



INTELIGÊNCIA ARTIFICIAL PARA GESTÃO ENERGÉTICA

ANTÓNIO PEDRO DE VAZ NUNES

julho de 2025

INTELIGÊNCIA ARTIFICIAL PARA GESTÃO ENERGÉTICA

António Pedro Vaz Nunes

**Dissertação para obtenção do Grau de Mestre em Energias
Sustentáveis**

Orientador no ISEP: Doutor Engenheiro Pedro Nuno Silva Faria

Supervisor no GECAD: Mestre Engenheiro Daniel Carlos Do Vale Ramos



Júri:

Presidente:

Olga dos Remédios Sobral Castro, Professor Adjunto, Instituto Superior de Engenharia do Politécnico do Porto

Vogais:

Sergio Filipe Carvalho Ramos, Professor Coordenador, Instituto Superior de Engenharia do Politécnico do Porto

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

Porto, 16 de Julho de 2025

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.

António Pedro Vaz Nunes

ISEP, Porto, 16 de Julho de 2025

Resumo

Este trabalho tem como objetivo explorar o papel da Inteligência Artificial (IA) na gestão energética, destacando a sua contribuição para a sustentabilidade e eficiência no setor. A crescente procura de energia e os desafios associados às alterações climáticas tornam urgente a adoção de tecnologias avançadas que otimizem o uso de recursos energéticos e que reduzam os impactos ambientais.

A IA, em conjunto com áreas como machine learning, deep learning e algoritmos de otimização, permite previsões precisas de consumo, a integração eficiente de fontes renováveis e a automação de processos em redes inteligentes (smart grids).

O estudo aborda ainda o papel das Comunidades Energéticas como soluções descentralizadas que promovem a produção, consumo e armazenamento de energia renovável a nível local. Estas comunidades, sustentadas por ferramentas como blockchain e contratos inteligentes, promovem a transparência e a democratização no setor energético.

Adicionalmente, são discutidos métodos de armazenamento de energia e a sua relevância para mitigar a intermitência de fontes renováveis, além de práticas como Demand Response, que equilibram a oferta e a procura, maximizando a flexibilidade e a estabilidade do sistema elétrico. As inovações tecnológicas analisadas neste trabalho demonstram o potencial da IA e de sistemas avançados para superar desafios e transformar a gestão energética, alinhando-a com as metas globais de sustentabilidade.

Palavras-chave: Comunidades Energéticas, Eficiência Energética, Gestão Energética, Inteligência Artificial, Redes Inteligentes, Sustentabilidade.

Abstract

This study aims to explore the role of Artificial Intelligence (AI) in energy management, highlighting its contribution to sustainability and efficiency in the sector. The growing demand for energy and the challenges associated with climate change make it urgent to adopt advanced technologies that optimize the use of energy resources and reduce environmental impacts.

AI, combined with machine learning, deep learning, and optimization algorithms, enables accurate consumption forecasts, efficient integration of renewable energy sources, and automation of processes in smart grids.

The study also addresses the role of Energy Communities as decentralized solutions that promote the production, consumption, and storage of renewable energy at the local level. These communities, supported by tools such as blockchain and smart contracts, foster transparency and democratization in the energy sector.

Additionally, methods of energy storage and their relevance in mitigating the intermittency of renewable sources are discussed, along with practices like Demand Response, which balance supply and demand while maximizing flexibility and stability in the electrical system. The technological innovations analyzed in this study demonstrate the potential of AI and advanced systems to overcome challenges and transform energy management, aligning it with global sustainability goals.

Keywords: Artificial Intelligence, Energy Communities, Energy Efficiency, Energy Management, Smart Grids, Sustainability.

Agradecimentos

Gostaria de manifestar o meu sincero agradecimento ao meu orientador, Pedro Faria, pelo constante apoio e pela orientação essencial ao longo desta jornada. Estendo também o meu reconhecimento ao coorientador, Daniel Ramos, cujo suporte técnico foi fundamental para o desenvolvimento deste trabalho. A troca de conhecimentos e a cooperação foram determinantes para que eu pudesse superar desafios e evoluir continuamente.

Também sou grato à minha família, que sempre encorajaram-me a seguir firme nos meus propósitos e a manter o foco, mesmo diante dos desafios.

Conteúdo

Declaração de Integridade	iii
Lista de Figuras	xiii
Lista de Tabelas	xv
Lista de Equações	xvii
Lista de Acrónimos	xix
Lista de Símbolos	xxiii
1 Introdução	1
1.1 Contexto e importância da gestão de energia	2
1.2 O papel da IA na otimização de recursos energéticos em edifícios	2
1.3 Justificação de IA na gestão energética	3
1.4 Objectivos da Dissertação	4
1.5 Colaboração Institucional	4
1.6 Estrutura da Dissertação	4
2 Estado da arte	5
2.1 Regras das Comunidades de Energia em Portugal	6
2.2 Gestão e Inovação Energética: Demand Response, Armazenamento e Comunidades	7
2.3 Inovações Tecnológicas: ML, Blockchain e Simulação	11
2.3.1 Métodos de Inteligência Artificial	13
2.3.2 Erros de Previsão	16
2.4 Comunidades: Desafios, Benefícios	19
3 Metodologias e Comunidades Energéticas	23
3.1 Metodologias	23
3.1.1 Estrutura da Metodologia	23
3.1.2 Etapas do Processo Metodológico	24
Tratamento de Dados	24
Escolha de Modelos de IA	24
Treino e Teste	24
Avaliação de Desempenho	25

Interpretação dos Resultados dos Modelos	25
Análise e Apresentação dos Resultados	25
Ferramentas Utilizadas	25
3.2 Comunidades Energéticas	25
4 Resultados e Discussão	27
4.1 Análise do Dataset	28
4.2 Apresentação dos Resultados	29
4.2.1 80% Treino e 20% Teste	30
4.2.2 60% Treino e 40% Teste	34
4.2.3 40% Treino e 60% Teste	39
4.2.4 29 Dias de Treino e 1 Dia de Teste	44
4.3 Análise e Interpretação dos Resultados	50
4.3.1 Impacto das Variáveis	50
4.3.2 Comparação entre Modelos	50
4.3.3 Treinos & Testes	51
4.3.4 Considerações Finais	51
4.4 Valores das Métricas de Erro de Previsão	51
4.5 Comparação com a Literatura	52
4.6 Implicações dos Resultados	52
5 Conclusão	55
Bibliografia	57
Apêndice A: Gestão e Inovação Energética.	61
Apêndice B: Inovações Tecnológicas	68
Apêndice C: Benefícios Comunitários, Custos de Implementação e Previsões.	72

Lista de Figuras

2.1	Distributed ERM (Ylä-Mononen, 2023)	10
2.2	AI (Khan, 2023)	12
4.1	Percentagem Previsão 80% Treino 20% Teste	30
4.2	Correlação LastDayRate - Availability 80% Treino 20% Teste.PNG	31
4.3	Análise LIME com KNN 80% 20% (1º período 15 min.)	31
4.4	Análise LIME com KNN 80% 20% (2º período 15 min.)	32
4.5	Análise LIME com KNN 80% 20% (3º período 15 min.)	32
4.6	Análise LIME com XGB 80% 20% (1º período 15 min.)	33
4.7	Análise LIME com XGB 80% 20% (2º período 15 min.)	33
4.8	Análise LIME com XGB 80% 20% (3º período 15 min.)	34
4.9	Percentagem Previsão 60% Treino 40% Teste	35
4.10	Correlação LastDayRate - Availability 60% Treino 40% Teste.PNG	35
4.11	Análise LIME com KNN 60% 40% (1º período 15 min.)	36
4.12	Análise LIME com KNN 60% 40% (2º período 15 min.)	36
4.13	Análise LIME com KNN 60% 40% (3º período 15 min.)	37
4.14	Análise LIME com XGB 60% 40% (1º período 15 min.)	38
4.15	Análise LIME com XGB 60% 40% (2º período 15 min.)	38
4.16	Análise LIME com XGB 60% 40% (3º período 15 min.)	39
4.17	Percentagem Previsão 40% Treino 60% Teste	40
4.18	Correlação LastDayRate - Availability 40% Treino 60% Teste.PNG	40
4.19	Análise LIME com KNN 40% 60% (1º período 15 min.)	41
4.20	Análise LIME com KNN 40% 60% (2º período 15 min.)	41
4.21	Análise LIME com KNN 40% 60% (3º período 15 min.)	42
4.22	Análise LIME com XGB 40% 60% (1º período 15 min.)	42
4.23	Análise LIME com XGB 40% 60% (2º período 15 min.)	43
4.24	Análise LIME com XGB 40% 60% (3º período 15 min.)	43
4.25	Períodos de Análise	44
4.26	Percentagem Previsão 29 Dias Treino 1 Dia Teste	45
4.27	Correlação LastDayRate - Availability 29 Dias Treino 1 Dia de Teste.	46
4.28	Análise LIME com KNN de 29 dias treino 1 dia teste (44º período 15 min.)	46
4.29	Análise LIME com KNN de 29 dias treino 1 dia teste (47º período 15 min.)	47
4.30	Análise LIME com KNN de 29 dias treino 1 dia teste (48º período 15 min.)	48
4.31	Análise LIME com XGB de 29 dias treino 1 dia teste (44º período 15 min.)	48

4.32	Análise LIME com XGB de 29 dias treino 1 dia teste (47º periodo 15 min.)	49
4.33	Análise LIME com XGB de 29 dias treino 1 dia teste (48º periodo 15 min.)	50

Lista de Tabelas

2.1	Quadro Geral Inteligência Artificial para Gestão Energética	5
2.2	Comparativo entre KNN e XGBoost	15
4.1	Intervalos das variáveis utilizadas no modelo.	28
4.2	Períodos de Análise	44
4.3	Valores das Métricas de Erro de Previsão	51
1	Gestão e Inovação Energética.	61
2	Inovações Tecnológicas.	68
3	Benefícios Comunitários, Custos de Implementação e Previsões.	72

Lista de Equações

2.1	MAE	16
2.2	RMSE	16
2.3	MAPE	17
2.4	wMAPE	18
2.5	SMAPE	18
2.5	SMAPE Reformulado	19

Lista de Acrónimos

ABC	<i>Artificial Bee Colony.</i>
ACO	<i>Ant Colony Optimization.</i>
AI	<i>Artificial Intelligence.</i>
AMI	<i>Advanced Metering Infrastructure.</i>
ANFIS	<i>Adaptive Neuro-Fuzzy Inference System.</i>
ANN	<i>Artificial Neural Network.</i>
ARIMA	<i>Autoregressive Integrated Moving Average.</i>
BANN	<i>Broad Area Neural Network.</i>
BEMS	<i>Building Energy Management System.</i>
BESS	<i>Battery Energy Storage System.</i>
BFO	<i>Bacterial Foraging Optimization.</i>
BPNN	<i>Backpropagation Neural Network.</i>
CB	<i>Community Benefit.</i>
CER	<i>Comunidades de Energia Renovável.</i>
CNN	<i>Convolutional Neural Network.</i>
CPLEX	<i>IBM CPLEX (software Optimization Studio).</i>
DBRNN	<i>Deep Bidirectional Recurrent Neural Network.</i>
DER	<i>Distributed Energy Resources.</i>
DERMS	<i>Distributed Energy Resource Management System.</i>
DGEG	<i>Direção-Geral de Energia e Geologia.</i>
DL	<i>Deep Learning.</i>
DLT	<i>Distributed Ledger Technology.</i>
DNN	<i>Deep Neural Network.</i>
DO	<i>Demand Optimization.</i>
DP	<i>Demand Prediction.</i>
DR	<i>Demand Response.</i>
DRL	<i>Deep Reinforcement Learning.</i>
DWT	<i>Discrete Wavelet Transform.</i>
EC	<i>Energy Community.</i>

EL	<i>Energy Label.</i>
ELM	<i>Extreme Learning Machine.</i>
EMM	<i>Energy Management Module.</i>
EMS	<i>Energy Management System.</i>
EP	<i>EnergyPlus.</i>
ER	<i>Energy Resources.</i>
ERM	<i>Energy Resource Management.</i>
ESS	<i>Energy Storage System.</i>
ETD-DBRNN	<i>Electricity Theft Detection using Deep Bidirectional Recurrent Neural Network.</i>
FF-DNN	<i>Feed-Forward Deep Neural Network.</i>
GA	<i>Genetic Algorithm.</i>
GAMS	<i>General Algebraic Modeling System.</i>
GBDT	<i>Gradient Boosting Decision Tree.</i>
GBM	<i>Gradient Boosting Machine.</i>
GMDHNN	<i>Group Method of Data Handling Neural Network.</i>
HEMS	<i>Home Energy Management Systems.</i>
HISIMI	<i>Historical Similar Mining.</i>
HMM	<i>Hidden Markov Model.</i>
HOMER	<i>Hybrid Optimization Model for Electric Renewables.</i>
HVAC	<i>Heating, Ventilation, and Air Conditioning.</i>
IACA	<i>Intelligent Advanced Control Algorithm.</i>
IMM	<i>Intermediate Monitor Meter.</i>
IOE	<i>Internet of Energy.</i>
IOT	<i>Internet of Things.</i>
IPFs	<i>Inter Planetary File System.</i>
ISOA	<i>Improved Snake Optimization Algorithm.</i>
IVNS	<i>Improved Version of the Variable Neighborhood Search.</i>
KNN	<i>K-Nearest Neighbors.</i>
LIME	<i>Local Interpretable Model-agnostic Explanations.</i>
LP	<i>Linear Programming.</i>
LSTM	<i>Long Short-Term Memory.</i>

MAE	<i>Mean Absolute Error.</i>
MAPE	<i>Mean Absolute Percentage Error.</i>
MAS	<i>Multi-Agent Systems.</i>
MATLAB	<i>MATrix LABoratory.</i>
MDP	<i>Markov Decision Process.</i>
MGWO	<i>Management System for SPV-based Microgrid.</i>
ML	<i>Machine Learning.</i>
MPC	<i>Model Predictive Control.</i>
NB	<i>Naïve Bayes.</i>
NLP	<i>Nonlinear Programming.</i>
NN	<i>Neural Network.</i>
NPV	<i>Net Present Value.</i>
P2P	<i>Peer-To-Peer.</i>
PCA	<i>Principal Component Analysis.</i>
PSO	<i>Particle Swarm Optimization.</i>
RBF	<i>Radial Basis Function.</i>
RL	<i>Reinforcement Learning.</i>
RMSE	<i>Root Mean Square Error.</i>
RNN	<i>Recurrent Neural Networks.</i>
RTP	<i>Real-Time Pricing.</i>
SA	<i>Simulated Annealing.</i>
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average.</i>
SIES	<i>Smart Integrated Energy System.</i>
SMAPE	<i>Symmetric Mean Absolute Percentage Error.</i>
SOM	<i>Self-Organising Map.</i>
SVM	<i>Support Vector Machine.</i>
SVR	<i>Support Vector Regression.</i>
TDNN	<i>Time Delay Neural Network.</i>
TRNSYS	<i>Transient System Simulation Software.</i>
TS	<i>Tabu Search.</i>
WT	<i>Wavelet Transform.</i>
XAI	<i>Explainable Artificial Intelligence.</i>
XGBoost	<i>Extreme Gradient Boosting.</i>

Lista de Símbolos

t	time	s
V	voltage	V
I	electric current	A
R	electrical resistance	Ω
T	temperature	$^{\circ}\text{C}$
L	load	kW

Capítulo 1

Introdução

A *Inteligência Artificial* (IA) ou *Artificial Intelligence* (AI) tem-se afirmado como um componente essencial na modernização da gestão energética, especialmente num contexto de crescente preocupação com a sustentabilidade e eficiência energética. Estudos recentes sublinham que a integração de IA permite otimizar o uso de recursos, prever padrões de consumo e mitigar os impactos ambientais através de soluções avançadas de previsão e planeamento (Ramli e Boucekara H.R.E.H. 2020).

