas globais sejam altas, o modelo não está a generalizar bem para as outras classes, o que limita a sua eficácia geral. Com a aplicação da técnica de *oversampling*, observa-se uma redução significativa nas métricas de desempenho do modelo. Esta diminuição deve-se à variabilidade adicional introduzida nos dados, a qual as redes neurais são particularmente sensíveis. Quando é aplicado o *grid search* para a otimização dos hiperparâmetros, as métricas do modelo voltam a aumentar. Este comportamento é muito positivo, pois significa que, após o balanceamento dos dados, o modelo foi capaz de ajustar-se e recuperar o desempenho, obtendo novamente bons resultados. A otimização dos hiperparâmetros através do *grid search* permite ao modelo ajustar-se melhor à nova distribuição dos dados, maximizando a sua capacidade de generalização.

Após a análise detalhada dos resultados obtidos no caso de estudo 3, é fundamental examinar as matrizes de confusão dos modelos que apresentaram o melhor desempenho em cada cenário. A Figura 23 apresenta essas matrizes de confusão para os três cenários testados, proporcionando uma compreensão mais aprofundada da precisão das previsões dos modelos. As matrizes de confusão adicionais estão disponíveis no APÊNDICE C.

Conforme mostrado na Tabela 4, no cenário 1, o modelo FFNN na sua configuração padrão demonstrou o desempenho mais robusto, alcançando altos índices de precisão. No cenário 2, o modelo FFNN, também na configuração padrão, destacou-se como o mais eficiente, exibindo

Resultados e Discussão

resultados excelentes que confirmam sua capacidade de generalização. No cenário 3, a abordagem que obteve os melhores resultados foi o modelo *random forest* na sua forma padrão.

As matrizes de confusão vêm provar, mais uma vez, que o excelente desempenho mostrado antes do balanceamento das classes não indica necessariamente que o modelo esteja, de facto, a ter um bom desempenho, ver Figura 23.

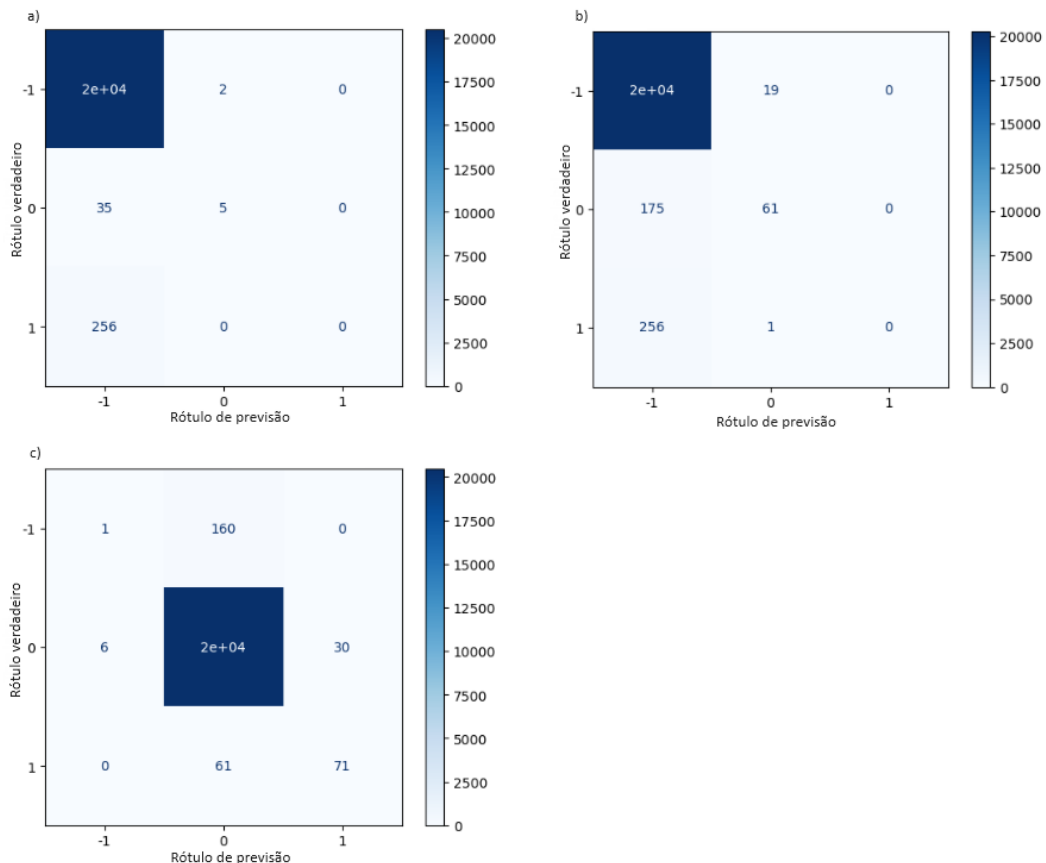


Figura 23 - Matriz de confusão: a) FFNN padrão (cenário 1), b) FFNN padrão (cenário 2) e c) *Random Forest* padrão (cenário 3)

Na matriz de confusão das Figura 23.a) e 23.b), observa-se que o modelo FFNN, na sua configuração padrão, apresentou uma tendência inesperada de prever uma classe minoritária. Este comportamento pode ser explicado pela variabilidade intrínseca nos dados, onde certos padrões da classe minoritária podem ter sido mais facilmente aprendidos pelo modelo durante o treino. No entanto, para as classes “desligado” e “arrefecimento”, o desempenho foi fraco, sugerindo que o modelo FFNN padrão apresenta dificuldades significativas na generalização e previsão correta de todas as classes, quando aplicado num ambiente real.

Relativamente à matriz de confusão do cenário 3, que representa o desempenho do modelo *random forest* na sua configuração padrão, há um claro indício de *overfitting* para a classe maioritária. Esse comportamento é típico quando o modelo aprende demasiado bem os

padrões da classe dominante nos dados de treino, negligenciando as classes minoritárias. Apesar de algumas previsões corretas para a classe “arrefecimento”, o desempenho geral do modelo continua a ser insatisfatório, porque não está a generalizar bem para todas as classes.

Para mitigar esses problemas, várias abordagens podem ser consideradas. No caso das FFNN, técnicas de regularização, como o *dropout* e *L2 regularization*, podem ser implementadas para reduzir o *overfitting*. Para o *random forest*, ajustes no número de árvores e na profundidade máxima podem melhorar a capacidade de generalização do modelo.

Na presente dissertação, estas técnicas não foram implementadas devido a limitações de tempo e recursos computacionais. É essencial consultar as restantes matrizes de confusão no APÊNDICE C para validar qual dos modelos está a ter um comportamento mais robusto nas previsões, proporcionando uma análise mais completa e informada.

4.3.1. Discussão e Resultados do Caso de Estudo 3

No presente caso de estudo, analisaram-se os desempenhos dos modelos de IA, utilizando uma abordagem distinta dos casos de estudo anteriores. As principais alterações incluíram a remoção da variável de humidade e a conversão das variáveis de temperatura de valores quantitativos para qualitativos. Estas mudanças tinham como objetivo simplificar os modelos e melhorar o seu desempenho.

Ao comparar os desempenhos dos modelos nos três cenários, observam-se várias semelhanças e diferenças.

Para a sala 103, os modelos de IA apresentaram inicialmente um bom desempenho. No entanto, após a aplicação de técnicas de balanceamento de classes, notou-se uma descida acentuada no desempenho, especialmente no *recall*. Isto indica que a introdução de dados sintéticos através de *oversampling* introduziu ruído, dificultando a generalização correta dos modelos. A aplicação de otimização de hiperparâmetros através do *grid search* não resultou em melhorias significativas, indicando que os intervalos de hiperparâmetros testados não foram suficientemente abrangentes para capturar a melhor configuração possível.

Na sala 102, o desempenho dos modelos seguiu uma tendência semelhante à observada na sala 103. Os modelos inicialmente mostraram bons resultados, mas o balanceamento de classes resultou numa ligeira diminuição nas métricas de desempenho, embora os modelos continuassem a apresentar bons resultados. A aplicação do *grid search* não teve qualquer impacto significativo, o que revela que o modelo já estava próximo do seu desempenho ótimo nas configurações padrão.

Já na sala 105, os resultados dos modelos foram inicialmente positivos, mas, tal como nas outras salas, o balanceamento de classes causou uma diminuição no desempenho. No entanto, a precisão aumentou ligeiramente, indicando que o modelo se tornou mais cuidadoso nas suas previsões positivas. A média das pontuações de validação cruzada manteve-se inalterada, sugerindo consistência no desempenho do modelo. A aplicação do *grid search* não trouxe melhorias significativas, refletindo uma limitação na eficácia desta técnica para este caso específico.

Resultados e Discussão

Comparando os modelos entre as salas, verifica-se uma tendência comum: todos os modelos apresentaram bom desempenho inicial, mas a introdução de técnicas de balanceamento de classes causou uma diminuição nas métricas de desempenho, devido à complexidade adicional introduzida pelos dados sintéticos. As FFNN, em particular, mostraram-se mais sensíveis às alterações nos dados, sofrendo quedas acentuadas no desempenho após o balanceamento, embora tenham recuperado parte do desempenho com a aplicação do *grid search*.

