

**Faculdade de Engenharia da Universidade do Porto**



**Previsão de Produção Renovável e de Consumo  
Para Auxílio da Ferramenta de Gestão Energética  
Comunitária**

**Nuno Miguel Carvalho de Castro Teixeira Lopes**

VERSÃO FINAL

Mestrado em Engenharia Eletrotécnica e de Computadores

Orientador: Prof. Doutor João P. S. Catalão  
Coorientador: Prof. Doutor Gerardo J. Osório

Março 2024





# Abstract

The present research addresses the importance of forecasting renewable energy production and energy consumption, as a crucial tool, for effective energy management in communities. In the face of the increasing use of renewable sources such as solar and wind energy in power generation, accurate anticipation of production becomes essential to optimize the utilization of these resources.

This study emphasizes the relevance of community energy management, characterized by the integration of diverse energy sources to meet local demands. Reliable forecasting of renewable production and consumption enables efficient resource allocation, aiming to maximize self-sufficiency and reduce dependence on non-renewable sources.

This dissertation focuses on the study of an innovative hybrid model that combines the predictive capabilities of the Long-Short Term Memory (LSTM) model with the Holt-Winters model. The study highlights the complementarity between LSTM, known for its ability to capture complex temporal patterns, and the Holt-Winters model, capable of considering seasonal trends and cyclical variations. The combination of these models results in a hybrid system capable of efficiently handling the inherent complexity of renewable energy production and consumption.

The specific objective of the tool developed in this study was to provide an integrated approach to reliable forecast wind and solar energy production, as well as energy consumption. The results are expressed through the Mean Absolute Percentage Error (MAPE) for each specific case.

Considering the strategic importance of forecasting in decision-making, the research not only provides an advanced technical tool but also valuable insights for professionals and managers involved in the management of communities and renewable energy systems. The successful implementation of this hybrid model has the potential to drive advancements in the transition to a more sustainable and efficient energy matrix.

**Keywords:** Renewable Production Forecasting, LSTM, Holt-Winters, Energy Efficiency.



# Resumo

A presente pesquisa aborda a importância das ferramentas de previsão para a previsão da produção renovável e do consumo de energia, para a eficaz gestão energética em comunidades. Diante da crescente adoção de fontes renováveis, como a energia solar e eólica, na produção de energia, a previsão eficaz da produção torna-se fundamental para otimizar a utilização desses recursos.

Este estudo destaca a importância da gestão energética comunitária, caracterizada pela integração de diversas fontes de energia para atender às procura locais. A previsão fidedigna da produção renovável e do consumo possibilita uma alocação eficiente de recursos, visando a maximização da autossuficiência e a redução da dependência das fontes não renováveis.

Esta dissertação centra-se no estudo de um modelo híbrido inovador que combina as capacidades preditivas do modelo *Long-Short Term Memory* (LSTM) com o modelo *Holt-Winters*. O estudo destaca a complementaridade entre o LSTM, reconhecido por sua habilidade em capturar padrões temporais complexos e o modelo de *Holt-Winters*, capaz de considerar tendências sazonais e variações cíclicas. A combinação destes modelos resulta num sistema híbrido capaz de lidar eficientemente com a complexidade inerente à produção e consumo de energia renovável.

O objetivo concreto da ferramenta desenvolvida neste estudo foi proporcionar uma abordagem integrada para prever a produção de energia eólica, solar e o consumo de forma eficiente. Os resultados obtidos são expressos por meio de Erro Percentual Absoluto Médio (MAPE) para os três casos de previsão mencionados.

Ao considerar a importância estratégica da previsão na tomada de decisões, a pesquisa oferece não apenas uma ferramenta técnica avançada, mas também *insights* valiosos para profissionais e gestores envolvidos na gestão de comunidades e sistemas de energias renováveis. A implementação bem-sucedida desse modelo híbrido tem o potencial de impulsionar avanços práticos na transição para uma matriz energética mais sustentável e eficiente.

**Palavras-chave:** Previsão de Produção Renovável, LSTM, *Holt-Winters*, eficiência energética.



# Agradecimentos

Na medida que esta dissertação marca o término de uma fase significativa na minha jornada académica, quero expressar o meu profundo agradecimento a todos que contribuíram para este momento.

Em primeiro lugar, agradeço ao Prof. João P. S. Catalão por me proporcionar a oportunidade de aprofundar os conhecimentos no domínio das ferramentas de previsão, e da sua importância na tomada de decisão, aplicáveis em ferramentas de interesse para a sociedade. Ao Prof. Gerardo J. Osório, um agradecimento especial, pelo tempo dispensado no acompanhamento deste trabalho.

Aos professores, colegas e toda a comunidade da Faculdade de Engenharia da Universidade do Porto (FEUP), agradeço pela rica experiência académica proporcionada ao longo destes anos. Em especial ao Prof. Cláudio Monteiro que gentilmente forneceu os dados para a previsão utilizados nesta dissertação, oriundos da unidade curricular Técnicas de Previsão.

À minha família, em especial aos meus pais e irmã, agradeço por todo o apoio incondicional que foi dado nesta etapa tão desafiadora.

Aos meus amigos que me ajudaram nos momentos menos bons e me incentivaram a nunca desistir.

Em suma, agradeço a todos, que de alguma forma, fizeram parte desta jornada. Todo o apoio foi fundamental, e esta conquista também é deles.

A todos, Obrigado.

Nuno Lopes.



# Índice

|                                                                                                 |           |
|-------------------------------------------------------------------------------------------------|-----------|
| Abstract.....                                                                                   | i         |
| Keywords: .....                                                                                 | i         |
| Resumo .....                                                                                    | iii       |
| Palavras-chave: .....                                                                           | iii       |
| Agradecimentos .....                                                                            | v         |
| Lista de Figuras .....                                                                          | ix        |
| Lista de Tabelas .....                                                                          | xi        |
| Abreviaturas e Símbolos .....                                                                   | xiii      |
| Lista de Abreviaturas .....                                                                     | xiii      |
| Lista de Símbolos para os Modelos de Previsão .....                                             | xiii      |
| Lista de Símbolos para o Modelo do Sistema de Gestão de Energia na Comunidade Energética .....  | xiv       |
| Lista de Variáveis para os Modelos de Previsão .....                                            | xiv       |
| Lista de Variáveis para o Modelo do Sistema de Gestão de Energia na Comunidade Energética ..... | xv        |
| <b>1. Introdução .....</b>                                                                      | <b>1</b>  |
| 1.1 - Enquadramento .....                                                                       | 1         |
| 1.2 - Motivação .....                                                                           | 1         |
| 1.3 - Organização da Dissertação .....                                                          | 1         |
| 1.4 - Material Utilizado.....                                                                   | 2         |
| <b>2. Estado da Arte .....</b>                                                                  | <b>3</b>  |
| 2.1 <i>Smart Grid</i> .....                                                                     | 3         |
| 2.2 <i>Demand-Side Management and Demand Response</i> .....                                     | 5         |
| 2.3 Recursos Energéticos Distribuídos .....                                                     | 7         |
| 2.4 Geração Fotovoltaica Residencial .....                                                      | 8         |
| 2.5 Geração Eólica Residencial .....                                                            | 9         |
| 2.6 Flexibilidade no Sistema Elétrico .....                                                     | 11        |
| 2.7 Veículos Elétricos .....                                                                    | 13        |
| 2.8 <i>Smart Homes and Energy Communities</i> .....                                             | 14        |
| 2.9 Técnicas de Previsão e Trabalhos Relacionados .....                                         | 15        |
| 2.10 Redes Neurais .....                                                                        | 16        |
| <b>3. Metodologia de Previsão .....</b>                                                         | <b>19</b> |
| 3.1 Modelo de Previsão de <i>Holt-Winters</i> .....                                             | 19        |
| 3.2 <i>Long Short-Term Memory Network (LSTM)</i> .....                                          | 20        |
| 3.3 Critérios de Quantificação do Erro .....                                                    | 22        |
| 3.4 Formulação Matemática Generalizada de Otimização .....                                      | 23        |
| 3.5 Sistema de Gestão de Energia Residencial e Restrições .....                                 | 24        |
| 3.6 Dados do Modelo de Previsão e do Sistema de Gestão de Energia Comunitária.....              | 27        |
| <b>4. Resultados .....</b>                                                                      | <b>31</b> |
| 4.1 Resultados do Modelo de Previsão.....                                                       | 31        |
| 4.2 Resultados do Modelo de Sistema de Gestão de Energia Comunitária.....                       | 36        |
| <b>Conclusões .....</b>                                                                         | <b>41</b> |
| <b>Referências .....</b>                                                                        | <b>43</b> |



# Lista de Figuras

|                                                                                        |    |
|----------------------------------------------------------------------------------------|----|
| Figura 2.1 - Visão de uma SG. ....                                                     | 3  |
| Figura 2.2 - Comparação entre a rede convencional e a SG.....                          | 4  |
| Figura 2.3 - Resumo dos impactos e performances da SG. ....                            | 5  |
| Figura 2.4 - Técnicas DSM para suavização do pico de carga. ....                       | 6  |
| Figura 2.5 - Definindo o DSM. ....                                                     | 7  |
| Figura 2.6 - Tipos de programas de DR. ....                                            | 7  |
| Figura 2.7 - Sistemas elétricos: presente e futuro.....                                | 8  |
| Figura 2.8 - Participação na produção de eletricidade renovável por tecnologia.....    | 10 |
| Figura 2.9- Tipos de Turbina Eólica.....                                               | 10 |
| Figura 2.10- Classificação das tecnologias BESS pela forma de energia armazenada. .... | 12 |
| Figura 2.11- Arquitetura de rede V2G. ....                                             | 13 |
| Figura 3.1- Modelo de <i>Holt-Winters</i> . ....                                       | 19 |
| Figura 3.2- Esquema do LSTM. ....                                                      | 21 |
| Figura 3.3- Fluxograma do código para a previsão. ....                                 | 22 |
| Figura 3.4- Arquitetura HEMS. ....                                                     | 25 |
| Figura 3.5- Cenários de produção fotovoltaica considerados no sistema base. ....       | 28 |
| Figura 3.6- Tarifas diárias de referência, fornecidas pela EDP. ....                   | 29 |
| Figura 4.1- Histórico dos 14 dias da potência eólica. ....                             | 31 |
| Figura 4.2- Previsão LSTM e erros RMSE na previsão da potência eólica. . ....          | 32 |
| Figura 4.3- Previsão de <i>Holt-Winters</i> na previsão eólica. ....                   | 32 |
| Figura 4.4- Previsão objetivo da potência eólica. ....                                 | 32 |
| Figura 4.5- Histórico dos 14 dias da potência solar.....                               | 33 |
| Figura 4.6- Previsão LSTM e erros RMSE na previsão da potência solar.....              | 34 |
| Figura 4.7- Previsão de <i>Holt-Winters</i> na previsão solar.....                     | 34 |
| Figura 4.8- Previsão objetivo da potência solar.....                                   | 34 |
| Figura 4.9- Histórico dos 14 dias do Consumo. ....                                     | 35 |
| Figura 4.10- Previsão LSTM e erros RMSE na previsão do consumo. ....                   | 36 |

|                                                                                                                                                                                                    |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Figura 4.11- Previsão de <i>Holt-Winters</i> na previsão do consumo. ....                                                                                                                          | 36 |
| Figura 4.12- Previsão objetivo do consumo. ....                                                                                                                                                    | 36 |
| Figura 4.13- Soma das cargas deslocáveis durante as 24 horas, considerando o caso base. ...                                                                                                        | 37 |
| Figura 4.14- Soma das cargas fixas durante as 24 horas. ....                                                                                                                                       | 37 |
| Figura 4.15- Procura total de carga no caso base sem o HEMS (preto) e a procura de carga programada após o HEMS (vermelho tracejada e azul tracejado para a casa 4 e casa 5, respetivamente). .... | 38 |
| Figura 4.16- Injeção de energia da rede para a casa(azul) e da casa para a rede (laranja) na casa 4. ....                                                                                          | 39 |
| Figura 4.17- Injeção de energia da rede para a casa(azul) e da casa para a rede (laranja) na casa 5. ....                                                                                          | 39 |
| Figura 4.18- Transações P2P na Comunidade Energética composta por 5 casas.....                                                                                                                     | 39 |

# Lista de Tabelas

|                                                                                    |    |
|------------------------------------------------------------------------------------|----|
| Tabela 2.1- Comparação de Baterias .....                                           | 12 |
| Tabela 3.1- Parâmetros considerados nos sistemas de armazenamento de energia ..... | 29 |
| Tabela 3.2- Tarifários Considerados .....                                          | 30 |
| Tabela 3.3- Cargas Deslocáveis consideradas para o sistema em estudo.....          | 30 |
| Tabela 4.1- Tentativas no modelo de previsão com a energia eólica. ....            | 31 |
| Tabela 4.2- Tentativas no modelo de previsão com a energia solar. ....             | 33 |
| Tabela 4.3- Tentativas no modelo de previsão com o consumo. ....                   | 35 |



# Abreviaturas e Símbolos

## Lista de Abreviaturas

|       |                                                 |
|-------|-------------------------------------------------|
| ARIMA | <i>Autoregressive Integrated Moving Average</i> |
| BESS  | <i>Battery Energy Storage System</i>            |
| CNN   | Redes Neurais Convolucionais                    |
| DR    | <i>Demand Response</i>                          |
| DSM   | <i>Demand Side Management</i>                   |
| HAWT  | <i>Horizontal Axle Wind Turbine</i>             |
| HEMS  | Sistema de Gestão de Energia Residencial        |
| HW    | <i>Holt-Winters</i>                             |
| IBP   | Programas Baseados em Incentivos                |
| LSTM  | <i>Long Short-Term Memory</i>                   |
| MAE   | Erro Médio Absoluto                             |
| MAPE  | Erro Percentual Absoluto Médio                  |
| MILP  | <i>Mixed-Integer Linear Programming</i>         |
| MLP   | <i>Multilayer Perceptron</i>                    |
| MSE   | Erro Quadrático Médio                           |
| PBP   | Programas Baseados em Preços                    |
| PV    | <i>Photovoltaics Panel</i>                      |
| RED   | Recursos Energéticos Distribuídos               |
| RFID  | <i>Radio frequency identification</i>           |
| RMSE  | Raiz do Erro Quadrático Médio                   |
| RNN   | Redes Neurais Recorrentes                       |
| SG    | <i>Smart Grid</i>                               |
| SH    | <i>Smart Home</i>                               |
| TOU   | <i>Time-of-Use</i>                              |
| V2G   | <i>Vehicle-to-Grid</i>                          |
| VAWT  | <i>Vertical Axle Wind Turbine</i>               |
| VE    | Veículo Elétrico                                |