Conforme destacado por (Nabavi, Motlagh N.H. e Zaidan M.A. 2021) as tecnologias baseadas em deep learning têm demonstrado ser particularmente eficazes na modelação de edifícios inteligentes, ao analisar variáveis como padrões de consumo, geração de energias renováveis, condições climáticas e custos de eletricidade. Estas metodologias não só aumentam a precisão na previsão da procura e oferta de energia, como também permitem reduzir em 84% a dependência da rede elétrica em cenários de simulação (Nabavi, Motlagh N.H. e Zaidan M.A. 2021). Por outro lado, (Ramli e Boucekara H.R.E.H. 2020) abordam os desafios associados ao agendamento e à gestão de recursos energéticos distribuídos em redes inteligentes. A aplicação de algoritmos avançados, como a otimização de vizinhança variável *Improved Version of the Variable Neighborhood Search* (IVNS), revela-se crucial para enfrentar problemas complexos, como a integração de fontes renováveis intermitentes, veículos elétricos e gestão de armazenamento de energia. Este método permite minimizar os custos operacionais e melhorar a confiabilidade dos sistemas energéticos, evidenciando o potencial da IA na gestão de recursos energéticos em grande escala (Ramli e Boucekara H.R.E.H. 2020). Estas abordagens inovadoras alinham-se com o objetivo deste documento, que visa fornecer uma metodologia para projetos de investigação no âmbito do Mestrado em Energias Sustentáveis. A inclusão de normas de formatação e orientações técnicas no desenvolvimento de projetos assegura que as investigações futuras possam explorar e aplicar as tecnologias discutidas para promover uma transição energética sustentável e eficiente.

1.1 Contexto e importância da gestão de energia

A gestão energética tornou-se uma prioridade estratégica nos últimos anos, perante o aumento constante da procura de energia e os desafios associados à sustentabilidade ambiental e eficiência económica (Binyamin, Ben Slama S. e Zafar B. 2024). O aumento da população mundial, a urbanização e a cada vez mais intensa atividade industrial, têm levado a um aumento na procura de energia, que consequentemente está a colocar uma pressão sobre os recursos naturais e na rede de infraestrutura de produção e distribuição de energia. Este aumento na procura destaca a relevância de uma gestão eficiente da energia, de forma a satisfazer as necessidades atuais sem comprometer a capacidade das gerações futuras de atender às suas próprias exigências (Contzen 2024). Para a Europa a transição para um sistema energético mais sustentável é uma prioridade estratégica. A dependência de fontes de energia fósseis não só aumenta a vulnerabilidade dos países a flutuações de preço e à instabilidade de mercados globais, como também contribui significativamente para as emissões de gases com efeito de estufa, agravando as alterações climáticas (Xiang, Chen Y. e Xu J. 2022). A gestão de energia, que inclui desde o planeamento do consumo até à adoção de tecnologias mais limpas e eficientes, deve ser vista como um meio para reduzir a pegada ambiental e melhorar a segurança energética. Novas possibilidades para uma gestão de energia mais eficaz é a introdução da inteligência artificial. Com a IA podemos prever padrões de consumo, otimizar processos de distribuição e maximizar o uso de fontes renováveis, ajustando em tempo real a oferta de energia de acordo com a procura (Draz, Ashraf H. e Makeen P. 2024). Deste modo, a IA desempenha um papel fundamental na criação de uma gestão de energia mais sustentável, eficiente e económica, promovendo a redução de desperdício energético e a minimização de custos operacionais. Neste cenário, a gestão de energia assume um papel crucial, não só na proteção ambiental, mas também no reforço da resiliência económica e na promoção da eficiência, tanto a nível nacional como global. A implementação de tecnologias inovadoras e a constante otimização dos recursos energéticos são passos chave para enfrentar os desafios atuais e construir um futuro energético mais sustentável.

1.2 O papel da IA na otimização de recursos energéticos em edifícios

A Inteligência Artificial desempenha, atualmente, um papel fundamental na otimização de recursos energéticos em edifícios, deste modo contribui significativamente para a eficiência e sustentabilidade dos mesmos. Como resposta às crescentes exigências ambientais e económicas, a IA oferece soluções avançadas para monitorizar, prever e ajustar o consumo de energia de maneira adaptativa permitindo reduzir o desperdício e maximizar a eficiência energética (Al-Ghaili, Ibrahim Z.B. e Bakar A.A. 2023). Com a integração de algoritmos de machine learning, análise preditiva e processamento em tempo real, torna-se possível desenvolver sistemas que ajustam automaticamente o uso de energia nos edifícios, ajustando-se a fatores como a ocupação, as condições climáticas e o período do dia. Estes sistemas inteligentes conseguem, por exemplo, fazer a gestão da iluminação, climatização e da ventilação, criando um ambiente confortável, saudável e sustentável, com menores custos operacionais (Ramli e Boucekara H.R.E.H. 2020).

Além disso, a IA possibilita a integração dos edifícios com redes elétricas inteligentes e fontes de energia renovável, desta forma o consumo é otimizado de acordo com a produção de energia renovável e com as flutuações do mercado. Ao prever padrões de utilização e ao adaptar o consumo a condições externas, a IA permite que os edifícios sejam energeticamente eficientes e preparados para um futuro sustentável. Neste contexto, o presente trabalho propõe-se a explorar as aplicações da IA na gestão e otimização de recursos energéticos em edifícios, com especial atenção à análise de modelos e algoritmos que melhor contribuam para a eficiência e sustentabilidade. Pretende-se assim investigar abordagens inovadoras, propor soluções viáveis para a gestão energética no sector da construção, alinhadas com as metas ambientais e de eficiência estabelecidas globalmente (Umar, Kumar D. e Ghose T. 2024).

1.3 Justificação de IA na gestão energética

A integração de técnicas de Inteligência Artificial na gestão de energia tem vindo a revelar-se uma mais-valia no desenvolvimento de soluções inovadoras que promovem a sustentabilidade, a eficiência e a autonomia dos sistemas energéticos. Estas abordagens permitem automatizar processos, antecipar padrões de consumo com elevada precisão e otimizar a utilização de fontes renováveis, assumindo um papel central no actual cenário de transição energética.

Entre as várias técnicas disponíveis, os algoritmos de *Machine Learning* (ML), como o *K-Nearest Neighbors* (KNN) e o *Extreme Gradient Boosting* (XGBoost), destacam-se pela sua eficácia na criação de modelos para previsão de consumo. O desempenho destes modelos é geralmente avaliado através de métricas de erro reconhecidas, como o *Mean Absolute Error* (MAE), *Root Mean Square Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) e *Symmetric Mean Absolute Percentage Error* (SMAPE).

Por outro lado, ferramentas de interpretabilidade como o *Local Interpretable Model-agnostic Explanations* (LIME) são fundamentais para compreender os resultados gerados, permitindo analisar o peso de cada variável e tomar decisões mais fundamentadas. Diferentes quantidades de dados para treino e teste ajudam a perceber como os modelos funcionam e a sua aplicabilidade em cenários reais.

Estas metodologias revelam-se especialmente úteis na gestão energética de edifícios inteligentes e comunidades locais de energia, onde a aplicação de IA pode trazer benefícios concretos, tais como:

- Redução de desperdícios energéticos;
- Diminuição dos custos operacionais;
- Aumento da eficiência e do conforto dos utilizadores;
- Integração mais eficaz de fontes de energia renovável;
- Maior autonomia nos sistemas de energia;

- Promoção da sustentabilidade a nível local e regional.

A adoção destas estratégias permite o desenvolvimento de soluções práticas, escaláveis e ajustadas aos desafios atuais, contribuindo para uma gestão energética alinhada com os objetivos de descarbonização, eficiência e resiliência (Khan, Saleh A.M. e Waseem M. 2023).

1.4 Objectivos da Dissertação

O objetivo principal desta dissertação é demonstrar como a IA pode contribuir para a otimização do uso de recursos energéticos, a previsão de padrões de consumo e a mitigação dos impactos ambientais através de soluções avançadas de previsão e planeamento. Para alcançar este objetivo geral, a dissertação propõe-se a:

- Diminuir o desperdício energético.
- Reduzir os custos operacionais.
- Promover a autonomia total de todos os sistemas de gestão de energia.

1.5 Colaboração Institucional

Esta dissertação foi desenvolvida no âmbito do Mestrado em Energias Sustentáveis do Instituto Superior de Engenharia do Porto (ISEP), em colaboração com o GECAD — Grupo de Investigação em Engenharia e Computação Inteligente para a Inovação e o Desenvolvimento. Esta colaboração possibilitou o acesso a dados reais, ferramentas analíticas e orientação especializada, elementos que foram fundamentais para o desenvolvimento e validação dos métodos aplicados neste trabalho.

1.6 Estrutura da Dissertação

A presente dissertação está organizada em cinco capítulos. O Capítulo 1 introduz o tema, enquadra a importância da gestão energética e define os objetivos do trabalho. O Capítulo 2 apresenta uma revisão do estado da arte, contemplando as principais abordagens tecnológicas e tendências na aplicação da Inteligência Artificial ao setor energético. O Capítulo 3 descreve a metodologia adotada e o conceito de comunidades energéticas. O Capítulo 4 apresenta os resultados experimentais, acompanhados de análise crítica e discussão. Por fim, o Capítulo 5 conclui o trabalho, destacando os principais contributos e propondo linhas de investigação futura.

Capítulo 2

Estado da arte

Nesta secção procede-se a uma análise exaustiva do estado da arte, centrando-se nas principais tendências e desenvolvimentos relacionados com a flexibilidade na gestão da energia. Serão abordados os avanços tecnológicos mais significativos, bem como as estratégias inovadoras implementadas para ultrapassar os desafios actuais do sector energético. Adicionalmente, enfatiza-se a aplicação de soluções tecnológicas avançadas que têm vindo a consolidar-se como ferramentas essenciais para otimizar a eficiência, sustentabilidade e resiliência dos sistemas energéticos. Este panorama pretende fornecer uma base sólida para a compreensão do contexto presente e das perspetivas futuras no domínio da gestão energética flexível.

Entre os tópicos destacados encontram-se *Demand Response* (DR), *Energy Community* (EC), *Energy Resource Management* (ERM) e *Energy Storage System* (ESS), cruciais para enfrentar os desafios de eficiência e sustentabilidade energética, a tabela 2.1 faz o resumo da integração de várias tecnologias com as necessidades da comunidade.

TABELA 2.1: Quadro Geral Inteligência Artificial para Gestão Energética

[Ref.]	Ano	Topics				Techniques			Problems		
		Demand Response Flexibility	Energy Community	Energy Resource Management	Energy Storage	Machine Learning Deep Learning	Simulation Tools	Blockchain	Community Benefit	Cost of Implementation	Forecast
Khan et al.	2023	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
Ali et al.	2023	✓	X	X	✓	✓	✓	X	✓	X	✓
Umar et al.	2024	✓	✓	X	✓	X	✓	✓	✓	✓	X
Ramli & Beuchekara	2020	✓	X	✓	✓	X	X	X	X	X	X
Todorean et al.	2023	X	✓	X	✓	X	X	✓	✓	X	X
Giglio et al.	2023	✓	✓	✓	✓	✓	X	X	X	✓	✓
Nabavi et al.	2021	✓	X	X	✓	✓	✓	X	X	✓	✓
Al-Ghaili et al.	2023	✓	X	X	✓	✓	✓	X	X	X	✓
Parvin et al.	2021	✓	X	X	✓	✓	✓	✓	X	X	✓
Kumar Maurya & Howard	2024	✓	X	✓	✓	✓	X	X	X	X	✓
Binjamin et al.	2024	✓	✓	X	✓	✓	✓	✓	✓	X	✓
Conte et al.	2022	X	✓	X	✓	✓	X	✓	✓	X	✓
Ahmed et al.	2024	X	X	X	X	✓	✓	✓	X	X	✓
Xiang et al.	2022	X	X	X	X	✓	✓	X	X	X	X
Draz et al.	2024	X	X	X	✓	✓	✓	X	X	✓	X
Parada Contzen	2024	X	X	X	✓	X	✓	X	X	X	X
Zhu et al.	2024	✓	X	✓	✓	✓	X	X	✓	X	✓
Reka et al.	2024	✓	X	X	X	✓	✓	X	X	X	✓
Antonopoulos et al.	2020	✓	X	X	✓	✓	✓	X	X	X	✓
Bennagi et al.	2024	X	✓	X	✓	✓	✓	X	X	X	✓
Diário da República	2019	✓	✓	✓	✓	X	X	X	X	X	X
Diário da República	2022	✓	✓	✓	✓	X	X	X	X	X	X

Um dos principais tópicos abordados é DR, que surge como foco em várias referências. Artigos como os (Khan, Saleh A.M. e Waseem M. 2023) e (Ali, Sulaima M.F. e Razak I.A.W.A 2023) mostram

uma forte relação entre esta flexibilidade e o uso em áreas como ML, *Deep Learning* (DL) e ferramentas como o Simulation Tools, destacando a relevância de métodos preditivos e simulações na otimização da resposta à procura em redes elétricas inteligentes. Energy Community e Energy Resource Management também são temas centrais. No trabalho de (Umar, Kumar D. e Ghose T. 2024), evidencia-se o papel das comunidades energéticas na descentralização da geração e armazenamento de energia, suportadas por técnicas como Blockchain e estratégias avançadas de armazenamento. A correlação entre estas tecnologias demonstra que soluções baseadas em inteligência artificial são promissoras para equilibrar eficiência operacional e previsibilidade de consumo. Comparando os artigos, (Khan, Saleh A.M. e Waseem M. 2023) destaca-se por abordar todos os tópicos e técnicas mencionados, apresentando um estudo mais abrangente. Por outro lado, (Ali, Sulaima M.F. e Razak I.A.W.A 2023) adota uma abordagem mais limitada, excluindo o armazenamento de energia, enquanto (Umar, Kumar D. e Ghose T. 2024) aprofunda-se na implementação prática em comunidades energéticas. Da análise da tabela 2.1 os autores (Al-Ghaili, Ibrahim Z.B. e Bakar A.A. 2023) (Kumar e Howard E. 2024) (Zhu, Chen S. e Liang X. 2024) (Reka, Dragicevic T. e Venugopal P. 2024) (Antonopoulos, Robu V. e Couraud B. 2020) apenas fazem referência a Demand Response Flexibility nunca abordando o tema da energy community. Em contrapartida os artigos de (Ahmed, Dubey M. e Kumar A. 2024) e (Todorean, Chifu V.R. e Cioara T. 2023) apenas abordam temas relacionados com blockchain.

2.1 Regras das Comunidades de Energia em Portugal

As *Comunidades de Energia Renovável* (CER) em Portugal são regulamentadas pelo Decreto-Lei n.º 162/2019, de 25 de outubro (República 2019) como parte da estratégia nacional para promover a transição energética sustentável e atingir as metas de energia renovável estabelecidas para 2030. As CER são definidas como pessoas coletivas que podem ser formadas por cidadãos, empresas ou instituições públicas, organizadas com adesão aberta e voluntária. Estas comunidades têm como objetivo principal gerar benefícios ambientais, sociais e económicos para os seus membros e para as comunidades locais, colocando em segundo plano a obtenção de lucros financeiros.

As CER têm o direito de produzir, consumir, armazenar e vender energia renovável, além de compartilhar a energia gerada entre os seus membros. Estas comunidades podem aceder diretamente aos mercados de energia ou fazê-lo através de fornecedores, assegurando que participam de forma equitativa e eficiente. A autonomia de gestão é um elemento essencial das CER, sendo que os membros mantêm o controlo sobre as operações e a responsabilidade de assegurar o equilíbrio no sistema elétrico nacional, ajustando desvios que possam ocorrer. Do ponto de vista técnico, as CER devem cumprir os requisitos aplicáveis às unidades de produção para autoconsumo, como registo ou licenciamento, dependendo da potência instalada. Os sistemas de contagem de energia utilizados devem ser precisos e garantir transparência na distribuição da energia produzida, incluindo os excedentes injetados na rede pública. Esses sistemas garantem que a energia seja partilhada de forma justa e que os custos associados sejam devidamente

repartidos.

Além disso, as CER assumem um papel inclusivo, promovendo a participação de consumidores domésticos, incluindo famílias de baixos rendimentos ou em situação de vulnerabilidade. O governo procura facilitar o acesso a instrumentos de financiamento e informações que suportem a constituição e o funcionamento destas comunidades. As autoridades públicas também contam com apoio regulatório para participar diretamente ou fomentar a criação de CER, reforçando o impacto social e económico desta iniciativa.

As CER têm a responsabilidade de contribuir de forma proporcional para os custos do sistema elétrico, assumindo encargos ajustados aos custos e que assegurem a sustentabilidade financeira a longo prazo. São igualmente responsáveis pela disponibilização de dados técnicos e operacionais, enquanto a *Direção-Geral de Energia e Geologia* (DGEG) acompanha o desenvolvimento das CER e apresenta propostas para superar barreiras administrativas ou regulamentares.

Esta regulamentação sublinha o papel fundamental das CER na promoção da descarbonização, na diminuição da dependência energética e na criação de emprego local. Para além disso, reforçam a coesão social, reduzem desigualdades e fortalecem as comunidades locais, posicionando Portugal como uma referência na implementação de políticas energéticas sustentáveis alinhadas com os objetivos europeus.

