



**INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA**

**Departamento de Engenharia Eletrotécnica de Energia e Automação**



## **Aplicação de Redes Neurais para Previsão de Cargas no horizonte do planeamento operacional**

**DIOGO ALEXANDRE TRINDADE RIBEIRO INÁCIO**  
(Licenciado em Engenharia Eletrotécnica)

Dissertação de natureza científica para obtenção do grau de Mestre em  
Engenharia Eletrotécnica  
Ramo: Energia

**Orientadores:**

Professor Doutor Francisco Alexandre Ganho da Silva Reis  
Professora Doutora Ana Alexandra Antunes Figueiredo Martins

**Júri:**

Presidente: Professora Doutora Rita Marcos Fontes Murta Pereira  
1º Vogal: Professor Doutor João Hermínio Ninitas Lagarto  
2º Vogal: Professor Doutor Francisco Alexandre Ganho da Silva Reis

**Fevereiro, 2023**





**INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA**

**Departamento de Engenharia Eletrotécnica de Energia e Automação**



## **Aplicação de Redes Neurais para Previsão de Cargas no horizonte do planeamento operacional**

**DIOGO ALEXANDRE TRINDADE RIBEIRO INÁCIO**  
(Licenciado em Engenharia Eletrotécnica)

Dissertação de natureza científica para obtenção do grau de Mestre em  
Engenharia Eletrotécnica  
Ramo: Energia

**Orientadores:**

Professor Doutor Francisco Alexandre Ganho da Silva Reis  
Professora Doutora Ana Alexandra Antunes Figueiredo Martins

**Júri:**

Presidente: Professora Doutora Rita Marcos Fontes Murta Pereira  
1º Vogal: Professor Doutor João Hermínio Ninitas Lagarto  
2º Vogal: Professor Doutor Francisco Alexandre Ganho da Silva Reis

**Fevereiro, 2023**



# Resumo

Dado o crescimento exponencial da população e, conseqüentemente, o aumento do consumo de energia elétrica, surge a necessidade de prever a procura, para garantir um abastecimento ininterrupto e estável.

Uma vez que a eletricidade é consumida ao mesmo ritmo que é produzida nas centrais, o uso da previsão de energia, tanto no lado da produção como do lado do consumo, é fulcral para se manter uma rede de transporte e distribuição estável.

No entanto, o consumo não é um valor linear, sendo afetado por variáveis externas como a temperatura, o dia da semana e o mês do ano. Um outro fator que introduz aleatoriedade no sistema, são as Fontes de Energia Renováveis (FER), devido à sua componente estocástica referente ao seu recurso primário.

Neste trabalho é apresentado um modelo *Multilayer Perceptron* de previsão a curto prazo (24h), definido como um tipo de Rede Neuronal, considerada como um método de Inteligência Artificial, que tomou por base os dados relativos aos consumos de energia, registados durante os períodos de 2014 a 2017.

Para a previsão em estudo, foram obtidos resultados de MAPE de 3,43%, 4,66% e RMSE de 2639MW, 1201MW, para o modelo MLP e *naïve* respetivamente.

As conclusões retiradas deste trabalho evidenciam que, através do modelo de previsão utilizado, se consegue obter resultados precisos, com margens de erro reduzida. Os resultados permitiram aferir que este método se apresenta como um método fiável para o estudo da previsão do consumo de energia.

**Palavras-chave:** Modelos de previsão; Previsão de cargas; Previsão no curto prazo; Redes Neurais.



# Abstract

Given the exponential growth of the population and, consequently, the increase in electricity consumption, the demand needs to be forecasted in order to guarantee an uninterrupted and stable supply.

Since electricity is consumed at the same rate as it is produced in the power plants, the use of power forecasting on both the production and consumption side is key to maintaining a stable transmission and distribution network.

However, consumption is not a linear value and is affected by external variables such as temperature, day of the week and month of the year. Another factor that introduces randomness into the system is the Renewable Energy Sources (RES), due to its stochastic component referring to its primary resource.

This work presents a Multilayer Perceptron model for short-term (24h) forecasting, defined as a type of Neural Network, considered as a method of Artificial Intelligence, which was based on data related to energy consumption, recorded during the periods from 2014 to 2017.

For the prediction under study, MAPE results of 3,43%, 4,66% and RMSE of 2639MW, 1201MW, were obtained for the MLP model and *naïve* respectively.

The conclusions drawn from this work show that, through the forecast model used, it is possible to obtain accurate results, with reduced error margins. The results allow us to conclude that this method is a reliable method for the study of energy consumption forecasting.

**Keywords:** Forecast Models; Load forecasting; Short-term forecast; Neural Networks.



## Agradecimentos

Antes de mais, agradecer ao Instituto Superior de Engenharia de Lisboa (ISEL), instituição que me acolheu e permitiu seguir Engenharia.

Um agradecimento ao Professor Doutor Francisco Reis, por se ter disposto a orientar este trabalho e pelo apoio rigoroso e motivante. À Professora Doutora Ana Martins, pela disponibilidade e orientação ao longo desta etapa. Aos dois, agradeço a transmissão de todo o conhecimento durante a licenciatura e o mestrado.

Aos meus pais, que me permitiram estudar e seguir o meu caminho, apoiando constantemente as minhas decisões, agradeço o seu esforço incrível. Sem eles, este passo não teria sido possível.

À Ana, pela motivação e apoio que me deu durante esta fase académica. Pela sua contribuição para eu fazer mais e melhor.



*Este trabalho e dedicado à minha avó.  
Obrigada por tudo o que fizeste por mim.*



# Lista de Siglas e Abreviaturas

ANN – Artificial Neural Network  
AR - Autoregressivos  
ARMA – Autoregressive-Moving-Average  
ARIMA – Auto-Regressive Integrated Moving Average  
BiLSTM – Bidirectional LSTM  
BT – Baixa Tensão  
BTN – Baixa Tensão Normal  
C – Célula  
C° - Centígrados  
CNN – Convolutional Neural Network  
CSPF – Clustering-based Similar Pattern Forecasting  
DC – Direct Current  
DGEG – Direção-Geral de Energia e Geologia  
EDP – Energias de Portugal  
ELM – Extreme Learning Machines  
ERSE – Entidade Reguladora dos Serviços Energéticos  
FER – Fontes de Energias Renováveis  
Fig – Figura  
FITNET – Function Fitting Neural Network  
FOA – Fruit Fly Optimization  
h - Horas  
IA – Inteligência Artificial  
i.e. – isto é  
LSTM – Long-Short-Term Memory  
LSSVM – Least Squares Support Vector Machine  
MA – Moving Average  
MAE – Mean Absolute Error  
MAPE – Mean Absolute Percent Error  
MASE – Mean Absolute Scaled Error  
ME – Mean Error  
Min – minutos

ML – Machine Learning  
MLP – Multi-Layer Perceptron  
MT – Média Tensão  
MSE – Mean-Squared Error  
Nº - Número  
PNN – Probabilistic Neural Network  
REN – Rede Energéticas Nacionais  
RMSE – Root Mean Squared Error  
RN – Redes Neurais  
RNA – Redes Neurais Artificiais  
RNN – Recurrent Neural Network  
SARIMA – Seasonal Autoregressive Integrated Moving Average  
SVM – Support Vector Machine  
TDNN – Time Delay Neural Network  
UE – União Europeia

## Lista de Símbolos

$L(t)$  – Carga

$x_j$  -Dados de entrada

$\alpha$  - *Drift*

$v(t)$  – Erro do modelo

$y(t)$  – Erro residual

$f(net)$  – Função transferência

$f_i(t)$  – Funções compostas por sinusoides

$l$  – *Lag*

$T$  – Matriz transposta

$n$  – Número de observações / tamanho da amostra

$\gamma$  – Números inteiros

$y_p(t)$  – Padrões climatéricos

$t_p$  – Período da altura do dia

$m$  – Período sazonal da série-temporal

$w_j$  – Peso do vetor

$\varepsilon_t$  – Ruído

$O$  – Sinal de saída

$t$  – Tempo

$\beta$  - Tendência

$\theta$  – Valor de *threshold*



# Índice

<b>Lista de Siglas e Abreviaturas</b> .....	<b>ix</b>
<b>Lista de Símbolos</b> .....	<b>xi</b>
<b>Lista de Tabelas</b> .....	<b>xv</b>
<b>Índice de Figuras</b> .....	<b>xvii</b>
<b>1. Introdução</b> .....	<b>1</b>
1.1. Enquadramento .....	1
1.2. Motivação e Objetivos.....	3
1.3. Estrutura da Dissertação .....	4
<b>2. Estado da Arte</b> .....	<b>5</b>
2.1. Introdução.....	5
2.2. Inteligência artificial .....	6
2.3. Redes Neurais .....	7
2.3.1. Conceitos introdutórios.....	7
2.3.2. Aprendizagem da Rede Neuronal .....	13
2.3.2.1. Fenómeno de <i>overfitting</i> e <i>underfitting</i> .....	15
2.4. Previsão do consumo de energia .....	16
2.4.1. Séries Temporais e as suas características .....	18
2.4.2. Modelos lineares .....	23
2.4.3. Modelos não-lineares .....	26
2.4.3.1. Métodos heurísticos.....	26
2.4.3.2. Modelos baseados em computação evolucionária (Híbridos).....	34
2.5. Aplicação ao contexto português.....	36
2.5.1. Caracterização do consumo em Portugal.....	43
<b>3. Metodologia</b> .....	<b>49</b>
3.1. Escolha do modelo .....	50
3.1.1. Implementação no Rstudio .....	50
3.2. Criação da Rede.....	54
3.2.1. Implementação no Rstudio.....	54
3.2.2. Métricas para avaliar o erro.....	59
3.3. Modelo <i>naive</i> .....	61
<b>4. Apresentação e Análise de Resultados</b> .....	<b>63</b>
4.1. Pré-processamento e Análise dos dados .....	63

4.2. Resultados obtidos .....	73
4.3. Comparação com resultados dos métodos <i>naive</i> .....	89
<b>5. Conclusões e trabalho futuro.....</b>	<b>97</b>
<b>6. Bibliografia.....</b>	<b>100</b>
<b>Anexos.....</b>	<b>105</b>

## Lista de Tabelas

4.1	Índices estatísticos dos anos 2014 a 2016 .....	64
4.2	Índices estatísticos de 2017.....	64
4.3	Indicadores de erro para os meses do ano de 2017.....	74
4.4	Feriado, dia da semana e mês correspondente .....	80
4.5	Tabela comparativa entre modelos usando indicador MAPE	90
4.6	Tabela comparativa entre modelos usando indicador RMSE	91
A.1	Valores previstos das 24h seguintes.....	106



# Índice de Figuras

1.1	Penetração das Fontes de Energias Renováveis, no sistema elétrico nacional.....	2
2.1	Relação entre IA, ML e RN .....	6
2.2	Neurónio Artificial.....	9
2.3	Rede neuronal.....	9
2.4	Rede neuronal direta.....	11
2.5	Rede neuronal direta, múltiplas camadas .....	12
2.6	Diferença de uma rede com underfitting e overfitting .....	15
2.7	Esquema de modelos para previsão do consumo .....	17
2.8	Consumo nos primeiros 6 meses do ano de 2017 em Portugal .....	18
2.9	Série de consumo de eletricidade do ano 2015 .....	19
2.10	Série estacionária VS não estacionária .....	21
2.11	Random walk process .....	22
2.12	Sumário dos modelos lineares .....	23
2.13	MLP com 2 camadas escondidas.....	27
2.14	Processo de <i>backpropagation</i> .....	28
2.15	Função gradiente .....	28
2.16	Arquitetura de uma rede CNN .....	31
2.17	Arquitetura de uma rede RNN.....	31
2.18	Célula RNN e célula LSTM .....	33
2.19	Preparação dos dados de entrada .....	33
2.20	Time delay neural network (TDNN).....	35
2.21	Consumo de energia primária per capita na UE-27 em 2020 .....	37
2.22	Consumo de energia elétrica: total e por tipo de consumo .....	38
2.23	Potência instalada em 2017 .....	39
2.24	Satisfação do consumo anual .....	40
2.25	Diagrama de carga do dia da ponta anual (de inverno) e do dia de ponta de Verão .....	40
2.26	Consumo no sector doméstico e peso do consumo do sector doméstico no consumo final de energia .....	41
2.27	Evolução dos preços médios da eletricidade em Portugal.....	42
2.28	Perfil de consumo normalizado para BTN Simples Classe B .....	44
2.29	Evolução do consumo mensal de 2017 face ao mês homólogo do ano anterior.....	45
2.30	Previsão de um dia genérico apresentado no site da REN .....	45
2.31	Diagrama de carga dos dias característicos (2017) .....	46
2.32	Diagrama de carga dos dias característicos (2021) .....	47