## Lista de Símbolos para os Modelos de Previsão

|                         |                                           |
|-------------------------|-------------------------------------------|
| $\alpha, \gamma, \beta$ | Parâmetros de suavização                  |
| $\sigma(\cdot)$         | Função sigmoide para o Modelo de Previsão |
| $n$                     | Número total de observações               |

## Lista de Símbolos para o Modelo do Sistema de Gestão de Energia na Comunidade Energética

|                 |                                                                                  |
|-----------------|----------------------------------------------------------------------------------|
| $\sigma(\cdot)$ | Função sigmoide no modelo de gestão de energia na comunidade energética.         |
| $N$             | Número total de elementos na amostra.                                            |
| $T$             | Número total de períodos.                                                        |
| $NA$            | Número total de iterações ou equipamentos.                                       |
| $NS$            | Número total dos sistemas de armazenamento de energia.                           |
| $E_o$           | Quantidade inicial de energia armazenada no sistema de armazenamento de energia. |
| $E_{24}$        | Quantidade final de energia armazenada no sistema de armazenamento de energia.   |
| $P_{max,car}$   | Potência máxima de carga permitida pelo sistema de armazenamento de energia.     |
| $P_{max,des}$   | Potência máxima de descarga permitida pelo sistema de armazenamento de energia.  |
| $\eta_{car}$    | Eficiência de carga do sistema de armazenamento de energia.                      |
| $\eta_{des}$    | Eficiência de descarga do sistema de armazenamento de energia.                   |
| $E_{max}$       | Capacidade máxima de armazenamento de energia do sistema.                        |
| $E_{min}$       | Capacidade mínima de armazenamento de energia do sistema.                        |

## Lista de Variáveis para os Modelos de Previsão

|                      |                                                    |
|----------------------|----------------------------------------------------|
| $l_t$                | Nível.                                             |
| $b_t$                | Tendência.                                         |
| $S_t$                | Sazonalidade.                                      |
| $m$                  | Período de Sazonalidade.                           |
| $F_{t+m}$            | Previsão para $m$ períodos à frente no tempo $t$ . |
| $S_{t-s}$            | Sazonalidade passada.                              |
| $\tilde{c}_t$        | Memória candidata.                                 |
| $\tanh$              | Função tangente hiperbólica.                       |
| $W_c, W_i, W_o, W_f$ | Pesos Ponderados.                                  |
| $h_{t-1}$            | Valor da saída anterior.                           |
| $b_c, b_i, b_o, b_f$ | Valor de ajuste.                                   |
| $x_t$                | Entrada atual.                                     |
| $i_t$                | Cálculo da porta de entrada.                       |
| $f_t$                | Cálculo da porta de avaliação.                     |
| $c_t$                | Célula de Memória.                                 |
| $c_{t-1}$            | Valor anterior da célula de memória.               |

|              |                                                  |
|--------------|--------------------------------------------------|
| $o_t$        | Cálculo da porta de saída.                       |
| $h_t$        | Cálculo da Saída da Unidade LSTM.                |
| $\tanh(c_t)$ | Tangente hiperbólica da célula de memória atual. |
| MAE          | Erro Médio Absoluto.                             |
| $\hat{y}_i$  | Vetor de valor/perfil previsto.                  |
| $y_i$        | Valores reais.                                   |
| MSE          | Erro Quadrático Médio.                           |
| RMSE         | Raiz do Erro Quadrático Médio.                   |
| MAPE         | Erro Percentual Absoluto Médio.                  |

## Lista de Variáveis para o Modelo do Sistema de Gestão de Energia na Comunidade Energética

|                                    |                                                                                             |
|------------------------------------|---------------------------------------------------------------------------------------------|
| $w$                                | Variável de decisão.                                                                        |
| $\pi_t^{G2H}, \pi_t^{H2G}$         | Tarifas de energia do tipo <i>Time-of-Use</i> para importação e exportação, respetivamente. |
| $P_{w,t}^{G2H}, P_{w,t}^{H2G}$     | Potência importada e exportada entre a rede e a casa, respetivamente.                       |
| $\Delta t$                         | Duração do intervalo de tempo.                                                              |
| $STUP_{w,i,t}$                     | Indica se o dispositivo $i$ for iniciado no intervalo de tempo $t$ no cenário $w$ .         |
| $SHDN_{w,i,t}$                     | Indica se o dispositivo $i$ for desligado no intervalo de tempo $t$ no cenário $w$ .        |
| $C_i^{ST}$                         | Custo de arranque (ou de ligar) do dispositivo $i$ .                                        |
| $C_i^{SD}$                         | Custo de paragens (ou de desligar) do dispositivo $i$ .                                     |
| $DI_{w,i}$                         | Índice de Desconforto para o dispositivo $i$ .                                              |
| $D_{w,t}^{Shift}$                  | Quantidade de carga deslocável no intervalo de tempo $t$ .                                  |
| $S_{w,i,t}$                        | Status operacional do dispositivo no intervalo $t$ .                                        |
| $P_i$                              | Potência nominal do dispositivo $i$ .                                                       |
| $LB_{i,s}, UB_{i,s}$               | Limites inferior e superior para o intervalo de operação padrão.                            |
| $LB_{i,b}, UB_{i,b}$               | Limites inferior e superior para o intervalo de operação deslocado.                         |
| $T_i$                              | Número total de intervalos para cada dispositivo $i$ .                                      |
| $B_{w,i,t}$                        | Status de uso preferido do usuário no intervalo $t$ .                                       |
| $P_{w,t}^{PV}$                     | Potência de produção fotovoltaica no intervalo $t$ .                                        |
| $D_{w,t}^{fix}$                    | Carga fixa no intervalo $t$ .                                                               |
| $P_{w,j,t}^{Car}, P_{w,j,t}^{Des}$ | Potência de carga e de descarga do BESS no intervalo $t$ , respetivamente.                  |
| $I_{w,j,t}^{Car}, I_{w,j,t}^{Des}$ | Variáveis binárias para carga e descarga do BESS.                                           |
| $P_j^{Car,max}$                    | Capacidade máxima de carga do BESS.                                                         |
| $P_j^{Des,max}$                    | Capacidade máxima de descarga do BESS.                                                      |
| $E_{w,j,t}$                        | Quantidade de energia armazenada no BESS no intervalo $t$ .                                 |
| $\eta_j^{Car}, \eta_j^{Des}$       | Eficiências de carga e descarga do BESS.                                                    |
| $E_j^{min}, E_j^{max}$             | Limite mínimo e máximo para a energia armazenada no BESS, respetivamente.                   |



# **1. Introdução**

## **1.1 - Enquadramento**

A eficiente integração de fontes de energia renovável é um desafio essencial na transição para uma matriz energética mais sustentável. O aumento da participação de energia como a solar e a eólica requer estratégias inovadoras para otimizar o seu uso. Nesse contexto, as previsões desempenham um papel crucial na gestão eficaz dessas fontes, possibilitando uma alocação mais eficiente de recursos.

A implementação de redes inteligentes e comunidades energéticas surge como uma solução eficaz para os desafios da integração de energias renováveis. As redes inteligentes permitem a coordenação dinâmica e a distribuição eficiente de energia, enquanto as comunidades energéticas promovem a colaboração local na produção, consumo e armazenamento de energia. A previsão desempenha um papel central nesse ecossistema, orientando as decisões operacionais e estratégicas para maximizar a autossuficiência e minimizar a dependência de fontes não renováveis.

## **1.2 - Motivação**

A motivação para este trabalho surge da compreensão da importância crucial das ferramentas de previsão durante a transição energética. Dada a dinâmica e intermitência das energias renováveis, a capacidade de antecipar a produção e o consumo torna-se essencial para uma gestão eficaz. A falta de previsões fidedignas pode resultar em subutilização ou sobrecarga da rede, comprometendo a confiabilidade do fornecimento de energia.

A crescente relevância das ferramentas de previsão motiva a investigação aprofundada deste tema, com o propósito de desenvolver uma ferramenta inovadora e eficaz. A compreensão das nuances e desafios associados à previsão nas energias renováveis impulsiona o desenvolvimento de abordagens mais inovadoras, contribuindo para a sustentabilidade do sistema energético.

## **1.3 - Organização da Dissertação**

Esta dissertação está organizada em cinco capítulos que abordam diversos aspetos relacionados ao tema central. No Capítulo 1 é apresentado um breve contexto sobre a importância da previsão nas energias renováveis. Além disso, foram delineados os objetivos, questões de pesquisa e motivações que orientam o desenvolvimento desta dissertação.

No Capítulo 2 é realizada uma revisão sistemática da literatura relacionada com os temas abordados na dissertação, oferecendo uma síntese do conhecimento adquirido a partir de diversas fontes.

No Capítulo 3 é apresentado a fundamentação matemática do trabalho desenvolvido, tanto para a criação do modelo de previsão tanto para a comunidade de energia renovável. O foco principal é a criação de um modelo híbrido de previsão com o objetivo de prever o dia seguinte aos dados selecionados.

No Capítulo 4 são apresentados os resultados obtidos no estudo do modelo de previsão e os resultados para a comunidade de energia com uma análise comparativa de diferentes cenários.

Finalmente, o Capítulo 5 apresenta as principais conclusões do trabalho, bem como propostas para futuras pesquisas.

A notação, simbologia e abreviações utilizadas ao longo do documento são as normalmente e cientificamente aceite. As equações, tabelas e figuras são numeradas relativamente ao capítulo em que se encontram e a sua numeração crescente no mesmo capítulo, reiniciando a numeração no início de um novo capítulo.

## **1.4 - Material Utilizado**

A formulação e resolução do modelo de previsão foi realizado com recurso ao *MATLAB*. Para a coleta de dados, foram empregues folhas de cálculo do *Microsoft Excel* e documentos do *Microsoft Word*.

Em relação à formulação, modelação e resolução do problema de otimização de energia no sistema comunitário foi utilizado o ambiente de programação em *Python*, juntamente com as bibliotecas especializadas em otimização e visualização de dados. A compilação final desta dissertação foi realizada no formato *Portable Document Format* (PDF).

O trabalho de dissertação envolveu a utilização de dois computadores distintos, um para as atividades de previsão e outro para a gestão da comunidade de energia, garantido uma abordagem abrangente e eficaz devido às limitações das licenças das *ToolBoxes* específicas do *MATLAB* instaladas num dos computadores, e à necessidade de utilizar o otimizador *Gorubi* em combinação com o *Python* em ambiente *Jupyter Notebook*, instalado no outro computador, ambos com características e especificações distintas.

## 2. Estado da Arte

### 2.1 Smart Grid

Atualmente, o setor de energia enfrenta desafios significativos, como o desperdício de eletricidade devido a dispositivos ineficientes, à falta de tecnologias inteligentes, à monitorização e comunicação intermitentes. Além disso, as redes elétricas existentes precisam lidar com questões de segurança, privacidade e a integração de diversas fontes de energia renovável. Para superar esses desafios, a implementação de redes elétricas inteligentes, também conhecidas como *Smart Grid* (SG), é vista como a solução ideal. Na Figura 2.1 é apresentada uma visão esquemática de uma SG, onde são destacadas as principais características e componentes desta.

O termo “*Smart Grid*” ganhou maior destaque a partir de 2005, graças à contribuição [2]. No entanto, é possível que o termo tenha sido utilizado anteriormente e tenha recebido várias definições ao longo do tempo. Uma característica comum entre as diversas definições se encontra relacionada com a aplicação de dispositivos eletrônicos que processam dados digitalmente, e possibilitam a comunicação, tornando a gestão da informação e o fluxo de dados, elementos cruciais do conceito de uma SG [3].

Conforme afirmado em [4], a SG é uma rede elétrica que utiliza fluxo bidirecional, ao contrário da rede elétrica tradicional, que é estática e unidirecional, com a energia fluindo apenas dos pontos de produção para os consumidores. Destaca-se o papel importante do medidor inteligente (*smart meter*) no contexto de uma SG, cujas capacidades incluem a medição do consumo de energia dos utilizadores, fornecendo dados adicionais à entidade vendedora ou ao operador do sistema para uma monitorização e faturação mais eficientes. A Figura 2.2 compara a rede convencional com a SG, destacando as diferenças fundamentais entre os dois sistemas.




Figura 2.1-Visão de uma SG [1].

A SG oferece vantagens substanciais para empresas do setor energético, para os consumidores e para o Ambiente. Para as empresas de energia, a automação da rede proporciona uma gestão da procura mais eficiente, redução de custos de infraestrutura e uma abordagem estratégica aprimorada para o planeamento. As redes inteligentes permitem resolver falhas de transmissão sem a necessidade de investir em transmissores de emergência dispendiosos, conferindo maior robustez ao sistema.

Para os utilizadores, a SG permite economias de energia e uma distribuição mais confiável, graças ao acesso em tempo real às informações da rede e à diminuição nos custos de distribuição. A capacidade de monitorizar e ajustar o consumo de energia em tempo real proporciona aos consumidores maior controlo sobre seus gastos e promove uma utilização mais eficiente dos recursos.

Sob a ótica ambiental, embora os benefícios nem sempre sejam quantificáveis a curto prazo, a SG desempenha um papel crucial na transição para fontes de energia mais limpas e eficientes, contribuindo para a redução de emissões de poluentes. Ao otimizar a gestão da procura e integrar fontes renováveis de forma mais eficaz, a SG desempenha um papel vital na promoção da sustentabilidade ambiental [6]. A Figura 2.3 oferece um resumo dos impactos e performances da SG, aprofundando os benefícios que estes sistemas trazem para o setor de energia, os consumidores e o meio ambiente.