Importa referir que o Decreto-Lei n.º 162/2019 foi revogado pelo Decreto-Lei n.º 15/2022 (República 2022), de 14 de janeiro, que veio atualizar e consolidar o regime jurídico aplicável às comunidades de energia renovável. Este novo diploma reforça a aposta na transição energética, garantindo um enquadramento mais abrangente e adaptado às necessidades atuais do setor energético, mantendo as CER como um elemento central na promoção de fontes renováveis e na descentralização da produção de energia.

2.2 Gestão e Inovação Energética: Demand Response, Armazenamento e Comunidades

A evolução das tecnologias energéticas tem promovido avanços significativos em áreas como Demand Response, comunidades de energia, gestão de recursos energéticos e armazenamento de energia (Khan, Saleh A.M. e Waseem M. 2023). A gestão do consumo destaca-se por integrar fontes renováveis, reduzir custos operacionais e melhorar a estabilidade da rede elétrica. Já as comunidades de energia enfrentam desafios, como a necessidade de infraestrutura tecnológica avançada, plataformas de gestão baseadas em IA e a sensibilização de membros para mudanças de hábitos (Giglio, Luzzani G. e Terranova V. 2023). Na gestão de recursos, os principais benefícios incluem eficiência energética, sustentabilidade e maior confiabilidade dos sistemas. O armazenamento de energia, por sua vez, é essencial para a integração com fontes renováveis, suporte à flexibilidade da rede e redução de custos. Apesar dos desafios, como custos iniciais

e complexidade técnica, essas iniciativas representam passos importantes para redes mais eficientes, sustentáveis e resilientes, permitindo maior participação em mercados de energia e uma transição energética eficaz (Binyamin, Ben Slama S. e Zafar B. 2024).

A tabela 1 apresenta um resumo dos principais conceitos, benefícios e desafios relacionados à evolução das tecnologias energéticas, como Demand Response, comunidades de energia, gestão de recursos e armazenamento de energia.

A Demand Response é uma prática inovadora e eficaz para equilibrar a oferta e a procura no setor energético, desempenhando um papel crucial em sistemas de energia cada vez mais descentralizados e integrados a fontes renováveis. Esta abordagem possibilita aos consumidores ajustarem os seus padrões de consumo em função de incentivos financeiros ou de preços dinâmicos, promovendo assim uma maior flexibilidade e eficiência na operação do sistema elétrico (Ali, Sulaima M.F. e Razak I.A.W.A 2023).

A DR consiste essencialmente em dois modelos:

- Programas baseados em preços, que incentivam os consumidores a ajustar o consumo de energia conforme variações tarifárias, como preços em tempo real ou períodos tarifários específicos. Esses programas são comuns em mercados mais experientes que incentivam uma gestão proativa do consumo.
- Programas baseados em incentivos que oferecem recompensas financeiras aos consumidores por reduzir ou deslocar o consumo em horários críticos, geralmente sob solicitação direta de operadores do sistema.

Ambos os modelos contribuem para evitar sobrecargas no sistema, reduzir custos operacionais e melhorar a confiabilidade do fornecimento de energia. A DR é particularmente eficaz em sistemas que integram recursos energéticos distribuídos *Distributed Energy Resources* (DER) e fontes renováveis intermitentes, como solar e eólica. Ao flexibilizar o consumo, a DR reduz os efeitos da variabilidade dessas fontes, reduz a necessidade de investimentos em infraestrutura e diminui o uso de centrais de reserva, que frequentemente utilizam combustíveis fósseis.

Existem diversos setores em que a DR é usada:

- Residencial: Consumidores são incentivados a adiar o uso de aparelhos de alta potência para horários fora de pico.
- Comercial e industrial: Grandes consumidores ajustam suas operações para atender a procuras específicas, contribuindo de forma significativa para a estabilidade do sistema elétrico.
- Comunidades de energia: Participantes colaboram para equilibrar localmente a oferta e a procura de energia, com apoio de tecnologias como blockchain para gestão de transações P2P (Umar, Kumar D. e Ghose T. 2024).

Os progressos em áreas como a Inteligência Artificial e a blockchain tem impulsionado a evolução da implementação da DR. As tecnologias desenvolvidas no âmbito da Inteligência Artificial permitem antever padrões de consumo e produção com maior precisão, enquanto os desenvolvimentos na área da blockchain promovem a automatização e a segurança das transações energéticas. Estas inovações contribuem para tornar os programas de DR mais eficientes e acessíveis, incentivando uma maior adesão por parte dos consumidores e aumentando a eficácia dos sistemas energéticos (Binyamin, Ben Slama S. e Zafar B. 2024).

Apesar de seus benefícios, crescente procura por soluções sustentáveis, enfrenta desafios como a necessidade de ampla adesão dos consumidores, investimentos iniciais em infraestrutura da rede elétrica e integração com tecnologias existentes. No entanto, o crescente interesse em políticas de sustentabilidade e a evolução tecnológica oferecem um futuro promissor para a expansão da DR em escala global (Khan, Saleh A.M. e Waseem M. 2023).

As comunidades energéticas surgem como uma solução inovadora e eficaz para enfrentar os desafios da transição energética. Estas comunidades permitem que consumidores e prosumers (indivíduos que consomem e produzem energia) colaborem para otimizar a geração, distribuição e consumo de energia a um nível local, promovendo independência energética e sustentabilidade ambiental.

As comunidades energéticas baseiam-se em sistemas descentralizados, onde recursos energéticos distribuídos DER, como painéis solares e baterias, desempenham um papel fundamental. Através de tecnologias como blockchain e contratos inteligentes, essas comunidades facilitam transações de energia *Peer-To-Peer* (P2P), garantindo segurança, transparência e eficiência no comércio de energia (Binyamin, Ben Slama S. e Zafar B. 2024).

No modelo das redes comunitárias, o excesso de energia gerado pelos prosumers pode ser vendido para vizinhos ou injetado na rede elétrica. Esses sistemas utilizam plataformas dinâmicas de gestão de energia, capazes de equilibrar oferta e a procura em tempo real e adaptar preços com base em variações do mercado (Umar, Kumar D. e Ghose T. 2024).

Entre as vantagens das comunidades energéticas, destacam-se:

- **Eficiência Económica:** A possibilidade de comercializar energia localmente reduzindo custos com transmissão e distribuição, beneficiando financeiramente os participantes;
- **Sustentabilidade:** Ao priorizar fontes renováveis e locais, essas comunidades diminuem a pegada de carbono;
- **Autonomia Energética:** A descentralização oferece um maior controlo sobre a geração e consumo de energia;
- **Inclusão Tecnológica:** O uso de inteligência artificial e blockchain facilita a automação e otimização de processos, incentivando a participação ativa dos consumidores.

Embora as comunidades energéticas apresentem um potencial transformador, a sua implementação enfrenta alguns desafios, como os elevados custos iniciais, necessidade de infraestrutura tecnológica robusta e regulação adequada.

A gestão de recursos energéticos ERM desempenha um papel crucial na operação eficiente e sustentável das redes elétricas modernas, especialmente com a crescente integração de fontes de energia renováveis, sistemas de armazenamento e veículos elétricos. O principal objetivo da gestão de recursos energéticos é otimizar o uso de recursos distribuídos, reduzindo custos operacionais e impactos ambientais, enquanto assegura o equilíbrio entre oferta e procura. Para tal, concentra-se em atividades como o planeamento e a programação de recursos a curto e médio prazo, a integração de fontes renováveis e de veículos elétricos na rede, e a redução de desperdícios e emissões de carbono, promovendo uma operação mais sustentável (Kumar e Howard E. 2024).




FIGURA 2.1: Distributed ERM (Ylä-Mononen, 2023)

No entanto, a gestão destes recursos enfrenta desafios significativos, como a intermitência das fontes renováveis, a variabilidade nos padrões de consumo e a complexidade crescente das redes elétricas modernas. Para superar estas dificuldades, o recurso a tecnologias avançadas e algoritmos de otimização tornou-se essencial. Um exemplo relevante é a aplicação de algoritmos meta-heurísticos, como a Busca por Vizinhança Variável Melhorada IVNS, que tem demonstrado grande eficiência na resolução de problemas de grande escala relacionados com a programação de recursos energéticos. Este método distingue-se por normalizar variáveis para assegurar um tratamento equilibrado, reduzir a dimensão dos problemas eliminando variáveis redundantes e utilizar técnicas de procura avançadas para encontrar soluções ótimas que maximizem os lucros e minimizem os custos (Ramli e Boucekara H.R.E.H. 2020).

O armazenamento de energia é essencial para integrar com fontes renováveis, equilibra a oferta, a procura e aumenta a eficiência das redes elétricas modernas. Sistemas como baterias de íons de lítio permitem armazenar energia em que o consumo é baixo ou inexistente para utilizá-la em picos de consumo, mitigando a intermitência de fontes renováveis e reduzindo perdas na transmissão. Em redes inteligentes, o armazenamento facilita a resposta à procura DR e reduz

a necessidade de grandes infraestruturas, promovendo redes descentralizadas mais resilientes. Tecnologias como algoritmos de otimização, incluindo a IVNS, maximizam a eficiência operacional, ajustando a capacidade e os limites de carga e descarga dos sistemas (Draz, Ashraf H. e Makeen P. 2024). O maior dos desafios do armazenamento de energia é o seu alto custo de implementação, contudo os avanços tecnológicos e a queda nos preços das baterias têm impulsionado a adoção desta tecnologia, tornando-a crucial para a transição energética sustentável.

2.3 Inovações Tecnológicas: ML, Blockchain e Simulação

Técnicas de Inteligência Artificial têm desempenhado um papel fundamental na gestão de energia. Áreas como Machine Learning, Deep Learning, e técnicas como *Artificial Neural Network* (ANN) permitem identificar padrões complexos e fazer previsões precisas (Bennagi, AlHousrya O. e Cotfas D.T. 2024).

Os vários autores identificados na tabela 2 fazem referência a métodos de IA, assim como ferramentas de simulação e negociação de preços através de Blockchain.

Abordagens como *Support Vector Machine* (SVM) e *Recurrent Neural Networks* (RNN), incluindo variantes como *Long Short-Term Memory* (LSTM), destacam-se no processamento de séries temporais. Técnicas de otimização baseadas em inteligência coletiva, como *Particle Swarm Optimization* (PSO) e *Ant Colony Optimization* (ACO), são usadas para resolver problemas de alta complexidade. Vários autores como (Khan, Saleh A.M. e Waseem M. 2023) e (Bennagi, AlHousrya O. e Cotfas D.T. 2024) abordam o tema dos *Genetic Algorithm* (GA) e técnicas híbridas, como *Adaptive Neuro-Fuzzy Inference System* (ANFIS), que combinam vantagens de diferentes metodologias. Em simulações, ferramentas como *MATrix LABoratory* (MATLAB), *EnergyPlus* (EP) e *Hybrid Optimization Model for Electric Renewables* (HOMER) auxiliam na validação de modelos. O uso de Smart Contracts e *Distributed Ledger Technology* (DLT) viabiliza sistemas energéticos descentralizados como é identificado no artigo (Parvin, Lipu M.S.H e Hannan M.A. 2021).

A gestão energética, no âmbito das redes inteligentes e dos sistemas de resposta à procura DR, tira partido de várias tecnologias avançadas, com impacto em diversas áreas incluindo inteligência artificial, aprendizagem automática ML, aprendizagem profunda DL, ferramentas de simulação e blockchain. Estas soluções possibilitam a otimização do uso de recursos energéticos, promovem a eficiência e reduzem custos, sendo essenciais para enfrentar os desafios associados à integração de fontes de energia renováveis e à crescente complexidade das redes elétricas.

Estas técnicas são amplamente utilizadas para prever o consumo e os preços de energia, aproveitando métodos como redes neurais artificiais ANN e modelos baseados em árvores de decisão para identificar padrões nos dados e apoiar decisões em tempo real. Relativamente à área de *Reinforcement Learning* (RL) é especialmente eficaz para o controlo de cargas dinâmicas, como exemplo os veículos elétricos, oferecendo soluções escaláveis para gerir dados complexos.

Os algoritmos inspirados na natureza, como GA e os PSO, destacam-se na resolução de problemas de otimização, como o agendamento de cargas e a definição de preços. Paralelamente, as redes




FIGURA 2.2: AI (Khan, 2023)

neurais artificiais, especialmente em arquiteturas de aprendizagem profundo, são fundamentais para prever padrões de consumo e preços, analisando séries temporais e dados complexos (Ali, Sulaima M.F. e Razak I.A.W.A 2023). Os *Multi-Agent Systems* (MAS) são ferramentas essenciais nos mercados de energia, pois permitem automatizar processos, otimizar a distribuição de recursos e definir preços, o que leva a uma maior eficiência e colaboração (Antonopoulos, Robu V. e Couraud B. 2020).

As ferramentas de simulação constituem um elemento crucial na representação matemática de sistemas energéticos, permitindo testar soluções antes da sua implementação. Plataformas baseadas em agentes e nuvens facilitam a integração de dados e a execução de modelos em larga escala, especialmente em cenários complexos envolvendo múltiplos intervenientes. O blockchain surge como uma tecnologia crucial para a gestão energética, garantindo transparência, segurança e eficiência. Contratos inteligentes automatizam transações e a gestão de recursos descentralizados, enquanto a rastreabilidade proporcionada pelo blockchain previne fraudes e facilita a integração com a *Internet of Energy* (IOE). Esta integração permite conectar dispositivos *Internet of Things* (IOT) e fontes de energia diversas, otimizando o consumo e promovendo o uso de energias renováveis (Parvin, Lipu M.S.H e Hannan M.A. 2021). Entre as principais aplicações práticas, destacam-se:

- A previsão de carga e preços, essencial para o planeamento e a operação eficiente das redes;
- A gestão automatizada da procura, que reduz custos e maximiza a flexibilidade do consumo;
- *Energy Management System* (EMS), que utilizam IA para controlar equipamentos e reduzir o

consumo em edifícios inteligentes.

Além disso, técnicas avançadas como redes neurais recorrentes bidirecionais RNN são usadas para detecção de fraudes e perdas técnicas, identificando anomalias e melhorando a segurança das redes.

Em resumo, estas tecnologias transformam a gestão energética ao promoverem maior eficiência, flexibilidade e sustentabilidade, sendo indispensáveis no desenvolvimento de redes elétricas inteligentes e no suporte à transição energética global (Khan, Saleh A.M. e Waseem M. 2023).

2.3.1 Métodos de Inteligência Artificial

No âmbito do desenvolvimento de sistemas inteligentes, a escolha do algoritmo de inteligência artificial mais adequado é um dos fatores determinantes para o sucesso de um modelo preditivo. Entre as diversas abordagens existentes, destacam-se algoritmos com naturezas distintas, como redes neuronais artificiais, métodos baseados em instâncias como o K-Nearest Neighbors (Ramos, Faria P. e Vale Z. 2023), classificadores marginais como o Support Vector Machine e técnicas de ensemble como o XGBoost.

Cada uma destas metodologias possui características próprias em termos de estrutura, capacidade de generalização, desempenho computacional e adequação a diferentes tipos de problemas e conjuntos de dados. Assim, torna-se pertinente realizar uma análise comparativa que permita compreender as suas principais vantagens, limitações e contextos de aplicação ideais.

Nos próximos tópicos, abordaremos os fundamentos de cada algoritmo para facilitar sua avaliação e aplicação em IA:

A) - ANN - Artificial Neural Network

As redes neuronais artificiais ANN são modelos computacionais inspirados na forma como o cérebro humano processa informação. Estas redes são constituídas por várias camadas de unidades interligadas, conhecidas como neurónios artificiais. Cada neurónio recebe dados de entrada, realiza um cálculo simples e transmite o resultado para outros neurónios, permitindo que a informação se propague pela rede.

Este tipo de sistema é particularmente eficaz na detecção de padrões complexos, sendo aplicado em diversas áreas, como o reconhecimento de imagens, a tradução automática, a análise de sentimentos e a previsão de dados ao longo do tempo. O processo de aprendizagem normalmente segue uma abordagem supervisionada: o modelo é alimentado com exemplos, ajustando progressivamente os seus parâmetros internos para reduzir os erros nas previsões. Assim, à medida que treina, a rede torna-se capaz de generalizar e produzir resultados fiáveis com novos dados.

Há várias arquiteturas possíveis dentro deste tipo de redes, destacando-se as redes profundas (DNN), que possuem múltiplas camadas ocultas, as *Convolutional Neural Network* (CNN), frequentemente usadas em visão computacional, e as redes recorrentes, mais indicadas para tratar

sequências, como texto ou áudio. No contexto atual da inteligência artificial, as redes neurais são consideradas uma das tecnologias mais potentes e adaptáveis.