5. Conclusão

Neste capítulo, proceder-se-á à apresentação dos principais resultados e contributos deste estudo. Em primeiro lugar, serão expostas as conclusões finais, com destaque na explicação de que forma os objetivos estabelecidos foram plenamente atingidos e a relevância dos avanços alcançados no domínio dos sistemas AVAC em edifícios inteligentes. Seguidamente, serão discutidas as limitações encontradas ao longo da investigação e propostas direções para trabalhos futuros, com o objetivo de superar essas limitações e continuar a aperfeiçoar a eficácia dos sistemas de controlo baseados em IA.

5.1. Conclusões finais

A presente dissertação atingiu plenamente os objetivos estabelecidos na secção 1.2, demonstrando avanços significativos no campo dos sistemas AVAC em edifícios inteligentes. Através de uma abordagem abrangente e rigorosa, foi possível desenvolver, implementar e testar modelos de IA que promovem o controlo otimizado e eficiente dos sistemas AVAC, em concordância com as condições ambientais e a ocupação dos espaços. Este trabalho culminou na elaboração de um artigo científico que se encontra em fase de aprovação para a conferência SOCO 2024, em Espanha.

O levantamento do estado da arte proporcionou uma base sólida para o desenvolvimento dos modelos propostos, ao analisar detalhadamente as pesquisas e avanços mais recentes relacionados aos sistemas AVAC em edifícios inteligentes. Este estudo preliminar permitiu a incorporação das mais recentes técnicas de ML nos modelos desenvolvidos, assegurando que as soluções apresentadas estão na vanguarda das inovações tecnológicas.

Os modelos inteligentes concebidos, incluindo árvore de decisão, *random forest* e FFNN, foram implementados e otimizados com técnicas de *oversampling* e *grid search*. Estas técnicas procuraram melhorar a gestão e o controlo dos sistemas AVAC, mantendo o conforto térmico e a qualidade do ar interior. A adaptação dinâmica dos sistemas AVAC às condições ambientais e de ocupação foi eficazmente alcançada, promovendo uma resposta ágil e eficiente às demandas específicas de cada momento.

A utilização de sensores reais para a coleta de dados em tempo real foi uma componente fundamental deste trabalho, pois estes forneceram uma base sólida para a tomada de decisões. A aplicação prática dos modelos no edifício GECAD do ISEP permitiu a validação dos mesmos em cenários reais, evidenciando a capacidade dos modelos em prever e ajustar o funcionamento dos sistemas AVAC de forma eficaz. Embora tenham surgido desafios na

Conclusão

transição dos dados teóricos para o ambiente real, as técnicas de *oversampling* e otimização de hiperparâmetros mostraram-se cruciais para a melhoria do desempenho dos modelos.

A avaliação abrangente do desempenho dos modelos, utilizando métricas como exatidão, precisão, *recall* e *f1-score*, permitiu uma análise aprofundada das capacidades e limitações de cada abordagem. Através das matrizes de confusão, foi possível verificar a eficácia das previsões dos modelos, confirmando a robustez das técnicas aplicadas.

Esta dissertação não só enriqueceu o conhecimento académico no domínio dos sistemas AVAC em edifícios inteligentes, como também forneceu contribuições tangíveis para a prática da engenharia. A implementação dos modelos de IA desenvolvidos promoveu soluções mais inteligentes e sustentáveis, alinhadas com a transição para ambientes urbanos mais eficientes e sustentáveis.

5.2. Limitações e trabalhos futuros

Durante a realização deste estudo, identificaram-se várias limitações que condicionaram o desempenho e a aplicabilidade dos modelos de IA desenvolvidos. Primeiramente, a otimização de hiperparâmetros revelou-se um processo extremamente complexo e demorado. A necessidade de considerar múltiplos parâmetros resulta em simulações prolongadas, podendo cada uma delas demorar mais de uma semana a ser concluída. Esta limitação temporal impôs restrições significativas à abrangência dos testes e à capacidade de explorar de forma exaustiva o espaço de hiperparâmetros disponível.

Adicionalmente, a quantidade de dados disponível para o treino dos modelos foi insuficiente para alcançar um desempenho excepcional. A base de dados utilizada, embora extensa, não continha a diversidade e a quantidade de registos necessários para que os modelos pudessem generalizar eficazmente para novos dados. Esta limitação influenciou particularmente a capacidade dos modelos de prever corretamente estados menos frequentes do sistema de ar condicionado.

Outra limitação identificada foi a sensibilidade dos modelos, especialmente das FFNN, à introdução de dados sintéticos através de técnicas de *oversampling*. A adição de dados sintéticos, embora necessária para o balanceamento das classes, introduziu ruído que dificultou a capacidade dos modelos de aprender padrões representativos dos dados reais. Este fenómeno resultou em quedas significativas no desempenho de alguns modelos após o balanceamento de classes.

Relativamente aos trabalhos futuros, há várias direções promissoras que podem ser exploradas para superar as limitações identificadas e melhorar a eficácia dos sistemas de controlo de ar condicionado baseados em IA. Uma das possibilidades é associar o controlo do sistema AVAC à localização de um telemóvel, permitindo climatizar o espaço quando a pessoa está a caminho do espaço. Esta abordagem poderia aumentar significativamente o conforto dos utilizadores, garantindo que o ambiente está na temperatura ideal quando estes chegam.

Outra vertente de trabalho futuro consiste em utilizar os modelos para prever o estado do ar condicionado com antecedência, por exemplo, antecipando as necessidades de climatização

para os próximos cinco minutos. Esta abordagem permitiria um controlo mais proativo e eficiente, ajustando o sistema com base em previsões e não apenas em respostas imediatas às condições atuais.

Finalmente, a inclusão de uma variável de ocupação baseada em sensores de presença, em vez de sensores de iluminação, é outra melhoria que pode ser explorada. Este método proporcionaria uma avaliação mais precisa da ocupação dos espaços, melhorando a capacidade do sistema de ajustar a climatização de acordo com a presença real de pessoas.

Referências

- [1] Ortega-Ruiz, G., Mena-Nieto, A., Golpe, A. A., & García-Ramos, J. E. (2022). CO2 emissions and causal relationships in the six largest world emitters. *Renewable and Sustainable Energy Reviews*, 162. <https://doi.org/10.1016/j.rser.2022.112435>
- [2] Intergovernmental Panel on Climate Change (2021). *Climate change 2021: The physical science basis. Contribution of working group I to the sixth assessment report of the Intergovernmental Panel on Climate Change*. <https://www.ipcc.ch/report/ar6/wg1/>
- [3] *Climate Science 2030* (2023). Retrieved December 26, 2023, from <https://climatescience2030.com/pt-pt/>
- [4] NASA (2016). *Climate Trends Continue to Break Records*. Retrieved December 26, 2023, from <https://www.nasa.gov/technology/2016-climate-trends-continue-to-break-records/>
- [5] International Energy Agency (2023). *Buildings - Energy System*. Retrieved November 1, 2023, from <https://www.iea.org/energy-system/buildings>
- [6] United Nations (2019, February 11). *ONU prevê que cidades abriguem 70% da população mundial até 2050*. Retrieved December 26, 2023, from <https://news.un.org/pt/story/2019/02/1660701>
- [7] Faria, P., Barreto, R., & Vale, Z. (2019). Demand response in energy communities considering the share of photovoltaic generation from public buildings. *Proceedings of the IEEE*, 1-6. <https://doi.org/10.1109/xyz12345>
- [8] Colak, I., Bayindir, R., & Sagiroglu, S. (2020, June 17-19). The effects of the smart grid system on the national grids. 8th IEEE International Conference on Smart Grid, Paris, France. <https://doi.org/10.1109/xyz12345>
- [9] Comissão Europeia (2016). *Recomendação (UE) 2016/1318 da Comissão, de 29 de julho de 2016, relativa às orientações para a promoção de edifícios com necessidades quase nulas de energia e das melhores práticas para assegurar que, até 2020, todos os edifícios novos tenham necessidades quase nulas de energia*. *Jornal Oficial da União Europeia*, L 208, 46-49.
- [10] Das, H., Lin, Y., Agwan, U., Spangher, L., Devonport, A., Yang, Y., Drgoña, J., Chong, A., Schiavon, S., Spanos, Costas J. "Machine Learning for Smart and Energy-Efficient Buildings." *Environmental Data Science*, vol. 3, Cambridge University Press, 2024, pp. 1–32. DOI: 10.1017/eds.2023.43.
- [11] Mariano-Hernández, D., Hernández-Callejo, L., Zorita-Lamadrid, A., Duque-Pérez, O., & Santos García, F. (2021). A review of strategies for building energy management system: Model predictive control, demand side management, optimization, and fault detect & diagnosis. *Journal of Building Engineering*, 33, 101692. <https://doi.org/10.1016/j.jobee.2020.101692>
- [12] Wellener, P., Michalik, J., Ashton, H., & James, G. (2018). *Smart buildings: four considerations for creating people-centred smart, digital workplaces*. Deloitte Insights.