Figura 2.2-Comparação entre a rede convencional e a SG, adaptado de[5].




Figura 2.3-Resumo dos impactos e performances da SG, adaptado de [6].

## 2.2 Demand-Side Management and Demand Response

O *Demand-Side Management* (DSM) desempenha um papel crucial na modelagem da futura rede elétrica, abrangendo o planeamento, implementação e monitorização de atividades dos serviços públicos para incentivar o uso de eletricidade pelos clientes, visando realizar alterações desejadas no perfil da carga concessionária [7]. As mudanças de perfil de carga, resultantes pelas estratégias de DSM podem ser classificadas em seis categorias [8], e podem ser visualizadas na Figura 2.4.

1. **Redução do pico (*Peak Clipping*):** Envolve a diminuição da carga durante os horários de pico do consumo de eletricidade.
2. **Preenchimento de Vales (*Valley Filling*):** Envolve o aumento de carga durante os períodos fora de pico.
3. **Deslocamento de Carga (*Load Shifting*):** Envolve a transferência de cargas do horário de pico para os horários fora do pico.
4. **Conservação Energética (*Load Reduction*):** Envolve melhorar a utilização de energia pela redução da carga a longo prazo.
5. **Crescimento Estratégico da Carga (*Strategic Load Growth*):** Envolve um aumento no consumo de energia dentro de certo limite
6. **Curvas de Carga Flexível (*Flexible Load Shaping*):** Envolve a redistribuição de carga por vários intervalos de tempo.




Figura 2.4- Técnicas DSM para suavização do pico de carga, adaptado de [7].

A principal função do DSM é aprimorar a eficiência do sistema elétrico ao otimizar o uso da eletricidade. Para alcançar esse objetivo, são empregues diversas estratégias e técnicas que procuram moldar o comportamento dos consumidores finais em relação ao uso da energia. Entre essas estratégias, destacam-se a eficiência energética e os *smart meter*, mencionados anteriormente, sendo uma das mais importantes, que será analisada com mais detalhes a seguir, o *Demand Response*.

Por exemplo em [9] são explorados os desafios e os obstáculos associados à implementação do DSM, abordando desde a falta de infraestruturas até à necessidade de uma compreensão mais clara dos benefícios e a criação de incentivos adequados no mercado de energia. A Figura 2.5 apresenta uma visão geral das três categorias principais de DSM.

O *Demand Response* (DR) é a prática de ajustar os padrões de consumo de eletricidade em resposta a sinais de mercado ou solicitações de operadores do sistema elétrico. Tem como objetivo equilibrar a oferta e a procura de eletricidade, especialmente em horas de pico ou em situações críticas. A Figura 2.6, ilustra os diferentes tipos de programas de DR, dividindo-os em dois tipos principais de programas: Programas baseados em Incentivos (IBP) e Programas baseados em Preços (PBP). Os programas IBP são subdivididos em Programas Clássicos e Programas Baseados no Mercado, enquanto o PBP utiliza tarifas dinâmicas dependentes do mercado.

Os programas IBP clássicos incluem programas de Controle Direto de Carga (DLC) e Programas de Carga Interruptível/Cortável. Já os IBP baseados no Mercado abrangem programas de oferta de Licitação sob Procura, Programas de Resposta de Emergência, Mercado de Capacidade e Mercado de Serviços Auxiliares. Os programas PBP têm como objetivo reduzir a curva de procura por meio de tarifas dinâmicas, ou seja, reduzir a procura elétrica durante as horas de pico e incentivar o consumo nas horas de menor procura/fora de pico.

As tarifas PBP incluem a Tarifa de Uso Horário (TOU), os Preços em Tempo Real (RTP), a Tarifa de Pico Crítico (CPP), os Preços de Dias Extremos (EDP) e a Tarifa de Pico Crítico de Dias Extremos (ED-CPP). Em [12] são discutidos os benefícios potenciais e os custos associados aos programas DR. Em termos de benefícios, os autores destacam as vantagens para os participantes, que podem economizar em faturas, principalmente durante os períodos de pico, além de experimentarem uma confiabilidade mais eficiente e impactos positivos no meio ambiente.




Figura 2.5-Definindo o DSM, adaptado de [10].




Figura 2.6-Tipos de programas de DR, adaptado de [11].

## 2.3 Recursos Energéticos Distribuídos

Em [13], os investigadores definem os Recursos Energéticos Distribuídos (RED) como “sistemas de geração de eletricidade localizados e ou próximos aos utilizadores finais. Esses sistemas têm a capacidade de fornecer simultaneamente eletricidade, arrefecimento e aquecimento para atender às procuras dos utilizadores locais”.

Em [14], é abordado o recente crescimento na implementação de RED devido à sua capacidade comprovada de reduzir as emissões de gases de efeito estufa e diminuir os custos associados à eletricidade. Os autores ainda ressaltam que os REDs desempenham um papel crucial ao auxiliar os consumidores finais na redução da dependência da rede elétrica principal como principal fonte de energia, resultando numa redução nos custos de aquisição de eletricidade.

No contexto do estudo [15], são exploradas as vantagens e desvantagens de RED. Destaca-se que os RED localizados próximos aos centros de carga têm o potencial de reduzir os fluxos de energia nas linhas, melhorando o perfil de tensão e minimizando as perdas nas linhas. No entanto, é enfatizado que uma integração inadequada de RED pode acarretar impactos negativos, como o aumento nas perdas de linhas ou problemas na qualidade de tensão.

Estes estudos convergem para a conclusão de que os RED constituem uma solução promissora para aprimorar a eficiência energética, diminuir os custos e atenuar os impactos ambientais vinculados à produção de eletricidade.




Figura 2.7-Sistemas elétricos: presente e futuro, conforme descrito em [16].

## 2.4 Geração Fotovoltaica Residencial

Em [17] é abordado a crescente exaustão dos recursos de combustíveis fósseis e as preocupações ambientais em constante ascensão, impulsionando uma pesquisa intensificada por alternativas energéticas. Nesse cenário, a energia solar destaca-se como um elemento central, sendo reconhecida como uma fonte alternativa crucial devido ao seu rápido desenvolvimento e à sua capacidade inata de reduzir o consumo de combustíveis fósseis, otimizando a estrutura energética e mitigando os impactos da poluição ambiental.

Apesar das vantagens evidentes, os autores ressaltam desvantagens intrínsecas nos sistemas de energia solar, derivadas da sua natureza imprevisível e da elevada dependência das condições atmosféricas. A abordagem desses desafios explora diversas estratégias que visam superar a variabilidade inerente da energia solar, com ênfase na coordenação eficiente em vários níveis, desde o design até a operação prática dos sistemas.

Em [18], é abordado a transição para sistemas de energia renovável, com destaque para a produção fotovoltaica residencial. Sendo enfatizado o crescimento exponencial dessa produção, especialmente em residências, como uma resposta significativa à procura da sustentabilidade. Embora se considere que os governos desempenhem um papel vital, é dito que o comportamento das famílias se torna decisivo no sucesso das iniciativas de expansão do reaproveitamento da energia solar. Apesar do reconhecimento global, a compreensão do comportamento da adoção da produção fotovoltaica residencial apresenta-se ainda como um obstáculo.

## **2.5 Geração Eólica Residencial**

Em [19], é afirmado que a energia eólica emerge como uma fonte crucial, destacando-se a sua competitividade tanto ambiental como económica, desempenhando um papel significativo na abordagem dos desafios globais associados à energia limpa e ao desenvolvimento sustentável diante das mudanças climáticas. Desde a primeira crise do petróleo, a energia eólica foi reconhecida como uma abordagem que aproveita os recursos endógenos, promovendo a independência energética, segurança e a descentralização do sistema de energia.

Em [20], é concluído que há uma previsão notável de expansão na capacidade de aproveitamento da energia renovável nos próximos anos. Neste cenário, a energia eólica e a energia solar fotovoltaica, mencionada anteriormente, devem liderar esse crescimento, representando 95% da expansão global das fontes renováveis. As previsões à data de 2023 sobre energias limpas apontam que:

- Até 2024, a produção combinada de energia eólica e solar fotovoltaica superará a produção hidroelétrica;
- Em 2025, as energias renováveis ultrapassarão o carvão como a principal fonte de produção de eletricidade;
- Entre 2025 e 2026, tanto a energia eólica quanto a solar fotovoltaica ultrapassarão a produção nuclear de eletricidade;
- Até 2028, as fontes de energia renovável representarão mais de 42% da produção global de eletricidade, com a energia eólica contribuindo com aproximadamente 12%.

A tendência apontada pelas previsões é observada na Figura 2.8, que respeita ao aumento da participação na produção de energia eólica e pela combinação de todas as energias renováveis.

Em [21] são discutidos os dois principais tipos de turbina eólica: as de eixo horizontal (*HAWT*) e as de eixo vertical (*VAWT*). Sendo destacado que as turbinas *HAWTs* são amplamente utilizadas em parques eólicos de grande escala. Mas é argumentado que, em larga escala, as *VAWTs* podem oferecer uma maior eficiência devido às cargas gravitacionais alternadas que afetam as *HAWTs*. Entre as vantagens das *VAWTs*, é destacado a dispensa de alinhamento constante com a direção do vento. Além disso, as *VAWT* são mecanicamente e estruturalmente mais capazes de suportar ventos mais fortes, o que oferece uma potencial vantagem em termos de segurança operacional durante condições de ventos fortes. A Figura 2.9, mostra os dois tipos de turbina eólica referidos.




Figura 2.8-Participação na produção de eletricidade renovável por tecnologia, retirado de [20].




Figura 2.9 -Exemplos de Turbinas Eólicas, [22].

## 2.6 Flexibilidade no Sistema Elétrico

Em [23] é explorada a crescente importância dos sistemas de armazenamento de energia baseado em baterias (BESS) diante do rápido crescimento populacional global e das transformações nos padrões de consumo, fatores que tem impulsionado significativamente o aumento no consumo de energia e eletricidade nas últimas décadas. O estudo destaca a imperativa necessidade do armazenamento de energia como uma solução para os desafios relacionados ao desequilíbrio entre produção e procura, bem como para lidar com as flutuações diárias e sazonais das fontes de energia renováveis. Os métodos de armazenamento de energia são classificados em cinco categorias: química, eletroquímica, elétrica, mecânica e térmica.

Em [24] é destacado o papel crucial do BESS, que consiste na conversão de energia elétrica numa forma armazenável para posterior reconversão quando necessária. O sistema de armazenamento de energia é considerado como uma abordagem promissora para operação de redes elétricas e o equilíbrio de carga, apresentando diversas propostas para dimensionamento, tais como, atender às procuras de pico, gerir a energia ao longo do tempo, mitigar a intermitência das fontes renováveis e melhorar a qualidade/confiabilidade da energia. Apesar dos benefícios potenciais do BESS para a operação do sistema de energia, são destacados desafios significativos para a sua implementação, incluindo a seleção da tecnologia adequada, a avaliação precisa dos benefícios técnicos e económicos e a diminuição de custos na aplicação efetiva.

Existem diversos métodos para categorizar as diferentes tecnologias de BESS, levando em consideração as suas funções, tempos de resposta e durações adequadas para o armazenamento. Os métodos adotados são distinguidos pela forma de energia armazenada, conforme exemplificado na Figura 2.11: a mecânica (armazenamento hidroelétrico por bombeamento, armazenamento de energia por ar comprimido e volante de inércia), a eletroquímica (baterias recarregáveis convencionais e baterias de fluxo), a elétrica (condensadores, supercondensadores e armazenamento magnético supercondutor), a termoquímica (combustíveis solares), a química (armazenamento de hidrogénio com células a combustível) e o armazenamento por energia térmica (armazenamento de calor sensível e armazenamento de calor latente).

Em [25], é afirmado que o armazenamento de energia por meio de baterias, conhecido como *Battery Energy Storage Systems* (BESS), tem atraído considerável atenção devido às suas vantagens distintas, como resposta rápida, controlabilidade e independência geográfica. Além disso, o BESS apresenta uma ampla variedade de aplicações, que vão desde o aperfeiçoamento da qualidade de energia a curto prazo até à gestão de energia a longo prazo, aumento da confiabilidade, garantia de fornecimento contínuo de energia.

Em relação às desvantagens, as preocupações económicas continuam sendo uma barreira significativa. Apesar da expectativa da redução de custos, a viabilidade económica permanece uma questão desafiadora para que o BESS seja plenamente adotado como uma solução convencional de armazenamento. Outra desvantagem, apresentada em [26], está relacionada à vida útil operacional da bateria, tornando a otimização do uso da bateria ao longo da sua vida útil, uma questão crítica para a maioria das aplicações.

Conforme mostra a Tabela 2.1, os BESS de Íon de Lítio exibem um equilíbrio superior, pois possuem alta eficiência e densidade de energia ao longo de um ciclo de vida prolongado. Embora o BESS de Sódio-Enxofre também ofereçam vantagens semelhantes, eles enfrentam questões relacionadas à segurança e requisitos rigorosos de operação e manutenção. As baterias de Chumbo-Ácido e Níquel-Cádmio apresentam características positivas em termos de desempenho a baixas temperaturas e custos mais baixos, no entanto, fica aquém em propriedades como densidade de energia e taxas de autodescarga.




Figura 2.10-Classificação das tecnologias BESS pela forma de energia armazenada, adaptado de [24].