B) - KNN - K-Nearest Neighbors

O KNN é um algoritmo bastante simples e intuitivo, geralmente usado em problemas de classificação, contudo, pode também ser aplicado em problemas de regressão. Ele é amplamente utilizado em modelos supervisionados de previsão e baseia-se na ideia de que exemplos semelhantes estão próximos no espaço das características. Para classificar um novo exemplo, o KNN identifica os 'k' exemplos mais próximos no conjunto de dados de treino — proximidade essa determinada por métricas como a distância euclidiana — e atribui ao novo ponto a classe mais frequente entre esses vizinhos.

Uma particularidade do KNN é que ele não possui um processo de treino propriamente dito: o algoritmo apenas armazena os dados e realiza os cálculos de distância no momento da previsão. Por isso, o KNN é conhecido como um “aprendiz preguiçoso”. Ele é especialmente eficaz em conjuntos de dados de pequena a média dimensão, mas pode tornar-se ineficiente em grandes volumes de dados devido ao custo computacional e à sensibilidade à escala das variáveis. Além disso, a escolha do parâmetro 'k' é fundamental: valores baixos podem levar a sobreajuste, enquanto valores elevados podem suavizar demais as fronteiras de decisão.

C) - SVM – Support Vector Machine

As máquinas de vetores de suporte são algoritmos de desenvolvimento computacional amplamente utilizados em tarefas de classificação e regressão. A sua principal função é encontrar uma fronteira de separação que divida os dados em categorias distintas com a maior margem possível entre elas. Essa fronteira, também chamada de hiperplano, é definida de forma a maximizar a distância entre os pontos de dados mais próximos de cada classe.

Este método é particularmente eficaz em situações em que as classes são bem distintas, e pode ser adaptado para resolver problemas mais complexos através do uso de funções kernel. Estas funções transformam os dados para um espaço dimensional superior, permitindo que o modelo identifique padrões não lineares com maior precisão.

As SVM são conhecidas pela sua robustez em conjuntos de dados com poucas amostras, sendo frequentemente aplicadas em áreas como reconhecimento de texto, detecção de fraudes, diagnóstico médico e análise de sentimentos. Além disso, possuem a vantagem de reduzir o risco de sobreajustamento, especialmente quando comparadas com outros modelos mais complexos.

Em suma, as máquinas de vetores de suporte são uma ferramenta poderosa para análise preditiva, oferecendo bons resultados mesmo em cenários com dados limitados ou de difícil separação.

D) - XGBoost - Extreme Gradient Boosting

O XGBoost é um algoritmo de ensemble baseado em árvores de decisão, concebido para oferecer elevada performance e eficiência. Utiliza o método de boosting de gradiente, no qual várias árvores são construídas sequencialmente. Cada nova árvore é treinada para corrigir os erros cometidos pelas anteriores, resultando num modelo final robusto e preciso.

O XGBoost destaca-se em tarefas de classificação e regressão, sobretudo em conjuntos de dados grandes e complexos, onde existem relações não lineares entre as variáveis. Para além disso, incorpora técnicas de regularização para evitar o sobreajuste, suporta processamento paralelo e lida eficazmente com valores em falta. A sua flexibilidade e desempenho tornaram-no uma escolha recorrente em competições e projectos avançados de ciência de dados.

Na tabela 2.2 é apresentado o comparativo entre os dois algoritmos utilizados no trabalho: **KNN** e **XGBoost**.

TABELA 2.2: Comparativo entre KNN e XGBoost

Critério	KNN	XGBoost	Observações
Tipo de modelo	Baseado em instâncias	Baseado em árvores de decisão	KNN é um algoritmo de aprendizagem tardia, XGBoost é proativo
Período de treino	Baixo	Alto	Apenas XGBoost necessita de treino intensivo.
Tempo de previsão	Alto	Baixo	KNN consulta todo o dataset, XGBoost aplica árvore treinada.
Robustez a dados extremos	Baixa	Alta	Árvores são naturalmente mais robustas
Requisitos de ajuste fino	Baixo	Alto	XGBoost exige tuning de muitos hiperparâmetros
Escalabilidade	Limitada	Alta	XGBoost é mais eficiente em grandes volumes de dados
Interpretabilidade	Média	Média-alta	Ambos oferecem interpretação, mas o XGBoost possui ferramentas específicas.

2.3.2 Erros de Previsão

A análise da performance de modelos preditivos representa uma fase essencial em trabalhos que envolvem modelação estatística ou métodos de previsão. Para avaliar a precisão das estimativas produzidas, é comum a utilização de indicadores que medem o grau de divergência entre os valores reais e os previstos. Entre os indicadores mais frequentemente aplicados destacam-se o Erro Absoluto Médio (MAE - Mean Absolute Error), o Erro Quadrático Médio da Raiz (RMSE - Root Mean Square Error), o Erro Percentual Absoluto Médio (MAPE - Mean Absolute Percentage Error) e o Erro Percentual Absoluto Médio Simétrico (SMAPE - Symmetric Mean Absolute Percentage Error) (Ramos 2020).

O MAE corresponde à média aritmética dos valores absolutos das diferenças entre as observações reais e as previsões. Esta métrica é de fácil interpretação e apresenta-se como uma medida robusta, atribuindo igual peso a todos os erros, independentemente da sua magnitude. No entanto, não considera a escala dos dados, o que pode dificultar a comparação entre diferentes conjuntos ou modelos (Ramos 2020).

$$MAE = \frac{1}{h} * \sum_{t=n-h}^n |A(t) - F(t)| \quad (2.1)$$

- A – Observação atual
- F – Observação de previsão
- n – Número de observações
- h – Estrutura usada para observações
- t – Período

O RMSE, por sua vez, calcula a raiz quadrada da média dos erros ao quadrado, conferindo maior penalização a desvios de maior amplitude. Esta característica torna-o especialmente útil em contextos onde grandes erros são particularmente indesejáveis. Contudo, a sua sensibilidade a outliers pode comprometer a sua utilidade em certos contextos práticos (Ramos 2020).

$$RMSE = \sqrt{\frac{1}{h} * \sum_{t=n-h}^n (A(t) - F(t))^2} \quad (2.2)$$

- A – Observação atual
- F – Observação de previsão
- n – Número de observações
- h – Estrutura usada para observações
- t – Período

O MAPE expressa o erro médio em termos percentuais, permitindo uma interpretação relativa do erro face à magnitude dos valores reais. Esta métrica é amplamente utilizada devido à sua natureza intuitiva e facilidade de comparação entre diferentes séries temporais ou domínios. No entanto, o MAPE apresenta limitações significativas quando os valores reais se aproximam de zero, podendo conduzir a distorções consideráveis ou mesmo a indefinições (Ramos 2020).

$$MAPE = \frac{1}{h} * \sum_{t=n-h}^n \left| \frac{A(t) - F(t)}{A(t)} \right| \quad (2.3)$$

- A – Observação atual
- F – Observação de previsão
- n – Número de observações
- h – Estrutura usada para observações
- t – Período

Para mitigar essas situações de indefinição, foram consideradas várias técnicas:

- A primeira técnica consistia em substituir os valores indefinidos por zero;
- A segunda, em simplesmente, ignorar esses valores.

No entanto, ambas apresentaram limitações, a substituição por zero introduz viés nos resultados, distorcendo a média do erro, enquanto ignorar os valores indefinidos pode levar à perda de informação relevante, comprometendo a representatividade da métrica.

Desta forma, optou-se por uma terceira técnica, pela utilização do WMAPE (Weighted Mean Absolute Percentage Error) Que contorna essas limitações ao ponderar os erros absolutos pela soma dos valores reais. Esta abordagem evita as distorções causadas por valores reais próximos de zero e mantém a capacidade de interpretação percentual, oferecendo uma métrica mais robusta e confiável em contextos onde o MAPE tradicional falha (Ramos 2020).

$$wMAPE = \frac{\sum_{i=1}^n |A_i - F_i|}{\sum_{i=1}^n |A_i|} \quad (2.4)$$

- A_i – Observação atual
- F_i – Observação de previsão
- n – Número de observações
- i – Índice da observação

Com o objetivo de contornar as limitações do MAPE foi utilizado o SMAPE, uma versão simétrica do MAPE que considera a média dos valores absolutos reais e previstos no denominador da fórmula. Esta abordagem confere maior estabilidade e simetria à métrica, reduzindo o impacto de valores extremos ou muito pequenos e proporcionando uma avaliação mais equilibrada do erro percentual (Ramos 2020).

$$SMAPE = \frac{1}{h} * \sum_{t=n-h}^n \frac{|F(t) - A(t)|}{0.5 * (A(t) + F(t))} \quad (2.5)$$

- A – Observação atual
- F – Observação de previsão
- n – Número de observações
- h – Estrutura usada para observações
- t – Período

Contudo, deparamo-nos com a mesma distorção provocada por valores iguais a zero no denominador, o que levou à aplicação das mesmas três técnicas acima referidas para lidar com os casos de indefinição:

A primeira técnica consiste em substituir o valor indefinido por zero;

A segunda técnica consiste na exclusão do valor da análise;

Recorreu-se como terceira opção da fórmula do SMAPE reformulada (Ramos 2020).

- A_t – Observação real
- F_t – Observação de previsão

$$SMAPE = \frac{\sum_{t=1}^n |F_t - A_t|}{\sum_{t=1}^n (A_t + F_t)} \quad (2.6)$$

- n – Número de observações
- t – Período

As duas primeiras técnicas foram descartadas por introduzirem distorções. A substituição de valores indefinidos por zero altera artificialmente o erro médio, enquanto a exclusão desses valores compromete a representatividade dos resultados. Assim, optou-se por utilizar o SMAPE reformulado. Nesta versão, o denominador utiliza a soma total dos valores reais e previstos, em vez da média por observação, o que elimina o risco de divisões por zero e confere maior robustez ao cálculo. Esta abordagem preserva a simetria da métrica e permite uma avaliação percentual estável, mesmo na presença de valores muito baixos ou nulos.

A escolha da métrica de avaliação mais adequada depende do contexto da aplicação, da natureza dos dados e dos objetivos específicos do estudo. Em muitos casos, é recomendável utilizar múltiplas métricas em simultâneo, de modo a obter uma compreensão mais abrangente e rigorosa do desempenho preditivo dos modelos em análise.

2.4 Comunidades: Desafios, Benefícios

O conceito de *Community Benefit* (CB) na gestão energética está intrinsecamente ligado à criação de valor económico, social e ambiental para comunidades que partilham e gerem energia renovável. Este modelo, que tem vindo a ganhar relevância com a expansão das comunidades de energia renovável CER, está alinhado com os objetivos da transição energética global, como a redução das emissões de carbono e o reforço da autossuficiência energética local (Conte, D’Antoni F. e Natrella G. 2022). A Tabela 3 resume os principais desafios encontrados na aplicação dessas tecnologias em comunidades.

A implementação de sistemas de gestão avançados, que integram IA, pode trazer benefícios significativos às comunidades energéticas, tais como:

- Autossuficiência Energética;
- Maior independência da rede elétrica convencional;
- Previsibilidade dos custos a longo prazo;
- Valorização Local: Criação de empregos e desenvolvimento de projetos de energia renovável que fortalecem a economia local;
- Equidade e Inclusão: Mecanismos de distribuição justa de recursos e incentivos que promovem a participação ativa de todos os membros da comunidade.

A integração de tecnologias de Inteligência Artificial em sistemas de gestão energética apresenta diversas vantagens, mas está associada a custos iniciais significativos, que variam conforme a escala e a complexidade do sistema. Esses custos incluem principalmente investimentos em infraestrutura, desenvolvimento de algoritmos personalizados e formação técnica especializada das equipes responsáveis (Zhu, Chen S. e Liang X. 2024).

A modernização das redes elétricas tradicionais para redes inteligentes (Smart Grids) requer a instalação de medidores avançados, *Advanced Metering Infrastructure* (AMI), sensores IOT e dispositivos de monitorização em tempo real. Estes elementos são fundamentais para a recolha de dados detalhados sobre consumo, geração de energia e condições climáticas. Contudo, a implementação de medidores inteligentes representa custos elevados, tanto pela necessidade de compatibilidade com a infraestrutura existente como pela exigência de escalabilidade dos sistemas. Além disso, o desenvolvimento de modelos de IA para prever o consumo, otimizar recursos e analisar a flexibilidade exige um investimento significativo em dados e poder computacional para treinar algoritmos avançados.

Outro fator de custo significativo é a integração de tecnologias de blockchain e contratos inteligentes. Estas ferramentas garantem transparência e confiança nas transações energéticas, mas as redes públicas podem ter custos de transação elevados, enquanto as redes privadas requerem manutenção constante e configurações de segurança robustas. Adicionalmente, os sistemas de IA para gestão energética geram grandes volumes de dados que precisam ser armazenados, processados e protegidos, o que implica custos relevantes associados a serviços na cloud ou em datacenters dedicados à função, particularmente em projetos de grande escala.

Para mitigar estes custos, algumas estratégias podem ser adotadas. Modelos baseados em incentivos, como os programas de resposta à procura (Demand Response), permitem envolver consumidores finais, reduzindo custos operacionais e aumentando a eficiência do sistema. O uso de tecnologias open-source também pode ser uma solução, pois reduz os custos de licenciamento e facilita o desenvolvimento de soluções personalizadas. Além disso, parcerias público-privadas representam uma abordagem eficaz para dividir os custos iniciais de implementação, especialmente em mercados energéticos em transição para redes inteligentes (Khan, Saleh A.M. e Waseem M. 2023).

A previsão (forecasting) é fundamental na gestão energética, permitindo decisões informadas e a otimização de recursos. Com a aplicação de IA, métodos como redes neurais artificiais e DP destacam-se pela sua capacidade de processar grandes volumes de dados e prever consumo, produção renovável e preços de energia. Estes modelos permitem antecipar as procuras em diferentes níveis, desde edifícios individuais até redes comunitárias, otimizando custos e aumentando a eficiência (Ramos, Faria P. e Vale Z. 2024a).

Ao combinar dados históricos e informações sobre o ambiente, podemos prever o consumo de energia e ajustar os preços. Os modelos de preços facilitam a negociação entre produtores e consumidores em mercados de energia flutuantes.

Na produção de renováveis, técnicas como redes neuronais e máquinas de vetores de suporte (SVM) analisam dados climáticos e históricos para prever a produção de energia solar e eólica, lidando com a variabilidade destas fontes. Além disso, a previsão de flexibilidade energética possibilita ajustar geração e consumo, promovendo a integração de renováveis.

Embora promissores, os métodos enfrentam desafios, como a necessidade de dados de alta qualidade e generalização para diferentes contextos. Contudo, avanços em algoritmos e acesso crescente a dados continuam a impulsionar a adoção de forecasting, essencial para uma gestão energética mais sustentável e resiliente.

Capítulo 3

Metodologias e Comunidades Energéticas

Esta dissertação tem como objetivo analisar o papel da Inteligência Artificial na gestão energética, focando na sua contribuição para a sustentabilidade e eficiência no setor. A relevância deste estudo justifica-se pela crescente procura energética e pelos desafios impostos pelas alterações climáticas. O aumento de procura de soluções de energia sustentável ambiental e a eficiência económica, tornou a gestão de energia uma área de interesse fundamental nos últimos anos. A crescente população mundial, a urbanização e a intensificação da atividade industrial têm pressionado os recursos naturais e a infraestrutura de produção e distribuição de energia, evidenciando a importância da gestão eficiente para suprir as necessidades atuais sem comprometer a capacidade das futuras gerações. A dependência de combustíveis fósseis aumenta a vulnerabilidade a flutuações de preço e instabilidade nos mercados, além de contribuir para as emissões de gases com efeito de estufa e agravar as alterações climáticas. A gestão de energia, que abrange desde o planeamento do consumo até à adoção de tecnologias mais limpas, visa reduzir a pegada ambiental e melhorar a segurança energética.

3.1 Metodologias

A dissertação investigará como a IA, combinada com áreas como machine learning, deep learning e algoritmos de otimização, pode:

- Gerar previsões precisas de consumo.
- Integrar eficientemente fontes renováveis.
- Automatizar processos em redes inteligentes (smart grids).

3.1.1 Estrutura da Metodologia

Esta secção apresenta, de forma estruturada, a metodologia adoptada no desenvolvimento deste trabalho, com enfoque na aplicação de algoritmos de Inteligência Artificial para a previsão de consumo energético, uma ferramenta essencial para a implementação de estratégias de DR em

comunidades de energia. O processo é composto por diversas etapas interligadas, desde a recolha e o tratamento de dados até à avaliação e análise dos resultados, conforme detalhado nas secções seguintes.

3.1.2 Etapas do Processo Metodológico

A primeira etapa consiste na recolha de dados. Para este fim, serão utilizados conjuntos de dados provenientes de sistemas reais, contendo registos com uma periodicidade de 15 minutos. Estas séries incluem informação sobre horários, datas, genero, idade, LastDayRate (Taxa de consumo do último dia) e temperatura.