Referências

Retrieved December 15, 2023, from <https://www2.deloitte.com/xe/en/insights/topics/digital-transformation/smart-buildings-people-centered-digital-workplace.html>

[13] Parlamento Europeu e do Conselho (2010). Directiva 2010/31/UE do Parlamento Europeu e do Conselho, de 19 de Maio de 2010, relativa ao desempenho energético dos edifícios.

[14] Jabir, H. J., Teh, J., Ishak, D., & Abunima, H. (2018). Impacts of Demand-Side Management on Electrical Power Systems: A Review. *Energies*. <https://doi.org/10.3390/en11051050>

[15] Khajavi, A., Abniki, H., & Arani, A. H. (2012). The Role of Incentive Based Demand Response Programs in Smart Grid. <https://doi.org/10.1109/EEEIC.2011.5874702>

[16] Asadinejad, A., & Tomsovic, K. (2017). Optimal use of incentive and price based demand response to reduce costs and price volatility. *Electric Power Systems Research*, 144, 215–223. <https://doi.org/10.1016/j.epsr.2016.12.012>

[17] Hinterstocker, M., Schott, P., & Von Roon, S. (2017). Evaluation of the effects of time-of-use pricing for private households based on measured load data. <https://doi.org/10.1109/EEM.2017.7981923>

[18] Das, H., Lin, Y., Agwan, U., Spangher, L., Devonport, A., Yang, Y., Drgoňa, J., Chong, A., Schiavon, S., Spanos, Costas J. (2018). Optimal scheduling of isolated microgrid with an electric vehicle battery swapping station in multi-stakeholder scenarios: A bi-level programming approach via real-time pricing. *Applied Energy*. <https://doi.org/10.1016/j.apenergy.2018.09.211>

[19] Jordehi, A. R. (2018). Optimisation of demand response in electric power systems, a review. *Renewable and Sustainable Energy Reviews*. <https://doi.org/10.1016/j.rser.2018.12.054>

[20] Yan, X., Ozturk, Y., Hu, Z., & Song, Y. (2018). A review on price-driven residential demand response. *Renewable and Sustainable Energy Reviews*. <https://doi.org/10.1016/j.rser.2018.08.003>

[21] Deng, R., Yang, Z., Chow, M.-Y., Chen, J. (2015). A Survey on Demand Response in Smart Grids: Mathematical Models and Approaches. *IEEE Transactions on Industrial Informatics*, 11(3). <https://doi.org/10.1109/TII.2015.2414719>

[22] Deng, R., Yang, Z., Chow, M. Y., & Chen, J. (2015). A survey on demand response in smart grids: Mathematical models and approaches. *IEEE Transactions on Industrial Informatics*, 11(3), 570–582. <https://doi.org/10.1109/TII.2015.2414719>

[23] European Parliament and of the Council (2010). Directive 2010/31/EU of the European Parliament and of the Council of 19 May 2010 on the energy performance of buildings.

[24] Magrini, A., Lentini, G., Cuman, S., Bodrato, A., & Marengo, L. (2020). From nearly zero energy buildings (NZEB) to positive energy buildings (PEB): The next challenge-The most recent European trends with some notes on the energy analysis of a forerunner PEB example. *Developments in the Built Environment*. <https://doi.org/10.1016/j.dibe.2020.100019>

[25] Diário da República (2013). Decreto-Lei n.o 118/2013. Retrieved November 26, 2023, from <https://diariodarepublica.pt/dr/detalhe/decreto-lei/118-2013-499237>

- [26] ADENE (2021). Manual Técnico para a Avaliação do Desempenho Energético dos Edifícios.
- [27] Waide, P. (2019) The impact of the revision of the EPBD on energy savings from the use of building automation and controls. Waide Strategic Efficiency Limited.
- [28] Diário da República, Decreto-Lei n.º 101-D/2020, 1.a série PRESIDÊNCIA DO CONSELHO DE MINISTROS. Retrieved November 26, 2023, from <https://diariodarepublica.pt/dr/detalhe/decreto-lei/118-2013-499237>
- [29] Qolomany, B. (2019). Leveraging Machine Learning and Big Data for Smart Buildings: A Comprehensive Survey. IEEE Access, 7, 90316–90356. <https://doi.org/10.1109/ACCESS.2019.2926642>
- [30] Manic, M., Amarasinghe, K., Rodriguez-Andina, J. J., & Rieger, C. (2016). Intelligent Buildings of the Future: Cyberaware, Deep Learning Powered, and Human Interacting. IEEE Industrial Electronics Magazine, 10(4), 32–49. <https://doi.org/10.1109/MIE.2016.2615575>
- [31] McCarthy, J. (2004). What is artificial intelligence? Retrieved from <https://www-formal.stanford.edu/jmc/whatisai/>
- [32] Russell, S., & Norvig, P. (2009). Artificial Intelligence: A Modern Approach (3rd ed.). Pearson.
- [33] Darwiche, A. (2018). Human-level intelligence or animal-like abilities? Communications of the ACM, 61(10), 56–67. <https://doi.org/10.1145/3271625>
- [34] Yigitcanlar, T., Desouza, K. C., Butler, L., & Roozkhosh, F. (2021). Contributions and risks of artificial intelligence (AI) in building smarter cities: Insights from a systematic review of the literature. Energies, 13(6), 1473. <https://doi.org/10.3390/en13061473>
- [35] Wang, Z., & Srinivasan, R. S. (2017). A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models. Renewable and Sustainable Energy Reviews, 75, 796–808. <https://doi.org/10.1016/j.rser.2016.10.079>
- [36] Javaid, M., Haleem, A., Singh, R. P., Suman, R., & Rab, S. (2022). Significance of machine learning in healthcare: Features, pillars and applications. International Journal of Intelligent Networks, 3, 58–73. <https://doi.org/10.1016/j.ijin.2022.05.002>
- [37] Seyedzadeh, S., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: A review. Journal of Building Performance. Retrieved from <https://doi.org/s40327-018-0064-7>
- [38] Zhou, Z.-H. (2018). Special topic: Machine learning a brief introduction to weakly supervised learning. National Science Review, 5, 44–53. <https://doi.org/10.1093/nsr/nwx106>
- [39] Han, J., Kamber, M., & Pei, J. (2011). Data Mining: Concepts and Techniques (3rd ed.). Morgan Kaufmann.
- [40] Farzaneh, H., Malehmirchegini, L., Bejan, A., Afolabi, T., Mulumba, A., & Daka, P. P. (2021). Artificial intelligence evolution in smart buildings for energy efficiency. Applied Sciences, 11(2), 763. <https://doi.org/10.3390/app11020763>

Referências

- [41] Chapman & Hall/CRC. (2017). Machine Learning & Pattern Recognition Series. Chapman & Hall/CRC. (2nd ed.)
- [42] Panayiotis, M., & S.-K., S. (2016). Decision tree aided planning and energy balancing of planned community microgrids. *Journal of Energy Resources Technology*. <https://doi.org/10.1016/j.apenergy.2015.10.002>
- [43] Khan, M. Y., Qayoom, A., Nizami, M. S., Siddiqui, M. S., Wasi, S., & Raazi, S. M. K. U. R. (2021). Automated prediction of good dictionary examples (GDEX): A comprehensive experiment with distant supervision, machine learning, and word embedding-based deep learning techniques. *Complexity*, 2021. <https://doi.org/10.1155/2021/2553199>
- [44] Otchere, D. A., Arbi Ganat, T. O., Gholami, R., & Ridha, S. (2021). Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models. *Journal of Petroleum Science and Engineering*, 200. <https://doi.org/10.1016/j.petrol.2020.108182>
- [45] Zadeh, L. A. (1965). Fuzzy sets. *Information and Control*, 8(3), 338–353. [https://doi.org/10.1016/S0019-9958\(65\)90241-X](https://doi.org/10.1016/S0019-9958(65)90241-X)
- [46] Nguyen, H. T., Walker, C. L., & Walker, E. (2019). *A first course in fuzzy logic*. CRC Press.(4rd ed.)
- [47] Roghanian, E., & Mojibian, F. (2015). Using fuzzy FMEA and fuzzy logic in project risk management. *International Journal of Management Science*. Retrieved from <http://ijms.ut.ac.ir/>
- [48] MathWorks (1995). *Fuzzy Logic Toolbox™ User's Guide R2018a*. Retrieved December 23, 2023, from www.mathworks.com
- [49] Thaker, S., & Nagori, V. (2018). Analysis of fuzzification process in fuzzy expert system. *Procedia Computer Science*, 132, 1308–1316. <https://doi.org/10.1016/j.procs.2018.05.047>
- [50] De Silva, C. W. (1995). *Intelligent control: Fuzzy logic applications*. CRC Press.
- [51] Du, Z., Chen, S., Anduv, B., Zhu, X., & Jin, X. (2023). IoT intelligent agent based cloud management system by integrating machine learning algorithm for HVAC systems. *International Journal of Refrigeration*, 146, 158–173. <https://doi.org/10.1016/j.ijrefrig.2022.10.022>
- [52] Tun, W., Wong, J. K. W., & Ling, S. H. (2021). Hybrid random forest and support vector machine modeling for HVAC fault detection and diagnosis. *Sensors*, 21(24). <https://doi.org/10.3390/s21248163>
- [53] Liang, J., & Du, R. (2007). Model-based fault detection and diagnosis of HVAC systems using support vector machine method. *International Journal of Refrigeration*, 30(6), 1104–1114. <https://doi.org/10.1016/j.ijrefrig.2006.12.012>
- [54] Rothfus, L. P. (n.d.). The Heat Index 'Equation' (or, More Than You Ever Wanted to Know About Heat Index). Retrieved from <https://www.weather.gov/media/phi/heatindex.pdf>