Tabela 2.1- Comparação de Baterias, adaptado de [27]

| Descrição                                         | Bateria de Sódio-Enxofre | Bateria de fluxo Vanádio-Redox | Bateria de Íon de Lítio | Bateria de Chumbo-Ácido |
|---------------------------------------------------|--------------------------|--------------------------------|-------------------------|-------------------------|
| Densidade das Células de Bateria (Wh/kg)          | 150                      | 25                             | 70-250                  | 50                      |
| Densidade de potência da célula de Bateria (W/kg) | 100                      | 100                            | 1000                    | 500                     |
| Eficiência Energética (%)                         | 80                       | 70                             | 95                      | 75                      |
| Ciclo de Vida                                     | >2500                    | >10 000                        | >5000                   | >500                    |
| Custo (\$/kWh)                                    | 285                      | 570                            | 430                     | 110                     |

## 2.7 Veículos Elétricos

Em [28], é afirmado que os acordos internacionais recentes determinam que as emissões de CO<sub>2</sub>, causados pelo consumo de combustíveis fósseis, devem ser reduzidas nas próximas décadas. O setor dos transportes é responsável por uma parte substancial do consumo de combustíveis fósseis, assim a introdução dos veículos elétricos (VEs) é uma das principais formas de reduzir o efeito de estufa. Devido aos avanços recentes nas indústrias de VEs, existem VEs que não apenas retiram energia da rede para carregar, mas também podem fornecer energia de volta à rede por exemplo, durante os horários de pico, contribuindo para satisfazer as procura de energia. Isto é chamado de transferência de energia do Veículo para a Rede (V2G) e permite que os VEs atuem como dispositivos de armazenamento de eletricidade para a rede. A Figura 2.11 mostra a arquitetura da rede V2G.

Em [29], é afirmado que as vantagens ambientais dos VEs frente aos desafios das mudanças climáticas. Apesar do reconhecimento generalizado dos VEs como uma opção ecologicamente favorável, a avaliação abrangente do impacto ambiental revela a influência crucial da matriz energética na emissão total de gases de efeito de estufa. Dependendo da origem da eletricidade, as emissões indiretas dos VEs podem ser significativas, somando-se às perdas de energia durante o armazenamento em baterias e durante a própria condução. Um estudo comparativo com veículos de combustão interna destaca a possibilidade de emissões mais baixas se esses veículos utilizarem exclusivamente e-combustível proveniente de eletricidade renovável.

Em [31], é afirmado que a integração efetiva dos veículos elétricos nos sistemas de *Smart Grid* requer modificações na topologia da rede, possibilitando que os VEs atuem como cargas controláveis. O uso de *Demand Side Management* (DSM) baseados em VE permite a programação flexível dos padrões de carga, evitando picos de consumo e facilitando a implementação de tecnologias V2G durante períodos de procura elevada. A coordenação entre empresas/concessionárias e consumidores é fundamental para o sucesso desse ciclo de carga/descarga, possibilitando o desenvolvimento intuitivo de programas de DSM centrados no consumidor.



Figura 2.11-Arquitetura de rede V2G, adaptado de [30].

## 2.8 Smart Homes and Energy Communities

Em [32] é apresentado o conceito de *Smart Home* (SH), definindo como uma residência equipada com sensores para observar o ambiente e dispositivos para fornecer serviços proativos, visando aprimorar a experiência dos ocupantes. A análise das tecnologias de sensores utilizadas nas SH abrange as vantagens e limitações de diferentes tipos de sensores. Um sensor comum é o sensor binário, que deteta o estado de um objeto ou movimento com um dígito único '1' ou '0'. Outro sensor mencionado na tese é o *Radio Frequency Identification* (RFID), uma tecnologia que utiliza comunicação via ondas de rádio para trocar dados entre um leitor e uma etiqueta eletrônica. Além disso, as câmaras de vídeo são consideradas sensores de alto conteúdo, oferecendo informações ricas para observação humana e interpretação por computador. Apesar das vantagens, cada sensor apresenta limitações: por exemplo, os sensores binários fornecem informações apenas a nível abstrato.

Em [33] são destacadas as vantagens das SH, enfatizando o conforto como principal benefício. Ao programar ações rotineiras, os moradores são isentos de preocupações, tornando as SH mais atrativas do que as residências convencionais. O controle remoto, seja por meio de *smartphones* ou computadores e a automação baseada em configurações predefinidas oferecem uma perspectiva mais positiva. Além disso, os sistemas de segurança em SH vão além das opções convencionais, incorporando *webcams* para uma monitorização remota, aumentando a segurança ao garantir o funcionamento adequado de todos os aspetos da residência. A eficiência energética é outra vantagem crucial, com iluminação automática respondendo não apenas à luz externa, mas também à presença ou ausência de pessoas nos ambientes. A implementação de SH, embora promissora, enfrenta desafios, incluindo preocupações com a segurança devido à constante conectividade à internet e custos elevados associados à adoção generalizada dessa tecnologia.

Em [34] são definidas as comunidades de energia como instituições impulsionadas por elas, assumindo o controlo social de recursos energéticos partilhados por meio de uma descentralização. Nesse modelo, consumidores, produtores e *prosumers* individuais podem desenvolver iniciativas independentes, contribuindo ativamente para a sustentabilidade. As comunidades de energia são entidades legais focadas na combinação de recursos, com potencial para reduzir preços e picos de energia.

Em [35] é abordado de forma abrangente a relevância das comunidades de energia para atingir as metas de neutralidade climática estabelecidas pela União Europeia até 2050. Ressalta a importância dessas comunidades como elementos-chave na transição do setor energético em direção a sistemas descentralizados e baseados em fontes renováveis, proporcionando o envolvimento direto dos cidadãos em atividades relacionadas com a produção, consumo, comércio e fornecimento de energia. O texto destaca a longa tradição de projetos de energia comunitária e principalmente nos países da Europa Ocidental e Nórdica, além de mencionar o papel significativo das cooperativas da energia nos Estados Unidos da América.

## 2.9 Técnicas de Previsão e Trabalhos Relacionados

Em [36] são analisadas as estratégias de previsão, classificadas em categorias com base no nível de análise matemática incorporado no modelo em métodos quantitativos e qualitativos. Os métodos quantitativos, como decomposição, regressão, suavização exponencial e abordagem Box-Jenkins, são aplicados quando há disponibilidade de dados históricos, enquanto os métodos qualitativos, como Delphi, ajuste de curva e comparações tecnológicas, são empregues em casos de dados históricos insuficientes. No contexto da previsão de carga elétrica, as técnicas são agrupadas em três categorias principais:

- Técnicas de Previsão Tradicionais, como regressão e suavização exponencial;
- Técnicas de Previsão Modificadas;
- Técnicas de *Soft Computing*;

Em [37], são exploradas técnicas de previsão para a energia eólica, energia solar e consumo. No contexto da previsão eólica, abordam estratégias, incluindo modelos estocásticos, *Autoregressive Integrated Moving Average* (ARIMA), redes neurais artificiais (ANN) e abordagens híbridas. Para a previsão da energia solar, são destacados modelos baseados em dados meteorológicos, ARIMA, ANN, técnicas de séries temporais.

Quanto à previsão do consumo, enfatizam características cruciais, como o perfil histórico de procura, temperatura, tendência semanal e padrões de ocupação. As técnicas exploradas são métodos estatísticos e abordagens híbridas que integram modelos ARIMA com técnicas de *machine learning*. Ainda são abordados desafios e limitações associados com as técnicas, destacando como promissora a solução oferecida por modelos híbridos para aprimorar a precisão das previsões.

Em [38] é abordado o fenómeno do crescimento excessivo de cianobactérias no Lago *Taihu*, localizado na China, devido à poluição hídrica, tendo como objetivo realizar previsões precisas deste fenómeno, considerando os fatores sazonais. A metodologia proposta incorpora algoritmos como *Holt-Winters* para capturar tendências sazonais e LSTM (*Long Short-Term Memory*) para extrair características de longo prazo. A combinação desses modelos visa aperfeiçoar a precisão das previsões, levando em consideração não apenas dados anteriores, mas também a influência da tendência sazonal.

Em [39] é abordada a importância e dependências do fornecimento de arroz para a região de *DKI Jakarta*, na Indonésia, impondo previsões para que se tomem atempadamente decisões. O estudo propõe comparar a precisão da previsão do fornecimento de arroz utilizando os métodos *Holt-Winters* e *Multilayer Perceptron* (MLP). O modelo é construído com base nos dados mensais de janeiro de 2011 a dezembro de 2020, com validação realizada de janeiro a março de 2021. A seleção do melhor modelo de previsão é baseada na menor margem de erro, medida pelos valores do *Root Mean Square Error* (RMSE) e *Mean Absolute Percentage Error* (MAPE). Em termos de resultados, mostraram a menor eficiência do método de *Holt-Winters* em comparação com o método MLP.

Em [40] é abordado a influência da ionosfera como uma fonte de erro que pode afetar a precisão do sistema de posicionamento global (GPS) em dados de satélite, cuja principal preocupação é a obtenção de medições de alta precisão. O objetivo da pesquisa é utilizar o método de *Holt-Winters* para analisar a previsão a curto prazo do atraso ionosférico usando medições do conteúdo total de elétrons (TEC) do GPS no período de sete meses na estação *Universiti Kebangsaan Malaysia* (UKM). Uma comparação baseada no menor valor de erro foi realizada entre os modelos de *Holt-Winters* aditivo e multiplicativo, a fim de escolher o modelo mais apropriado para este estudo. Em termos de resultados, a comparação entre os modelos aditivo e multiplicativo mostra que o modelo multiplicativo apresenta menor quantidade de erros.

Em [41] é abordado o desenvolvimento de um método de previsão híbrido, para realizar previsões precisas do consumo mensal de eletricidade, mesmo em situações em que há uma disponibilidade limitada de dados históricos. Para atingir esse objetivo, integrou-se o algoritmo de otimização da mosca da fruta (FOA) ao método de suavização exponencial de *Holt-Winters* (HW) para melhorar a precisão da previsão. As conclusões do estudo indicam que o modelo proposto, oferece excelente desempenho mesmo quando o conjunto de dados é limitado, apresentando um bom valor de MAPE.

Em [42] foi desenvolvido um modelo de previsão a curto prazo para a produção de energia fotovoltaica (PV) na Tailândia, utilizando a técnica estatística da previsão temporal *Holt-Winters*. A pesquisa concentra-se na proposta de parâmetros adequados e determinar a quantidade necessária de dados para cada estação do ano, visando aperfeiçoar a eficácia do modelo de previsão. Implementando a técnica proposta no *MATLAB*, a pesquisa valida os resultados da previsão, enfatizando a simplicidade do método como uma vantagem significativa. Em conclusão, é apresentado um método promissor para prever a produção de energia PV, com potencial para otimizar sistemas de gestão de energia e suavização de energia por meio de sistemas de armazenamento, oferecendo uma abordagem simplificada e eficaz para a previsão a curto prazo nesse contexto específico.

## 2.10 Redes Neurais

As redes neurais representam uma abordagem de inteligência artificial baseada na aprendizagem profunda, inspirada no funcionamento do cérebro humano. Essas redes são compostas por neurónios interconectados em camadas, formando um sistema adaptativo que aprende com os erros e aprimora o seu desempenho continuamente [43]. Em relação às vantagens, as redes neurais são capazes de modelar relações não-lineares entre variáveis, o que é crucial para muitas tarefas do mundo real.

No entanto, há desafios associados ao uso de redes neuronais. Frequentemente, essas redes requerem grandes conjuntos de dados para um treino eficaz, o que pode ser um desafio em domínios nos quais os dados são escassos. Além disso, o treino das redes neuronais, especialmente modelos profundos, pode ser intensivo computacionalmente e demorado, exigindo hardware especializado. Existem vários tipos de redes neuronais, cada uma com características específicas e aplicações únicas, por exemplo [44] [45]:

- ***Feed Forward Neural Networks* (Redes Neuronais com Retro Alimentação)** - estruturadas de forma linear, essas redes permitem que a informação flua numa única direção, da camada de entrada para a camada de saída;
- ***Recurrent Neural Network* (Redes Neuronais Recorrentes- RNNs)** - caracterizadas pelos *loop* nos feedbacks, as RNNs possuem conexões retroalimentadas, permitindo que informações anteriores influenciem as saídas atuais. São frequentemente utilizadas em aplicações de séries temporais para prever resultados futuros;
- ***Convolutional Neural Networks* (Redes Neuronais Convolucionais - CNNs)** - projetadas especialmente para tarefas de visão computacional, as CNNs são eficazes no reconhecimento de padrões em imagens;
- ***Autoencoder Neural Network*** - projetadas para representar a informação de entrada num espaço dimensional menor, essas redes são frequentemente utilizadas em tarefas de redução de dimensionalidade;
- ***Cascade Neural Network*** - construídas sequencialmente, as redes em cascata adicionam módulos de processamento um de cada vez. Cada módulo é treinado independentemente e tem a responsabilidade de corrigir os erros residuais cometidos pelos módulos anteriores.



## 3. Metodologia de Previsão

### 3.1 Modelo de Previsão de *Holt-Winters*

O método de *Holt-Winters* faz parte de uma classe de técnicas de suavização exponencial projetada para analisar o comportamento de uma série temporal, decompondo em componentes de tendência, sazonalidade e nível [46].

Existem diversas variações do modelo de *Holt-Winters*, dependendo de como as componentes de tendência e sazonalidade são estimadas e combinadas. As formas comuns incluem o método aditivo e o método multiplicativo. Nesta tese, é usado o método multiplicativo. No modelo multiplicativo, as componentes de tendência e sazonalidade são multiplicadas pelo valor médio da série temporal para gerar a previsão, considerando a descrição dada por [47]:

- **Nível:** 
$$l_t = \alpha \left( \frac{Y_t}{S_{t-s}} \right) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (3.1)$$

- **Tendência:** 
$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (3.2)$$

- **Sazonalidade:** 
$$S_t = \gamma \left( \frac{Y_t}{l_t} \right) + (1 - \gamma)S_{t-s} \quad (3.3)$$

- **Previsão para  $m$  períodos à frente:** 
$$F_{t+m} = (l_t + b_t m) S_{t-s+m} \quad (3.4)$$

Os parâmetros  $\alpha, \gamma, \beta$ ,  $0 \leq \alpha, \gamma, \beta \leq 1$ , são denominados respectivamente como parâmetros de suavização para o nível médio  $S_t$ , tendência  $T_t$  e índice sazonal  $I_t$ , enquanto o índice  $s$  representa o comprimento da sazonalidade. A abordagem multiplicativa permite prever os valores futuros com base na tendência, sazonalidade e o nível da série temporal, permitindo uma análise mais robusta e precisa.

A Figura 3.1 ilustra a forma como o modelo de *Holt-Winters* interage com o modelo de previsão LSTM, e os resultados das diversas previsões realizadas fluem para uma comparação entre o valor real e o valor previsto da variável de produção a prever.