Foram analisados um total de 1.169.274 registos de dados, referentes à participação de 405 indivíduos. A amostra foi composta por 203 participantes do sexo feminino e 202 do sexo masculino.

A distribuição etária dos participantes foi a seguinte:

- 3,00% (11 participantes) tinham entre 20 e 29 anos
- 25,80% (105 participantes) tinham entre 30 e 39 anos
- 38,70% (158 participantes) tinham entre 40 e 49 anos
- 23,80% (97 participantes) tinham entre 50 e 59 anos
- 8,60% (35 participantes) tinham entre 60 e 69 anos
- 0,10% (0 participantes) tinham entre 70 e 79 anos

Verifica-se que a faixa etária mais representada corresponde à dos 40–49 anos, representando cerca de 39% da amostra total. Em contraste, não foram registados participantes na faixa dos 70 aos 79 anos, o que poderá indicar uma menor representatividade deste grupo etário.

Tratamento de Dados

Antes de alimentar os modelos, os dados serão sujeitos a processos de limpeza e normalização. Vão ser eliminados valores nulos e incoerências, e aplicadas transformações que garantam consistência entre as variáveis.

Escolha de Modelos de IA

Serão seleccionados dois algoritmos de machine learning: K-Nearest Neighbors (KNN) e XGBoost. O KNN é um método baseado em instâncias, eficaz para conjuntos de dados com relações locais, enquanto o XGBoost é um algoritmo baseado em árvores de decisão.

Treino e Teste

Serão considerados diferentes cenários de separação dos dados: 80% treino 20% teste, 60% treino 40% teste, 40% treino 60% teste e 29 dias de treino para 1 dia de teste. Esta diversidade

de abordagens visa avaliar o comportamento dos modelos em distintos contextos de disponibilidade de dados.

Avaliação de Desempenho

A qualidade das previsões será avaliada através de métricas padronizadas: MAE (Erro Absoluto Médio), RMSE (Raiz do Erro Quadrático Médio), MAPE (Erro Percentual Absoluto Médio) e SMAPE (Erro Percentual Absoluto Médio Simétrico). Estas métricas permitem uma comparação consistente entre os diferentes modelos e configurações.

Interpretação dos Resultados dos Modelos

Foi utilizado o modelo LIME (Local Interpretable Model-Agnostic Explanations) para analisar o peso e a influência de cada variável nas decisões dos modelos. Esta ferramenta permite uma interpretação acessível dos resultados, essencial em contextos práticos que exigem a compreensão por parte dos utilizadores finais.

Análise e Apresentação dos Resultados

Os resultados obtidos serão exportados para análise gráfica e comparativa. Através de visualizações e interpretações detalhadas, serão identificadas tendências de desempenho, limitações metodológicas e o potencial de integração em sistemas reais.

Ferramentas Utilizadas

Para a implementação prática das metodologias, será utilizado o ambiente Google Colab em conjunto com a linguagem Python, aproveitando as suas bibliotecas avançadas para análise de dados, modelação e simulação.

3.2 Comunidades Energéticas

O estudo também abordará a importância das Comunidades Energéticas como soluções descentralizadas para promover a produção, consumo e armazenamento de energia renovável em nível local. Essas comunidades, apoiadas por tecnologias como blockchain e contratos inteligentes:

- Promovem a transparência.
- Democratizam o setor energético.

Paralelamente a dissertação irá analisar, métodos de armazenamento de energia e a sua relevância para mitigar a intermitência de fontes renováveis e práticas como Demand Response, que visam equilibrar oferta e procura, maximizando a flexibilidade e a estabilidade do sistema elétrico.

Capítulo 4

Resultados e Discussão

Neste capítulo, aplica-se a metodologia apresentada no capítulo 3 a um conjunto de dados reais com o objetivo de avaliar a eficácia dos modelos propostos na previsão da disponibilidade dos utilizadores em cenários de Demand Response. Serão apresentados os resultados obtidos com diferentes configurações de treino e teste, seguidos de uma análise detalhada das variáveis mais influentes, comparação entre modelos, e discussão das implicações práticas dos resultados, nomeadamente no contexto das comunidades de energia.

Com o objetivo de avaliar e identificar a estratégia mais eficiente para a previsão de padrões de consumo de energia, foi realizado um estudo com base no artigo (Silva, Faria P. e Vale Z. 2022), utilizando o método LIME (Ramos, Faria P. e Vale Z. 2024b).

O código correspondente divide o conjunto de dados em (80%, 60%, 40% e 29 dias) para treino e (20%, 40%, 60% e 1 dia) para teste, gerando explicações com base nas variáveis de entrada que mais influenciam o desempenho do modelo em determinados períodos do conjunto de teste. Foram considerados, por padrão, os períodos 1, 2 e 3 para as análises com divisões de 80% de treino e 20% de teste, 60% de treino e 40% de teste, e 40% de treino e 60% de teste, respectivamente, além dos períodos 44, 47 e 48 para a análise com 29 dias de treino e 1 dia de teste. Além disso, as explicações são geradas a partir de métodos de machine learning previamente treinados, nomeadamente o KNN e o XGBoost.

Este capítulo é dedicado à apresentação e discussão dos resultados obtidos ao longo da investigação.

Na secção 4.1, são introduzidas as faixas de valores a considerar e a estudar. Posteriormente, na secção 4.2, apresentam-se os dados recolhidos, bem como os resultados obtidos a partir das diferentes estratégias analisadas.

A secção 4.3 foca-se na análise detalhada dos resultados apresentados.

Na secção 4.4 serão abordados os resultados obtidos a partir da aplicação das métricas de erro nos dados de previsão.

A secção 4.5 é dedicada à comparação entre os resultados obtidos e os estudos previamente publicados na literatura científica. Por fim, a secção 4.6 aborda as implicações práticas e teóricas decorrentes dos resultados alcançados.

4.1 Análise do Dataset

O conjunto de dados utilizado neste estudo é composto por variáveis que representam características temporais, demográficas e contextuais. A Tabela 4.1 apresenta os intervalos de valores admissíveis para cada uma das variáveis de entrada (inputs), os quais foram definidos com base na análise estatística dos dados disponíveis e nas características do sistema modelado.

As variáveis podem ser classificadas em contínuas e discretas, de acordo com a natureza dos seus valores. As variáveis contínuas assumem valores dentro de um intervalo real, podendo apresentar frações e decimais, como é o caso da temperatura ambiente, que varia entre 4°C e 25°C. Já as variáveis discretas assumem valores inteiros ou categóricos, representando, por exemplo, dias do mês, faixas etárias, ou valores binários como gênero e disponibilidade.

Esta distinção é essencial para a escolha das técnicas de análise e modelação, dado que diferentes tipos de variáveis exigem abordagens estatísticas e computacionais adequadas

TABELA 4.1: Intervalos das variáveis utilizadas no modelo.

Variável	Unidade	Descrição	Valor Mínimo	Valor Máximo	Tipo
LastDayRate	-	Taxa do último dia útil considerada.	1	5	Input
Temperature	°C	Temperatura ambiente registada.	4	25	Input
Period	Minutos	Periodicidade de 15 minutos.	1	2880	Input
DayofMonth	-	Dia do mês correspondente à observação.	1	30	Input
DayofWeek	-	Dia da semana (1 para Domingo, até 7 para Sábado).	1	7	Input
Age	-	Faixa etária do utilizador.	3	5	Input
Gender	Binário	Gênero (0 para Feminino, 1 para Masculino).	0	1	Input
Availability	Binário	Disponibilidade do utilizador (variável alvo).	0	1	Output

O modelo baseia-se em múltiplas variáveis de previsão (inputs) para estimar a variável de saída (output), correspondente à disponibilidade dos consumidores em eventos de Demand Response.

O input "LastDayRate" é um componente dinâmico que atualiza a avaliação do consumidor com base no seu desempenho no evento de DR mais recente, considerando o mesmo contexto. Essa taxa avalia a capacidade do consumidor em cumprir as reduções solicitadas no último evento, permitindo ajustes contínuos na sua confiabilidade. A sua escala varia de 1 a 5.

O input "temperature" corresponde ao valor da temperatura ambiente registada em graus Celsius no instante da análise. A temperatura medida encontra-se no intervalo de 4°C a 25°C.

O input "Period" representa a periodicidade das observações, com intervalos de 15 minutos. Assume-se um mês com 30 dias, o que resulta num total de 2880 períodos mensais (96 períodos de 15 minutos por dia $\times$ 30 dias).

Os inputs "DayofMonth" e "DayofWeek" indicam, respetivamente, o dia do mês (de 1 a 30) e o dia da semana (de 1 para Domingo a 7 para Sábado) correspondentes à observação.

Adicionalmente, são considerados dados sobre o utilizador, como a "Age", representada por valores de 3 a 5, em que cada valor representa uma faixa etária:

3 - [40,49]

4 - [50,59]

5 - [60,69]

O "Gender", representado binariamente (0 para Feminino, 1 para Masculino).

A variável "Availability" representa a disponibilidade do utilizador para participar em eventos de Demand Response. É uma variável binária, onde 1 indica disponibilidade e 0 indica indisponibilidade, sendo o valor a prever pelo modelo.

4.2 Apresentação dos Resultados

O código executa uma divisão estratificada do conjunto de dados em diferentes proporções de treino e teste: 80% 20%, 60% 40%, 40% 60% e uma configuração adicional com 29 dias de treino e 1 dia de teste. Para cada uma dessas divisões, são analisados intervalos temporais específicos do conjunto de teste. Por padrão, os períodos avaliados são os períodos 1, 2 e 3 nas divisões 80% 20%, 60% 40% e 40% 60%, e os períodos 44, 47 e 48 na análise com 29 dias de treino e 1 dia de teste.

O método LIME é utilizado para gerar explicações locais, ou seja, associadas a previsões pontuais com uma resolução temporal de 15 minutos. As explicações são baseadas nos modelos KNN e XGBoost treinados em cada cenário, e têm como objetivo identificar as variáveis de entrada que mais influenciam, positiva ou negativamente, as previsões da variável de saída Availability.

As variáveis de entrada consideradas são:

"temperature"

"DayOfMonth"

"LastDayRate"

"DayOfWeek"

"Period"

"AGE"

"Gender"

A variável de saída analisada é:

"availability"

4.2.1 80% Treino e 20% Teste

A imagem 4.1 apresenta um gráfico tridimensional que compara o desempenho de dois modelos de machine learning — KNN (K-Nearest Neighbors) e XGB (XGBoost) — na tarefa de previsão com uma divisão de dados de 80% para treino e 20% para teste. O gráfico mostra a percentagem de acerto dos modelos em relação aos dados reais, representados como 100%. O modelo KNN atingiu uma precisão de 88,46%, enquanto o modelo XGB obteve um resultado ligeiramente superior, com 89,62%. Esta visualização permite avaliar de forma clara a eficácia dos modelos preditivos em relação ao valor real, contribuindo para a análise comparativa de desempenho em cenários de aprendizagem supervisionada.




FIGURA 4.1: Percentagem Previsão 80% Treino 20% Teste

Considerando que os dados representados no gráfico 4.2 correspondem aos três primeiros períodos de cada dia, ao longo de um mês, com início às 12h00 e intervalos de 15 minutos, observa-se uma correlação aparente entre as variáveis LastDayRate e Availability. A variável Availability, com valores binários (0 ou 1), indica a existência ou não de disponibilidade nesse período. Verifica-se que, quando Availability assume o valor 0 (sem disponibilidade), a LastDayRate tende a apresentar maior variabilidade e, em diversos casos, valores mais baixos. Tal comportamento sugere que a ausência de disponibilidade poderá também estar associada a outras variáveis, como a temperatura, idade, género, entre outras.




FIGURA 4.2: Correlação LastDayRate - Availability 80% Treino 20% Teste.PNG

Resultados KNN

A primeira verificação 4.3 foi para o modelo KNN onde revela que a variável "LastDayRate" foi a que mais influenciou negativamente a classificação, com um contributo de aproximadamente -0.77, empurrando fortemente a previsão para a classe negativa. Outra variável com contributo negativo é o período em contraste com "DayofWeek", "DayofMonth", "temperature" e "Age" que apresentam resultados positivos, mas muito reduzidos, o que não altera o resultado final.




FIGURA 4.3: Análise LIME com KNN 80% 20% (1º período 15 min.)

A Figura 4.4 mostra a influência das variáveis no modelo KNN para uma previsão positiva. A variável "LastDayRate" tem o maior impacto positivo (0.53), seguida por "DayofMonth" (0.01) e "DayofWeek". Variáveis como "Age", "Period" e "temperature", contribuem negativamente, mas de forma muito reduzida, não alterando o resultado final.

Analisando a figura 4.5, observa-se que o modelo KNN é influenciado por diversas variáveis,




FIGURA 4.4: Análise LIME com KNN 80% 20% (2º período 15 min.)

sendo a variável "LastDayRate" que exerce o impacto positivo mais considerável (0.54). Adicionalmente, a variável "Period", quando excede 2158.00, contribui negativamente (0.09), assim como a "temperature" (0.02) quando igual ou inferior a 11.00. Outras variáveis, como "DayofMonth", "Age" e "DayofWeek", apresentam contribuições positivas, embora de magnitude reduzida, não afetando o resultado final de forma significativa.




FIGURA 4.5: Análise LIME com KNN 80% 20% (3º período 15 min.)

Resultados XGB

Com base na análise do modelo XGBoost 4.6, a variável "LastDayRate" é o fator preponderante que direciona a classificação para a classe negativa, especialmente quando o seu valor é inferior ou igual a 2. As variáveis "temperature", "Age", "DayofWeek" e "Period", contribuem positivamente para a classificação, mas sem um impacto considerável.




FIGURA 4.6: Análise LIME com XGB 80% 20% (1º período 15 min.)

Analisando o modelo XGBoost da Figura 4.7, o "LastDayRate" emerge como o fator determinante para a classificação positiva. Variáveis como "Age" e "DayofMonth" influenciam a classificação negativamente. As variáveis "DayofWeek", "temperature" e "Period" influenciam a classificação positivamente, embora em menor grau.




FIGURA 4.7: Análise LIME com XGB 80% 20% (2º período 15 min.)

Para a análise do modelo XGBoost apresentado na Figura 4.8 revela que a variável "LastDayRate" desempenha um papel crucial na previsão de classificações positivas. "DayofMonth",

"DayofWeek" e "temperature", exercem uma influência, ainda que insignificativa, nas classificações positivas. Por outro lado "Period" e "Age" têm um impacto nas classificações negativas.




FIGURA 4.8: Análise LIME com XGB 80% 20% (3º período 15 min.)

4.2.2 60% Treino e 40% Teste

Nesta nova análise, o conjunto de dados é dividido de forma estratificada, utilizando 60% dos dados para treino e os 40% restantes para teste. Posteriormente, são produzidas explicações interpretáveis com base nas variáveis de entrada que mais impactam o desempenho do modelo ao longo de intervalos temporais específicos do conjunto de teste (por defeito, os períodos 0, 1 e 2).

Através do gráfico 4.9 apresentado, é possível observar a performance comparativa entre os valores reais e os previstos pelos modelos KNN e XGB, com base numa divisão de 60% para treino e 40% para teste. O valor real foi estabelecido como referência a 100%, enquanto o modelo KNN obteve uma precisão de 88,68% e o modelo XGB alcançou 89,69%. Verifica-se, assim, que ambos os modelos apresentam um bom desempenho preditivo, com o XGB a evidenciar uma ligeira vantagem face ao KNN.




FIGURA 4.9: Percentagem Previsão 60% Treino 40% Teste

O gráfico 4.10 ilustra a evolução das variáveis LastDayRate e Availability ao longo dos três primeiros períodos de cada dia, durante um mês, com início às 12h00 e intervalos de 15 minutos.

É evidente, pela flutuação acentuada da variável Availability, que a disponibilidade não é constante nem puramente aleatória, sugerindo que poderá estar associada a outros fatores contextuais ou comportamentais. Nesse sentido, considera-se que a disponibilidade pode depender de diversas variáveis explicativas, tais como a temperatura, o dia do mês, o período do dia (entre os três analisados), o dia da semana e até mesmo a idade. Devemos considerar que este resultado depende fortemente do nível de treino realizado (60%). Nota-se que isso influencia diretamente os testes finais.




FIGURA 4.10: Correlação LastDayRate - Availability 60% Treino 40% Teste.PNG

Resultados KNN

Nesta verificação 4.11 foi para o modelo KNN onde revela que a variável "LastDayRate" foi a que mais influenciou positivamente a classificação, com um contributo de aproximadamente 0.53, empurrando fortemente a previsão para a classe positiva. Em contraste com "DayofWeek", "DayofMonth", "temperature", "Age" e "Period" que apresentam resultados negativos, mas muito reduzidos, o que não altera o resultado final.