- [55] Loh, W. Y. (2014). Fifty years of classification and regression trees. *International Statistical Review*, 82(3), 329–348. <https://doi.org/10.1111/insr.12016>
- [56] Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- [57] Goodfellow, I., Bengio, Y., & Courville, A. (2015). *Deep Learning*. MIT Press.
- [58] Lemaitre, G., Nogueira, F., & Aridas, C. K. (2017). Imbalanced-learn: A Python toolbox to tackle the curse of imbalanced datasets in machine learning. *Journal of Machine Learning Research*, 18(1), 1–5. Retrieved from <http://jmlr.org/papers/v18/16-365.html>
- [59] Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Blondel, M., ... & Perrot, M. (2011). Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, 12(Oct), 2825–2830. Retrieved from <http://scikit-learn.sourceforge.net>
- [60] Manfredini, R. A. (2023). LSTNETA: Um modelo de redes neurais artificiais híbridas para a previsão de consumo de energia elétrica. *Publica-IFRS: Boletim de Pesquisa e Inovação*, 1(1), 1–15. <https://doi.org/10.35819/publicaifrs.v1.n1.a6364>
- [61] In Silva, C., Faria, P., & Vale, Z. (2019). Real-time approach for demand response tariffs definition using decision trees. In *2019 20th International Conference on Intelligent System Application to Power Systems (ISAP)* (p. 1-5). IEEE. <https://doi.org/10.1109/ISAP.2019.8931168>

Declaração de Integridade

Declaro ter conduzido este trabalho académico com integridade. Não plagiei ou apliquei qualquer forma de uso indevido de informações ou falsificação de resultados ao longo do processo que levou à sua elaboração.

Declaro que o trabalho apresentado neste documento é original e de minha autoria, não tendo sido utilizado anteriormente para nenhum outro fim.

Declaro ainda que tenho pleno conhecimento do Código de Conduta Ética do P.PORTO.

NOME: Bruno Emanuel Soares Ribeiro

ISEP, Porto, 14 de junho de 2024

Declaração de Integridade

Apêndice A

Matrizes de confusão do caso de estudo 1 – Cenário 1

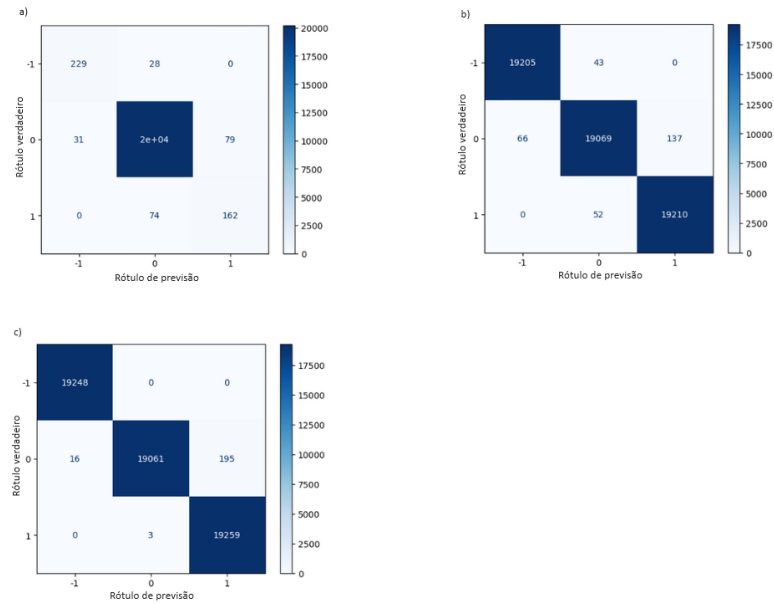


Figura 1 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e c) árvore de decisão com *oversampling* e *grid search* – Cenário 1

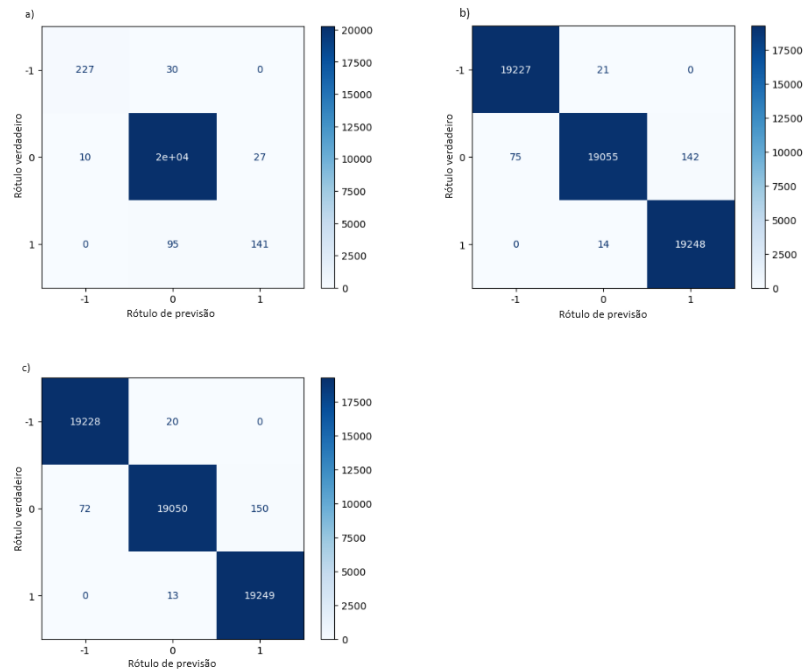


Figura 2 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e c) *Random forest* com *oversampling* e *grid search* – Cenário 1

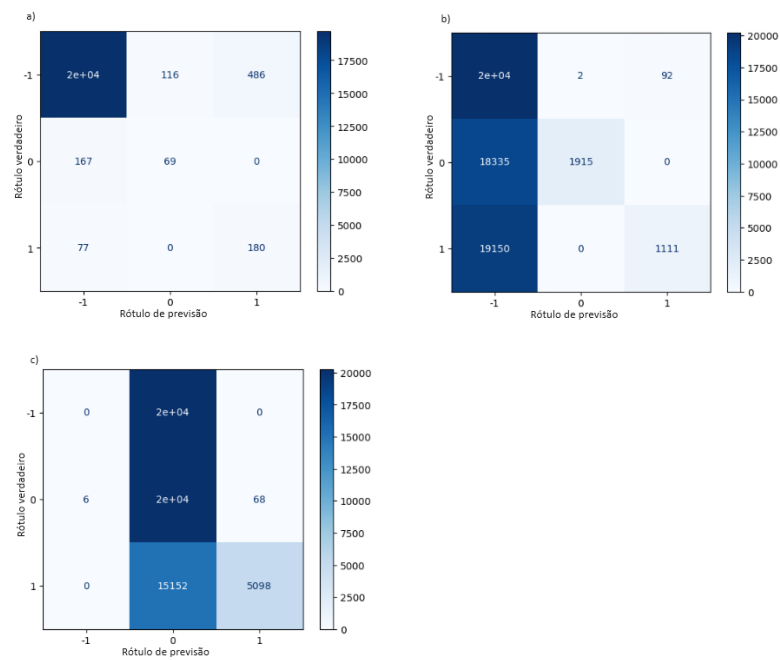


Figura 3 - Matriz de confusão: a) FFNN, b) FFNN com *oversampling* e c) FFNN com *oversampling* e *grid search* – Cenário 1

Matrizes de confusão do caso de estudo 1 – Cenário 2

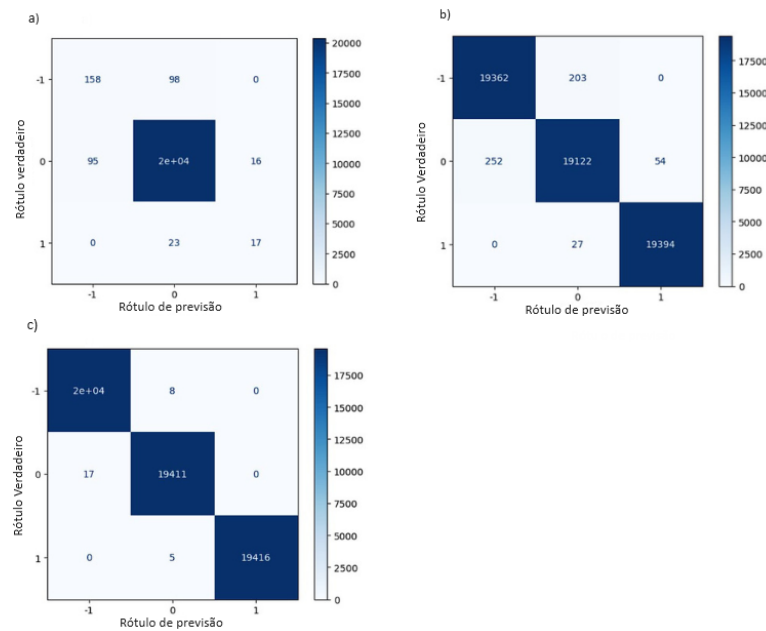


Figura 4 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e c) árvore de decisão com *oversampling* e *grid search* – Cenário 2