3.1	Rede <i>default</i> com 5 nós .....	51
3.2	Comparação dos 3 métodos (Média, Mediana, Moda) .....	52
3.3	Previsão do dia seguinte através da função <i>forecast</i> .....	53
3.4	Fluxograma com processo da previsão .....	55
3.5	Variáveis explicativas (xreg) a azul. ....	56
3.6	Lista das variáveis explicativas .....	56
3.7	Criação da Rede (2) .....	57
3.8	Definição da Rede .....	57
3.9	Previsão guardada na variável <i>fc12</i> .....	57
3.10	Ciclo <i>for</i> criado para prever o mês de janeiro .....	58
3.11	Dados de saída e atualizações das variáveis .....	58
3.12	Comparação dos dados previstos com os dados reais, usando a função <i>accuracy</i> .....	61
4.1	Consumo de energia nos anos 2014 a 2017 .....	65
4.2	Valores de temperatura nos anos 2014 a 2017 .....	65
4.3	Consumo de 3 anos em Portugal .....	66
4.4	Variação da temperatura ao longo de 3 anos .....	66
4.5	Consumo nos primeiros 6 meses do ano de 2017 em Portugal .....	67
4.6	Comportamento do consumo e da temperatura .....	68
4.7	Consumo entre Janeiro e Agosto de 2017 .....	69
4.8	Variação do consumo ao longo de uma semana de Janeiro de 2017 .....	69
4.9	Variação do consumo ao longo de uma semana de Agosto de 2017 .....	70
4.10	Variação do consumo numa segunda-feira em Janeiro .....	70
4.11	Variação do consumo numa segunda-feira em Agosto .....	71
4.12	Diferença de consumo entre os dias da semana .....	72
4.13	Consumo ao fim de semana e durante a semana .....	72
4.14	Indicador MAPE ao longo do ano de 2017 .....	74
4.15	Erro relativo calculado na previsão do mês de abril do ano 2017 .....	75
4.16	erro entre dia 15 e 16 de Abril de 2017 .....	76
4.17	Comportamento da previsão desde dia 16 de Abril (feriado) até dia 19, no ano de 2017 .....	77
4.18	Comparação do consumo previsto e real para o dia 16 de Abril (Páscoa), no ano de 2017 .....	78
4.19	Comparação do consumo previsto e real para os 3 dias seguintes à Páscoa .....	78
4.20	Desvio em feriados e festividades no ano de 2017 .....	79
4.21	Desvio em dias que sucedem feriados no ano de 2017 .....	80
4.22	Temperaturas de 3 feriados ao longo do ano de 2017 .....	81
4.23	Consumo de 3 feriados ao longo do ano de 2017 .....	82
4.24	Variação do erro usando uma nova <i>dummie</i> para dias de pontes.....	83

4.25	Temperaturas de 3 dia úteis ao longo do ano de 2017 .....	84
4.26	Consumo de 3 dias úteis ao longo do ano de 2017 .....	84
4.27	Desvios ao longo do dia para todo o ano 2017 .....	85
4.28	Horas que apresentam uma maior percentagem de erro .....	86
4.29	Número de erros acima de 10% em todo o ano de 2017 .....	87
4.30	Número de erros acima de 10% em todo o ano de 2017, sem feriados e pontes .....	88
4.31	Erros nos dias de semana do ano de 2017, sem feriados e pontes.....	89
4.32	Comparação do MAPE para MLP e Naive .....	90
4.33	Comparação do RMSE para MLP e Naive .....	91
4.34	Previsão usando método naive diário, MAPE: 6,72 .....	92
4.35	Previsão usando método naive semanal, MAPE: 4,68 .....	93
4.36	Comparação dos erros dos dois métodos do modelo naive .....	94
4.37	Previsão usando método MLP, MAPE: 3,33 .....	95
4.38	Previsão e erro, usando método naive semanal .....	96
4.39	Previsão e erro, usando método MLP .....	96
A.1	Previsão e consumo real das 24h seguintes .....	105
A.2	Variação do erro ao longo do dia em todos os sábados, domingo e segunda do ano [real-previsto].....	107
A.3	Variação do MAPE com a temperatura para o ano previsto de 2017 .....	108



# Capítulo 1

## Introdução

O presente capítulo apresenta um enquadramento do tema, a motivação que levou à elaboração desta dissertação e a estrutura do documento.

Apenas como nota introdutória, ao longo de todo o documento serão usados os termos "previsão de carga" e "previsão do consumo" que terão o mesmo significado, apesar de um ser expresso em energia e o outro em potência.

### 1.1 Enquadramento

A previsão do consumo de energia é um tema em desenvolvimento, com cada vez mais importância no contexto atual, tornando-se hoje parte crucial nos sistemas de planeamento e operação, detidos pelas entidades responsáveis dos sistemas elétricos. Este desenvolvimento, despoleta uma crescente atualização das metodologias de previsão, para que estas possam garantir o equilíbrio dos sistema elétrico, entre a produção e o consumo, capturando diferentes características impactantes da previsão (sazonalidade, temperatura, dia da semana, entre outras) e respondendo a diferentes horizontes temporais.

A integração de Fontes de Energias Renováveis (FER), com carácter intermitente, tem exigido dos operadores de rede uma atualização constante das ferramentas de previsão, de forma a poder gerir os recursos disponíveis. A crescente penetração das FER, acrescenta níveis de incerteza na previsão e conseqüentemente, no balanço energético, dada a aleatoriedade do seu recurso primário.




Figura 1.1: Penetração das Fontes de Energias Renováveis, no sistema elétrico nacional [1]

Por forma a manter o balanço energético, é tão importante agir tanto no lado do consumo, garantindo que os dados recolhidos e monitorizados, são feitos com cada vez mais precisão e rapidez, como do lado da produção, garantindo que existe disponibilidade de recursos para produção. Dessa forma, também os equipamentos que temos instalados atualmente nas nossas casas são cada vez mais mais inteligentes, capazes de monitorizar e transmitir os nossos consumos, facilitando os processos de recolha de dados e aumentando a fiabilidade das previsões.

A importância da atualização e melhoria dos métodos de previsão, deve-se ao facto de os custos operacionais associados a um erro de previsão, serem elevados, pois podem envolver mobilização de reserva contratada a um preço mais elevado no mercado. No caso de a previsão errar por defeito, poderá originar falhas graves, comprometendo toda a rede elétrica. Ainda assim, avaliar e prever o consumo de energia elétrica num determinado contexto, seja ele habitacional ou empresarial, é importante, no sentido em que poupa recursos a nível financeiro e de sustentabilidade.

O foco desta dissertação é pois disponibilizar uma ferramenta de curto-prazo (horizonte do planeamento operacional) para providenciar ao operador de rede uma previsão para as próximas 24 horas. Para o efeito ter-

se-á acesso a uma série temporal ([www.ren.pt](http://www.ren.pt)) que será caracterizada e identificados os factores que mais influenciam um exercício de previsão de carga (sazonalidade, dias úteis e fins de semana, temperatura, etc). Posteriormente será desenvolvido o método de previsão para o horizonte de planeamento com base em Redes Neurais e quantificado o erro da previsão.

As previsões de carga inserem-se em horizontes temporais diferentes, desde anuais a instantâneos, sendo que cada um serve um propósito diferente. Os intervalos mais utilizados são: anual, mensal, semanal, diário e instantâneo.

O primeiro ajuda em estudos de investimentos, para reforços da Rede Elétrica. O segundo e o terceiro, servem para gerir planos de manutenção programada de equipamentos e coordenações térmicas respetivamente. A previsão diária auxilia no planeamento operacional e é baseado em informações de mercado e outras previsões de carga. O horizonte instantâneo servirá para pequenos ajustes nos valores a produzir nas centrais.

O presente trabalho pretende aplicar métodos de previsão de curto prazo (diários), de forma a apoiar o operador de rede na gestão diária da rede.

## 1.2 Motivação e Objetivos

Uma vez que a procura mundial de energia cresce rapidamente, a par com as preocupações das alterações climáticas, da proteção do ambiente e dos preços voláteis da energia, nasce a necessidade da criação de acordos internacionais. Em 2015, foi estabelecido o Objetivo de Desenvolvimento Sustentável 7, um dos 17 Objetivos de Desenvolvimento Sustentável, estabelecidos pela Assembleia Geral das Nações Unidas, que visa, até 2030, aumentar substancialmente a participação de energias renováveis na matriz energética global.

Como referido anteriormente, a intrusão de energias renováveis no sistema elétrico nacional, desestabiliza o balanço energético, devido aos seus recursos estocásticos, levando à necessidade de atualização dos métodos de previsão, por parte dos operadores de rede. Num even-

tual déficit energético, as consequências são especialmente relevantes, tendo em conta a mobilização de recursos de reserva (centrais de *backup*) e os seus custos inerentes.

O paradigma estabelecido serve de motivação ao trabalho apresentado. A ferramenta que se preconiza com este trabalho deverá disponibilizar aos operadores de rede uma previsão do consumo para as próximas 24 horas, mantendo os elevados padrões no que respeita à segurança de abastecimento e robustez do sistema.

Esta dissertação assenta em quatro etapas relevantes: 1) pré processamento e caracterização dos dados; 2) criação da Rede Neuronal e descrição das métricas que a acompanham; 3) previsão do consumo para o horizonte operacional, quantificando o erro; 4) comparação dos resultados com modelo de referência;

## 1.3 Estrutura da Dissertação

O presente trabalho está dividido de seguinte forma:

Capítulo 2: “Estado da Arte” apresenta os atuais estudos em vigor tendo por base as Redes Neurais. São explicados os diversos Modelos e Métodos, focando nos que atualmente são mais utilizados.

Capítulo 3: “Metodologia” refere os métodos que vão ser primordialmente usados na análise e comparação das variáveis. É também explicado o processo inicial no tratamento dos dados e a obtenção dos primeiros resultados, que permitirão perceber as relações existentes entre as diferentes variáveis.

Capítulo 4: “Apresentação e Análise de resultados” descreve os dados com os quais se irá trabalhar ao longo do documento, detalhando as variáveis presentes e os seus efeitos ao longo das simulações. São apresentados os resultados obtidos da previsão e é feita uma comparação com um modelo de referência.

Por fim, Capítulo 5: “Conclusões e trabalho futuro” são retiradas as principais conclusões do trabalho e indicadas sugestões para trabalhos futuros.

# Capítulo 2

## Estado da Arte

No presente capítulo é feita uma introdução ao tema da Inteligência Artificial, com foco nas Redes Neurais. Em seguida são apresentadas as metodologias utilizadas na previsão do consumo de energia e a sua aplicação no contexto elétrico português.

### 2.1 Introdução

Face à crescente necessidade de processar grandes quantidades de dados e informação, tornou-se pertinente criar técnicas de aprendizagem automáticas que permitiriam resolver um elevado número de tarefas complexas no contexto de problemas de previsão de carga.

Estas técnicas de aprendizagem automáticas inserem-se numa das áreas da Inteligência Artificial (IA), cujo objetivo é o desenvolvimento de processos que permitam aos computadores aprender com a experiência, ou seja, criar programas que sejam capazes de recriar conhecimentos a partir de exemplos.

Assim, pretende-se apresentar neste capítulo uma revisão ao estado da arte no que diz respeito aos métodos de previsão de carga, designadamente na aplicação das Redes Neurais Artificiais (RNA) à previsão de carga.

Com efeito, é feita uma breve introdução ao tema da Inteligência Artificial e a sua relação com as Redes Neurais. Em seguida, é apresentada uma definição breve das Redes Neurais e em como estas são utilizadas para prever carga.

No subcapítulo seguinte, é apresentada a importância de considerar as tendências e sazonalidades presentes nas séries temporais e, consequentemente, nos dados a fornecer aos modelos.

Por fim, é feita uma apresentação do sistema elétrico português e de como este se adaptou à previsão do consumo.

## 2.2 Inteligência Artificial

O conceito de Inteligência Artificial não é recente. Já os nossos antepassados sonhavam com a ideia de substituir a mão de obra escrava por máquinas autônomas capazes de realizar as tarefas mais difíceis. O desenvolvimento desta ideia deu-se de forma mais ampla no Século XX com a evolução da ciência computacional.