Figura 3.1-Modelo de *Holt-Winters*, adaptado de [48].

### 3.2 Long Short-Term Memory Network (LSTM)

O modelo *Long Short-Term Memory* (LSTM) é uma evolução das Redes Neurais Recorrentes (RNN), desenvolvido para superar os desafios que frequentemente se encontram com a utilização de gradientes, que ocorrem nas RNNs convencionais. A inovação central do LSTM reside na introdução da célula de estado e de uma estrutura constituída por portas, proporcionando a capacidade de lidar com as dependências de longo prazo, e mitigando o risco do desaparecimento do gradiente [49], [50]. O conceito fundamental do LSTM envolve a célula de estado e três tipos de portas: de entrada, de avaliação e de saída. Cada porta desempenha uma função específica:

- **Porta de Entrada (*Input Gate*):** Responsável por atualizar o estado da célula, decidindo quais as informações a ser adicionadas.
- **Porta de Avaliação/Esquecimento (*Forget Gate*):** Determina quais informações que serão eliminadas.
- **Porta de Saída (*Output Gate*):** Responsável por determinar a saída da célula atual.

O processo de atualização da célula numa rede neural LSTM envolve as etapas [51]:

1. **Cálculo da Memória Candidata:** a primeira etapa consiste em calcular a memória candidata, representada por  $\tilde{c}_t$ . Esta candidata é obtida aplicando a função tangente hiperbólica ( $\tanh$ ) à combinação linear dos valores da saída anterior ( $h_{t-1}$ ) e do dado de entrada atual ( $x_t$ ), ponderados pelos respetivos pesos ( $W_c$ ) e acrescidos de um valor de ajuste ( $b_c$ ).

$$\tilde{c}_t = \tanh(W_c * [h_{t-1}, x_t] + b_c) \quad (3.5)$$

2. **Cálculo da Porta de Entrada ( $i_t$ ):** é realizado através da aplicação da função sigmoide ( $\sigma(\cdot)$ ) à combinação linear dos valores da saída anterior ( $h_{t-1}$ ) e do dado de entrada atual ( $x_t$ ), ponderados pelos respetivos pesos ( $W_i$ ) e acrescidos de um valor de ajuste ( $b_i$ ).

$$i_t = \sigma(W_i * [h_{t-1}, x_t] + b_i) \quad (3.6)$$

3. **Cálculo da Porta de Avaliação/Esquecimento ( $f_t$ ):** é utilizado um processo similar à porta de entrada, onde a função sigmoide ( $\sigma(\cdot)$ ) é aplicada à combinação linear dos valores da saída anterior ( $h_{t-1}$ ) e do dado de entrada atual ( $x_t$ ), ponderados pelos pesos ( $W_f$ ) e acrescidos de um valor de ajuste ( $b_f$ ).

$$f_t = \sigma(W_f * [h_{t-1}, x_t] + b_f) \quad (3.7)$$

4. **Atualização da Célula de Memória:** a célula de memória atual é atualizada com base nos resultados das portas de avaliação e entrada. O valor anterior da célula de memória ( $c_{t-1}$ ) é multiplicado pelo resultado da porta de avaliação ( $f_t$ ), e o produto é somado ao produto da porta de entrada ( $i_t$ ) pela memória candidata  $\tilde{c}_t$ .

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (3.8)$$

5. **Cálculo da Porta de Saída:** aplica-se a função sigmoide ( $\sigma(\cdot)$ ) à combinação linear dos valores da saída anterior ( $h_{t-1}$ ) e do dado de entrada atual ( $x_t$ ), ponderados pelos pesos ( $W_o$ ) e acrescidos de um valor de ajuste ( $b_o$ ).

$$o_t = \sigma (W_o * [h_{t-1}, x_t] + b_o) \quad (3.9)$$

6. **Cálculo da Saída da Unidade LSTM:** a saída da unidade LSTM ( $h_t$ ) é calculado multiplicando o resultado da porta de saída  $o_t$  pela tangente hiperbólica da célula de memória atual ( $c_t$ ).

$$h_t = o_t * \tanh (c_t) \quad (3.10)$$

Este processo de atualização permite que a LSTM mantenha informações relevantes, eliminando as irrelevantes, tornando-a eficaz para lidar com dependências temporais de longo prazo.

O modelo de previsão apresentado implementa uma estratégia híbrida para a previsão de potência eólica, potência solar e consumo, integrando uma Rede Neural Recorrente com Memória de Longo Prazo (LSTM) e o método de *Holt-Winters*, conforme é esquematizada na Figura 3.3. Inicialmente, ocorre a normalização dos dados históricos para facilitar o treino eficaz da LSTM. Simultaneamente, é aplicado o método de *Holt-Winters* aos dados de teste, incorporando parâmetros cruciais de suavização,  $\alpha, \gamma, \beta$ , descritos na Seção 3.1.

A abordagem híbrida é então introduzida, unindo as previsões geradas pelo LSTM e pelo método de *Holt-Winters* como entradas para uma Rede Neural de Alimentação Direta




Figura 3.2-Esquema do LSTM, adaptado de [49].



Figura 3.3- Fluxograma do código para a previsão.

### 3.3 Critérios de Quantificação do Erro

Nesta secção é abordada a quantificação dos erros em modelos de previsão que são uma etapa crucial na avaliação do desempenho destes modelos. Existem várias métricas frequentemente usadas para quantificar os erros nos modelos de previsão, tais como [52]:

- **Erro Médio Absoluto (MAE):** o MAE é a média das diferenças absolutas entre as previsões e os valores reais.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.11)$$

- **Erro Quadrático Médio (MSE):** o MSE é a média dos quadrados das diferenças entre as previsões e os valores reais.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.12)$$

- **Raiz do Erro Quadrático Médio (RMSE):** o RMSE é a raiz quadrada do MSE e fornece uma medida na mesma magnitude que a variável em estudo.

$$RMSE = \sqrt{MSE} \quad (3.13)$$

- **Erro Percentual Absoluto Médio (MAPE):** o MAPE expressa o erro médio em percentagem, considerando o quociente entre a diferença entre o valor real e o previsto com o valor médio real no período  $i$ .

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \times 100 \quad (3.14)$$

As métricas de quantificação do erro de previsão desempenham um papel crucial na análise e comparação da eficácia dos modelos de previsão. Essas métricas constituem uma base objetiva que facilitam a tomada de decisão fundamentada, e o aperfeiçoamento constante dos modelos. Por fornecerem uma medida quantitativa do desempenho, essas métricas tornam-se essenciais para validar a confiabilidade das previsões, orientando o desenvolvimento e a otimização contínua dos modelos preditivos.

### 3.4 Formulação Matemática Generalizada de Otimização

Neste ponto é abordada a formulação matemática de um sistema de autogeração de eletricidade em residências de uma comunidade energética, visando a minimização dos custos diários de eletricidade dos produtores-consumidores, otimizando os padrões de carga e descarga dos veículos elétricos. Consideramos a autogeração de Energias Renováveis e sua simulação em diferentes cenários, incluindo o uso ESS. No problema de otimização são considerados limites e restrições impostos pelos eletrodomésticos e pelas necessidades dos utilizadores.

A formulação matemática generalizada segue o modelo MILP [53]. Este método é uma técnica de otimização matemática que combina elementos da Programação Linear (PL) com a inclusão de variáveis inteiras. Enquanto a PL lida com variáveis contínuas, a MILP permite que algumas ou todas as variáveis do problema sejam restritas a valores inteiros. A abordagem para resolver um problema MILP envolve a aplicação de algoritmos *branch-and-bound*, os quais fragmentam o espaço de soluções em subconjuntos menores com complexidade teórica semelhante.

O objetivo deste estudo visa otimizar a gestão energética numa comunidade residencial, procurando a redução das despesas diárias dos consumidores. Considerando aspetos como penalidades por desconforto associadas a alterações nos horários de operação dos eletrodomésticos. A função objetivo deste problema é apresentada na equação 3.15 [54]:

$$\begin{aligned} \text{Min } Z = & \left( \sum_{w \in \Omega} p_w \left( \sum_{t=1}^{NT} [\pi_t^{G2H} p_{w,t}^{G2H} \Delta t - \pi_t^{H2G} p_{w,t}^{H2G} \Delta t] \right) \right) + \left( \sum_{w \in \Omega} p_w \left( \sum_{t=1}^{NT} [STUP_{w,i,t} C_i^{ST} + \right. \right. \\ & \left. \left. SHDN_{w,i,t} C_i^{SD}] \right) \right) - \left( \sum_{i=1}^{NA} [C_i^{ST} + C_i^{SD}] \right) + \left( \sum_{w \in \Omega} p_w \left( \sum_{i=1}^{NA} \sigma [DI_{w,i}^+ + DI_{w,i}^-] \right) \right) \end{aligned} \quad (3.15)$$

A função objetivo descrita pela Equação 3.15 é composta por quatro termos distintos que refletem diferentes aspetos do problema:

- **Custo das Transações de Energia (Primeiro Termo):** este termo representa o custo das transações de energia entre a casa e a rede. Tem em consideração um mecanismo de pacote de preços de Time-of-Use (TOU), onde o preço da eletricidade varia ao longo do tempo, ponderando na função objetivo os custos associados à compra e venda de energia entre a casa e a rede.

- **Custo de Liga/Desliga dos Eletrodomésticos (Segundo Termo):** este termo reflete o custo com as operações de ligar e desligar cada eletrodoméstico. Incentiva hábitos mais sustentáveis ao penalizar situações de ligar/desligar demasiado frequentes. Os parâmetros  $C^{ST}_i$  e  $C^{SD}_i$  com valores elevados representam o custo associado a essas operações.
- **Custo de Desconforto por Deslocamento de Cargas (Terceiro Elemento):** o terceiro termo representa o custo total de ligar/desligar dos ativos ao longo do período de agendamento, onde o sinal reflete a penalização total pelo desvio entre o arranque e a paragem dos equipamentos controláveis fora do período de agendamento.
- **Custo Total Associado ao Desconforto (Quarto Elemento):** o último termo refere-se ao custo total associado ao desconforto, penalizando o deslocamento da procura da carga para fora dos horários desejados.

Em conjunto, estes termos procuram encontrar valores para as variáveis de decisão que minimizam o custo total, considerando as transações de energia, custos de ligar/desligar, penalidades de desconforto e custos associados ao uso da tarifa TOU [55].

### 3.5 Sistema de Gestão de Energia Residencial e Restrições

A estrutura do Sistema de Gestão de Energia Residencial (HEMS) é delineada como um sistema abrangente que oferece serviços especializados para eficaz monitorização e controlo da produção, armazenamento e consumo de eletricidade em residências inteligentes. O HEMS engloba programas de resposta à procura, serviços de automação, gestão de energia, visualização/análise de dados, auditoria e serviços de segurança, constituindo um conjunto essencial de funcionalidades. A Figura 3.4 mostra de forma genérica a arquitetura HEMS de uma casa com domótica capaz de habilitar ou desabilitar o funcionamento dos equipamentos ligados ao HEMS, mostrando ainda a forma como a informação flui entre o HEMS e o utilizador.

O HEMS facilita uma comunicação bidirecional entre as residências e a empresa de fornecimento de energia elétrica, possibilitando um acompanhamento em tempo real, controle preciso e análise detalhada dos dados relacionados ao consumo de eletricidade [56]. A presente dissertação, segue o modelo HEMS, conforme descrito em [57].

A gestão eficiente do consumo de energia em cada residência envolve a imposição de várias restrições de agendamento pelo HEMS para otimizar as cargas residenciais e impor restrições económicas [54].




Figura 3.4-Arquitetura HEMS, adaptado de [56].

As limitações inerentes ao problema estão associadas às restrições técnicas e económicas associadas ao transporte da carga, à interação de energia entre o HEMS e a rede elétrica, bem como ao uso do Dispositivo de Armazenamento de Energia Residencial (BESS). A restrição 3.16 expressa a quantidade de carga deslocável em cada intervalo de tempo  $D_{w,t}^{Shift}$  é dependente da potência nominal do dispositivo,  $P_i$ , e de seu status operacional determinado pela variável binária  $S_{w,i,t}$ .

$$D_{w,t}^{Shift} = \sum_{i=1}^{NA} S_{w,i,t} P_i \quad (3.16)$$

Para determinar os intervalos ótimos de operação dos eletrodomésticos, a variável binária  $S_{w,i,t}$  assume o valor de “1” durante os períodos em que o *prosumer* pode ligar o dispositivo e “0” fora desses intervalos, conforme apresentada em 3.17 e 3.18. Além disso, é introduzida a variável binária  $B_{w,i,t}$  para representar o status de uso preferido do utilizador. Esta variável é “1” durante a operação do eletrodoméstico e “0” quando está desligado, como indicado nas próximas Equações 3.19 e 3.20.

$$S_{w,i,t} \leq \begin{cases} 0 & \text{se } t < LB_{i,s} \\ 1 & \text{se } LB_{i,s} \leq t \leq UB_{i,s} \\ 0 & \text{se } t > UB_{i,s} \end{cases}, \quad S_{w,i,t} \in \{0,1\} \quad (3.17)$$

$$\sum_{t=1}^{NT} S_{w,i,t} = T_i \quad \forall i = 1, 2, \dots, NA \quad (3.18)$$

$$B_{w,i,t} = \begin{cases} 0 & \text{se } t < LB_{i,b} \\ 1 & \text{se } LB_{i,b} \leq t \leq UB_{i,b} \\ 0 & \text{se } t > UB_{i,b} \end{cases}, \quad B_{w,i,t} \in \{0,1\} \quad (3.19)$$

$$\sum_{t=1}^{NT} B_{w,i,t} = T_i \quad \forall i = 1, 2, \dots, NA \quad (3.20)$$

Conforme descrito anteriormente, é essencial aplicar uma penalização para mitigar as operações desnecessárias de ligar e desligar. Mesmo que um dispositivo possa ser acionado e desligado várias vezes ao longo do dia, tal prática não é sustentável. Portanto, mecanismos de controlo devem ser incorporados para desencorajar a ocorrência frequente dessas operações.