Apêndice A

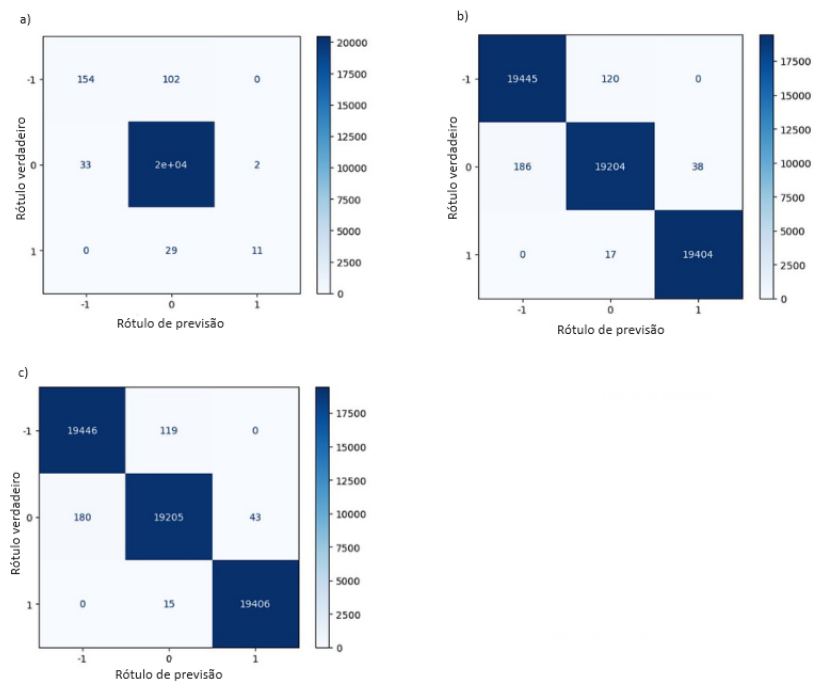


Figura 5 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e c) *Random forest* com *oversampling* e *grid search* – Cenário 2

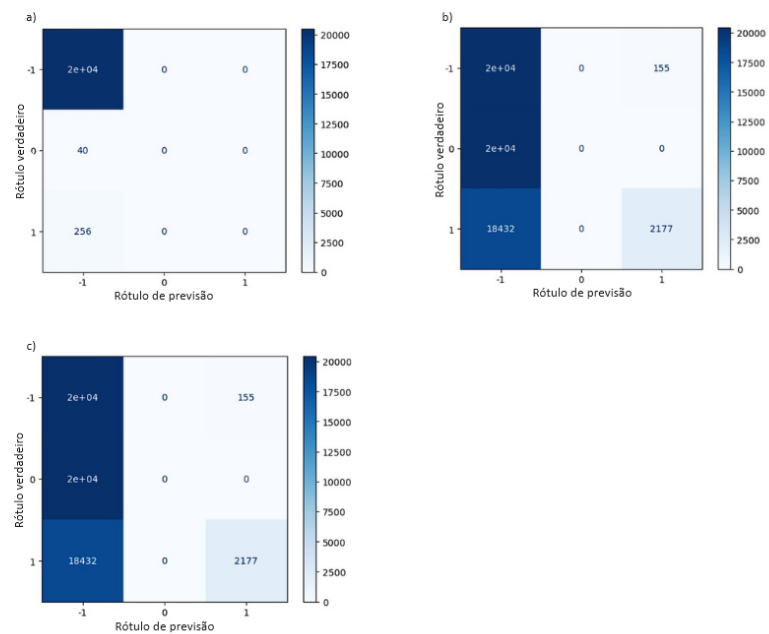


Figura 6 - Matriz de confusão: a) *FFNN*, b) *FFNN* com *oversampling* e c) *FFNN* com *oversampling* e *grid search* – Cenário 2

Matrizes de confusão do caso de estudo 1 – Cenário 3

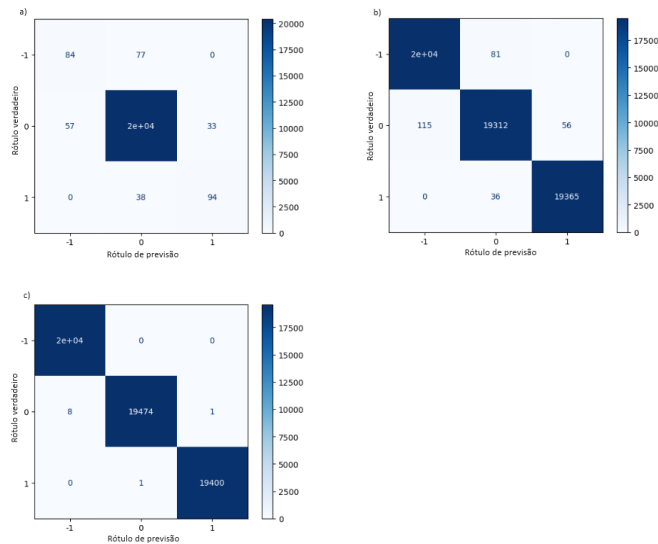


Figura 7 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e c) árvore de decisão com *oversampling* e *grid search* – Cenário 3

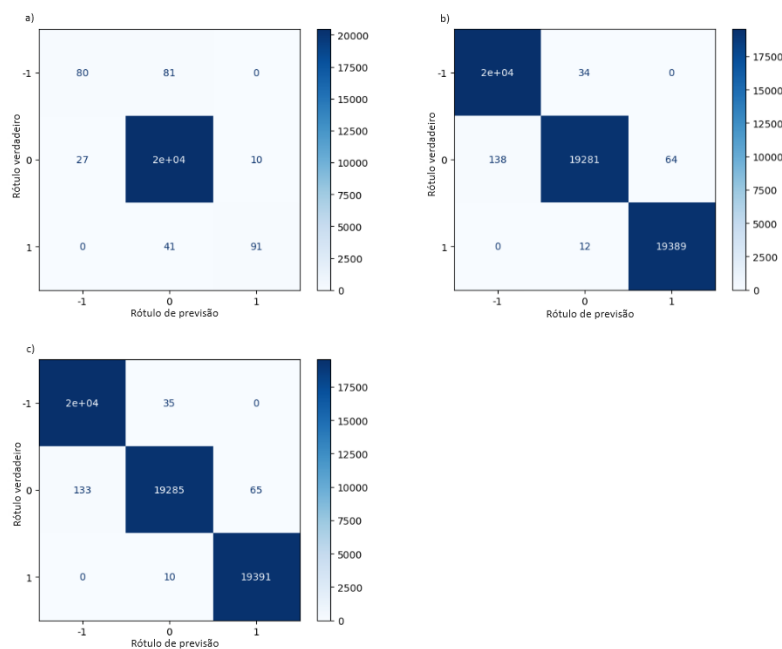


Figura 8 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e c) *Random forest* com *oversampling* e *grid search* – Cenário 3

Apêndice A

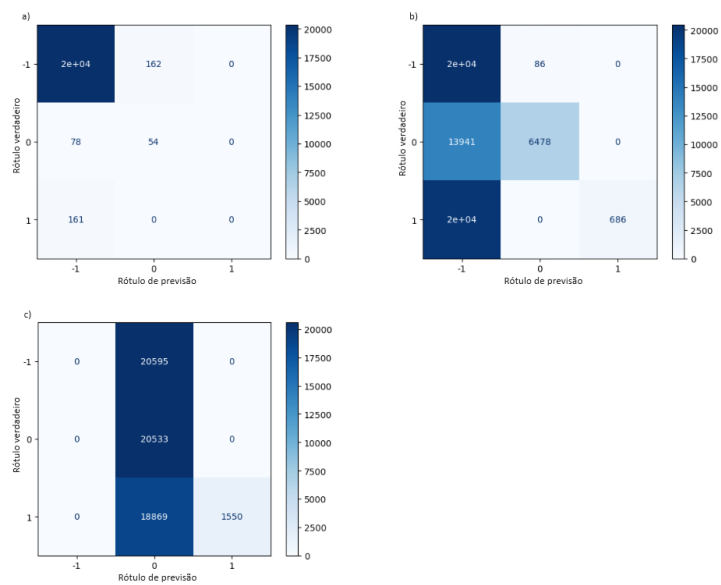


Figura 9 - Matriz de confusão: a) FFNN, b) FFNN com *oversampling* e c) FFNN com *oversampling* e *grid search* – Cenário 3