Atualmente, a Inteligência Artificial está presente numa enorme variedade de áreas tecnológicas sendo certo que, dentro destas áreas estão as Redes Neurais.

Uma rede neuronal nada mais é do que um modelo matemático capaz de reproduzir o comportamento do cérebro humano. Apesar das Redes Neurais se inserirem no campo da Inteligência Artificial, existem algumas diferenças entre os dois conceitos.




Figura 2.1: Relação entre IA, ML e RN

Segundo [2], um sistema de IA será capaz de (i) armazenar conhecimento, (ii) aplicar o conhecimento para resolver problemas e (iii) adquirir novo conhecimento através de experiências.

Atualmente existem máquinas que executam tarefas mais eficaz e rapidamente do que humanamente é viável, mas cingem-se a tarefas repetitivas e sequenciais e só assim o resultado é o esperado.

A diferença entre Inteligência Artificial e Redes Neurais incide, portanto, na forma como cada uma destas é desenvolvida/construída. Enquanto que as Redes Neurais simulam uma rede artificial de neurónios (ou nós), inspirados pelos neurónios que constituem o cérebro animal, a Inteligência Artificial cria máquinas capazes de reproduzir o comportamento humano e as suas capacidades em realizar certas tarefas.

Para já, parece-nos exequível afirmar que não existem computadores e algoritmos com inteligência mais avançada do que o Homem, até porque para a criar, ter-se-ia que partir da imaginação humana, o que naturalmente acarretaria limitações.

Existem, no entanto, máquinas que reteem informação e que corrigem com o número de iterações que fazem. Ou seja, perante uma certa tarefa, o algoritmo produz um resultado, e após N repetições daquela tarefa, o resultado estará muito mais perto da competência que se visa alcançar.

A Inteligência Artificial, composta por algoritmos com capacidade para reproduzir competências inatas aos seres humanos, como o caso do raciocínio, a aprendizagem, o planeamento e a criatividade, constitui um exemplo do aprendizado por via das repetições, pelo que será tão mais eficaz quanto mais repetidas, demoradas, complexas e abundantes em dados forem essas tarefas.

## **2.3 Redes Neurais**

### **2.3.1 Conceitos introdutórios**

Uma rede neuronal tem como elemento fundamental o neurónio, que pode ser biológico ou artificial. O desenvolvimento do estudo do neurónio biológico, que adquire conhecimento através da experiência, tem origem no início da década de 90, e criou uma nova janela de conhecimento

que permitiu a criação do conceito de neurónio artificial, que vê o cérebro como um sistema computacional.

Partindo da ideia que “Redes Neurais formam a inteligência humana, vamos reproduzir isso e criar Inteligência Artificial”, foram então desenvolvidas técnicas utilizadas na solução de casos ou problemas específicos, relacionados com diversos sectores da sociedade tais como saúde, economia, transporte, educação, indústria de máquinas ou eletricidade.

Os neurónios artificiais constituem os elementos básicos de uma Rede Neuronal que, segundo [3], podem ser representados por modelos matemáticos em que as sinapses entre eles são representadas por pesos de ligação, que modelam o efeito dos dados de entrada.

Em referência à Fig 2.2, o sinal segue desde os dados de entrada  $x_1, \dots, x_n$ , indicado pelas setas, enquanto que o sinal de saída é representado por (O). O sinal de saída é dado pela seguinte relação:

$$O = f(net) = \sum_{j=1}^N w_j x_j \quad (2.1)$$

em que  $w_j$  é o peso do vetor e a função  $f(net)$  é referida como uma função transferência. A variável  $net$ , é definida como um produto escalar entre o peso e os dados de entrada,

$$net = w^T x = w_1 x_1 + \dots + w_n x_n \quad (2.2)$$

em que  $w^T$ , é uma matriz transposta e, os dados de saída (O) são calculados segundo duas condições,

$$O = f(net) = \begin{cases} 1 & \text{se } w^T x \geq \theta \\ 0 & \text{se outro valor} \end{cases} \quad (2.3)$$

onde  $\theta$  é denominado de valor de *threshold*, ou seja, um valor limite [3].




Figura 2.2: Neurónio Artificial [3]

Em termos conceptuais, [4] esclarece que “uma rede neuronal é constituída por vários neurónios artificiais todos ligados entre si e agrupados em diferentes camadas, designadas”: camada de entrada (*Input layer*), camada oculta (*Hidden layer*) e camada de saída (*Output layer*). O neurónio é, assim, o elemento essencial de uma rede neuronal.




Figura 2.3: Rede Neuronal [5]

É referido em [6] que uma Rede Neuronal Artificial (RNA) não é mais do que “modelos simplificados do sistema nervoso central do ser humano.” Designada como uma estrutura interconectada de unidades computacionais, a RNA é um processador com capacidade de conservar conheci-

mento semelhante ao comportamento de um cérebro, na medida em que o “conhecimento é adquirido a partir de um ambiente, através de um processo de aprendizagem” e em que o “conhecimento é armazenado nas conexões, também designadas por ligações ou sinapses, entre nós”, [6].

No processo de aprendizagem, é imperativo atribuir um algoritmo como ponto de partida para daí se alcançar um determinado objetivo, sendo certo que, pese embora este seja o método comum para se obter um dado resultado, [6] considera que é também possível construir Redes Neurais Artificiais a partir de modificações à sua estrutura interna, tal como ocorre com a morte e novas sinapses do cérebro.

O autor confere que a inspiração para a criação das Redes Neurais Artificiais foi o sistema nervoso do ser vivo, em concreto o ser humano que, apesar da complexidade que o seu cérebro apresenta, a proximidade a este sistema constituiria uma forte base para a construção de sistemas inteligentes.

A lógica do funcionamento do cérebro, embora complexa, é prática e organizada: organiza os seus constituintes para que execute determinada tarefa. [6] explana a ideia suprarreferida e sintetiza o funcionamento do neurónio que se procura replicar para efeitos artificiais, na medida em que um neurónio é uma célula que responde a sinais eletroquímicos, que recebem sinais de outros neurónios via sinapses, transmitindo estímulos a outros tantos neurónios.

De volta ao neurónio artificial, [7] expõe a arquitetura de um neurónio com um comportamento comparador em que produz uma determinada saída em função do efeito das diversas entradas. Como se referiu, este é composto por várias conexões e [7] refere que, além das conexões, o neurónio é composto por um integrador. A função deste elemento é agregar os argumentos de entrada a um único valor através da função de soma, pesar as entradas numa combinação linear e pela função de ativação, pode condicionar massivamente o sinal de saída, embutindo um elemento de não linearidade ao processo. Assim, o funcionamento do neurónio pode reduzir-se a: para um neurónio com dado número de entradas e apenas uma saída, calcula-se o peso de cada neurónio para se alcançar o objetivo daquela rede neuronal.

A rede neuronal é arquitetada em função do algoritmo de aprendiza-

gem escolhido para treinar a rede, sendo este um elemento essencial para se alcançar um determinado resultado, pois a forma em que os neurónios estão dispostos está intimamente relacionada com esse algoritmo.

Em [7], são concedidos três tipos fundamentais de classes de Redes Neurais:

(1) Redes diretas de uma camada:

Neste tipo de redes, os neurónios estão organizados sob forma de camadas. Trata-se de uma rede estritamente direta, ou seja, é acíclica.




Figura 2.4: Rede neuronal direta [7]

Como é possível verificar pela Figura 2.4, a rede é de apenas uma camada, onde a camada de entrada não é considerada, já que nesta não é feito qualquer processamento computacional.

(2) Redes diretas de múltiplas camadas:

Segundo [6], este tipo de Redes distingue-se pela presença de uma ou mais camadas escondidas, cujos membros correspondentes são denominados por unidades escondidas. A função destes neurónios, é de intervir entre a entrada externa e a saída da rede de uma forma útil.

Ao adicionar uma ou mais camadas escondidas, a rede passa a ser

capaz de extrair relações de complexidade de maior ordem. As unidades escondidas são capazes de extrair informação de uma ordem de grandeza superior sendo esta capacidade particularmente valiosa quando a dimensão da camada de entrada é substancial.

Os nós de entrada, fornecem elementos pertencentes ao padrão de ativação, constituindo respetivamente um conjunto de entradas para os neurónios da segunda camada (i.e., da primeira camada escondida). Consequentemente, os sinais de saída da segunda camada vão passar a ser os sinais de entrada da terceira, e assim sucessivamente.

A Figura 2.5 ilustra o esquema de uma rede neuronal direta de múltiplas camadas.




Figura 2.5: Rede neuronal direta, múltiplas camadas [7]

### (3) Redes recorrentes:

Uma rede que seja recorrente distingue-se das anteriores através da presença de, pelo menos, um ciclo com *feedback*.

### 2.3.2 Aprendizagem da Rede Neuronal

A dificuldade que um modelo enfrenta é a de responder com resultados positivos a dados nunca antes observados, portanto, existe a necessidade de treinar a Rede o máximo de vezes possível, visto que uma das mais importantes propriedades das Redes Neurais é a sua capacidade de aprender durante o processo de treino. Quantas mais iterações existirem, mais a sua performance melhora ao longo do tempo.

A Rede aprende segundo o ambiente, através de um processo interno de ajuste aplicado aos pesos das sinapses e aos níveis da *bias*. Entenda-se por *bias*, um parâmetro usado na equação da Rede Neuronal que serve para ajustar o valor de saída, juntamente com a soma das entradas para o neurónio. Este parâmetro, torna a rede mais flexível, permitindo que a Rede inicialize o seu valor de origem, num qualquer ponto.

Segundo [2], o processo de aprendizagem é uma questão de ponto de vista, pelo que não se torna fácil concordar numa definição exata do termo. No entanto, a definição de aprendizagem aplicado ao contexto das Redes Neurais é definido como:

1. A Rede Neuronal é estimulada pelo ambiente.
2. A Rede Neuronal sofre alterações nos seus parâmetros livres (i.e. pesos das ligações) como resultado desta estimulação.
3. A rede neuronal responde de uma nova forma ao ambiente, devido às mudanças que ocorreram na sua estrutura interna.

Sendo assim, um conjunto exato de regras bem definidas proporciona à Rede Neuronal um processo de aprendizagem.

Não existe um conjunto de regras ideais que possamos seguir, que retirem sempre os melhores resultados da Rede Neuronal, no entanto, para cada aplicação, existem parâmetros e definições que se podem ajustar por forma a otimizar ao máximo a nossa rede e ir de encontro aos resultados que pretendemos.

Cada algoritmo apresenta as suas características e os seus resultados, tendo em conta as condições sob as quais devem operar uma das quais o método de aprendizagem. Segundo [2] cada Rede Neuronal pode ser caracterizada através de diferentes tipos de aprendizagem:

(1) Aprendizagem supervisionada:

Este tipo processo de aprendizagem utiliza um "professor" e a Rede

Neuronal é treinada através de uma entrada, que contém padrões e características desejadas do padrão/objetivo pretendido. Este processo de aprendizagem compara um vetor de saída com o vetor de entrada, calculando um erro que será usado para ajustar os pesos das ligações entre os neurónios da rede.

A aprendizagem supervisionada pode ser utilizada em modelos de previsão. Em [8], foi proposto um modelo baseado em aprendizagem supervisionada, capaz de prever a precipitação hora a hora, (*Hourly rainfall forecast*). Este modelo considera a correlação dos dados de precipitação em diferentes épocas do ano. De forma a obter o menor erro possível, a rede procura ajustar os pesos para valores ótimos que possam representar valores desejados para o problema da previsão da precipitação horária.

Assim, é usada uma função, *mean-squared error* (MSE) que visa calcular o erro entre os vetores de saída e as entradas.

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (2.4)$$

onde,

$n$  - tamanho da amostra

$e_t$  - diferença entre o valor real e o valor previsto

(2) Aprendizagem não-supervisionada:

Ao contrário do método anterior, neste não existe um padrão ou objetivo definido à partida, apenas é introduzido o padrão dos dados na entrada, i.e não existe a presença de um "professor".

A Rede Neuronal terá que aprender, descobrindo e adaptando-se ao padrão fornecido pelos dados de entrada.

Um exemplo deste fenómeno é o *clustering*. Este tipo de análise consiste em reconhecer, descobrir semelhanças num dado conjunto de dados e tentar agrupá-los consoante essas semelhanças.