Com vista a mitigação das ocorrências desnecessárias de ligar e desligar, as variáveis  $STUP_{w,i,t}$  e  $SHDN_{w,i,t}$  representam respetivamente os custos operacionais de ligar e desligar, relacionando-se com o estado operacional dos dispositivos, como expresso na Equação 3.21.

$$STUP_{w,i,t} - SHDN_{w,i,t} = S_{w,i,t} - S_{w,i,t-1} \quad \forall t = 1, 2, 3, \dots, N \quad (3.21)$$

Na Equação 3.22 é evidenciada que o índice de desconforto de um dispositivo controlável depende se o eletrodoméstico está a ser usado durante o período de operação padrão ou durante o período de operação deslocado. Isto implica que, para o primeiro caso, o índice de desconforto será igual a “0”, enquanto para o segundo caso, assumirá um valor positivo.

$$DI_{w,i} \geq \frac{1}{T_i} [\sum_{t=1}^{NT} t \times B_{w,i,t} - \sum_{t=1}^{NT} t \times S_{w,i,t}] \quad (3.22)$$

Em seguida, apresentam-se as limitações relacionadas com a transição energética entre o *prosumer*, a rede, e as restrições impostas BESS. A Equação 3.23 ilustra o papel do BESS e da micro geração individual da comunidade energética, equilibrando a potência para cada intervalo de tempo.

$$P_{w,t}^{G2H} - P_{w,t}^{H2G} + P_{w,t}^{PV} = D_{w,t}^{Fix} + D_{w,t}^{Shift} + \sum_{j=1}^{NS} P_{w,j,t}^{Car} - \sum_{j=1}^{NS} P_{w,j,t}^{Des} \quad (3.23)$$

A Equação 3.23 destaca no lado esquerdo da igualdade a eletricidade adquirida da rede pelo *prosumer* e a energia elétrica proveniente de fontes renováveis. Subsequentemente, subtrai-se a eletricidade vendida pelo *prosumer* à rede. O lado direito da equação, representa a eletricidade necessária para alimentar as cargas fixas e deslocáveis, além da potência destinada ao carregamento do BESS, e um termo negativo referente à potência de descarga do BESS.

As próximas equações têm como função a representação binária do estado do BESS, a utilização de variáveis binárias ( $I_{w,j,t}^{Car}$  e  $I_{w,j,t}^{Des}$ ) para indicar se o BESS está em modo de carga ou descarga em intervalos de tempo específicos. A restrição desta equação assegura que o BESS não realiza simultaneamente carga e descarga, garantindo a consistência operacional.

$$0 \leq I_{w,j,t}^{Car} + I_{w,j,t}^{Des} \leq 1 \quad (3.24)$$

As Equações 3.25 e 3.26 limitam a potência de carga e descarga do BESS, respeitando as capacidades máximas.

$$P_{w,j,t}^{Car} \leq I_{w,j,t}^{Car} P_j^{Car,max} \quad (3.25)$$

$$P_{w,j,t}^{Des} \leq I_{w,j,t}^{Des} P_j^{Des,max} \quad (3.26)$$

A Equação 3.27 descreve a dinâmica de armazenamento de energia num BESS num determinado intervalo de tempo, determinando a quantidade de energia armazenada no BESS com base na energia armazenada no período anterior, na eficiência de carga e descarga e na potência de carga e descarga.

A representação descrita na Equação 3.27 é fundamental para simular como a energia é acumulada ou libertada no BESS ao longo do tempo, considerando as características operacionais do sistema.

$$E_{w,j,t} = E_{w,j,t-1} + \eta_j^{Car} P_{w,j,t}^{Car} \Delta t - \frac{1}{\eta_j^{Des}} P_{w,j,t}^{Des} \Delta t \quad (3.27)$$

A Equação 3.28 estabelece uma restrição no modelo, garantindo que a quantidade de energia armazenada no BESS durante o primeiro intervalo de tempo seja igual à quantidade de energia armazenada durante o último intervalo de tempo. Assim, ela estabelece que, no término do período analisado, a quantidade de energia armazenada no BESS deve permanecer igual ao valor inicial.

$$E_{w,j,1} = E_{w,j,T} \quad (3.28)$$

A Equação 3.29 impõe restrições sobre a quantidade de energia que pode ser armazenada no BESS. O objetivo é garantir que a energia armazenada permaneça dentro de limites específicos, evitando cenários em que o sistema atinja níveis críticos de carga ou descarga.

$$E_j^{min} \leq E_{w,j,t} \leq E_j^{max} \quad (3.29)$$

As restrições acima descritas são fundamentais para o correto funcionamento e a segurança do BESS, garantindo a operação dentro de margens aceitáveis e prevenindo danos causados por condições extremas de carga ou descarga. O modelo de otimização foi também projetado de forma a otimizar o fluxo de energia na rede de distribuição, considerando a topologia radial do sistema, a qual é caracterizada por uma estrutura em que a energia flui de uma fonte central para os pontos periféricos (por exemplo, quando uma casa está a comprar energia à rede, esta não poderá estar simultaneamente a vender energia à rede).

## 3.6 Dados do Modelo de Previsão e do Sistema de Gestão de Energia Comunitária

### 3.6.1 Modelo de Previsão

Para o modelo de previsão, os dados utilizados (eólica/solar/consumo) foram recolhidos da unidade curricular Técnicas de Previsão, oriundos de diversas fontes, como a REN [58], REE [59] e OMEL [60]. Os dados utilizados para as diversas previsões realizadas consideram o histórico dos perfis de produção solar, eólica e consumo dos 14 dias anteriores discretizados em períodos horários, permitindo a previsão para o dia seguinte, ou seja, das 24 horas seguintes. De salientar que a ferramenta de previsão não utiliza dados exógenos.

O modelo de previsão foi desenvolvido no software MATLAB na versão R2023b. O sistema operativo utilizado foi o *Windows 11*, com um processador 11th Gen Intel(R) Core (TM) i7-1195G7@2.90 GHz 1.80 GHz.

### 3.6.2 Sistema de Gestão de Energia Comunitária

Para o sistema de gestão de energia comunitária foi considerado um conjunto de 5 residências com uma potência contratada de 10,35 kVA cada uma, as quais apresentam a capacidade de participar em transações de energia *peer-to-peer* (P2P), permitindo a compra e venda de energia dentro da comunidade energética ou com a própria rede de distribuição. Essas transações estão limitadas a uma capacidade máxima de 40% e 35%, respetivamente, para a venda de energia.

Os dados de previsão da potência solar foram normalizados, resultando na criação de um perfil de produção fotovoltaico também normalizado. Este último foi desenvolvido combinando os perfis inseridos para minimizar as incertezas, considerando que os perfis estão associados a um dia típico de inverno, conforme a Figura 3.5.

As instalações fotovoltaicas em cada residência consistem em seis painéis de 395 Wp cada, totalizando uma capacidade instalada de 2,38 kW por residência. Para avaliar o desempenho do modelo e da comunidade energética em transacionar energia, foi atribuído o índice de conforto máximo ( $\alpha = 250$ ), a todos os utilizadores, visando contornar as adversidades ao desconforto pela deslocação de cargas.

O modelo de otimização e gestão de energia da comunidade energética foi desenvolvido em *Python*, utilizando o ambiente *Jupyter Notebook* v3.12, e recorrendo ao otimizador *Gurobi* v11.0.0. O sistema operativo utilizado foi o *Windows 10*, com uma CPU Intel(R) Core (TM) i5-5200U CPU @2.20GHz. Relativamente aos BESS incorporados nas residências da comunidade, a potência máxima tanto para carga como para a descarga é de 2,5 kW, considerando ainda uma eficiência de carga de 90% e uma eficiência de descarga de 85%, conforme indicado na Tabela 3.1.




Figura 3.5- Cenários de produção fotovoltaica considerados no sistema base.

Tabela 3.1-Parâmetros considerados nos sistemas de armazenamento de energia

| $E_0$ (kWh) | $E_{24}$ (kWh) | $P_{maxcarga}$ (kW) | $P_{maxdescarga}$ (kW) | $\eta_{carga}$ | $\eta_{descarga}$ | $E_{max}$ (kWh) | $E_{min}$ (kWh) |
|-------------|----------------|---------------------|------------------------|----------------|-------------------|-----------------|-----------------|
| 0,5         | 0,5            | 2,5                 | 2,5                    | 0,9            | 0,85              | 4               | 1               |

A análise envolve as tarifas incorporadas no modelo proposto. Em Portugal, as tarifas base são estabelecidas no início do ano pela Entidade Reguladora dos Serviços Energéticos (ERSE) [61] e, posteriormente, ajustadas pelos fornecedores de eletricidade, neste caso a EDP [62] foi a escolhida como fornecedora de eletricidade, oferecendo três planos distintos baseados em diferentes períodos (tarifa simples, tarifa bi-horária, tarifa tri-horária), conforme é indicado na Figura 3.6 e na Tabela 3.2.

No estudo focado na operação do HEMS numa única residência, foram especificadas 10 cargas deslocáveis, incluindo diversos eletrodomésticos essenciais para o quotidiano, como a máquina de lavar roupa, o secador de roupa entre outros equipamentos como aquecedores de água, ar condicionados ou carregadores de veículos elétricos.

A Tabela 3.3 fornece informações sobre os eletrodomésticos de cada casa, sua potência nominal, duração da operação, início e fim da operação e os horários de operação preferenciais, como por exemplo, o secador de roupa que tem uma potência de 4,0 kW, no caso de estudo, o seu início de operação é as 18:30 e, o fim, é as 19:30h, tendo a duração de 1h. Para a produção de energia fotovoltaica (PV), os dados são gerados para cinco cenários distintos, estes cinco cenários são resultantes do modelo de previsão efetuados.




Figura 3.6-Tarifas diárias de referência, fornecidas pela EDP.

Tabela 3.2-Tarifários Considerados

| Hora (h) | T. Simples (€/kWh) | Tarifa Bi-Horária (€/kWh) | Tarifa Tri-Horária (€/kWh) |
|----------|--------------------|---------------------------|----------------------------|
| 0        | 0,1516             | 0,0887                    | 0,0864                     |
| 1        | 0,1516             | 0,0887                    | 0,0864                     |
| 2        | 0,1516             | 0,0887                    | 0,0864                     |
| 3        | 0,1516             | 0,0887                    | 0,0864                     |
| 4        | 0,1516             | 0,0887                    | 0,0864                     |
| 5        | 0,1516             | 0,0887                    | 0,0864                     |
| 6        | 0,1516             | 0,0887                    | 0,1446                     |
| 7        | 0,1516             | 0,1863                    | 0,1446                     |
| 8        | 0,1516             | 0,1863                    | 0,2854                     |
| 9        | 0,1516             | 0,1863                    | 0,2854                     |
| 10       | 0,1516             | 0,1863                    | 0,1446                     |
| 11       | 0,1516             | 0,1863                    | 0,1446                     |
| 12       | 0,1516             | 0,1863                    | 0,1446                     |
| 13       | 0,1516             | 0,1863                    | 0,1446                     |
| 14       | 0,1516             | 0,1863                    | 0,1446                     |
| 15       | 0,1516             | 0,1863                    | 0,1446                     |
| 16       | 0,1516             | 0,1863                    | 0,2854                     |
| 17       | 0,1516             | 0,1863                    | 0,2854                     |
| 18       | 0,1516             | 0,1863                    | 0,2854                     |
| 19       | 0,1516             | 0,1863                    | 0,2854                     |
| 20       | 0,1516             | 0,1863                    | 0,1446                     |
| 21       | 0,1516             | 0,0887                    | 0,1446                     |
| 22       | 0,1516             | 0,0887                    | 0,0864                     |
| 23       | 0,1516             | 0,0887                    | 0,0864                     |

Tabela 3.3- Cargas Deslocáveis consideradas para o sistema em estudo

| Carga                 | Potência (kW) | Duração (h) | Caso Base          |                  | Pref. Operação 1 (h) | Pref. Operação 2 (h) |
|-----------------------|---------------|-------------|--------------------|------------------|----------------------|----------------------|
|                       |               |             | Iníc. Operação (h) | Fim Operação (h) |                      |                      |
| Máq. Lavar Roupa      | 2,0           | 3           | 15:00              | 18:00            | 08:00                | 18:00                |
| Secador de Roupa      | 4,0           | 1           | 18:30              | 19:30            | 18:30                | 22:30                |
| Máq. Lavar Louça      | 2,0           | 2           | 09:00              | 11:00            | 09:00                | 18:00                |
| Aq. Águas Sanit. (T1) | 3,5           | 2           | 04:00              | 06:00            | 00:00                | 06:00                |
| Aq. Águas Sanit. (T2) | 3,5           | 2           | 16:00              | 18:00            | 09:00                | 18:00                |
| Carregador EV (T1)    | 7,5           | 3           | 18:00              | 21:00            | 18:00                | 00:00                |
| Carregador EV (T2)    | 7,5           | 3           | 4:00               | 7:00             | 00:00                | 08:00                |
| Ar Condicionado (T1)  | 2,0           | 2           | 6:00               | 08:00            | 00:00                | 08:00                |
| Ar Condicionado (T2)  | 2,0           | 2           | 18:00              | 20:00            | 15:00                | 20:00                |
| Ar Condicionado (T3)  | 2,0           | 2           | 22:00              | 00:00            | 20:00                | 00:00                |

## 4.Resultados

### 4.1 Resultados do Modelo de Previsão

Neste capítulo serão apresentados os resultados do modelo de previsão para as 24 horas seguintes das fontes renováveis e carga/consumo.

#### 4.1.1 Previsão da Produção Eólica

A primeira previsão foi a da potência eólica, onde foram realizadas tentativas como mostra a Tabela 4.1, considerando o critério do MAPE como o minimizador de erro da previsão. A tentativa 1 apresenta o menor MAPE final de 8,28. A Figura 4.1 fornece uma visão clara do histórico da potência eólica nos 14 dias utilizados no modelo. Isto ajuda a contextualizar as previsões e avaliar a sua aderência à realidade.