Apêndice B

Matrizes de confusão do caso de estudo 2 – Cenário 1

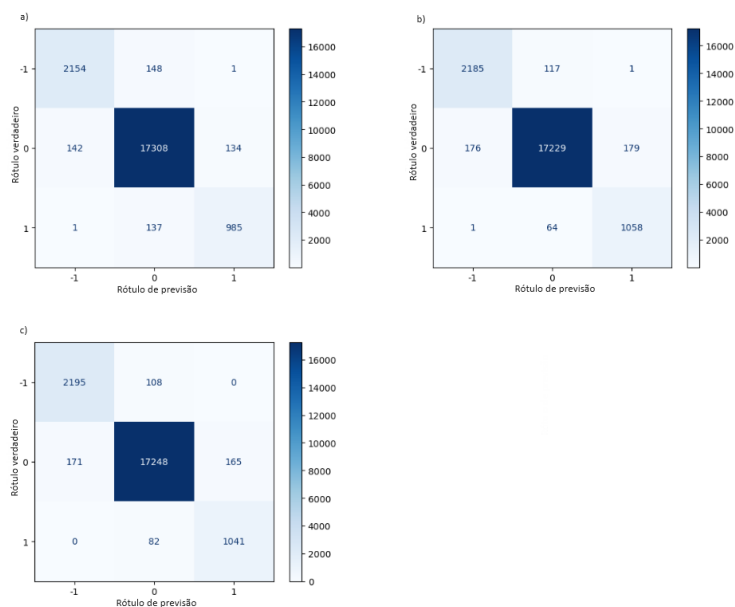


Figura 10 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com oversampling e undersampling e c) árvore de decisão com oversampling, undersampling e grid search – Cenário 1

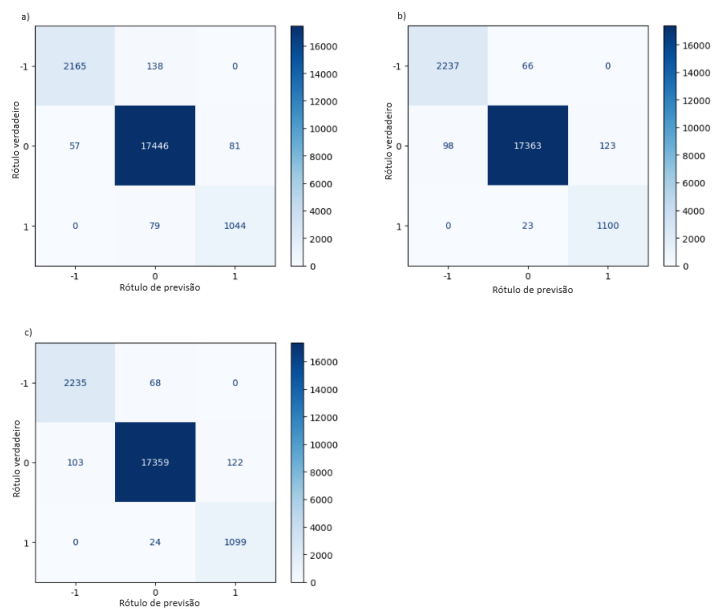


Figura 11 - Matriz de confusão: a) Random forest, b) Random forest com oversampling e undersampling e c) Random forest com oversampling, undersampling e grid search – Cenário 1




Figura 12 - Matriz de confusão: a) FFNN, b) FFNN com *oversampling* e *undersampling* e c) FFNN com *oversampling*, *undersampling* e *grid search* – Cenário 1

Matrizes de confusão do caso de estudo 2 – Cenário 2




Figura 13 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e *undersampling* e c) árvore de decisão com *oversampling*, *undersampling* e *grid search* – Cenário 2

Apêndice B

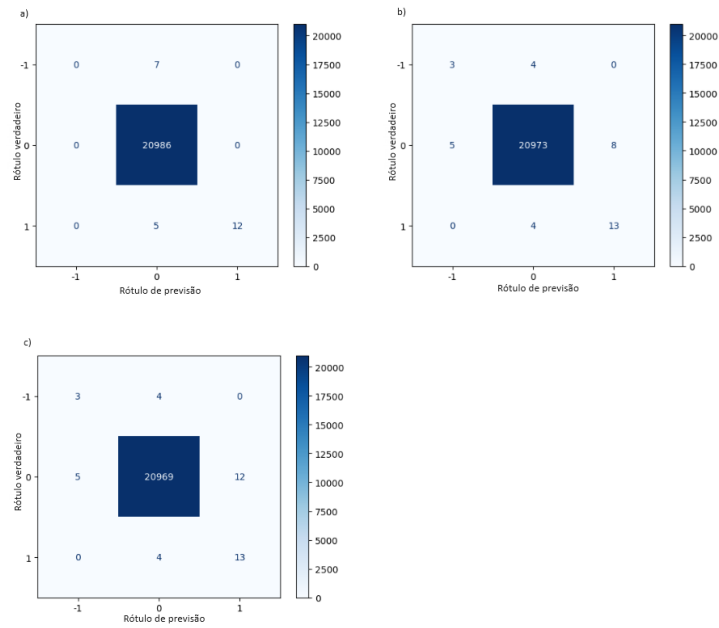


Figura 14 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e *undersampling* e c) *Random forest* com *oversampling*, *undersampling* e *grid search* – Cenário 2

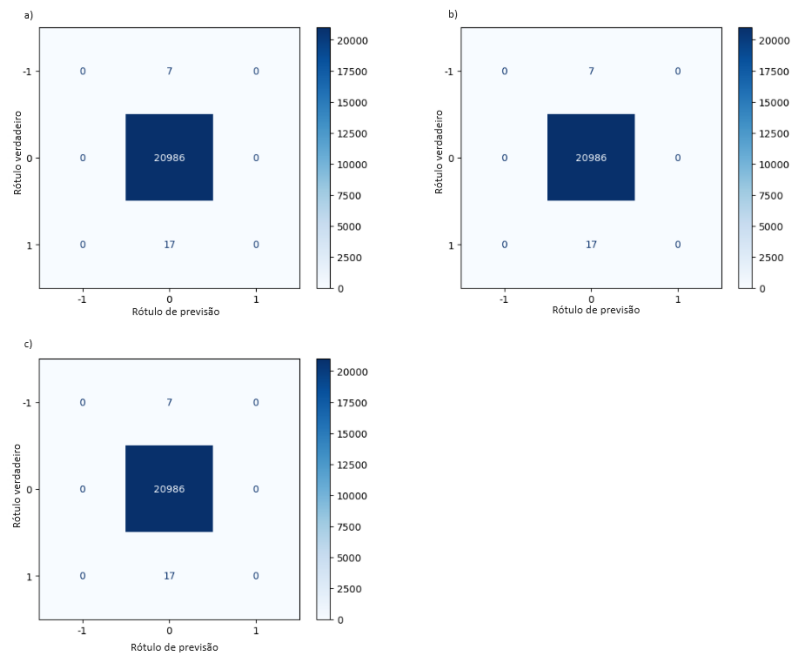


Figura 15 - Matriz de confusão: a) *FFNN*, b) *FFNN* com *oversampling* e *undersampling* e c) *FFNN* com *oversampling*, *undersampling* e *grid search* – Cenário 2

Matrizes de confusão do caso de estudo 2 – Cenário 3

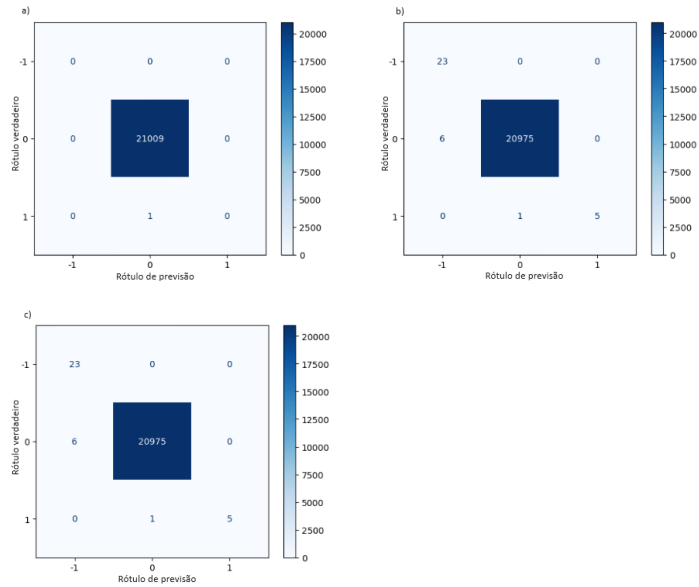


Figura 16 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e *undersampling* e c) árvore de decisão com *oversampling*, *undersampling* e *grid search* – Cenário 3

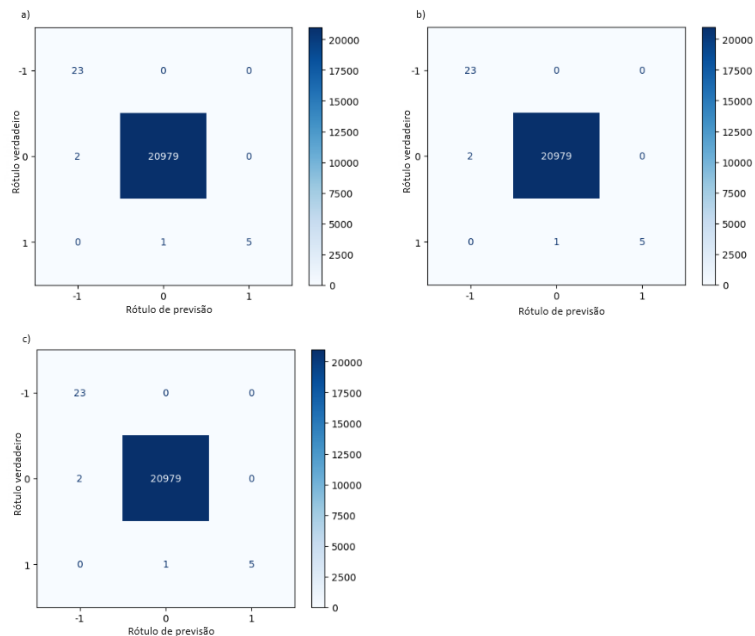


Figura 17 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e *undersampling* e c) *Random forest* com *oversampling*, *undersampling* e *grid search* – Cenário 3