O trabalho apresentado em [9], assenta nisto mesmo, na criação de um modelo com aprendizagem não-supervisionada, chamado de *Clustering-based Similar Pattern Forecasting* (CSPF), usado para prever a carga

elétrica Nacional, no curto espaço de tempo (15min). O modelo usa como recurso outros modelos *clustering* capazes de identificar padrões de carga nas séries temporais.

O tipo de aprendizagem sob o qual este trabalho incide é a aprendizagem supervisionada.

### 2.3.2.1 Fenómeno de *overfitting* e *underfitting*

Um modelo diz-se bem treinado se conseguir generalizar, a partir da base de dados disponível para o seu treino, os conceitos (ou características) aprendidos a exemplos ainda não “vistos” pelo modelo durante a sua fase de treino.

As terminologias utilizadas em *Machine Learning*, relativamente a quão bem um modelo está treinado, podem dividir-se em *underfitting* e *overfitting*. Estas são as duas maiores causas de uma má performance de um algoritmo de *Machine Learning*.




Figura 2.6: .  
Diferença de uma rede com *underfitting* e *overfitting* [10]

*Overfitting* é a terminologia utilizada quando uma rede neuronal modela demasiado bem a base de dados de treino. Poderá pensar-se que modelar a base de dados de treino de uma forma “quase perfeita” seria algo vantajoso, contudo, quando o modelo aprende detalhadamente os dados de treino, verifica-se, também, que existe uma aprendizagem do ruído (ou algumas flutuações aleatórias) presentes na base de dados. Isto é uma desvantagem, uma vez que esse ruído não é aplicável aos novos

cenários, contribuindo para o aumento do erro da saída, denominado por *Error on Test Data*.

Ao longo do tempo, à medida que o algoritmo aprende a base de dados de treino, o erro associado ao treino do modelo baixa. Se o modelo continuar a ser treinado por muito tempo, a sua performance relativamente à base de dados de treino continuará a aumentar, uma vez que o modelo começa a aprender também os ruídos nela existentes. Simultaneamente, o erro associado ao teste do modelo aumenta, uma vez que a capacidade do modelo em generalizar diminui.

Por outro lado, *underfitting* é a terminologia utilizada quando um modelo não consegue, simultaneamente, ajustar-se aos dados de treino, bem como aplicar-se de um modo satisfatório a novos cenários. Este caso é mais simples de ser detetado, face ao anterior, dada uma boa métrica de desempenho. A solução reside em alterar os algoritmos de *Machine Learning*.

Uma vez que a procura de energia pode ser representada por um conjunto de valores, que representam uma evolução de uma quantidade que evolui ao longo do tempo, este pode ser tratado como um problema de previsão de séries temporais [11].

Nas últimas duas décadas surgiram várias técnicas associadas a séries temporais para o estudo da previsão do consumo de energia, sendo que as mais usadas são os métodos de Inteligência Artificial, a Regressão Linear, os *Support Vector Machine* (SVM) e os modelos estatísticos, *autoregressive integrated moving average* (ARIMA) e *seasonal autoregressive integrated moving average* (SARIMA) [12]. As Redes Neurais inserem-se nos métodos da Inteligência Artificial.

## 2.4 Previsão do consumo de energia

A Fig 2.7 esquematiza o tipo de modelos que serão apresentados neste capítulo.

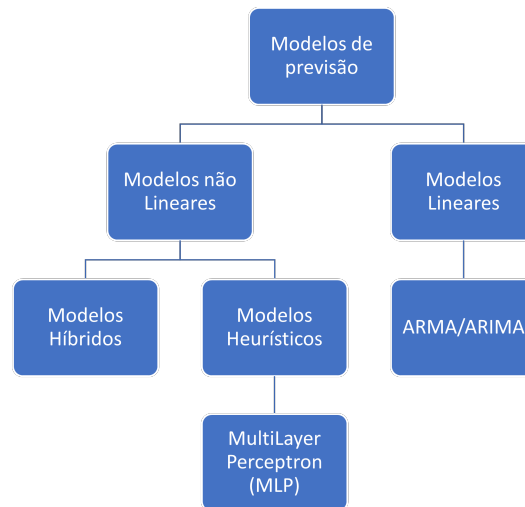


Figura 2.7: Esquema de modelos para previsão do consumo

Segundo [11], as Redes Neurais são as mais eficientes, não só pela sua robustez e flexibilidade, mas também pela facilidade em lidar com dados não-lineares, especialmente a *MultiLayer perceptron* (MLP).

Em 1995, foram introduzidos modelos de previsão, que ainda hoje são utilizados em aplicações como *data mining*, classificação e previsão usando dados temporais [13]. São exemplo disso os modelos SVM, que classificam os dados de treino, num espaço de características, através de um mapeamento não linear. O modelo associa aos novos dados, uma ou outra característica, mapeando essas escolhas no espaço, com mais ou menos distância entre características.

O processo de adaptação aos novos métodos de previsão foi demorado e gerou algum ceticismo. No estudo realizado por Hippert [14], é explicada a origem do ceticismo ao adotar estes novos métodos. Nele foram revistos 40 trabalhos (de 1991 a 1999) que estudaram as aplicações e os resultados das Redes Neurais no curto prazo.

Primeiramente, muitos dos trabalhos usaram Redes Neurais demasiado complexas, com parâmetros a mais para o conjunto de amostras que tinham, tornando a rede *overfitted* relativamente aos dados, com os erros obtidos elevados. Segundo, os modelos não eram testados repetidamente, o que levava mais uma vez a resultados pouco satisfatórios, uma vez que as redes não sofreram iterações suficientes para criar e mo-

dular os seus parâmetros.

Cometendo estes dois erros, entende-se a origem da dificuldade nas empresas em adaptarem-se às novas formas de prever utilizando as Redes Neurais nos seus métodos. Este balanceamento entre criar o modelo e adaptá-lo aos dados não é uma tarefa fácil e requer uma análise complexa tanto dos dados como dos resultados.

Eventualmente os modelos foram aperfeiçoados, novos resultados surgiram e garantiram a eficiência no uso de modelos com este tipo de tecnologia.

Os modelos não-lineares, estão diretamente ligados com os modelos de séries temporais, sendo assim, o capítulo seguinte pretende descrever o que são séries temporais e as suas características.

### 2.4.1 Séries Temporais e as suas características

Uma série temporal é uma série de valores indexados por ordem cronológica. Exemplos de séries temporais que assistimos no nosso dia-a-dia são, as medições de temperatura, as medições de precipitação, as alturas das ondas, os preços das ações de uma empresa, os consumos de energia de um país, etc.

A Fig. 2.8 representa os valores de consumos de energia durante 6 meses.




Figura 2.8: Consumo nos primeiros 6 meses do ano de 2017 em Portugal

No gráfico podemos observar algumas das características inerentes a

dados temporais, como a tendência e sazonalidade. Quando se pretende fazer previsão usando séries temporais, há que ter em consideração a tendência e sazonalidade dos dados.

### **Tendências e Sazonalidades**

As tendências e sazonalidades são duas características importantes presentes em séries temporais. As tendências são variações que tendem a ocorrer no longo prazo da série temporal, apresentando crescimentos ou declínios em sucessivos períodos de tempo. As sazonalidades são padrões que ocorrerem ao fim de um certo tempo, da mesma forma e no mesmo espaço temporal, de forma cíclica.

Padrões sazonais facilmente reconhecidos são normalmente horários, semanais ou mensais, mas poderão tomar outra forma consoante os dados que usados. Por exemplo, na série relativa ao consumo de energia no ano 2015, nota-se a presença de tendência e a existência de sazonalidade.




Figura 2.9: Série de consumo de eletricidade do ano 2015 [15]

O facto de existir tendência e sazonalidade nos dados, não impede a obtenção de bons resultados de previsão, no entanto, existe a necessidade de caracterizar as tendências e sazonalidades no conjunto de dados a tratar.

Estas podem ter efeitos locais ou globais no conjunto de dados. Por exemplo, um comportamento crescente dos valores durante um período mais calmo, poderá significar uma anomalia local, que não irá afetar os dados de forma global, visto ser um valor ainda assim baixo quando comparado com valores de pico que ocorrerão nas amostras de dados. Por outro lado, uma anomalia global terá um outro impacto na amostra. Existe, portanto, a necessidade de identificar este tipo de anomalias e saber como corrigi-las.

[16] refere que uma das abordagens clássicas para lidar com tendências e sazonalidades em dados temporais, é a de decompor a série temporal, estimando as duas componentes e removendo-as dos dados. O autor refere a importância de realizar o processo antes da primeira iteração do modelo.

Segundo [17], os métodos clássicos, i.e ARIMA, funcionam bastante bem quando a variação é criada por uma tendência linear regular e/ou sazonalidade regular, no entanto, não funcionam tão bem quando a tendência e/ou efeitos sazonais vão mudando ao longo do tempo ou quando os valores sucessivos das flutuações irregulares são correlacionados. Se a série temporal tiver mais do que uma componente não aleatória, [18] propõe que se teste a existência de um deles (tendência ou sazonalidade) depois da eliminação do outro componente.

Numa forma simples, podemos dizer que séries temporais que não variam no tempo e que não tenham presença de tendência ou sazonalidade, são séries estacionárias.

### **Estacionaridade**

Uma série temporal estacionária é aquela cujas propriedades não dependem do momento em que a série é observada.

Adotando uma definição mais formal, dado um espaço de tempo  $t_1, \dots, t_l$  a distribuição estatística  $X_{t_1}, \dots, X_{t_l}$  é a mesma que a variação estatística  $X_{t_1+\gamma}, \dots, X_{t_l+\gamma}$  para todo o  $l$  e  $\gamma$  [19]. Isto significa que, a longo prazo, não irão existir padrões previsíveis. É, de facto, uma definição forte e que não se aplica facilmente no nosso dia-a-dia, pelo que existe a necessidade de criar uma definição de segunda ordem em que a média e a variação do processo estocástico não dependem de  $t$ , ou seja, são constantes e a correlação entre  $X_t$  e  $X_{t+\gamma}$  apenas depende de  $\gamma$ .

De forma geral, observando os dados ao longo do tempo, esperamos que estes sejam consistentes e que variem com uma certa aleatoriedade em torno de um valor médio. Se assim acontecer, estamos perante uma série temporal estacionária.




Figura 2.10: Série estacionária e série não estacionária [20]

A Fig 2.10 apresenta a diferença entre uma série estacionária e uma não estacionária, para o mesmo conjunto de dados, que representam o valor das ações da empresa Google, ao longo de 4 anos.

Os modelos estacionários representam uma grande percentagem dos modelos das séries temporais.

As séries não-estacionárias, por norma, são mais difíceis de modelar, sendo mais difícil obter previsões para os seus valores futuros.

Existem vários exemplos de séries não-estacionárias que definem a imprevisibilidade dos dados e a aleatoriedade das ações. A título de exemplo, o chamado *random walk process* é definido como "um processo em que o valor atual de uma variável é composto pelo valor passado mais um termo de erro definido como ruído branco (uma variável normal com

média zero e variância um)”. Algebricamente é definido como:

$$y_t = y_{t-1} + \epsilon_t \quad (2.5)$$

em que os valores  $\epsilon_t$  são independentes e possuem média de valor "0".

Um processo desta natureza não permite prever o resultado de  $(y_t - y_{t-1})$ , ou seja, a variação de  $y$  é totalmente aleatória. Pode ser demonstrado que a média de um *random walk process* é constante mas a sua variação não o é [19]. Dessa forma, um processo destes é considerado não-estacionário e a sua variação aumenta com  $t$ .

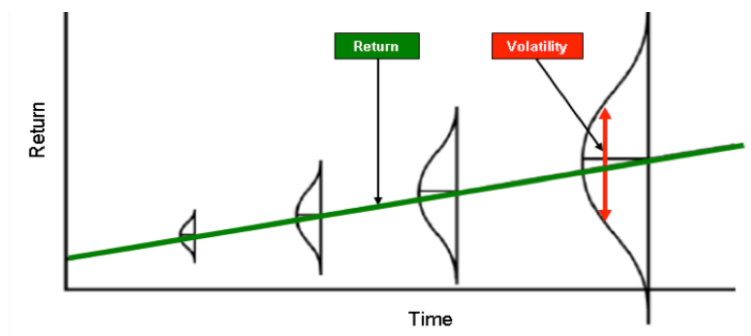


Figura 2.11: *Random walk process* [21]

À definição anterior, pode ser adicionada uma constante, ou *drift*, que se irá comportar como uma tendência. Para  $\alpha > 0$ , a tendência é no sentido ascendente.

$$y_t = y_{t-1} + \alpha + \epsilon_t \quad (2.6)$$

Concluindo, e segundo [19], ao utilizarmos um modelo de um processo estacionário para modelar uma série estacionária, iremos produzir resultados pouco fidedignos e más previsões.