FIGURA 4.11: Análise LIME com KNN 60% 40% (1º período 15 min.)

A Figura 4.12 mostra a influência das variáveis no modelo KNN para uma previsão positiva. A variável "LastDayRate" tem o maior impacto Positivo (0.53), seguida por "DayofWeek", "temperature" e "DayofMonth". "Period" e "Age" contribuem negativamente, mas de forma muito reduzida, não alterando o resultado final.




FIGURA 4.12: Análise LIME com KNN 60% 40% (2º período 15 min.)

Analisando a figura 4.13, observa-se que o modelo KNN é influenciado por diversas variáveis. Para uma previsão positiva, a variável "LastDayRate" exerce um impacto positivo considerável (0.36) quando se situa entre 3.00 e um limite superior 5. Adicionalmente, a variável "Period" contribui negativamente (0.08), assim como a "temperature"(0.01) quando igual ou inferior a 12.00. Outras variáveis, como "DayofMonth", "DayofWeek" apresentam contribuições negativas embora de magnitude reduzida, não afetando o resultado final de forma significativa.




FIGURA 4.13: Análise LIME com KNN 60% 40% (3º período 15 min.)

Resultados XGB

Para a análise do modelo XGBoost apresentado na Figura 4.14 revela que a variável "LastDayRate" desempenha um papel crucial na previsão de classificações positivas, principalmente acima do limiar de 3. Adicionalmente, as variáveis "Age", "DayofMonth", "DayofWeek" "Period" exercem também uma influência, ainda que secundária, nas classificações positivas.




FIGURA 4.14: Análise LIME com XGB 60% 40% (1º período 15 min.)

Com base na análise do modelo XGBoost 4.15, evidencia-se que a variável "LastDayRate" tem um papel determinante na previsão de classificações positivas, sobretudo quando estas ultrapassam o limiar de 3. Para além disso, as variáveis "Age", "DayofMonth", "DayofWeek" e "temperature" também influenciam as classificações positivas, embora de forma menos significativa. "Period" exerce uma influência, ainda que secundária, nas classificações negativas.




FIGURA 4.15: Análise LIME com XGB 60% 40% (2º período 15 min.)

Por fim, para o treino de 60% e teste de 40% e com base na análise do modelo XGBoost 4.16, observa-se que a variável "LastDayRate" desempenha um papel fundamental na previsão de classificações positivas, especialmente quando estas superam o limiar de 2. Em contra ciclo as

variáveis "DayofMonth" e "temperature" contribuem para as classificações negativas, embora com um impacto não relevante.




FIGURA 4.16: Análise LIME com XGB 60% 40% (3º período 15 min.)

4.2.3 40% Treino e 60% Teste

Foi efetuada uma nova bateria de testes e treinos para avaliar a performance do modelo. Foram utilizados 40% dos dados para treino e os 60% restantes para teste. Em seguida, geram-se explicações interpretáveis com base nas variáveis de entrada que mais influenciam o desempenho do modelo ao longo de intervalos temporais específicos do conjunto de teste (por defeito, os períodos 0, 1 e 2).

Através do gráfico 4.17 apresentado, é possível observar a performance comparativa entre os valores reais e os previstos pelos modelos KNN e XGB, com base numa divisão de 60% para treino e 40% para teste. O valor real foi estabelecido como referência a 100%, enquanto o modelo KNN obteve uma precisão de 86,29% e o modelo XGB alcançou 89,55%. Verifica-se, assim, que ambos os modelos apresentam um bom desempenho preditivo, com o XGB a evidenciar uma ligeira vantagem face ao KNN. Esta diferença, embora não seja muito significativa, sugere que o modelo XGB é ligeiramente mais eficaz na previsão dos valores analisados, aproximando-se mais dos resultados reais.




FIGURA 4.17: Percentagem Previsão 40% Treino 60% Teste

Os dados representados na imagem 4.18 correspondem aos três primeiros períodos de cada dia, ao longo de um mês, com início às 12h00 e intervalos de 15 minutos. Apesar de o LastDayRate ter uma forte influência na Availability, isso não é totalmente visível no gráfico apresentado, porque a disponibilidade depende também de outros factores, como o período do dia, o mês, a idade e a temperatura. Estes factores alteram o impacto do LastDayRate, tornando a relação entre as variáveis mais complexa.




FIGURA 4.18: Correlação LastDayRate - Availability 40% Treino 60% Teste.PNG

Resultados KNN

A Figura 4.19 mostra a influência das variáveis no modelo KNN para uma previsão positiva. A variável "LastDayRate" tem o maior impacto positivo (0.55). Variáveis como "Age", "temperature" e "Period" contribuem negativamente, mas de forma muito reduzida, sem comprometer o resultado final.




FIGURA 4.19: Análise LIME com KNN 40% 60% (1º periodo 15 min.)

A Figura 4.20 mostra a influência das variáveis no modelo KNN para uma previsão positiva. A variável "LastDayRate" tem o maior impacto positivo (0.53), seguida por "temperature" e "DayofMonth" embora os seus valores não sejam significativos. Variáveis como "Age", "Period" e "DayofWeek" contribuem negativamente, mas de forma muito reduzida, não alterando o resultado final.




FIGURA 4.20: Análise LIME com KNN 40% 60% (2º periodo 15 min.)

Analisando a figura 4.21, observa-se que o modelo KNN é influenciado pelo "LastDayRate" para uma previsão positiva, As restantes variaveis contribuem negativamente, embora de magnitude reduzida, não afetando o resultado final de forma significativa.




FIGURA 4.21: Análise LIME com KNN 40% 60% (3º período 15 min.)

Resultados XGB

A Figura 4.22 apresenta uma análise LIME do modelo XGBoost para o primeiro período de 15 minutos, com divisão de dados 40% treino e 60% teste. Nessa análise, a variável "LastDayRate" (0,61) desempenha um papel crucial na previsão positiva. As demais variáveis, embora também apresentem efeitos positivos, possuem valores pouco significativos. A variável "DayofWeek" é a única que exibe impacto negativo, porém sem influenciar significativamente o resultado.




FIGURA 4.22: Análise LIME com XGB 40% 60% (1º período 15 min.)

Da mesma forma análise do modelo XGBoost apresentado na Figura 4.23 revela a variável "LastDayRate" tem influência decisiva na previsão positiva. As outras variáveis, apesar serem positivas os seus valores são pouco significativos. Os valores das variáveis "Period" e "temperature" são negativos, mas não têm influência no resultado final.




FIGURA 4.23: Análise LIME com XGB 40% 60% (2º período 15 min.)

A análise do modelo XGBoost apresentado na Figura 4.24 mais uma vez revela que todas as variáveis à exceção de "DayofWeek" são determinantes na antecipação de classificações positivas. Contudo a variável "LastDayRate" (0.51) é que a que mais influencia o resultado final.




FIGURA 4.24: Análise LIME com XGB 40% 60% (3º período 15 min.)

4.2.4 29 Dias de Treino e 1 Dia de Teste

Por fim, foi realizada a análise com 29 dias de dados para treino e 1 dia para teste no Google Colab, foi necessário ajustar o código de forma a separar os dados de acordo com o período pretendido. Considerando que cada dia possui 96 períodos de 15 minutos, obtemos:

29 dias × 96 períodos de 15 minutos = 2784 períodos de 15 minutos para o conjunto de treino

1 dia × 96 períodos de 15 minutos = 96 períodos de 15 minutos para o conjunto de teste

Os três períodos de análise foram definidos com base nos momentos em que o valor da Lastday rate atingiu seus picos mais altos. Paralelamente, considerou-se também os intervalos com as temperaturas máximas registradas. Essa combinação permitiu identificar com precisão os períodos mais críticos.

É possível observar que nos pontos 44, 47 e 48, correspondentes aos períodos 2828, 2831 e 2832, respectivamente, os valores de LastDayRate atingem o seu pico (4). Além disso, as temperaturas nesses mesmos períodos também estão entre as mais elevadas, com 17°C e 16°C.




FIGURA 4.25: Períodos de Análise

A correlação entre a taxa final elevada e o calor intenso revelou padrões relevantes. Assim, os períodos escolhidos refletem condições extremas para uma análise mais aprofundada.

LastDayRate	Temperature	Period	DayofMonth	DayofWeek	Age	Gender	Availability
4	17	2828	30	2	3	0	1
4	16	2831	30	2	3	0	1
4	16	2832	30	2	3	0	1

TABELA 4.2: Períodos de Análise

A imagem 4.26 apresenta um gráfico que compara o desempenho entre os valores reais e os previstos pelos modelos KNN e XGB, tendo por base um cenário de 29 dias dedicados ao treino e 1 um dia à fase de teste.

A barra referente aos dados reais está representada com 100%, servindo como base comparativa. O modelo KNN alcançou uma precisão de 66,67%, o que indica que acertou aproximadamente dois terços das previsões durante o período de teste. Já o modelo XGB obteve um desempenho significativamente superior, com uma taxa de acerto de 88,54%, demonstrando maior capacidade de captar os padrões presentes nos dados. A comparação evidencia a superioridade do XGBoost em relação ao KNN para essa tarefa específica, reforçando a importância da escolha adequada do modelo conforme a complexidade e as características dos dados utilizados.




FIGURA 4.26: Percentagem Previsão 29 Dias Treino 1 Dia Teste

Portanto, com base nesta análise gráfica 4.27, conclui-se que a correlação entre LastDayRate e Availability, no cenário de 29 dias de treino e 1 dia de teste, não é evidente de forma direta. Como será analisado a seguir, essa correlação depende fortemente das outras variáveis, como o período do dia (manhã, tarde, noite), a temperatura, o dia do mês, e o dia da semana as quais influenciam diretamente o comportamento da disponibilidade.

Já as restantes variáveis como gênero e idade não demonstraram influência significativa neste contexto específico, sugerindo que o comportamento de disponibilidade está mais associado a fatores temporais e operacionais do que a perfis individuais.




FIGURA 4.27: Correlação LastDayRate - Availability 29 Dias Treino 1 Dia de Teste.

Resultados KNN

A Figura 4.28 mostra a classe positiva com alta confiança (valor previsto de 1.00). A explicação local da previsão indica que a variável "LastDayRate", com valor igual a 4.00, foi o principal fator que contribuiu positivamente para essa classificação, especialmente por estar acima do limite de 3.00. A variável "DayofWeek" também contribuí positivamente, embora com impacto marginal.




FIGURA 4.28: Análise LIME com KNN de 29 dias treino 1 dia teste (44º período 15 min.)

Por outro lado, algumas variáveis apresentaram influência negativa o "DayOfMonth"(30.00), e "temperature"(17.00), mas seu efeito combinado foi insuficiente para alterar a decisão final do modelo. Variáveis como Age e Gender tiveram impacto desprezível na previsão.

Analisando a figura 4.29, observa-se que o modelo KNN é influenciado por "LastDayRate", "temperature" e "DayofWeek" para uma previsão positiva, Pode-se considerar que o "Period" exerce uma influência negativa sobre a "Availability". As demais variáveis também contribuem negativamente, mas não influenciam de forma relevante o resultado final.




FIGURA 4.29: Análise LIME com KNN de 29 dias treino 1 dia teste (47º período 15 min.)

Para a análise do modelo KNN apresentado na Figura 4.30 revela que as variáveis "DayOfMonth" e "Period" desempenham um papel crucial na previsão de classificações negativas e as variáveis "LastDayRate", "temperature" e "DayofWeek" exercem uma influencia positiva para o resultado final.




FIGURA 4.30: Análise LIME com KNN de 29 dias treino 1 dia teste (48º periodo 15 min.)

Resultados XGB

Com base na análise do modelo XGBoost 4.31, evidencia-se que a variável "LastDayRate" tem um papel determinante na previsão de classificações positivas, sobretudo quando estas ultrapassam o limiar de 3. Para além disso, a variável "DayofMonth" também influencia as classificações positivas, embora de forma menos significativa.




FIGURA 4.31: Análise LIME com XGB de 29 dias treino 1 dia teste (44º periodo 15 min.)

A Figura 4.32 mostra a influência das variáveis no modelo XGB para uma previsão positiva. A variável "LastDayRate" tem o maior impacto positivo (0.60), seguida por "DayofWeek", e "DayofMonth". "Period" e "temperature" contribuem negativamente, mas de forma muito reduzida, não alterando o resultado final.




FIGURA 4.32: Análise LIME com XGB de 29 dias treino 1 dia teste (47º período 15 min.)

Da mesma forma análise do modelo XGBoost apresentado na Figura 4.33 revela que as variáveis "LastDayRate" e "DayofMonth" desempenham um papel crucial na previsão de classificações positivas. Além disso, destaca-se a influência negativa de variáveis como "Period", "temperature" e "DayofWeek", que contribuem significativamente para previsões de classificações negativas.




FIGURA 4.33: Análise LIME com XGB de 29 dias treino 1 dia teste (48º período 15 min.)

4.3 Análise e Interpretação dos Resultados

4.3.1 Impacto das Variáveis

A variável "LastDayRate" revela-se consistentemente como a mais influente em todos os testes e modelos analisados. Quando o valor de LastDayRate é superior a 3, tende a favorecer classificações positivas, enquanto valores iguais ou inferiores a 2 influenciam negativamente as previsões direcionando-as para a classe negativa.

As variáveis DayofMonth, DayofWeek, Age, temperature, Gender e Period apresentam contributos geralmente reduzidos. Isto sugere que exercem uma influência residual na maioria dos casos e desempenham um papel complementar, reforçando ou atenuando o impacto da variável LastDayRate.

4.3.2 Comparação entre Modelos

No modelo KNN, observa-se uma forte sensibilidade à variável LastDayRate, tanto nas previsão positivas como nas negativas. As variáveis secundárias apresentam um impacto muito reduzido, com variações pouco expressivas que não alteram significativamente os resultados. Este comportamento mantém-se consistente em todas as divisões de treino e teste, o que reforça a confiança na robustez do LastDayRate como preditor dominante.

Já o modelo XGBoost evidencia uma maior valorização das variáveis secundárias, especialmente em cenários com conjuntos de dados mais extensos, como na divisão 40/60. Em alguns testes, praticamente todas as variáveis, com exceção de uma ou duas, são consideradas relevantes, o que sugere que o modelo é capaz de captar interações mais subtis entre os dados. Ainda assim, o LastDayRate mantém-se como a variável com maior influência nas previsões positivas.

4.3.3 Treinos & Testes

Com uma divisão de 80% para treino e 20% para teste, os modelos tendem a ser mais confiantes nas suas classificações, apresentando uma influência mais “limpa” e centrada no LastDayRate, com variáveis secundárias mostrando menor oscilação nos contributos. Quando a proporção de treino é reduzida para 60% e teste aumenta para 40%, os modelos mantêm a sua coerência, mas verifica-se um ligeiro aumento da influência das variáveis secundárias, possivelmente devido à maior diversidade nos dados de teste. O XGBoost começa a oferecer interpretações mais ricas, embora o KNN se mantenha mais conservador. Já com 40% de treino e 60% de teste, observa-se um aumento na complexidade das decisões para o XGBoost, onde todas as variáveis, exceto uma ou duas, se tornam relevantes. O KNN continua a focar-se no LastDayRate, mas as variações secundárias ganham ligeiramente mais expressão. Essa proporção destaca a maior resiliência do XGBoost em cenários com menos dados de treino.

4.3.4 Considerações Finais

A variável “LastDayRate” é o principal fator determinante na maioria das classificações, destacando-se como o melhor indicador isolado. O XGBoost, por sua vez, demonstra maior sensibilidade a interações complexas entre variáveis, tornando-se a escolha mais adequada quando se trabalha com conjuntos de teste maiores. O KNN, embora mais estável, apresenta uma menor expressividade, sendo ideal para cenários com menor variabilidade. A alteração na proporção de treino/teste afeta principalmente a expressividade das variáveis secundárias.

4.4 Valores das Métricas de Erro de Previsão

Os resultados obtidos a partir da aplicação das métricas de erro nos dados de previsão estão apresentados na tabela 4.3. As métricas consideradas incluem MAE, RSME, MAPE e SMAPE, que permitem avaliar o desempenho do modelo sob diferentes perspectivas. Esses indicadores quantificam a precisão das previsões realizadas, sendo fundamentais para comparar e validar a eficácia do modelo adotado. Todos os cálculos foram efetuados utilizando o Microsoft Excel.