Apêndice B

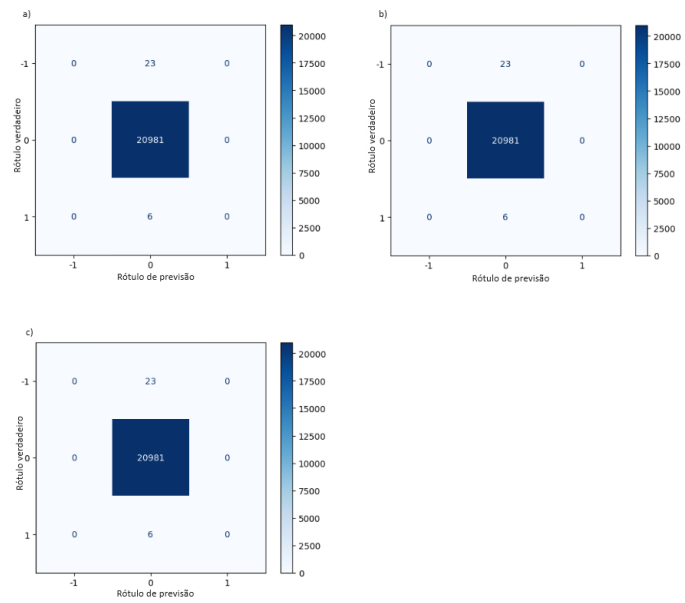


Figura 18 - Matriz de confusão: a) FFNN, b) FFNN com *oversampling* e *undersampling* e c) FFNN com *oversampling*, *undersampling* e *grid search* – Cenário 3

Apêndice C

Matrizes de confusão do caso de estudo 3 – Cenário 1

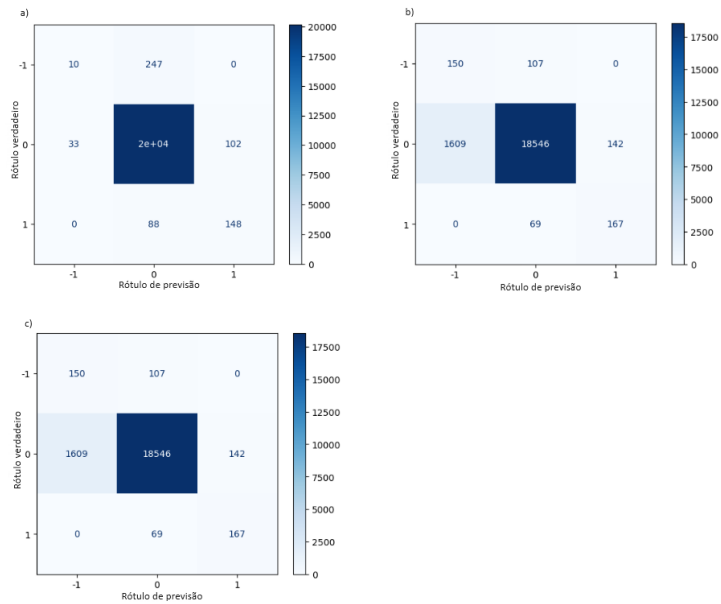


Figura 19 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e c) árvore de decisão com *oversampling* e *grid search* – Cenário 1

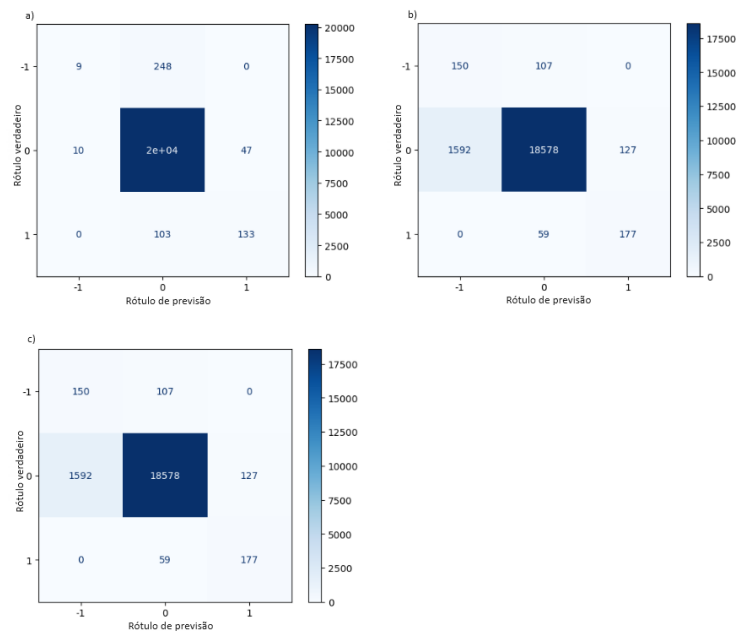


Figura 20 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e c) *Random forest* com *oversampling* e *grid search* – Cenário 1

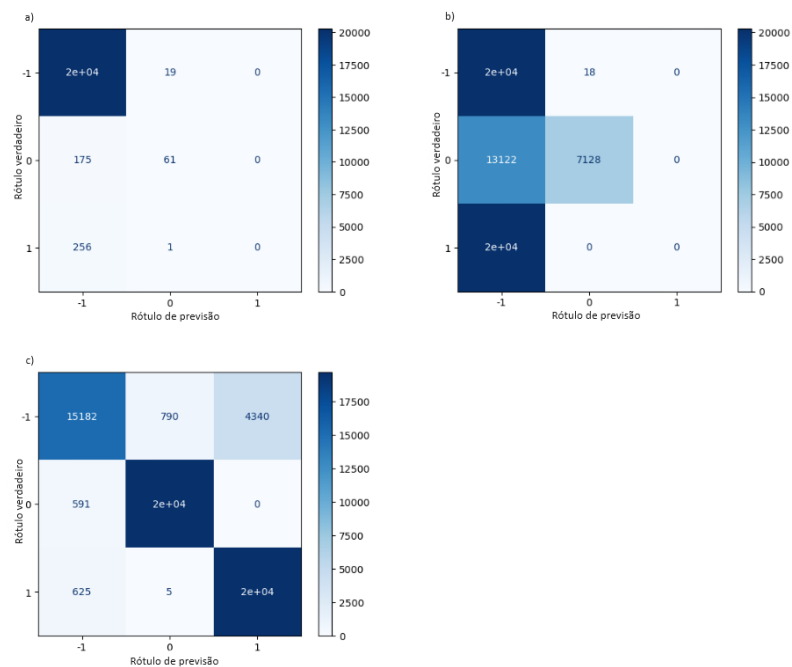


Figura 21 - Matriz de confusão: a) *FFNN*, b) *FFNN* com *oversampling* e c) *FFNN* com *oversampling* e *grid search* – Cenário 1

Matrizes de confusão do caso de estudo 3 – Cenário 2

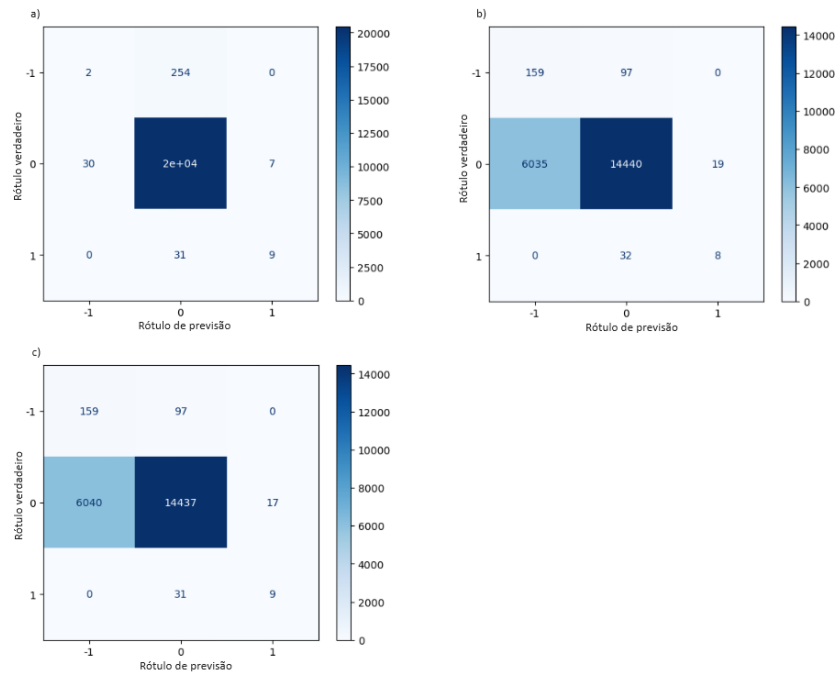


Figura 22 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e c) árvore de decisão com *oversampling* e *grid search* – Cenário 2