A solução passa por transformar o não-estacionário em estacionário numa primeira instância. O processo que permite realizar esta mudança nos dados é chamado de *Difference*.

A desvantagem deste processo é que se perde um valor por cada diferença que é feita.

Para os casos em que existe uma tendência linear, o chamado *drift*, o processo de "conversão" de não-estacionária para estacionária é apelidado de *Detrending* e consiste em subtrair a tendência.

Seja

$$y_t = \alpha + \beta_t + \epsilon_t \quad (2.7)$$

subtraindo a tendência,

$$y_t - \beta_t = \alpha + \epsilon_t \quad (2.8)$$

Neste caso, nenhuma observação é perdida após o processo.

### 2.4.2 Modelos lineares

Segundo [22], a filosofia por trás de um modelo linear é a de sintetizar todas as variantes do problema e apresentar a solução com equações não muito complexas. Refere o autor que é também importante entender que estes modelos, quando associados à previsão de energia elétrica, são separados em *peak load* e *load shape*.

A Fig. 2.12 sumariza os modelos apresentados neste subcapítulo.

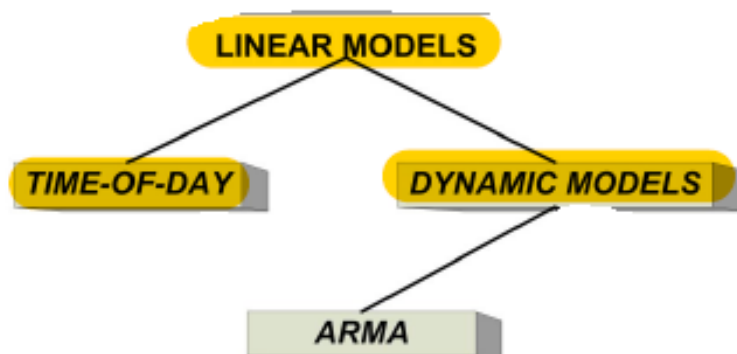


Figura 2.12: Sumário dos modelos lineares. Adaptado de [22]

Dentro do modelo *load shape* podemos definir duas variantes, *Time of the day* e *dynamic*. No estudo feito por [22], o autor explica que em modelos *Time of the day*, estes caracterizam a carga  $L(t)$  em cada ponto discreto no tempo  $t$ , com um intervalo de previsão  $T$ .

$$L(t), t = 1, 2, \dots, T - 1, T \quad (2.9)$$

O modelo guarda  $T$  valores de carga, baseados em valores observados anteriormente da dita carga.

Alguns modelos guardam os dados de carga até várias semanas antes, outros apenas a semana anterior. Um típico modelo *Time of the day* é apresentado na seguinte equação:

$$L(t) = \sum_{i=1}^T \alpha_i f_i(t) + v(t) \quad (2.10)$$

em que a carga  $L(t)$  é dada pela combinação linear finita de funções  $f_i(t)$ , compostas por sinusoides que variam entre 24h e 168h, dependendo da previsão prevista e por  $v(t)$  que representa o erro do modelo.

Os modelos *dynamic*, acrescentam uma nova camada de complexidade, percebendo que a carga não depende apenas do *time of the day*, mas também de condições climáticas e outras variáveis aleatórias. Estes modelos podem ser classificados como ARMA [22] e são caracterizados pela seguinte equação:

$$L(t) = y_p(t) + y(t) \quad (2.11)$$

em que  $y_p(t)$ , segundo [23], depende inteiramente da altura do dia e das condições climáticas usuais desse mesmo dia; esta componente pode ser representado pela equação 2.10. O termo  $y(t)$  representa um erro residual para a carga, tendo em conta as possíveis alterações de clima.

Em [23], é descrito um modelo *dynamic* formado por 5 componentes em  $y_p(t)$ , em que os componentes principais são os padrões médios de carga diária e a média de aumento de carga semanal. Inclui também erros que estão relacionados com a *bias* e com as possíveis alterações climáticas.

A equação 2.11, serve como base para outras literaturas, com formas de representar a componente da carga diferentes.

Em [24], a componente da carga passa por um processo de filtragem, com o intuito de remover a componente periódica,

$$L(t) = L(t) - L(t - t_p) \quad (2.12)$$

onde  $t_p$  representa o período da altura do dia da componente e  $L(t)$  representa o resultado do processo, sem a componente periódica.

Os modelos ARIMA são uma evolução dos modelos (ARMA) que surgem da combinação de três classes importantes de modelos de previsão, modelos autoregressivos (AR), modelos integrados e modelos moving average (MA). Os ARIMA diferenciam-se dos modelos ARMA devido à sua componente integradora, representada pela letra "I". Quando, por exemplo, uma série é (I), isso significa que ela é estacionária após diferenciação, ou seja, sendo  $X_t$  a série temporal não estacionária,  $X_t - X_{(t-1)}$  já é estacionária.

Na introdução deste capítulo foi referida a dificuldade destes modelos em lidar com a não-linearidade, tendo sido então feita uma adaptação aos modelos existentes, incluindo uma variável relativa à temperatura.

A previsão de energia não é um tema trivial e apresenta inúmeras variáveis não-lineares que necessitam ser trabalhadas e introduzidas num modelo, o que não se coaduna com a definição de modelo linear.

Os modelos lineares apresentam o enorme desafio que é transcrever as variáveis do problema real para a equação que define o modelo.

Para previsão de carga, os modelos apresentados são limitativos e não têm em conta outras variáveis que poderão interferir no processo de previsão. Já os modelos *dynamic*, consideram que a carga não depende só do dia, mas também de outras variáveis como a temperatura, o mês, a estação do ano e outras variáveis aleatórias.

### 2.4.3 Modelos não-lineares

Dado o avanço feito por investigadores, os modelos não-lineares ganharam uma maior atenção e foram mais explorados, usando Redes Neurais, durante a segunda metade dos anos 80. Entre eles está James Anderson [25], que apresentou um modelo baseado no facto das ligações entre neurónios serem reforçadas cada vez que estas eram ativadas.

Com o avanço da tecnologia, os modelos que surgiam eram cada vez mais complexos e mais precisos. No ano de 1980, Kunihiko Fukushima [26] apresentou um modelo que usava reconhecimento visual de padrões.

Mais recentemente, [22] refere um conjunto de características afetas às Redes Neurais que as tornam na ferramenta ideal para prever consumos de carga. O autor caracteriza as Redes Neurais com aprendizagem adaptada, organização própria, tolerância de erro, operação em tempo real e facilidade de integração nos sistemas atuais.

Desde o aparecimento das RNA, vários autores trabalharam para perceber se estes modelos superavam os anteriormente citados (ARMA). [27] conclui que tanto para previsões curtas como longas, os modelos baseados em RNA têm um melhor desempenho quando comparadas com os modelos ARMA.

As previsões a curto prazo são especialmente interessantes devido ao facto de estarem ligadas diretamente à previsão de carga e aos preços de mercado existentes. Um trabalho realizado em 2001 [14] relativo a previsões no curto espaço temporal, refere que, para previsões de carga usando modelos baseados em Redes Neurais, para um espaço temporal curto, facilmente se atingem previsões com 10% de *mean absolute percent error* (MAPE) e que a mínima diminuição deste erro, digamos 1%, poderá representar uma redução volumosa de custos.

Tendo em conta a Fig 2.7, em seguida serão apresentados modelos que têm por base as Redes Neurais.

#### 2.4.3.1 Métodos heurísticos

##### Modelos Multilayer Perceptron

Os Multilayer Perceptron (MLP) são modelos de Redes Neurais, que simulam o cérebro humano, heurísticamente [28]. Segundo o autor, estu-

dos recentes demonstram que estes modelos superam outros algoritmos de Machine Learning, em várias componentes, incluindo modelos de regressão linear.

Uma Rede Neuronal MLP contém uma camada de dados com neurónios, que servem como recetores, uma ou mais camadas que analisam os dados e que passam por várias iterações e, por fim, a camada de saída que prevê os dados finais [29].





Figura 2.13: MLP com 2 camadas escondidas [30]


Para problemas que consistem em vários dados de saída, existe a necessidade de utilizar um modelo que consista no agrupamento de outros modelos.

Os MLP baseam-se em calcular os valores de neurónios numa camada específica, tendo em conta a soma dos pesos dos dados de saída da camada anterior [31]. Os pesos considerados inicialmente são aleatórios [31], no entanto, após a primeira iteração, são ajustados através do processo de *backpropagation*.

*Backpropagation* é um algoritmo vastamente utilizado para treinar Redes Neurais. Nesse processo de treino da rede, quando se pretende diminuir o erro e aumentar a previsão, o algoritmo calcula o gradiente da função do erro, derivando a função do erro, tendo em conta os "pesos" utilizados para os dados de entrada e numa próxima iteração recalcula os mesmos, ajustando assim a rede ao longo das iterações (figura 2.14).

Figura 2.14: Processo de *backpropagation*

Este algoritmo de aprendizagem apresenta, no entanto, algumas limitações matemáticas, não garantindo encontrar o valor global mínimo ou máximo da função de erro, mas apenas um valor local, como demonstrado na figura 2.15.

Figura 2.15: Função gradiente  
[32]

Os modelos MLP são frequentemente apelidados de *black boxes* por possuírem parâmetros desconhecidos do utilizador e permitirem criar variáveis e neurónios que terão um efeito desconhecido nos resultados, sendo o seu controlo feito por tentativa e erro, analisando os resultados e ajustando os parâmetros novamente.

No estudo [33], foi criado um modelo híbrido que inclui o modelo MLP, capaz de prever o consumo de energia, a ser instalado em contadores inteligentes. O modelo é dividido em 3 fases: (i) previsão da componente linear e sazonal da série cronológica utilizando um modelo de média móvel integrada autoregressiva (SARIMA), (ii) previsão da série de erros usando um técnica Machine Learning, e (iii) combinação de previsões lineares e não lineares de (i) e (ii) usando um modelo secundário Machine Learning [33]. O modelo MLP é usado na fase (iii) do processo, sendo que o autor justifica a sua utilização com a robustez em aproximar qualquer função não-linear. Nesta fase, o modelo procura encontrar a melhor combinação entre previsões lineares e não-lineares. Os parâmetros de entrada para a Rede Neuronal, são obtidos em fases posteriores, utilizando modelos SARIMA.

O autor compara os resultados obtidos através de diferentes modelos, sendo que o modelo proposto, híbrido, apresenta os melhores resultados. O modelo MLP apesar de, quando utilizado de forma independente, não apresentar os melhores resultados, constitui uma percentagem importante quando incluído no modelo híbrido criado.

Também no trabalho [28], foi criada uma rede que aprende dados de consumo de energia elétrica com variáveis explicativas e dados de entrada em falta [28]. A Rede proposta utiliza um conjunto de MLPs, chamados de "*softmax ensemble network*", em que o peso de cada MLP é determinado por uma função "*softmax*", que representa o peso total do conjunto de sub-redes. O objetivo desta rede, constituída por sub-camadas MLP, é de efetuar a alocação de valores em falta, relativos às leituras dos contadores inteligentes, considerando as saídas e pesos das sub-redes MLP. O modelo é treinado em 2 fases: na primeira fase, cada sub-rede é formada independentemente pelo conjunto de dados que lhe é atribuído; na segunda fase, o peso do conjunto atribuído a cada sub-rede é ajustado, e as sub-redes desnecessárias são removidas com base no peso

do conjunto [28]. Quando comparado com outros algoritmos de Machine Learning frequentemente utilizados em modelos de regressão linear, *convolutional neural network* (CNN) e *recurrent neural network* (RNN), o proposto obteve sempre valores mais baixos de MAPE, na ordem dos 5%.

Os modelos referidos serão introduzidos no subcapítulo seguinte.

No estudo realizado por Hippert [14], este conclui que existe ainda espaço para maior definição e validação de modelos MLP.

Os modelos MLP continuam, no entanto, bastante atuais no que toca a problema de previsão usando Redes Neurais.