A Figura 4.2, apresenta a previsão LSTM, incluindo os erros RMSE associados. Este gráfico fornece uma comparação entre a previsão e os valores reais, destacando as áreas de precisão e potenciais divergências. A Figura 4.3 destaca a previsão de *Holt-Winters*. A Figura 4.4, apresenta a previsão final das 24 horas seguintes que é a combinação entre a previsão LSTM e a previsão *Holt-Winters*, este resultado integrado sugere que a abordagem combinada resultou numa previsão mais robusta, capaz de capturar nuances importantes da potência eólica.

Tabela 4.1-Tentativas no modelo de previsão com a energia eólica

| Tentativa | MAPE Final |
|-----------|------------|
| 1         | 8,2823     |
| 2         | 10,9978    |
| 3         | 13,8896    |
| 4         | 27,1269    |
| 5         | 11,1425    |
| 6         | 8,3635     |




Figura 4.1-Histórico dos 14 dias da potência eólica.




Figura 4.2-Previsão LSTM e erros RMSE na previsão da potência eólica.




Figura 4.3-Previsão de *Holt-Winters* na previsão eólica.




Figura 4.4- Previsão objetivo da potência eólica.

### 4.1.2 Previsão da Produção Solar

A próxima energia renovável analisada é a solar. A tentativa 4, demonstrou o melhor desempenho, alcançando um MAPE de 11,81. Outros resultados estão apresentados na Tabela 4.2. Na Figura 4.5 é demonstrado de forma inequívoca que a evolução da potência solar ao longo do dia é influenciada pela posição do sol no céu e por outros fatores atmosféricos. No amanhecer, a potência é baixa, aumentando gradualmente durante a manhã. Em torno do meio-dia, atinge seu pico máximo, com a radiação solar incidindo com menor obliquidade. No período da tarde, a potência solar vai diminuindo conforme o movimento aparente do Sol em direção a oeste, chegando a zero no pôr-do-sol.

Além disso, por tratar-se de dados com amostragem horária, não é possível visualizar com rigor o problema da nebulosidade ou passagem de nuvens pelos painéis fotovoltaicos, pelo que o fenómeno não é estudado em pormenor neste trabalho.

A Figura 4.6 apresenta a previsão realizada com a abordagem LSTM, acompanhada dos erros RMSE associados. Esta permite identificar as áreas de concordância e possíveis discrepâncias entre a previsão e os dados reais. A Figura 4.7 ilustra os resultados da previsão realizada pelo modelo de *Holt-Winters*, proporcionando uma alternativa à abordagem anterior. A Figura 4.8, apresenta a previsão final da energia solar para o dia objetivo. Esta representação integrada oferece uma visão mais confiável da potência solar para o dia objetivo.

A análise dos resultados da energia solar destaca a variabilidade sazonal significativa, exigindo uma abordagem mais rigorosa às condições atmosféricas específicas. O notável desempenho alcançado nas tentativas 1 e 3 sugerem a existência de margem para o ajuste do modelo, visando otimizações adicionais na qualidade das previsões.

Tabela 4.2-Tentativas no modelo de previsão com a energia solar

| Tentativa | MAPE Final |
|-----------|------------|
| 1         | 17,2365    |
| 2         | 14,3171    |
| 3         | 20,7112    |
| 4         | 11,8081    |
| 5         | 15,4380    |
| 6         | 15,8244    |




Figura 4.5-Histórico dos 14 dias da potência solar.




Figura 4.6-Previsão LSTM e erros RMSE na previsão da potência solar.




Figura 4.7-Previsão de Holt-Winters na previsão solar.




Figura 4.8- Previsão objetivo da potência solar.

### 4.1.3 Previsão do Consumo (Carga)

Neste caso de estudo, foi considerada a previsão do consumo para o dia objetivo, onde mais uma vez foram feitas várias tentativas para minimizar o valor do MAPE, cujos resultados nas diversas tentativas foram considerados razoáveis. A título de exemplo apresenta-se os resultados da tentativa 3 para a previsão do consumo com MAPE final de 2,70. A Tabela 4.3 destaca os resultados obtidos em diferentes tentativas para a previsão do consumo, evidenciando a consistência na procura por MAPEs finais aceitáveis.

A Figura 4.9 mostra o histórico de consumo ao longo de 14 dias, fornecendo valores para avaliar a eficácia das previsões. A Figura 4.10 ilustra a previsão realizada pelo modelo LSTM e os respectivos erros RMSE na previsão do consumo, enquanto a Figura 4.11 mostra os resultados da previsão com o modelo *Holt-Winters*. Estes gráficos permitem uma comparação entre as previsões e os dados reais. A Figura 4.12 mostra a previsão final para as 24 horas seguintes, resultante da combinação das abordagens de previsão. O modelo de previsão aqui desenvolvido demonstra um bom desempenho na previsão de carga (consumo), com valores de MAPEs significativamente reduzidos.

Tabela 4.3-Tentativas no modelo de previsão com o consumo

| Tentativa | MAPE Final |
|-----------|------------|
| 1         | 4.5953     |
| 2         | 3.4751     |
| 3         | 2.6968     |
| 4         | 2.8346     |
| 5         | 6.3502     |
| 6         | 2.7436     |




Figura 4.9-Histórico dos 14 dias do consumo.




Figura 4.10-Previsão LSTM e erros RMSE na previsão do consumo.




Figura 4.11-Previsão de Holt-Winters na previsão do consumo.




Figura 4.12-Previsão objetivo do consumo.

## 4.2 Resultados do Modelo de Sistema de Gestão de Energia Comunitária

A Figura 4.13 apresenta os resultados da soma das cargas que foram consideradas deslocáveis ao longo de 24 horas, sendo estas as mesmas especificadas na Tabela 3.3 do capítulo anterior. As cargas deslocáveis referem-se a eletrodomésticos como máquinas de lavar louça, máquinas de lavar roupa, ar condicionado entre outros, conforme detalhado no estudo focado na operação do HEMS numa única residência.

No âmbito desta pesquisa, o termo “cargas fixas” faz referência aos dispositivos elétricos ou equipamentos presentes na residência que não apresentam flexibilidade em relação aos horários de operação, mantendo uma procura constante ao longo do tempo.

Ao contrário das cargas deslocáveis, sujeitas à programação para operar em momentos específicos, as cargas fixas permanecem em funcionamento durante períodos determinados ou de forma contínua.

A Figura 4.14 apresenta a soma das cargas fixas ao longo de 24 horas do dia, considerando o cenário base. Estas cargas fixas englobam dispositivos como iluminação permanente, sistemas de refrigeração estáveis e outros equipamentos essenciais que não sofrem variações significativas nos seus padrões de operação diária. A Figura 4.15 ilustra a diferença entre o cronograma do caso base e o cronograma otimizado pelo HEMS tanto para a casa 4 como para a casa 5, onde os três cronogramas são praticamente idênticos. Este resultado deriva da utilização de um índice de conforto máximo ( $\alpha = 250$ ). É evidente que a introdução do HEMS teve um impacto significativo na distribuição da procura de carga ao longo do tempo.

Os períodos de pico de consumo, que eram anteriormente representados pela linha preta, foram notavelmente reduzidos. Além disso, a procura de carga programada após a implementação do HEMS mostra uma tendência de se concentrar nos períodos após as 21h, denominados como “períodos de vazio”. Essa reconfiguração da procura de carga evidencia a capacidade do HEMS em otimizar a gestão energética, deslocando a procura para momentos em que a oferta de energia é mais abundante ou quando os custos são mais baixos.




Figura 4.13-Soma das cargas deslocáveis durante as 24 horas, considerando o caso base.




Figura 4.14-Soma das cargas fixas durante as 24 horas.

Em relação às Figuras 4.16 e 4.17, constata-se que ao longo do dia não é economicamente viável comercializar a energia armazenada no BESS com a rede. Durante os períodos de alta incidência solar, a produção de energia fotovoltaica é significativa, reduzindo a necessidade de adquirir energia da rede.

A otimização do HEMS conduz a maiores volumes de energia provenientes da rede para a casa, no início e no final do dia, como é notória nas figuras. Esta maior injeção ocorre principalmente devido à indisponibilidade de fontes de energia renovável, especificamente a produção de energia PV, e à incapacidade do BESS em compensar essa ausência de RES. Como resultado, torna-se necessário injetar energia na casa para atender à procura de carga.

Para uma maior compreensão da Figura 4.18, é crucial descrever o significado de cada parte do círculo. Na parte mais externa, são exibidos o cronograma base e o cronograma otimizado pelo HEMS em cada casa, na figura é mostrada a quantidade de energia armazenada nas baterias e na parte mais interna são apresentados diagramas das injeções de energia casa para a rede e rede para casa. Assim, as linhas que saem de várias casas para outras, são linhas que conectam as casas e representam as trocas de energias P2P entre elas.

Também é possível observar na Figura 4.18 em que momentos ocorrem as trocas P2P, uma vez que as linhas que conectam uma casa à outra começam e terminam no mesmo intervalo de tempo. Por exemplo, entre a casa 3 e a casa 5 existe uma transição P2P, onde a casa 3 envia energia para a casa 5 entre as 2:00 e 5:00 horas, e a casa 5 recebe essa quantidade de energia no mesmo período horário. Reforçando a ideia anterior com outra transação P2P, entre a casa 4 e a casa 5, a casa 4 disponibiliza uma quantidade de energia entre as 2:00 e as 5:00 horas, e a casa 5 recebe essa energia em igual intervalo de tempo, devolvendo entre as 4:00 e 5:00h parte dessa energia que será armazenada no BESS da casa 4.




Figura 4.15-Procura total de carga no caso base sem o HEMS (preto) e a procura de carga programada após o HEMS (vermelho tracejado e azul tracejado para a casa 4 e casa 5, respetivamente).




Figura 4.16-Injeção de energia da rede para a casa(azul) e da casa para a rede (laranja) na casa 4.




Figura 4.17-Injeção de energia da rede para a casa(azul) e da casa para a rede (laranja) na casa 5.




Figura 4.18 -Transações P2P na Comunidade Energética composta por 5 casas.



# Conclusões

Neste capítulo destaca-se o desempenho do modelo de previsão para as energias renováveis (eólica e solar) e consumo (carga) no contexto do estudo. Para a energia eólica, diversas tentativas foram realizadas e os resultados foram avaliados com base no critério do MAPE. Nas diversas tentativas realizadas foram apresentadas com um MAPE aceitável, indicando resultados promissores nas previsões. A combinação das abordagens LSTM e *Holt-Winters* resultou em previsões que se aproximam dos valores reais, conforme evidenciado nas Figura 4.4, representando a previsão final para as 24 horas seguintes.

No caso da energia solar, o modelo também obteve resultados satisfatórios, apresentando um MAPE aceitável para os perfis considerados, os quais não contêm evidências do efeito da nebulosidade ou passagem de nuvens. A Figura 4.8 ilustra a previsão final, utilizando uma abordagem combinada, refletindo o comportamento do modelo na previsão da potência solar.

A previsão do consumo (carga) para o dia objetivo também foi conduzida com várias tentativas, tendo sido apresentado os resultados da tentativa 3 devido ao MAPE final de 2,70. A Figura 4.12 exibe a previsão final do consumo, evidenciando a capacidade do modelo em antecipar o comportamento do consumo com precisão aceitável. Além disso, o trabalho também apresenta os resultados considerando o HEMS implementado num sistema residencial comunitário, enfatizando a otimização do consumo de cargas deslocáveis ao longo de 24 horas.

Em valores médios, é possível enfatizar uma média do MAPE para a previsão da produção eólica foi de 13,30, enquanto a previsão da produção solar alcançou uma média de MAPE de 15,89, e finalizando com uma média do MAPE na previsão de carga de 3,78 permitindo assim reforçar a hipótese de sucesso na combinação das ferramentas de previsão utilizadas neste trabalho. Os resultados obtidos proporcionam uma contribuição valiosa para a compreensão da previsão dos perfis de energia renováveis e a sua relevância para os modelos de gestão comunitária de energia, delineando caminhos para futuras pesquisas e melhorias.

Para trabalhos futuros sugere-se exploração de outras possibilidades de ferramentas híbridas de previsão, como também a consideração do fenômeno da nebulosidade e da passagem de nuvens nos sistemas fotovoltaicos. Também é possível sugerir a consideração de uma maior variação no índice de desconforto no sistema HEMS utilizado para validação dos resultados de previsão, ou a implementação do modelo HEMS descrito no trabalho num outro ambiente de programação, como é o caso do *MATLAB*, ou a combinação das ferramentas desenvolvidas para um código *open-source*.



# Referências

- [1] Ordem dos Engenheiros, “Redes Inteligentes de Energia-Smart Grids.”, online: [https://www.ordemengenheiros.pt/fotos/dossier\\_artigo/43d873018197200548480134e8ef5272.pdf](https://www.ordemengenheiros.pt/fotos/dossier_artigo/43d873018197200548480134e8ef5272.pdf) (acedido em dezembro de 2023)
- [2] S. M. Amin, B. F. Wollenberg, “Toward\_a\_smart\_grid\_power\_delivery\_for\_the\_21st\_century”, IEEE Power Energy Magazine, pp 34-41, 2005
- [3] H. Lund, P. A. Østergaard, D. Connolly, and B. V. Mathiesen, “Smart energy and smart energy systems,” *Energy*, vol. 137. Elsevier Ltd, pp. 556-565, Oct. 15, 2017. doi: 10.1016/j.energy.2017.05.123.
- [4] J. Zheng, D. W. Gao, and L. Lin, “Smart meters in smart grid: An overview,” in *IEEE Green Technologies Conference*, 2013, pp. 57-64. doi: 10.1109/GreenTech.2013.17.
- [5] J. Farias Fardin, “4ª. Jornada Científica URBENERE Brasil Vitória-ES CARTA DE VITÓRIA SMART GRID.” [Online]. Available: <http://www.abradee.com.br/setor-de-distribuicao/a-distribuicao-de-energia>, (acedido em dezembro de 2023)
- [6] M. A. Judge, A. Khan, A. Manzoor, and H. A. Khattak, “Overview of smart grid implementation: Frameworks, impact, performance and challenges,” *J Energy Storage*, vol. 49, May 2022, doi: 10.1016/j.est.2022.104056.
- [7] C. W. Gellings “The Concept of Demand-Side Management for Electric Utilities”, Proceedings of the IEEE, Vol 73, pp 1468-1470, 1985
- [8] C. Bharathi, D. Rekha, and V. Vijayakumar, “Genetic Algorithm Based Demand Side Management for Smart Grid,” *Wirel Pers Commun*, vol. 93, no. 2, pp. 481-502, Mar. 2017, doi: 10.1007/s11277-017-3959-z.
- [9] G. Strbac, “Demand side management: Benefits and challenges,” *Energy Policy*, vol. 36, no. 12, pp. 4419-4426, Dec. 2008, doi: 10.1016/j.enpol.2008.09.030.
- [10] P. Warren, “A review of demand-side management policy in the UK,” *Renewable and Sustainable Energy Reviews*, vol. 29. pp. 941-951, 2014. doi: 10.1016/j.rser.2013.09.009.
- [11] S. Iqbal, Q. Ain “User Comfort Enhancement in Home Energy Management Systems using Fuzzy Logic”, (acedido em dezembro de 2023)
- [12] M. H. Albadi and E. F. El-Saadany, “A summary of demand response in electricity markets,” *Electric Power Systems Research*, vol. 78, no. 11. pp. 1989-1996, Nov. 2008. doi: 10.1016/j.epsr.2008.04.002.
- [13] Y. Yang, S. Zhang, and Y. Xiao, “Optimal design of distributed energy resource systems coupled with energy distribution networks,” *Energy*, vol. 85, pp. 433-448, Jun. 2015, doi: 10.1016/j.energy.2015.03.101.