TABELA 4.3: Valores das Métricas de Erro de Previsão

Métricas de Erro de Previsão	80% Treino 20% Teste		60% Treino 40% Teste		40% Treino 60% Teste		29 Dias de Treino 1 Dia Teste	
	KNN	XGB	KNN	XGB	KNN	XGB	KNN	XGB
MAE	0,1154	0,1038	0,1132	0,1031	0,1371	0,1045	0,3333	0,1146
RMSE	0,3398	0,3222	0,3365	0,3210	0,3703	0,3232	0,5774	0,3385
Métricas de Erro de Previsão	80% Treino 20% Teste		60% Treino 40% Teste		40% Treino 60% Teste		29 Dias de Treino 1 Dia Teste	
	KNN	XGB	KNN	XGB	KNN	XGB	KNN	XGB
MAPE	17,86%	16,06%	17,51%	15,94%	21,18%	16,13%	50%	17,19%
SMAPE	8,88%	7,87%	8,68%	7,80%	10,66%	7,89%	20%	8,40%

De uma forma geral, o modelo XGB apresentou um desempenho superior ao modelo KNN em todas as divisões de treino e teste analisadas. As métricas de erro — MAE, RMSE, MAPE e SMAPE — indicam que o XGB produziu previsões mais precisas e consistentes, com valores mais baixos

de erro em todos os cenários testados. O modelo KNN demonstrou sensibilidade à redução da quantidade de dados de treino, especialmente no cenário com 29 dias de treino e 1 dia de teste, onde os erros aumentaram significativamente. Em contraste, o XGB manteve um desempenho estável mesmo em condições de treino mais restritivas.

4.5 Comparação com a Literatura

Para a realização deste trabalho, foi utilizado como referência o artigo (Silva, Faria P. e Vale Z. 2022), que apresenta vários pontos em comum com a abordagem aqui desenvolvida. Ambos os estudos partilham como tema central a participação dos consumidores em programas de DR, com particular foco na previsão ou optimização da resposta dos participantes face a eventos deste tipo. Destaca-se, em ambos os casos, a ênfase na flexibilidade e activação do consumidor, sublinhando a importância de um papel mais activo por parte dos utilizadores na estabilidade e eficiência do sistema eléctrico – algo especialmente relevante perante o aumento da penetração de fontes de energia renovável e da necessidade de respostas rápidas à necessidade de energia eléctrica. Tanto este trabalho como o artigo em análise fazem uso de dados históricos e contextuais dos consumidores com o objectivo de melhorar a previsão ou a gestão da resposta a eventos de DR. Por fim, importa referir que os dois textos demonstram uma preocupação comum com a incerteza inerente ao comportamento dos consumidores, procurando mitigá-la através da aplicação de métricas de desempenho e de técnicas avançadas de modelação e previsão.

4.6 Implicações dos Resultados

Os resultados obtidos demonstram que a variável "LastDayRate" é, de forma consistente, o principal indicador das classificações positivas e negativas nos diferentes cenários testados, independentemente do modelo (KNN ou XGBoost) ou da proporção de treino/teste. Esta evidência sugere que o histórico de comportamento do consumidor em eventos de DR pode ser usado como um forte indicador de fiabilidade e predisposição para futuras ações corretivas ou preventivas no âmbito da gestão de energia.

A implicação prática mais evidente é a possibilidade de priorizar consumidores com altas taxas de cumprimento ($LastDayRate > 3$) para programas de incentivo ou participação mais ativa em iniciativas energéticas descentralizadas, como comunidades energéticas. Esta abordagem permitiria otimizar a alocação de recursos e promover uma gestão mais eficiente da procura.

Adicionalmente, o facto de o modelo XGBoost demonstrar maior sensibilidade a interações complexas entre variáveis indica que este pode ser preferido em cenários com maior variabilidade de dados ou em sistemas onde se pretende captar padrões subtis. Por sua vez, o modelo KNN revelou-se mais robusto e previsível, sendo ideal para ambientes mais estáticos ou com restrições computacionais.

Do ponto de vista teórico, os resultados obtidos vêm reforçar os contributos da literatura que evidenciam a relevância da personalização e da segmentação dos perfis de consumidores de

energia, com vista a potenciar a eficácia dos programas de DR. A utilização da ferramenta LIME para interpretar os contributos das variáveis acrescenta uma dimensão de clareza e compreensão dos resultados, fatores cruciais para fomentar a confiança dos stakeholders na aplicação de modelos suportados por Inteligência Artificial.

Por fim, estes resultados poderão servir de base para o desenvolvimento de plataformas inteligentes de apoio à decisão para operadores de rede e comercializadores de energia, bem como constituir um instrumento de suporte à formulação de políticas públicas orientadas para a promoção da eficiência energética.

Capítulo 5

Conclusão

A integração da Inteligência Artificial (IA) na gestão energética revela-se fundamental para abordar os desafios contemporâneos de sustentabilidade, eficiência e transição energética. Este estudo demonstra que técnicas avançadas, como machine learning, deep learning e blockchain, desempenham um papel crucial na gestão eficiente dos recursos energéticos, facilitando estimativas detalhadas de consumo, integração otimizada de fontes renováveis e automação de processos em redes inteligentes. Estas tecnologias não reduzem apenas o desperdício energético, mas também contribuem para a diminuição dos custos operacionais e das emissões de carbono.

As comunidades energéticas emergem como uma solução inovadora e descentralizada, promovendo a ampliação do acesso à produção e ao consumo de energia, com impactos positivos significativos na independência energética local e na sustentabilidade ambiental. Apoiada em tecnologias como contratos inteligentes e blockchain, esta abordagem garante maior transparência, segurança nas transações e uma participação ativa dos seus membros.

Adicionalmente, métodos de armazenamento de energia e práticas como Demand Response (DR) apresentam um papel crucial na mitigação da intermitência das fontes renováveis, promovendo a flexibilidade e a estabilidade do sistema elétrico. Neste contexto, os resultados obtidos nesta dissertação, focados na análise de padrões de consumo aplicados ao DR, revelam-se altamente relevantes para a operacionalização eficaz das comunidades de energia. Através de modelos baseados em IA, como KNN e XGBoost, é possível antecipar o comportamento da procura energética e implementar estratégias automatizadas de gestão do consumo em tempo real. Esta capacidade de projeção permite às comunidades ajustar dinamicamente a utilização de energia às condições de produção renovável local, reduzindo a dependência da rede, otimizando os recursos partilhados e promovendo a resiliência energética. Assim, os contributos deste trabalho reforçam o papel do DR como um elo essencial entre a inteligência artificial e a autonomia operacional das comunidades energéticas, possibilitando uma resposta mais eficaz aos desafios técnicos e económicos da transição energética descentralizada.

Estas abordagens são complementadas por algoritmos de otimização e simulações avançadas, que melhoram a confiança na eficiência das redes, reduzindo a necessidade de infraestruturas tradicionais dispendiosas. Apesar dos desafios iniciais, como os custos de implementação e a complexidade técnica, os avanços tecnológicos e as estratégias regulatórias, como o Decreto-Lei

n.º 15/2022 em Portugal, reforçam a viabilidade destas inovações. Este enquadramento legislativo fomenta a participação comunitária e garante a inclusão social e energética, alinhando-se com as metas de descarbonização e transição energética.

Em síntese, o estudo demonstra que a IA e tecnologias emergentes podem transformar de forma positiva a gestão energética, tornando-a mais sustentável, resiliente e eficiente. Estas soluções tecnológicas não só permitem enfrentar os desafios atuais, mas também posicionam a gestão energética como um pilar essencial para um futuro sustentável e alinhado com os objetivos globais de desenvolvimento sustentável.

Bibliografia

- Ahmed, K., Dubey M. e Kumar A. (2024). Artificial intelligence and IoT driven system architecture for municipality waste management in smart cities: A review. Em: *Measurement: Sensors* 36. ISSN: 26659174. DOI: 10.1016/j.measen.2024.101395.
- Ali, A.N.F., Sulaima M.F. e Razak I.A.W.A (2023). *Artificial Intelligence Application in Demand Response: Advantages, Issues, Status, and Challenges*. DOI: 10.1109/ACCESS.2023.3237737.
- Antonopoulos, I., Robu V. e Couraud B. (2020). *Artificial intelligence and machine learning approaches to energy demand-side response: A systematic review*. DOI: 10.1016/j.rser.2020.109899.
- Bennagi, A., AlHousrya O. e Cotfas D.T. (2024). *Comprehensive study of the artificial intelligence applied in renewable energy*. DOI: 10.1016/j.esr.2024.101446.
- Binyamin, S., Ben Slama S. e Zafar B. (2024). Artificial intelligence-powered energy community management for developing renewable energy systems in smart homes. Em: *Energy Strategy Reviews* 51. ISSN: 2211467X. DOI: 10.1016/j.esr.2023.101288.
- Conte, F., D'Antoni F. e Natrella G. (2022). A new hybrid AI optimal management method for renewable energy communities. Em: *Energy and AI* 10. ISSN: 26665468. DOI: 10.1016/j.egyai.2022.100197.
- Contzen, M.P. (2024). Medium voltage level power control using distributed photo-voltaic generation and hydrogen storage. Em: *International Journal of Electrical Power and Energy Systems* 157. ISSN: 01420615. DOI: 10.1016/j.ijepes.2024.109858.
- Draz, A., Ashraf H. e Makeen P. (2024). Artificial intelligence computational techniques of flywheel energy storage systems integrated with green energy: A comprehensive review. Em: *e-Prime - Advances in Electrical Engineering, Electronics and Energy* 10. ISSN: 27726711. DOI: 10.1016/j.prime.2024.100801.
- Al-Ghaili, A.M., Ibrahim Z.B. e Bakar A.A. (2023). *A Systematic Review on Demand Response Role Toward Sustainable Energy in the Smart Grids-Adopted Buildings Sector*. DOI: 10.1109/ACCESS.2023.3287641.
- Giglio, E., Luzzani G. e Terranova V. (2023). An Efficient Artificial Intelligence Energy Management System for Urban Building Integrating Photovoltaic and Storage. Em: *IEEE Access* 11, pp. 18673–18688. ISSN: 21693536. DOI: 10.1109/ACCESS.2023.3247636.
- Khan, M.A., Saleh A.M. e Waseem M. (2023). *Artificial Intelligence Enabled Demand Response: Prospects and Challenges in Smart Grid Environment*. DOI: 10.1109/ACCESS.2022.3231444.
- Kumar, P. e Howard E. (2024). Artificial Intelligence to Enhance Energy Management and Distribution in Smart Grid Communication Networks. Em: *Tuijin Jishu/Journal of Propulsion Technology* 45 (2), pp. 1001–4055.

- Nabavi, S.A., Motlagh N.H. e Zaidan M.A. (2021). Deep Learning in Energy Modeling: Application in Smart Buildings with Distributed Energy Generation. Em: *IEEE Access* 9, pp. 125439–125461. ISSN: 21693536. DOI: 10.1109/ACCESS.2021.3110960.
- Parvin, K., Lipu M.S.H e Hannan M.A. (2021). Intelligent Controllers and Optimization Algorithms for Building Energy Management towards Achieving Sustainable Development: Challenges and Prospects. Em: *IEEE Access* 9, pp. 41577–41602. ISSN: 21693536. DOI: 10.1109/ACCESS.2021.3065087.
- Ramli, M.A.M. e Boucekara H.R.E.H. (2020). Solving the problem of large-scale optimal scheduling of distributed energy resources in smart grids using an improved variable neighborhood search. Em: *IEEE Access* 8, pp. 77321–77335. ISSN: 21693536. DOI: 10.1109/ACCESS.2020.2986895.
- Ramos, D. (2020). *Reinforcement Learning of a Multi-Agent System for the Forecasting of Electricity Consumption*. Rel. téc. URL: <https://hdl.handle.net/10216/138254>.
- Ramos, D., Faria P. e Vale Z. (2023). Explainable Artificial Intelligence for Definition of Inputs in Neural Networks and K-nearest Neighbors Forecasting of Electricity Consumption. Em: *IEEE PES Innovative Smart Grid Technologies Conference Europe*. IEEE Computer Society. ISBN: 9798350396782. DOI: 10.1109/ISGTEUROPE56780.2023.10408289.
- (2024a). Analysis of the Consumption and Sensors Features Contribution to the Consumption Forecast Using Explainable AI in Buildings. Em: *2024 22nd International Conference on Intelligent Systems Applications to Power Systems, ISAP 2024*. Institute of Electrical e Electronics Engineers Inc. ISBN: 9798331531751. DOI: 10.1109/ISAP63260.2024.10744322.
 - (2024b). Comparison of Inputs Correlation and Explainable Artificial Intelligence Recommendations for Neural Networks Forecasting Electricity Consumption. Em: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Vol. 14468 LNCS. Springer Science e Business Media Deutschland GmbH, pp. 51–62. ISBN: 9783031486517. DOI: 10.1007/978-3-031-48652-4_4.
- Reka, S., Dragicevic T. e Venugopal P. (2024). *Big data analytics and artificial intelligence aspects for privacy and security concerns for demand response modelling in smart grid: A futuristic approach*. DOI: 10.1016/j.heliyon.2024.e35683.
- República, Diário da (2019). *Diário da República, 1.ª série PRESIDÊNCIA DO CONSELHO DE MINISTROS*. Rel. téc. URL: <https://files.dre.pt/1s/2019/10/20600/0004500062.pdf>.
- (2022). *Diário da República, 1.ª série PRESIDÊNCIA DO CONSELHO DE MINISTROS*. Rel. téc. URL: <https://files.diariodarepublica.pt/1s/2022/01/01000/0000300185.pdf>.
- Silva, C., Faria P. e Vale Z. (2022). Using Supervised Learning to Assign New Consumers to Demand Response Programs According to the Context. Em: *2022 IEEE International Conference on Environment and Electrical Engineering and 2022 IEEE Industrial and Commercial Power Systems Europe, IEEEIC / I and CPS Europe 2022*. Institute of Electrical e Electronics Engineers Inc. ISBN: 9781665485371. DOI: 10.1109/IEEEIC/ICPSEurope54979.2022.9854646.
- Todorean, L., Chifu V.R. e Cioara T. (2023). Cooperative Games Over Blockchain and Smart Contracts for Self-Sufficient Energy Communities. Em: *IEEE Access* 11, pp. 73982–73999. ISSN: 21693536. DOI: 10.1109/ACCESS.2023.3296258.

- Umar, A., Kumar D. e Ghose T. (2024). Decentralized Community Energy Management: Enhancing Demand Response Through Smart Contracts in a Blockchain Network. Em: *IEEE Access* 12, pp. 80781–80798. ISSN: 21693536. DOI: 10.1109/ACCESS.2024.3409706.
- Xiang, Y., Chen Y. e Xu J. (2022). *Research on sustainability evaluation of green building engineering based on artificial intelligence and energy consumption*. DOI: 10.1016/j.egy.2022.08.266.
- Zhu, X., Chen S. e Liang X. (2024). Next-generation generalist energy artificial intelligence for navigating smart energy. Em: *Cell Reports Physical Science*, p. 102192. ISSN: 26663864. DOI: 10.1016/j.xcrp.2024.102192.

Apêndice A

Gestão e Inovação Energética.

TABELA 1: Gestão e Inovação Energética.

[Ref.]	Ano	Demand Response Flexibility	Energy Community	Energy Resource Management	Energy Storage
Khan	2023	Integração de fontes renováveis. Redução de custos operacionais. Participação no mercado de energia. Previsão de capacidade de resposta. Melhoria da estabilidade da rede elétrica.	Smart meters. Sistemas inteligentes para gestão comunitária. Educação e sensibilização dos membros. Custos de execução e conservação de sistemas.	Redução de custos operacionais. Aumento da confiabilidade do sistema. Eficiência energética. Sustentabilidade. Participação ativa em mercados energéticos.	Integração com fontes renováveis. Suporte à flexibilidade da rede. Redução de custos operacionais. Armazenamento descentralizado. Gestão eficiente da carga. Apoio à sustentabilidade.
Ali	2023	Peak Clipping. Valley Filling. Load Shifting. Incentivo e preços dinâmicos. Participação ativa dos consumidores. Integração de recursos distribuídos.	X	X	Sistemas de baterias domésticas. Veículos elétricos como unidades de armazenamento móvel. Armazenamento inteligente residencial. Utilização de baterias para equilíbrio da rede.
Umar	2024	Load Shifting. Peak Clipping. Valley Filling. Modelagem de elasticidade. Programas de incentivos. Integração de baterias.	Gestão local de energia. Troca de energia (P2P). Incentivos baseados em blockchain. Transparência e segurança. Envolvimento comunitário. Resiliência local.	X	Sistemas de baterias domésticas. Armazenamento distribuído para flexibilidade da rede. Utilização de baterias para estabilização da rede.
Ramli & Boucekara	2020	DR integrado a veículos elétricos (V2G/V2H). Gestão de (DER) com DR. Redução de carga por meio de programas de DR. DR com algoritmos de otimização da rede. DR para redução de custos operacionais.	X	DERs. Gestão de unidades de geração distribuída (DGUs). Integração com (ESUs). Utilização de EVs como recursos de energia.	ESUs. Armazenamento em EVs. Garantia de armazenamento mínimo. Eficiência de carga e descarga. Armazenamento em micro-redes. Integração com DGUs.