#### **Outros métodos**

Um estudo apresentado em 2021 por [34], visa comparar os modelos utilizados em Redes Neurais, para previsão da produção de energias renováveis. Os modelos referidos e comparados são : *multi-layer perception* (MLP), *recurrent neural network* (RNN), e *convolutional-neural network* (CNN), bem como *long-short-term memory* (LSTM). O autor refere que estes modelos são capazes de realizar previsões a curto prazo em séries temporais de fontes de energia renováveis e de utilizar informação prévia que influencia o seu valor em previsões futuras [34].

O estudo refere que a tendência dos modelos de Redes Neurais, utilizados para este estudo está a ir de encontro a modelos CNN e RNN. Os primeiros estão direcionados para processar grandes quantidades de dados, tais como imagens e séries-temporais e são largamente usados para prever energia eólica e solar.

A arquitetura deste tipo de redes CNN está representada na figura 2.16. Este tipo de modelos conta com cinco tipos de *layers*, “input-layer”, “convolutional-layer”, “pooling-layer”, “fully-connected-layer” e “output-layer” [34], que estão divididas em três tipos de funções.

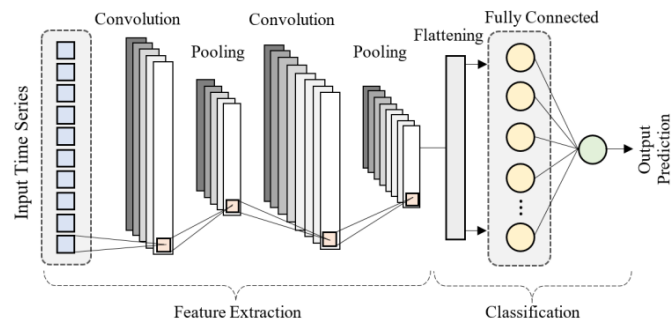


Figura 2.16: Arquitetura de uma rede CNN [34]

As camadas de entrada especificam a série temporal e atribuem "pesos" à mesma. As *layers convolutional* determinam as associações locais, ao passo que as *layers pooling* reduzem a dimensão das características relacionadas com a variável. Por fim, as camadas de saída combinam os dados provenientes das camadas anteriores e preveem um valor [34].

Por outro lado, as redes RNN assestam em ciclos durante a fase de treino, filtrando os dados e minimizando o erro antes de passar o valor à próxima fase. Dado que possuem memória, à medida que mais ciclos são criados, mais afinados serão os resultados.

Os valores de saída são comparados com os valores pretendidos, gerando um erro que é enviado como *feedback*, por forma a atualizar os "pesos" em todas as camadas até obter um resultado admissível.




Figura 2.17: Arquitetura de uma rede RNN [34]

Um estudo apresentado por [35] compara os dois métodos de Machine Learning referidos (CNN e RNN). No estudo, os métodos são utilizados com o intuito de classificar uma base de dados de relatórios, provenientes de exames médicos que detetam a presença de embolia pulmonar

(obstrução de uma artéria do pulmão). O objetivo destes modelos é o de retirar a informação relevante dos relatórios e prever, com base no texto do relatório, a existência ou não da patologia. Os modelos foram treinados com uma base de dados de 215 relatórios e treinado segundo as mesmas condições. O autor refere que os resultados obtidos estão dentro do expectável, quando comparados com outros estudos da mesma natureza, referindo que existe uma dificuldade em interpretar as decisões dos modelos e os erros de classificação, visto tratarem-se de “*black boxes*”. O autor conclui que os resultados sugerem a viabilidade das CNNs e RNNs, na classificação automática de relatórios de texto de imagens, e apoiam a aplicação destas técnicas em escala na área da classificação de relatórios de imagens de texto, para vários casos de utilização [35].

Para além dos problemas apresentados em [35] relativamente aos modelos RNN, estes têm ainda dificuldade na previsão quando alimentados com elevado volume de dados de entrada. Desta forma, foi criado um modelo apelidado de *Long short-term Memory* (LSTM) [34], capaz de resolver esta dificuldade.

Este modelo, sendo uma adaptação do RNN, é capaz de capturar a dependência de séries temporais em aplicações de previsão, ou seja, tem a capacidade de memorizar informações passadas pelas redes durante muito tempo, refletindo esses dados na previsão. A arquitetura dos modelos RNN e LSTM é bastante semelhante, sendo a única alteração a camada de ativação. Existe uma única camada de ativação em cada célula do modelo RNN, enquanto que no LSTM existe um conjunto de camadas de ativação. Em redes LSTM, a célula de memória (C) está aliada a funções de transferência (sigmoid ou tanh), que regulam a informação direcionada às celas e decidindo se se deve adicionar ou eliminar essa informação [35].

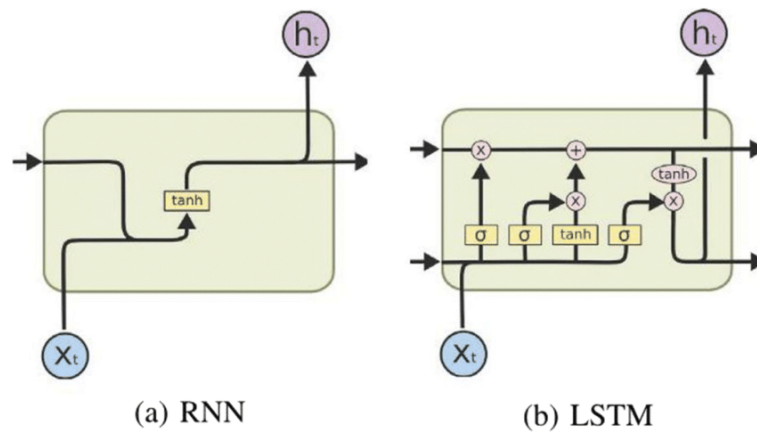


Figura 2.18: Célula RNN e célula LSTM. Adaptado de [34]

Um outro modelo usado na classificação de dados e reconhecimento de padrões, é o *Probabilistic Neural Network* (PNN). Em 2010, foi apresentado um trabalho em que o autor utiliza um modelo (PNN), como alternativa ao MLP [36]. Neste estudo, é prevista a carga de meia em meia-hora, sendo que o modelo proposto, aprende mais rápido mas demora mais tempo a classificar os resultados e necessita de mais memória. Este modelo é construído através de um método que prepara os dados de entrada, separando as amostras em diferentes "pacotes" de dados que são introduzidos na rede, em intervalos diferentes, segundo diferentes escalas de valores. [36] A figura 2.19, apresenta um esquema de preparação dos dados de entrada.




Figura 2.19: Preparação dos dados de entrada [36]

Os resultados obtidos foram satisfatórios, com erros admissíveis dado que as variáveis de temperatura não foram consideradas para o estudo. O autor conclui que as RNA carecem de maior ligação com o ser-humano e

daí serem necessários maiores conjuntos de dados para obter melhores previsões.

### 2.4.3.2 Modelos baseados em computação evolucionária (Híbridos)

Os modelos híbridos representam a combinação de duas ou mais técnicas de Machine Learning. Estes modelos são mais robustos, uma vez que têm as vantagens das técnicas individuais envolvidas e melhoram a previsão. Ao combinar modelos separados, estruturas complexas podem ser modeladas com maior precisão [11]. Estes modelos combinam frequentemente modelos lineares com modelos não lineares, para serem mais robustos e mais precisos. Os modelos híbridos mais tradicionais são uma combinação de ARIMA para relações lineares e SVM ou ANN para modelar a componente não-linear [11].

Em 2012, [37] apresenta um estudo que prevê a carga anual usando um modelo *Least Squares Support Vector Machine* (LSSVM), derivado do *support vector machine* (SVM). No mesmo trabalho, é também referido um modelo proposto em 2011 denominado de (FOA) *Fruit Fly Optimization Algorithm* que reproduz o comportamento das chamadas moscas da fruta.

No seu trabalho, [37] cria um modelo híbrido (LSSVM-FOA) para prever a carga elétrica anual, comparando os resultados com outros quatro modelos, obtendo valores de erro entre -3% e +3% e indicadores (MAPE, MSE e MAE) muito abaixo dos restantes modelos.

Um estudo realizado em 2021 [38], toma por base a abordagem *LSTM* e cria uma extensão da mesma, *BiLSTM Bidirectional LSTM*, com o intuito de desenvolver um método de previsão do consumo de eletricidade por hora, durante um mês inteiro, capaz de reter dependências no longo-prazo, em ambas as direções, isto é, passando pelos dados duas vezes, de trás para a frente e vice-versa. Este modelo é composto não só por Redes Neurais *LSTM*, mas também integra dois outros conceitos de Redes Neurais, *Time delay neural network* (*TDNN*) e *Function fitting neural network* (*FITNET*).

O conceito *TDNN*, foi introduzido na década de 80 e usado em aplicações de reconhecimento de voz, leitura labial, reconhecimento de manuscritos, análise de imagens, etc. Estas redes operam de forma complexa e têm duas características que as tornam únicas. Ao contrário de redes regula-

res, estas recebem as suas entradas através de uma "janela" de saída da camada imediatamente abaixo. Cada unidade tem ligações à saída e a valores de saída com atraso, isto é, valores passados (*Delay*).




Figura 2.20: Time delay neural network (TDNN) [39]

Outra característica deste tipo de modelos é o facto de este não depender da posição durante o treino de *backpropagation*, isto é, vai conseguindo criar cópias da rede neuronal ao longo do tempo.

O erro gerado é, em seguida, lido e analisado através do método de *backpropagation* para todas estas cópias criadas, sendo que estas aprenderão as características mais salientes, tornando-se independentes da posição relativa aos valores de entrada.

O termo *FITNET* provém da junção das palavras *fit* e *network*, e não são mais do que Redes Neurais que têm como base funções que se ajustam aos dados de base. Essas funções (linhas, curvas, sinusóides), quando introduzidas no mundo das Redes Neurais, poderão ajudar a diminuir o erro entre iterações e criar uma rede ainda mais precisa e otimizada. Estas funções ajudam a escolher os parâmetros que mais aproximação trarão à rede, relativamente ao conjunto de dados introduzido, podendo ser mais ou menos complexas quando *a priori* se conhece a forma dos dados ou não.

Em [38], com o modelo *BiLSTM*, juntamente com os processos de treino *TDNN* e *FITNET*, o autor obtém valores muito promissores, na or-

dem dos 3% para RMSE durante a fase de treino e 2,8% na fase de previsão. Os resultados foram obtidos para a previsão de um mês de avanço, sem grandes oscilações ou aumentos de erro ao longo dos resultados. Desta forma, o modelo criado por [38], mostra-se uma boa solução para previsão de consumo de carga horária.

## **2.5 Aplicação ao contexto português**

Através da rede de distribuição ( $U < 110$  kV) e transporte ( $U > 110$  kV), responsabilidades da E-Redes e REN respetivamente, a energia é fornecida aos consumidores. Do ponto de vista agregado e tendo em consideração a figura 2.21, Portugal foi em 2019 o 4º país com o menor consumo de energia primária por habitante [40], quando comparado com os países da UE-27.




Figura 2.21: Consumo de energia primária per capita na UE-27 em 2020 [40]

Desagregando o consumo total por setor de atividade, na figura 2.22 encontra-se ilustrado o consumo de energia elétrica total e por sector ao longo dos últimos 21 anos em Portugal [41].

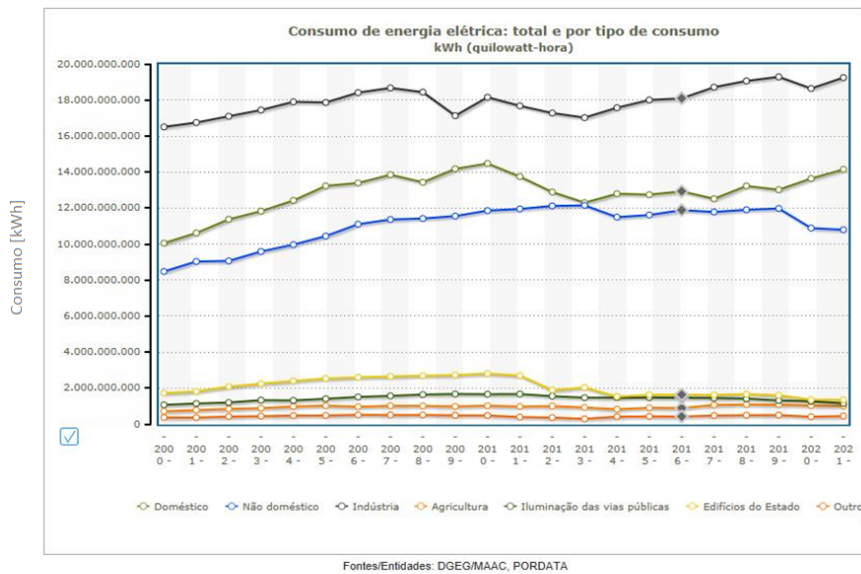


Figura 2.22: Consumo de energia elétrica: total e por tipo de consumo [41]

O maior consumidor de energia elétrica, ao longo dos 21 anos de dados, é o setor da Indústria, que representa 38,4% do total consumido. O setor doméstico representa 27,5% do consumo total, registado nos anos referidos.