- [14] W. Tushar *et al.*, “Three-Party Energy Management with Distributed Energy Resources in Smart Grid,” *IEEE Transactions on Industrial Electronics*, vol. 62, no. 4, pp. 2487-2498, 2015, doi: 10.1109/TIE.2014.2341556.
- [15] A. Alarcon-Rodriguez, G. Ault, and S. Galloway, “Multi-objective planning of distributed energy resources: A review of the state-of-the-art,” *Renewable and Sustainable Energy Reviews*, vol. 14, no. 5. pp. 1353-1366, Jun. 2010. doi: 10.1016/j.rser.2010.01.006.
- [16] A. R. Branco and C. Rio De Janeiro, “Recursos Energéticos Distribuídos: Impactos no Planejamento Energético julho 2018 | NOTA DE DISCUSSÃO.” [Online]. Available: <http://www.epe.gov.br>
- [17] S. Zhang and Y. Tang, “Optimal schedule of grid-connected residential PV generation systems with battery storages under time-of-use and step tariffs,” *J Energy Storage*, vol. 23, pp. 175-182, Jun. 2019, doi: 10.1016/j.est.2019.01.030.
- [18] M. Alipour, H. Salim, R. A. Stewart, and O. Sahin, “Residential solar photovoltaic adoption behaviour: End-to-end review of theories, methods and approaches,” *Renew Energy*, vol. 170, pp. 471-486, Jun. 2021, doi: 10.1016/j.renene.2021.01.128.
- [19] B. Loganathan, H. Chowdhury, I. Mustary, M. M. Rana, and F. Alam, “Design of a micro wind turbine and its economic feasibility study for residential power generation in built-up areas,” in *Energy Procedia*, Elsevier Ltd, 2019, pp. 812-819. doi: 10.1016/j.egypro.2019.02.153.
- [20] Abriendomundo, “Renewables 2023.” [Online]. Available: [www.iea.org](http://www.iea.org)
- [21] R. Howell, N. Qin, J. Edwards, and N. Durrani, “Wind tunnel and numerical study of a small vertical axis wind turbine,” *Renew Energy*, vol. 35, no. 2, pp. 412-422, Feb. 2010, doi: 10.1016/j.renene.2009.07.025.
- [22] “Turbinas Eólicas.” Accessed: Feb. 06, 2024. [Online]. Available: <https://depositphotos.com/br/vector/horizontal-vertical-axis-wind-turbine-principle-structure-outline-diagram-labeled-648775174.html>
- [23] M. S. Guney and Y. Tepe, “Classification and assessment of energy storage systems,” *Renewable and Sustainable Energy Reviews*, vol. 75. Elsevier Ltd, pp. 1187-1197, 2017. doi: 10.1016/j.rser.2016.11.102.
- [24] X. Luo, J. Wang, M. Dooner, and J. Clarke, “Overview of current development in electrical energy storage technologies and the application potential in power system operation,” *Appl Energy*, vol. 137, pp. 511-536, 2015, doi: 10.1016/j.apenergy.2014.09.081.
- [25] Y. Yang, S. Bremner, C. Menictas, and M. Kay, “Battery energy storage system size determination in renewable energy systems: A review,” *Renewable and Sustainable Energy Reviews*, vol. 91. Elsevier Ltd, pp. 109-125, Aug. 01, 2018. doi: 10.1016/j.rser.2018.03.047.
- [26] Y. Yang, S. Bremner, C. Menictas, and M. Kay, “Modelling and optimal energy management for battery energy storage systems in renewable energy systems: A review,” *Renewable and Sustainable Energy Reviews*, vol. 167. Elsevier Ltd, Oct. 01, 2022. doi: 10.1016/j.rser.2022.112671.

- [27] X. Li and S. Wang, "Energy management and operational control methods for grid battery energy storage systems," *CSEE Journal of Power and Energy Systems*, vol. 7, no. 5, pp. 1026-1040, Sep. 2021, doi: 10.17775/CSEEJPES.2019.00160.
- [28] A. M. Koufakis, E. S. Rigas, N. Bassiliades, and S. D. Ramchurn, "Offline and Online Electric Vehicle Charging Scheduling with V2V Energy Transfer," *IEEE Transactions on Intelligent Transportation Systems*, vol. 21, no. 5, pp. 2128-2138, May 2020, doi: 10.1109/TITS.2019.2914087.
- [29] G. O. Barros, G. Novo, "TE 119 - Veículos Elétricos em Portugal - Oportunidades e Desafios Económicos e Ambientais", (acedido em dezembro de 2023).
- [30] U. ur Rehman, "A robust vehicle to grid aggregation framework for electric vehicles charging cost minimization and for smart grid regulation," *International Journal of Electrical Power and Energy Systems*, vol. 140, Sep. 2022, doi: 10.1016/j.ijepes.2022.108090.
- [31] S. Mohanty *et al.*, "Demand side management of electric vehicles in smart grids: A survey on strategies, challenges, modelling, modeling, and optimization," *Energy Reports*, vol. 8, pp. 12466-12490, Nov. 2022, doi: 10.1016/j.egyr.2022.09.023.
- [32] D. Ding, R. A. Cooper, P. F. Pasquina, and L. Fici-Pasquina, "Sensor technology for smart homes," *Maturitas*, vol. 69, no. 2, pp. 131-136, Jun. 2011. doi: 10.1016/j.maturitas.2011.03.016.
- [33] V. Gopinath, A. Srija, S. Krishna Rao, and A. Madhuri, "Smart Homes: Steps, components, utilities and challenges," *International Journal of Engineering and Technology (UAE)*, vol. 7, pp. 436-440, 2018, doi: 10.14419/ijet.v7i2.7.10858.
- [34] J. J. Cuenca, E. Jamil, and B. Hayes, "State of the Art in Energy Communities and Sharing Economy Concepts in the Electricity Sector," *IEEE Trans Ind Appl*, vol. 57, no. 6, pp. 5737-5746, 2021, doi: 10.1109/TIA.2021.3114135.
- [35] I. F.G. Reis, I. Gonçalves, M. A.R. Lopes, and C. Henggeler Antunes, "Business models for energy communities: A review of key issues and trends," *Renewable and Sustainable Energy Reviews*, vol. 144. Elsevier Ltd, Jul. 01, 2021. doi: 10.1016/j.rser.2021.111013.
- [36] A. Kumar Singh, S. Khatoon, M. Muazzam, and D. K. Chaturvedi, "Network and Complex Systems: An Overview of Electricity Demand Forecasting Techniques," vol. 3, no. 2, 2013, [Online]. Available: [www.iiste.org](http://www.iiste.org)
- [37] S. F. Rafique and Z. Jianhua, "Energy management system, generation and demand predictors: A review," *IET Generation, Transmission and Distribution*, vol. 12, no. 3. Institution of Engineering and Technology, pp. 519-530, Feb. 13, 2018. doi: 10.1049/iet-gtd.2017.0354.
- [38] C. Wang and X. Zhou, "Water Bloom Prediction Method Based on Holt-Winters-LSTM," in *Proceedings - 2023 15th International Conference on Intelligent Human-Machine Systems and Cybernetics, IHMSC 2023*, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 108-111. doi: 10.1109/IHMSC58761.2023.00033.

- [39] D. Sugiarto, W. Hidayat, D. Ariatmanto, and A. Yaqin, "Comparing Holt-Winters and Multi Layer Perceptron in Forecasting the Amount of Rice Supply," in *ICOI ACT 2021 - 4th International Conference on Information and Communications Technology: The Role of AI in Health and Social Revolution in Turbulence Era*, Institute of Electrical and Electronics Engineers Inc., 2021, pp. 252-255. doi: 10.1109/ICOI ACT53268.2021.9563977.
- [40] N. A. Elmunim, M. Abdullah, A. M. Hasbi and S. A. Bahari, "Short-term Forecasting Ionospheric Delay Over UKM, Malaysia, Using the Holt-Winters Method".
- [41] W. Jiang, X. Wu, Y. Gong, W. Yu, and X. Zhong, "Holt-Winters smoothing enhanced by fruit fly optimization algorithm to forecast monthly electricity consumption," *Energy*, vol. 193, Feb. 2020, doi: 10.1016/j.energy.2019.116779.
- [42] W. Kanchana and S. Sirisukprasert, "PV Power Forecasting with Holt-Winters Method," in *2020 8th International Electrical Engineering Congress, iEECON 2020*, Institute of Electrical and Electronics Engineers Inc., Mar. 2020. doi: 10.1109/iEECON48109.2020.229517.
- [43] "SAS: Análise, Inteligência Artificial e Gestão de Dados | SAS." Accessed: Feb. 12, 2024. [Online]. Available: [https://www.sas.com/pt\\_pt/home.html](https://www.sas.com/pt_pt/home.html)
- [44] M. Dua, D. Makhija, P. Y. L. Manasa, and P. Mishra, "A CNN-RNN-LSTM Based Amalgamation for Alzheimer's Disease Detection," *J Med Biol Eng*, vol. 40, no. 5, pp. 688-706, Oct. 2020, doi: 10.1007/s40846-020-00556-1.
- [45] S. Leijnen and F. van Veen, "The Neural Network Zoo," MDPI AG, May 2021, p. 9. doi: 10.3390/proceedings2020047009.
- [46] L. Liu and L. Wu, "Holt-Winters model with grey generating operator and its application," *Commun Stat Theory Methods*, vol. 51, no. 11, pp. 3542-3555, 2022, doi: 10.1080/03610926.2020.1797804.
- [47] T. M. Dantas, F. L. Cyrino Oliveira, and H. M. Varela Repolho, "Air transportation demand forecast through Bagging Holt Winters methods," *J Air Transp Manag*, vol. 59, pp. 116-123, Mar. 2017, doi: 10.1016/j.jairtraman.2016.12.006.
- [48] J. V. 'Lisboa and C. F. 'Gomes, *Gestão de Operações*, 3ª. 2018.
- [49] W. Zha *et al.*, "Forecasting monthly gas field production based on the CNN-LSTM model," *Energy*, vol. 260, Dec. 2022, doi: 10.1016/j.energy.2022.124889.
- [50] J. Wang, J. Li, X. Wang, J. Wang, and M. Huang, "Air quality prediction using CT-LSTM," *Neural Comput Appl*, vol. 33, no. 10, pp. 4779-4792, May 2021, doi: 10.1007/s00521-020-05535-w.
- [51] J. Cao, Z. Li, and J. Li, "Financial time series forecasting model based on CEEMDAN and LSTM," *Physica A: Statistical Mechanics and its Applications*, vol. 519, pp. 127-139, Apr. 2019, doi: 10.1016/j.physa.2018.11.061.
- [52] D. Chicco Corresp, M. J. Warrens, G. Jurman, and D. Chicco, "The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE, and RMSE in regression analysis evaluation analysis evaluation 4," 2021.

- [53] J. Larrosa, A. Oliveras, and E. Rodríguez-Carbonell, “Mixed Integer Linear Programming Combinatorial Problem Solving (CPS),” 2023.
- [54] M. S. Javadi, M. Gough, M. Lotfi, A. Esmaeel Nezhad, S. F. Santos, and J. P. S. Catalão, “Optimal self-scheduling of home energy management system in the presence of photovoltaic power generation and batteries,” *Energy*, vol. 210, Nov. 2020, doi: 10.1016/j.energy.2020.118568.
- [55] P. K. Wesseh and B. Lin, “A time-of-use pricing model of the electricity market considering system flexibility,” *Energy Reports*, vol. 8, pp. 1457-1470, Nov. 2022, doi: 10.1016/j.egyr.2021.12.027.
- [56] J. M. Veras *et al.*, “A multi-objective demand response optimization model for scheduling loads in a home energy management system,” *Sensors (Switzerland)*, vol. 18, no. 10, Oct. 2018, doi: 10.3390/s18103207.
- [57] G. Ribeiro and D. P. João S Catalão, “FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO Energy Management in Residential Communities with Renewable Microgeneration and Storage.”
- [58] “REN | Redes Energéticas Nacionais.” Accessed: Feb. 08, 2024. [Online]. Available: <https://www.ren.pt/>
- [59] “Inicio | Red Eléctrica.” Accessed: Feb. 08, 2024. [Online]. Available: <https://www.ree.es/es>
- [60] “OMEL.” Accessed: Feb. 08, 2024. [Online]. Available: <https://www.omeldiversificacion.es/pt>
- [61] “ERSE - Início.” Accessed: Feb. 08, 2024. [Online]. Available: <https://www.erse.pt/inicio/>
- [62] “Gás Natural, Eletricidade e Serviços Energéticos | EDP.” Accessed: Feb. 08, 2024. [Online]. Available: <https://www.edp.pt/particulares/>