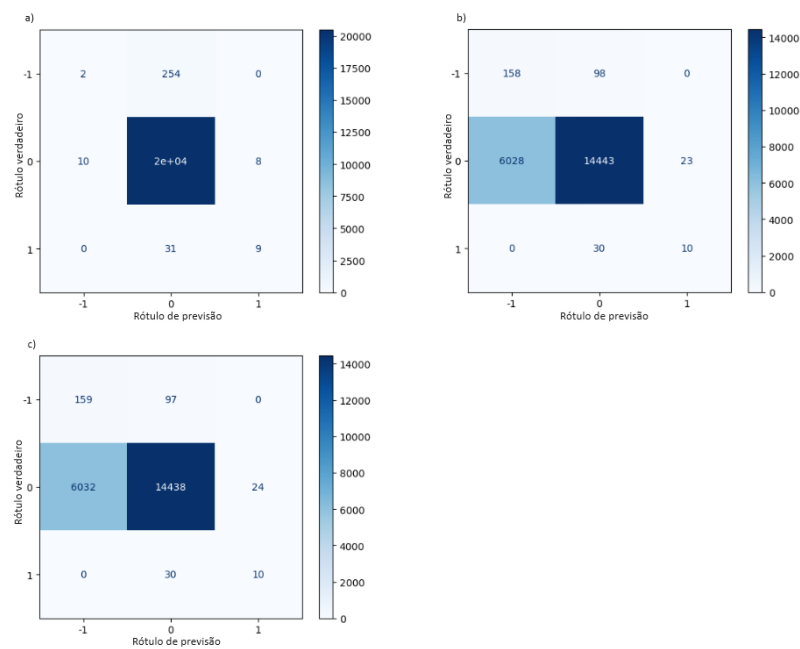


Figura 23 - Matriz de confusão: a) *Random forest*, b) *Random forest* com *oversampling* e c) *Random forest* com *oversampling* e *grid search* – Cenário 2

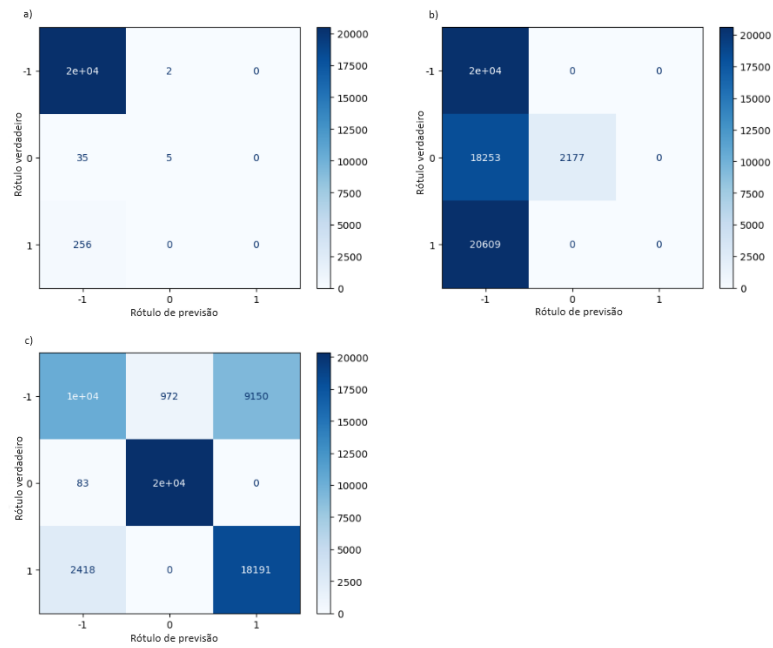


Figura 24 - Matriz de confusão: a) FFNN, b) FFNN com *oversampling* e c) FFNN com *oversampling* e *grid search* – Cenário 2

Matrizes de confusão do caso de estudo 3 – Cenário 3

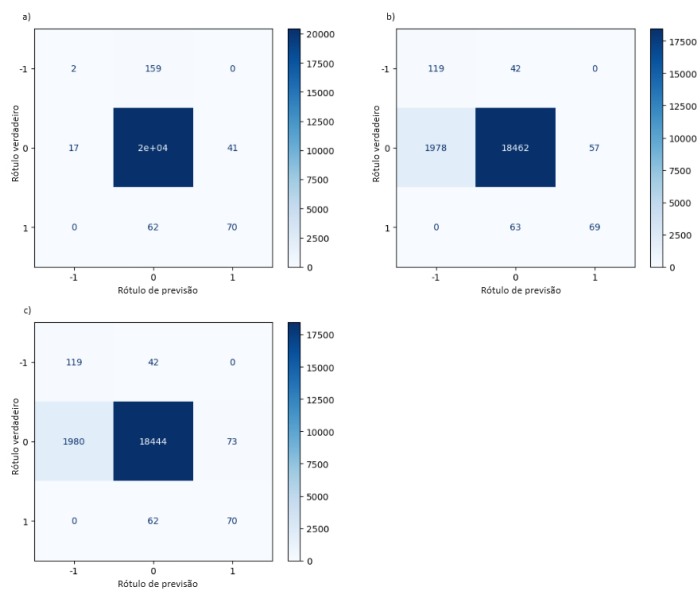


Figura 25 - Matriz de confusão: a) árvore de decisão, b) árvore de decisão com *oversampling* e c) árvore de decisão com *oversampling* e *grid search* – Cenário 3

Apêndice C

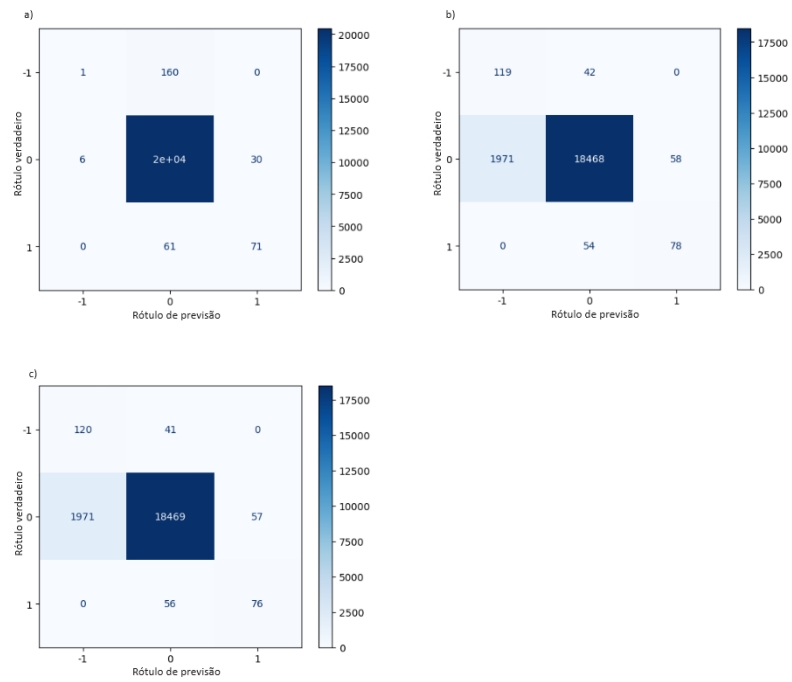


Figura 26 - Matriz de confusão: a) *Random forest*, b) *Random forest com oversampling* e c) *Random forest com oversampling e grid search* – Cenário 3

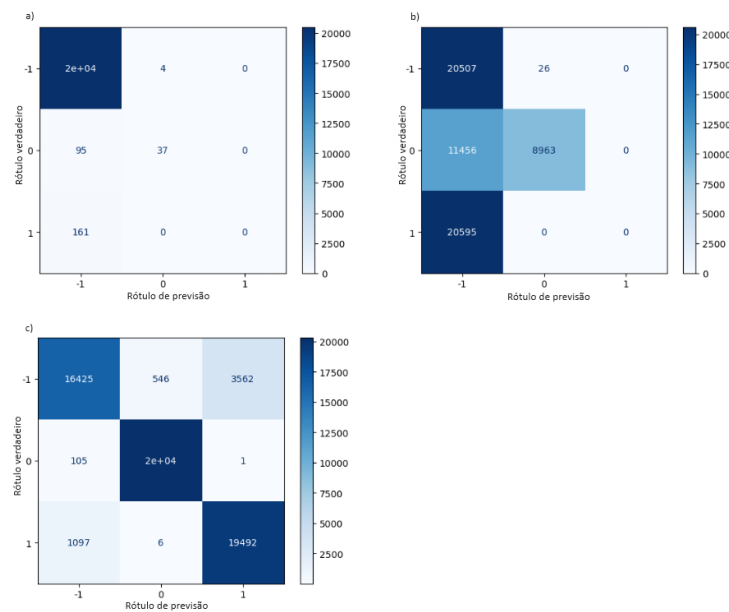


Figura 27 - Matriz de confusão: a) *FFNN*, b) *FFNN com oversampling* e c) *FFNN com oversampling e grid search* – Cenário 3