Os consumos de energia elétrica, são satisfeitos por diferentes fontes de energia instaladas em Portugal. A figura 2.23 apresenta os valores de potência instalada por tipo de produção.

**Potência Instalada em 2017**

Potência Instalada no Final do Ano [MW]	2017	2016
<b>Total</b>	<b>19 800</b>	<b>19 539</b>
<b>Renovável</b>	<b>13 397</b>	<b>13 087</b>
Hídrica	7 193	6 945
Eólica	5 090	5 070
Biomassa	624	613
<i>Cogeração</i>	<i>351</i>	<i>351</i>
Solar	490	459
<b>Não Renovável</b>	<b>6 403</b>	<b>6 452</b>
Carvão	1 756	1 756
Gás Natural	4 607	4 636
<i>Cogeração</i>	<i>778</i>	<i>807</i>
Outros	40	60
<i>Cogeração</i>	<i>27</i>	<i>47</i>
<b>Bombagem</b>	<b>2 698</b>	<b>2 437</b>
Produção Despachável	12 368	12 108
Produção não Despachável	7 432	7 432

Figura 2.23: Potência instalada em 2017 [42]

No final do ano de 2017, segundo [42], o valor total da potência de produção instalada era de 19 800 MW, dos quais 13 397 MW de origem renovável e 6 403 MW não renovável.

Ainda no que concerne a potência instalada, anualmente é publicado um documento que agrega os dados mais relevantes do setor da energia em Portugal produzidos pela DGEG chamado de "Energia em Números"[1].

Segundo os dados apresentados no referido documento, desde 2010 a potência instalada subiu cerca de 3,5 GW sobretudo em centrais de produção de eletricidade a partir de fontes renováveis.

Em igual período, a potência instalada das centrais de produção de eletricidade não renovável diminuiu 21%, enquanto a potência instalada das centrais de produção de eletricidade renovável subiu 58%.

A figura 2.24, ilustra como os tipos de produção contribuíram para satisfazer o consumo em 2017.

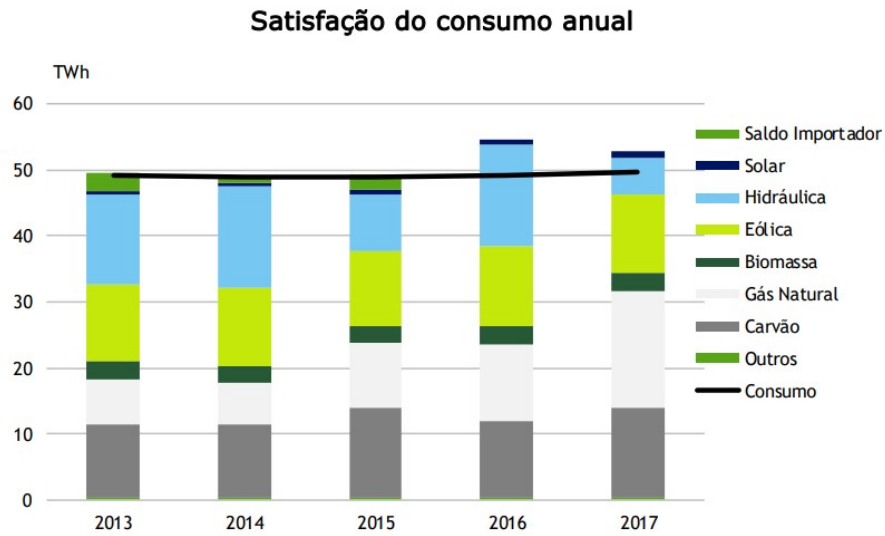


Figura 2.24: Satisfação do consumo anual [42]

Considerando a figura anterior e segundo [42], em 2017 a produção renovável abasteceu 40% do consumo (incluindo o saldo exportador), o valor mais baixo desde 2012.

Os dias de ponta de Inverno e Verão, estão representados na figura 2.25 e evidenciam as contribuições necessárias dos vários tipos de produção, para satisfazer os consumos nesses dias.

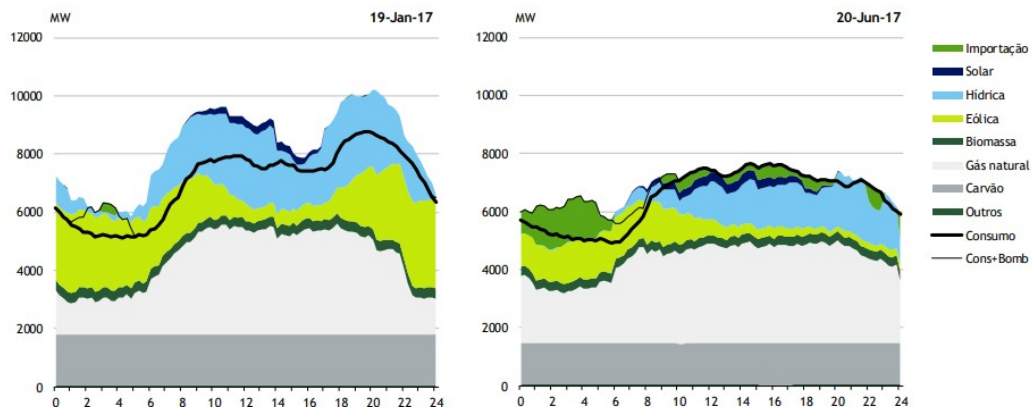


Figura 2.25: Diagrama de carga do dia da ponta anual (de inverno) e do dia de ponta de Verão [42]

O diagrama referente ao dia de ponta anual de Inverno, ocorrido em 19 de janeiro, evidencia uma contribuição elevada da componente não renovável (carvão e gás natural), bem como de hídrica e de eólica. Embora em menor escala, é também de notar a presença de alguma componente solar. No diagrama do dia típico relativo ao Verão, correspondente ao dia 20 de junho, a componente não renovável (carvão e também gás natural), contribuíram de forma bastante significativa para a satisfação do consumo, tendo sido acompanhadas, ao longo do dia, de hídrica e de eólica e em algumas horas de solar.

O sector doméstico, apesar de não refletir a maior percentagem de consumo em Portugal, apresenta extrema importância quando se fala de previsão de consumos. Neste sector tem existido uma evolução quanto à utilização de energia, não só pela constante evolução dos aparelhos instalados nas nossas casas, como pelas atualizações dos preços da energia.

Nas casas das famílias portuguesas, a eletricidade é a principal fonte de energia consumida, de acordo com o documento apresentado em [43], com uma percentagem de 46,4%.

Também no mesmo documento, é referido que a crescente eficiência dos eletrodomésticos, bem como os melhores isolamentos nas casas, afetam os valores de consumos e dependência energética. A figura 2.26, apresenta o valor do consumo no sector doméstico e peso (%) do consumo do sector doméstico no consumo final de energia.




Figura 2.26: Consumo no sector doméstico e peso do consumo do sector doméstico no consumo final de energia [43]

Existe uma redução no valor de consumo desde os anos de 2005 até

2013, sendo que daí em diante há um crescimento subtil nos valores.

Um inquérito “Hábitos sustentáveis na cozinha em Portugal” [44] realizado pela marca de eletrodomésticos Beko, revela que “um em cada três lares portugueses (55% dos entrevistados) afirmaram ter alterado os seus hábitos em relação à utilização de alguns eletrodomésticos desde que os preços da energia começaram a aumentar”.

O estudo revela que os hábitos que mais foram alterados têm sido os de adequar o tempo de utilização dos eletrodomésticos e utilização de menos aparelhos elétricos. Ficou ainda evidenciado, através dos resultados, que cerca de 90% dos portugueses têm agora em atenção à eficiência energética de um eletrodoméstico no momento da compra.

O preço médio da eletricidade dita o aumento ou não do consumo. Para os consumidores domésticos, a figura 2.27, apresenta a evolução dos preços da eletricidade, no setor doméstico, ao longo de 11 anos.

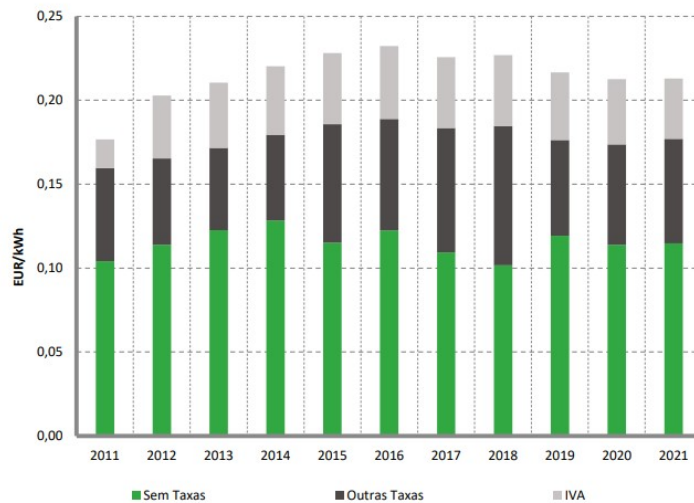


Figura 2.27: Evolução dos preços médios da eletricidade em Portugal [40]

Ao longo dos últimos anos verificou-se um aumento dos preços entre 2008 e 2016, tendo reduzido em 2017 e voltado a subir em 2018. Comparando estes dados com a figura 2.26, não é clara a influência do preço nos valores de consumo, no entanto, são perceptíveis alguns comportamentos dos dois gráficos. Entre 2011 e 2016, o preço médio da eletricidade au-

mentou gradualmente. Entre 2011 e 2013, o consumo registado diminuiu consecutivamente. De 2017 em diante, o preço da eletricidade diminuiu e o consumo aumentou também nesse período.

### **2.5.1 Caracterização do consumo em Portugal**

Os consumos de energia das famílias portuguesas são registados e publicados anualmente pela ERSE (Entidade Reguladora dos Serviços Energéticos).

Estes dados são obtidos, preferencialmente, através de equipamento de medição com registo de consumos em períodos de 15 minutos e, quando assim é, o perfil do consumo desses consumidores é desenhado de forma exata. No entanto, quando não se dispõe de equipamentos inteligentes de medição que façam a leitura e envio de dados, há que criar e estimar um perfil de consumo do consumidor. Os perfis são divididos em inicial e final e são criados tendo por base a potência contratada e o consumo dos doze meses anteriores. Estes perfis são mais tarde atribuídos e servirão como base para o cálculo da estimativa do consumo.

No documento publicado pela ERSE [45], é mencionado como agir quando existem anomalias identificadas nos dados de consumos. São definidos dois procedimentos:

- 1) Definição de um fator multiplicativo a aplicar à energia ou à potência no período.
- 2) Estimativa da energia elétrica para o período em falta, períodos com erro ou por anulação de uma leitura passada.

Estes métodos preenchem as lacunas encontradas nos dados referentes às leituras dos consumos de energia, permitindo completar os valores em falta para que se proceda à correta leitura e interpretação dos dados recolhidos.

Com base na informação disponibilizada pela ERSE em [46], relativa à procura de energia e perfis de consumo, são apresentados os perfis de consumo para clientes BTN (potências contratadas inferiores ou iguais a 41,4 kVA). Os valores das ordenadas são valores normalizados, obtidos segundo a metodologia descrita nos trabalhos de caracterização do consumo elaborados pela EDP Distribuição.

A Fig 2.28 apresenta o perfil de consumo para o regime BTN Simples classe B (Potência contratada inferior ou igual a 13,8kVA e energia superior a 7140kwh/ano), com duas semanas do ano de 2016, uma relativa ao Inverno e outra ao Verão, o que permite observar as diferenças no comportamento do consumo entre as duas estações.




Figura 2.28: Perfil de consumo normalizado para BTN Simples Classe B [45]

O comportamento das curvas anteriores, revela que existe um maior consumo em meses de Inverno do que em meses de Verão. Em meses mais frios, as curvas tendem a ter dois picos de consumo, enquanto que no Verão, apenas aparece um pico de consumo. Também é perceptível a diferença nos valores de consumo entre dias de semana e os fins de semana, sendo que se registam valores de consumo inferiores em fins de semana.