[Ref.]	Ano	Demand Response Flexibility	Energy Community	Energy Resource Management	Energy Storage
Todorean	2023	X	Integração de prosumers nas CER. Blockchain. Smart contracts. Distribuição de benefícios. Menor dependência de energia externa. Aumento da resiliência energética local.	X	Armazenamento local em bateria. Baterias como suporte á infraestrutura. Gestão da capacidade de armazenamento. Gestão de incertezas.
Giglio	2023	Intermitência das Fontes Renováveis. Previsão da Procura e Produção. Gestão Inteligente da Procura. Comunidades Energéticas e Consumo Colaborativo. Impacto Económico de DR.	Criação de CER. Troca de Energia entre Utilizadores Locais. Promoção de Baixas Emissões. Mercados de Energia Locais. Gestão Recursos Energéticos. Incentivo a sistemas renováveis e Baterias.	Integração de Fontes de Energia Renovável. SEM.	Baterias de íons de Lítio (Li-ion). Supercondensadores (BESS). Sistemas de armazenamento de fabricantes como Sonnen, Tesla Energy, LG Chem e CellCube.
Nabavi	2021	X	HEMS. Modelos Baseados em IoT. Métodos de Programação Linear (LP). Algoritmos Genéticos.	X	Baterias de íons de Lítio (Li-ion). Armazenamento de energia eletroquímica. ESS. Supercondensadores.
Al-Ghaili	2023	X	Programas de Carga Interrompível. BEMS. Programação LP/NLP.	X	ESS. Baterias de Íons de Lítio. Armazenamento Térmico de Energia.
Parvin	2021	X	Infraestruturas de Medição Avançada. Gestão de Energia em Edifícios. Redes Neurais Artificiais. MAS. Tarifa de Tempo de Uso.	X	Baterias de Íons de Lítio (Li-ion). Supercondensadores. Armazenamento de Energia Integrado em Microgrids. Baterias de Fluxo Redox. Integração com Renováveis.
Draz	2024	X	Infraestruturas (AMI). Redes de Comunicação em Redes Eléctricas Inteligentes. Modelos de Preços Dinâmicos. Gestão de Carga Baseadas em Perfis.	X	EMS & DERMS. Integração de renováveis com armazenamento. Gestão de Energia com IoT. Baterias. Armazenamento hidroelétrico. Armazenamento de energia otimizado por IA. Algoritmos para carga e descarga. Armazenamento na gestão da variabilidade das renováveis.

[Ref.]	Ano	Demand Response Flexibility	Energy Community	Energy Resource Management	Energy Storage
Binyamin	2024	X	Integração de fontes renováveis e armazenamento de energia. Geração distribuída e mercados Peer-to-Peer (P2P). Real-Time Pricing. V2G. Equilíbrio energético em redes locais e microgrids. Estratégias de leilão e negociação de energia.	X	P2P. Gestão comunitária baseada em IA. Estruturas descentralizadas para as CER. Criação de incentivos. Otimização da infraestrutura comunitária. Sistemas de armazenamento. Gestão do estado de carga (SoC). Armazenamento bidirecional em mercados P2P. Algoritmos para gestão de armazenamento.
Conte	2022	X	Definição de CER. Benefícios econômicos, ambientais e sociais. BESS. Análises preditivas na gestão energética. Modelos de controlo centralizado.	X	BESS. Maximização de benefícios econômicos através BESS. Definição de ciclos de vida para BESS. BESS no MPC.
Draz	2024	X	X	X	ESDs. Integração de Sistemas de Armazenamento com RESs. Aplicações Comerciais de Armazenamento de Energia. Otimização de Sistemas de Armazenamento por AI.
Parada Contzen	2024	X	X	X	Armazenamento de hidrogênio através da geração fotovoltaica. Hidrogénio no controlo do fator de potência. Indústria e mobilidade elétrica com hidrogénio.
Zhu	2024	Gestão inteligente de sistemas energéticos. Gestão preditiva e robusta de sistemas. Eficiência no controlo de HVAC. Controlo eficiente de carga para EVs.	X	X	Gestão inteligente e riscos operacionais. Previsão de ciclo de vida das baterias. Otimização de carga e descarga de baterias. Manutenção preditiva de sistemas de armazenamento. Armazenamento de energia em fontes renováveis.

[Ref.]	Ano	Demand Response Flexibility	Energy Community	Energy Resource Management	Energy Storage
Reka	2024	Preços dinâmicos para maior flexibilidade. Projeção de consumo em sistemas renováveis. Perfis de utilizador para maximizar flexibilidade. Otimização dos padrões de consumo.	X	X	X
Antonopoulos	2020	Utilização de algoritmos de AI. Implementação de esquemas baseados em incentivos. Otimização do consumo energético. Classificação de perfis de consumo. Integração de dispositivos IoT.	X	X	Armazenamento em redes inteligentes. IA para otimização de baterias. Previsão de capacidade e vida útil. Suporte à estabilidade da rede. Estratégias eficientes de carregamento.
Bennagi	2024	X	Integração de Microgrids. Uso de IA em Comunidades Energéticas. Eficiência Operacional e Sustentabilidade. Previsão de Consumo e Produção de Energia. Estudos de Caso e Implementações Reais.	X	Integração com redes elétricas. Otimização com IA. Desafios de custo e densidade. Dispositivos de armazenamento duráveis. Minimização da degradação em ciclos.
Diário da República	2019	Equilíbrio da rede elétrica. Integração de sistemas descentralizados. Incentivos ao autoconsumo coletivo e comunidades de energia. Participação ativa dos consumidores no mercado de energia. Adaptação regulamentação.	Regime jurídico das comunidades de energia renovável. Participação ativa de consumidores em comunidades energéticas. Promoção da produção descentralizada e do autoconsumo. Benefícios ambientais, económicos e sociais das comunidades energéticas. Acessibilidade e inclusão de todos os consumidores, incluindo os mais vulneráveis.	Gestão de recursos energéticos distribuídos em comunidades renováveis. Integração de sistemas de armazenamento e produção local. Monitorização e contagem de energia consumida e injetada na rede. Responsabilidade dos participantes pela gestão de desvios no sistema elétrico. Otimização da utilização de infraestruturas para maximizar eficiência energética.	Armazenamento de energia elétrica em dispositivos específicos, incluindo EVs. Integração de sistemas de armazenamento com unidades de produção para autoconsumo. Regras para contagem e monitorização de energia armazenada e consumida. Utilização de armazenamento bidirecional para gestão energética eficiente. Incentivos e regulamentações para promover o uso de sistemas de armazenamento.

[Ref.]	Ano	Demand Response Flexibility	Energy Community	Energy Resource Management	Energy Storage
Diário da República	2022	Equilíbrio da rede elétrica. Integração de sistemas descentralizados. Incentivos ao autoconsumo coletivo e comunidades de energia. Participação ativa dos consumidores no mercado de energia. Adaptação regulamentação.	Regime jurídico das comunidades de energia renovável. Participação ativa de consumidores em comunidades energéticas. Promoção da produção descentralizada e do autoconsumo. Benefícios ambientais, económicos e sociais das comunidades energéticas. Acessibilidade e inclusão de todos os consumidores, incluindo os mais vulneráveis.	Gestão de recursos energéticos distribuídos em comunidades renováveis. Integração de sistemas de armazenamento e produção local. Monitorização e contagem de energia consumida e injetada na rede. Responsabilidade dos participantes pela gestão de desvios no sistema elétrico. Otimização da utilização de infraestruturas para maximizar eficiência energética.	Armazenamento de energia elétrica em dispositivos específicos, incluindo EVs. Integração de sistemas de armazenamento com unidades de produção para autoconsumo. Regras para contagem e monitorização de energia armazenada e consumida. Utilização de armazenamento bidirecional para gestão energética eficiente. Incentivos e regulamentações para promover o uso de sistemas de armazenamento.

Apêndice B

Inovações Tecnológicas

TABELA 2: Inovações Tecnológicas.

[Ref.]	Ano	ML & DL	Simulation Tools	Blockchain
Khan	2023	ML; ANN; SVM; DL; RL; MAS; PSO; GA; PCA; CNN; LSTM; RNN; AIS; ACO; IMM; ETD-DBRNN; GBM; ISOA; ELM; SVR.	TRNSYS; MATLAB/Simu-link; EnergyPlus; HOMER.	Smart-contracts
Ali	2023	ANNs; ML; Swarm; SVM; PCA	X	X
Umar	2024	X	X	Smart-contracts; P2P
Toderean	2023	X	X	Smart-contracts; P2P
Giglio	2023	ML; ANNs; DL; RNN	X	X
Nabavi	2021	DL; SIES; ANNs; LSTM; DWT	WT; LSTM; DWT; NPV	X
Al-Ghaili	2023	ML; NN; RL; GA; Fuzzy Logic	EnergyPlus; GridLAB-D; TRNSYS; GAMS; MATLAB; CPLEX; OpenDSS	X
Parvin	2021	ANN; ANFIS; MPC; RL; DL; GA; PSO; ACO; ABC; SA; TS; NN-PC	X	Smart-contracts; P2P; DERs

[Ref.]	Ano	ML & DL	Simulation Tools	Blockchain
Kumar Maurya & Howard	2024	ML; DL; ANN; RNN; SVM; RL; AD	X	X
Binyamin	2024	DL; DRL; MDP	Q-Learning; RTP	Smart-contracts; P2P; IPFS
Conte	2022	TDNN; MPC; LSTM; CNN-LSTM; PSO	X	Smart-contracts; Distributed Ledger
Ahmed	2024	ML; ANN; DL	X	Distributed Ledger
Xiang	2022	LSTM; NN; AI-EMM	Kaggle Dataset; Energy Modelling	X
Draz	2024	ML; IACA; ANN; Fuzzy Logic; MPC	MATLAB; HOMER; OpenDSS; Plexos; Energy-PLAN	X
Zhu	2024	DL; ML; RL; XAI; Bayesian Optimization	X	X
Reka	2024	ML; DL; RL; NN; EL; GANs; CNNs; LSTM; Autoencoders	MATLAB; HOMER; OpenDSS; Plexos; Energy-Plus; Pyomo; GridLAB-D	X
Antonopoulos	2020	ANN; CNN; GBDT; HMM; kNN; LSTM; MAS; MDP; PSO; RL; SVM; SVR; SOM; FF-DNN; R-DNN	X	X
Bennagi	2024	ANN; SVM; BANN; BPNN; GA; RBFNN; SARIMA; ANFIS; NB; HISIMI; TRNSYS; GMDHNN; RBF; ARIMA; CNN; RNN; ML; PSO; BFO; ARIMA; MGWO; RL; LSTM; ISOA; ELM; SVR; Fuzzy.	TRNSYS; ARIMA; HISIMI; MATLAB/Simulink.	X

Apêndice C

Benefícios Comunitários, Custos de Implementação e Previsões.

TABELA 3: Benefícios Comunitários, Custos de Implementação e Previsões.

[Ref.]	Ano	Community Benefit	Cost Implementation	Forecast
Khan	2023	Redução de custos de energia. Maior sustentabilidade energética. Participação ativa dos consumidores. Maior confiabilidade e estabilidade da rede elétrica. Acessibilidade a tecnologias avançadas. Remuneração mais justa e proporcional. Impulso à inovação tecnológica e criação de empregos locais. Personalização de soluções energéticas.	Smart Meters. Redes de comunicação. Sensores e atuadores. Plataformas de gestão de energia. Integração com blockchain. Análise de dados. Campanhas de sensibilização e educação comunitária. Conformidade regulatória e legalização. Pesquisa e desenvolvimento (P&D). Criação de contratos e incentivos econômicos.	Previsão de Carga. Previsão de Preços. Previsão de Geração. Previsão de Flexibilidade.
Ali	2023	Confiabilidade e acessibilidade energética. Redução de custos para os consumidores. Sustentabilidade ambiental. Envolvimento e capacitação comunitária.	X	Previsão da carga elétrica. Previsão dos preços da eletricidade. Previsão da flexibilidade de cargas específicas. Integração de incertezas nas previsões. Desenvolvimento de sistemas de previsão.

[Ref.]	Ano	Community Benefit	Cost Implementation	Forecast
Umar	2024	Independência energética local. Sustentabilidade e resiliência. Participação ativa da comunidade. Redução de custos. Transparência e segurança.	Transações em blockchain: 0,0005 USDT. Otimização da microgrid: 1993,63 USD. DR resultou em uma economia total de 715 USD.	X
Toderean	2023	Redução da pegada de carbono. Promoção da sustentabilidade local. Independência energética da comunidade. Resiliência energética local aumentada. Equilíbrio entre geração e consumo de energia. Criação de incentivos. Confiança e transparência com blockchain. Benefícios econômicos.	X	X
Giglio	2023	X	Painéis fotovoltaicos: 129.600 euros. Baterias de armazenamento: 570.000 euros. Manutenção anual dos painéis: 35 euros por kW. Diminuição de 7% ao ano no custo dos painéis. Retorno do investimento: 13 anos.	Previsão meteorológica Solcast API.
Nabavi	2021	X	Instalação de Sistemas Renováveis. Sistemas de Armazenamento de Energia. Integração Tecnológica. Operação e Manutenção. Energia da Rede. Relações à Incerteza e Intermittência.	Energia Eólica - DWT-LSTM. MAPE. DWT.

[Ref.]	Ano	Community Benefit	Cost Implementation	Forecast
Al-Ghaili	2023	X	X	NARX. NARNET. LSTM. TCN. MPC. Análise de Dados em Tempo Real.
Parvin	2021	X	X	ANN. LSTM. ARX. NARNET. ANFIS. MPC. NN-PC.
Kumar Maurya & Howard	2024	X	X	ANN. RNN. SVM. Análise de dados históricos e fatores externos. Previsão de padrões de geração de energia renovável.
Binyamin	2024	Redução dos custos energéticos. Fortalecimento da resiliência energética comunitária. Compartilhamento de excedentes energéticos. Incentivos para adoção de tecnologias limpas. Redução das emissões de carbono da comunidade. Criação de mercados locais de energia. Gestão de recursos energéticos locais. Estímulo à colaboração comunitária.	X	Previsão de geração de energia renovável. Estimativa de consumo energético doméstico. Padrões de consumo baseados em dados históricos. Estimativa de preços em tempo real. Análise de variação climática.
Conte	2022	Benefícios econômicos. Benefícios ambientais. Benefícios sociais. Otimização do uso de recursos energéticos. Incentivo ao uso de energias renováveis.	X	Previsão de geração de energia renovável. Previsão de procura energética agregada. Previsão de serviços comuns. Uso de TDNN, LSTM e CNN. Efeito das previsões em algoritmos de controlo preditivo.

[Ref.]	Ano	Community Benefit	Cost Implementation	Forecast
Ahmed	2024	X	X	Aumento dos resíduos sólidos municipais até 2050. Expansão do mercado de tecnologias baseadas em IA e IoT. Sistemas inteligentes para otimização de informação. Redução de emissões e custos operacionais por IoT. Monitorização em tempo real em smartcities.
Draz	2024	X	Flywheel Energy Storage System (FESS). Sistemas Híbridos (ex.: Solar e ESD). Otimização do Armazenamento para redução de custos.	X
Zhu	2024	Eficiência Energética e Sustentabilidade. Acessibilidade e Inclusão Social. Gestão e Planeamento Colaborativo. Segurança e Redução de Riscos. Formação Educativa e Tecnológica.	X	Previsão de Geração de Energia Fotovoltaica. Previsão de Geração de Energia Eólica. Previsão de Procura de Energia. Previsão de Preços de Carbono. Previsão e Diagnóstico de Falhas.
Reka	2024	X	X	Análise da DR em Smart Grids. Uso de ML para prever a carga e preços.Algoritmos de análise de consumo. Implementação de técnicas de aprendizagem. Comparação entre modelos preditivos.

[Ref.]	Ano	Community Benefit	Cost Implementation	Forecast
Antonopoulos	2020	X	X	Estimativa de consumo com machine learning. Modelos para prever preços de energia. Previsão de fontes renováveis. Previsão de carga com redes neurais. Métodos probabilísticos para a variabilidade energética.
Bennagi	2024	X	X	Modelos de previsão (ANNs e técnicas híbridas). Modelos baseados em CNN (velocidade do vento). Modelos de consumo energético (ARIMA e séries temporais). Irradiância solar e temperatura usando SVM e RF. Otimização da gestão de energia em eólicas com ML.