As previsões dos consumos, de todos os setores, são apresentadas em [47] e são feitas para diferentes intervalos temporais, desde horários a mensais. Os dados apresentados em [47], são referentes aos consumos totais de eletricidade, em Portugal Continental. Os dados incluem as perdas nas redes de transporte e distribuição e o consumo verificado é provisório e resulta de telemidas ou de estimativas feitas pela REN.

Também em [47], temos disponíveis os dados de anos anteriores, que permitem ter uma visão mais alargada dos consumos durante o ano.

A figura 2.29, ilustra a evolução mensal do consumo ao longo de todo o ano de 2017, face ao mês homólogo do ano anterior.




Figura 2.29: Evolução do consumo mensal de 2017 face ao mês homólogo do ano anterior [47]

Atentando no eixo das abcissas, para o ano de 2017, o consumo no mês de Janeiro foi cerca de 6% superior ao do ano de 2016, no entanto, os 3 meses que se seguiram, registaram valores de consumo inferiores aos meses homólogos.

A previsão horária, é apresentada na figura 2.30, bem como a verificação do consumo.

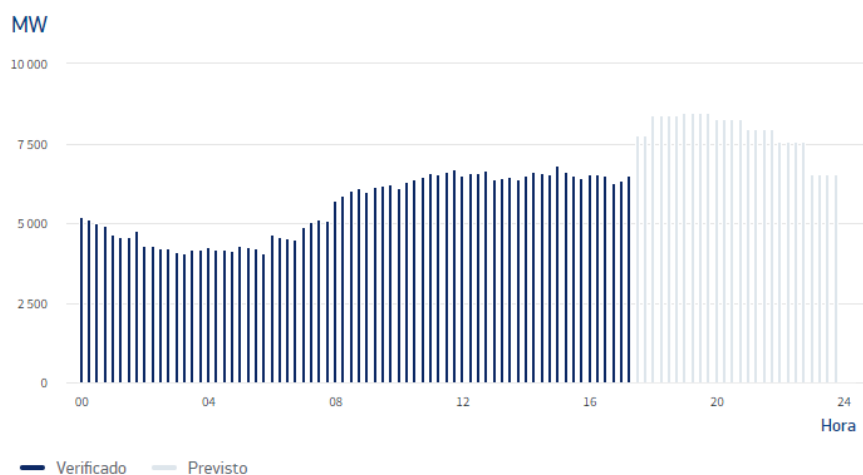


Figura 2.30: Previsão de um dia genérico apresentado no site da REN [47]

Em 2017, segundo dados da REN [42], o valor máximo registado de consumo foi de 8771 MW, no dia 19 de janeiro. Este valor ficou 630 MW

acima do valor registado no ano anterior. Na figura 2.32, são ilustradas 4 curvas de consumo, referentes a dias característicos, referentes ao dia da ponta anual (de Inverno) e a três outros ilustrativos das épocas sazonais de primavera, verão e outono.




Figura 2.31: Diagrama de carga dos dias característicos [2017] [42]

As pontas máximas diárias apresentam intervalos consideráveis entre si, tendo em conta a estação do ano que representam. No Inverno, a ponta máxima é de 8771 MW no período das 19h-20h, enquanto que no Verão o período de máxima é entre as 15h-16h.

A Fig 2.32 apresenta quatro diagramas de carga representativos do consumo, referentes aos mesmos dias referidos anteriormente.

Como termo de comparação, no ano de 2021, a ponta de carga máxima do consumo verificada foi de 9 888 MW e registou-se no dia 12 de janeiro. Este valor ficou a 980 MW acima do registado no ano anterior.




Figura 2.32: Diagrama de carga dos dias característicos [2021] [42]

O estudo da previsão realizado neste trabalho, tem em conta, para além dos fatores mencionados, o mês, os dias da semana, os feriados e as horas do dia. Estes fatores influenciam os valores de consumo e serão apresentados no capítulo seguinte.

A previsão do consumo no curto prazo, em Portugal, foi também estudada em [48], utilizando um modelo de alisamento exponencial, denominado de *Holt-Winters*. Foram previstas 7 semanas, individualmente. Este modelo é frequentemente utilizado para realizar previsão de séries temporais que possuem tendência e sazonalidade, podendo este ser formulado de maneira aditiva ou multiplicativa. O método aditivo é utilizado quando as variações sazonais são aproximadamente constantes, enquanto que o método multiplicativo é adequado a séries em que a amplitude das variações sazonais é proporcional ao nível da série.

O volume de dados de entrada utilizados foi sendo alterado ao longo das previsões, de forma a perceber a influência nos resultados finais. Com estes modelos, foram obtidos valores de MAPE na ordem dos 10% para as semanas previstas. O autor conclui que ao aumentar o número de observações, mantendo o mesmo horizonte temporal para teste, os resultados foram piores em comparação com as restantes dimensões de série de dados testadas.

Uma outra abordagem é usada em [9], para prever o consumo num

curto horizonte temporal em Portugal. No trabalho, é apresentado um novo algoritmo, *Clustering-based Similar Pattern Forecasting algorithm* (CSPF), que pretende prever o consumo do dia seguinte, com intervalos de 15 minutos. Este algoritmo opera através de outros dois algoritmos que têm como funções identificar padrões nos dados de consumo e diferenças entre séries temporais. O modelo inicialmente, através de um algoritmo de (*clustering*), agrupa dias que apresentem padrões semelhantes nos dados de consumo. Para cada dia é atribuída uma etiqueta de agrupamento e é formado um padrão de consumo, que mais tarde será comparado com o dia que se pretende prever. Os dias que tenham padrões semelhantes ao dia a prever, são selecionados. Em seguida, para os dias selecionados, são consideradas as temperaturas desses mesmos dias através de um processo de classificação. Os resultados mensais de MAPE obtidos, variam no intervalo de [2,7%-5,1%].

No capítulo que se segue será feita uma descrição dos dados utilizados e das metodologias desenvolvidas e aplicadas para o problema da previsão do consumo a curto prazo.

# Capítulo 3

## Metodologia

Neste capítulo são introduzidas as metodologias utilizadas no tratamento dos dados bem como na criação da Rede Neuronal e integração do modelo MLP, que servirá de base para prever o consumo de energia do dia seguinte.

Os *softwares* que auxiliaram no tratamento dos dados e desenvolvimento da Rede Neuronal serão também identificados ao longo deste capítulo.

Os dados originais relativos aos consumos de energia afetos aos anos de 2014 a 2017, apresentam-se em folhas de cálculo no *software Microsoft Excel*, num único separador, dividido em 4 colunas "Data", "Consumo", "Temperatura" e "Dia da semana". As colunas encontram-se agrupadas em blocos de 15 minutos, divididos entre consumo (expresso em kWh), temperatura e dia da semana.

Para efeitos de leitura e tratamento daqueles dados recorreu-se ao *software Rstudio*, que serviu de *software* base ao trabalho. Este *software*, normalmente utilizado para tratamento de dados e pesquisas estatísticas, usa como linguagem de programação a linguagem R e recorre a pacotes, criados para auxiliar o utilizador, para o seu funcionamento.

Para o presente estudo, além dos pacotes básicos e necessários à escrita do código, foram fundamentais para a criação das Redes Neurais e da previsão do consumo os seguintes pacotes: *forecast*, *nnfor* e *ggplot2*. O primeiro disponibiliza os algoritmos necessários à previsão, o segundo contém o modelo que servirá como base da Rede Neuronal e o terceiro permite apresentar os gráficos relativos às previsões obtidas.

## 3.1 Escolha do modelo

Tendo em conta a sua fiabilidade, alto nível de liberdade que confere ao utilizador no que toca à definição dos seus parâmetros e adaptabilidade com dados não lineares, o modelo escolhido para auxiliar o estudo da previsão do consumo de energia foi o *Multilayer Perceptron* (MLP). Como explicado em 2.4.3.1, estes modelos funcionam como Redes de camadas que tratam os dados através de pesos e parâmetros, definidos pelo utilizador, consoante os resultados obtidos.

### 3.1.1 Implementação no Rstudio

O *software* Rstudio disponibiliza um pacote chamado "*nnfor*", criado para o estudo da previsão de séries temporais com Redes Neurais. Este pacote facilita a previsão para séries-temporais através de Redes MLP - *Multilayer Perceptrons* e ELM - *Extreme Learning Machines*, que têm, por sua vez, como base o pacote *neuralnet*.

Os dois pacotes, *nnfor* e *neuralnet*, diferem no volume de dados capazes de suportar. Enquanto que o pacote *neuralnet* tende a ser muito demorado a treinar as Redes quando estas constituam grandes volumes de dados, o pacote *nnfor* caracteriza-se como um modelo mais rápido e eficiente no treino de Redes com o mesmo número de dados [49].

Tanto as Redes MLP como ELM, disponibilizadas no *nnfor*, permitem uma previsão simples e/ou uma previsão mais avançada do consumo de energia, isto é, permitem que o utilizador possa alterar certos parâmetros que afetam a performance da Rede.

Para o modelo MLP, segundo [49], na forma mais simplista da Rede, basta alimentá-la com uma série temporal, e em seguida, a função automaticamente define o número de nós e repetições que a série é treinada - 5 nós e 20 repetições. Desta forma, existe um compromisso entre velocidade de treino e *performance* [49].

No intuito de identificar qual a melhor combinação e qual oferecia melhores resultados quanto à previsão, o supra-referido estudo criou 6 variações de modelo, cada uma com diferentes nós de camada sendo certo que, para efeitos de comparação daquelas variações de modelo, recorreu-se aos indicadores MSE e MAE de cada modelo. Concluiu o

autor [50] naquele estudo que, independentemente do número de camadas e neurónios, não se verifica uma melhoria de resultados aquando do aumento do número de neurónios, existem até modelos com menos neurónios com melhores resultados do que modelos com mais neurónios.

Apesar de apenas ser necessário introduzir a série-temporal, a função continua a necessitar de outros argumentos que tanto podem ser definidos pelo utilizador como podem ser definidos pelo *default* da função. Se forem definidos pela mesma, esta cria uma Rede com 5 nós e realiza 20 repetições com os dados introduzidos, figura 3.1.




Figura 3.1: Rede *default* com 5 nós

Como padrão, o método que o modelo considera para realizar a previsão, é a mediana. Segundo [51], "A mediana é menos sensível a *outliers* e mais robusta que a média a assimetrias na distribuição de previsão, enquanto a moda é insensível a ambas". No mesmo trabalho, é feita uma comparação dos 3 métodos, usando 2 conjuntos de dados distintos, figura 3.2.




Figura 3.2: Comparação dos 3 métodos (Média, Mediana, Moda) [51]

A má performance da média em comparação com as restantes é evidente. Com suficientes previsões a combinar, a moda tem melhores resultados que a mediana, resultados expectáveis dada a sua robustez à não-normalidade. A média por muito que se aumente nunca chega a valores de *MASE* (*Mean Absolute Scaled Error*) tão bons quanto as restantes.

Outro dado interessante prende-se com a convergência da mediana e da moda à medida que se aumentam as repetições.

Um outro argumento imprescindível para o caso de estudo são o número de *lags*. Este argumento permite ao utilizador seleccionar os atrasos autorregressivos.

No fundo, os *lags* são usados quando resultados de um dado período afetam os períodos seguintes. Se optarmos pela definição *default* da função, esta define *lags* de 1 a  $m$ , sendo  $m$  o período sazonal da série-temporal. Para este estudo, os *lags* são de uma enorme importância pelo que foram definidos tendo por base os dados dos dias da semana, da temperatura e do mês.

Ainda na construção da Rede, foram utilizadas variáveis binárias ou variáveis explicativas. Estas são usadas para melhorar a previsão quando existe sazonalidade nos dados e atuam como *switches* que ligam e desligam parâmetros numa equação, e tanto são 1 como 0, podendo ser representadas como verdadeiro ou falso. No caso da carga, existem não uma, mas diferentes sazonalidades. São variáveis que agrupam características existentes nos dados de base, permitindo usar uma única equação de regressão, evitando escrever várias equações para cada grupo de variáveis.

No caso de estudo, foram consideradas variáveis explicativas para o mês e para o dia da semana.

Segundo [51], as Redes Neurais não são muito boas a modelar tendências sendo assim, há que remover as tendências dos dados antes de os modelar, através do argumento *difforder*, presente no pacote *nnfor*. O argumento definiu-se para *NULL*, ou seja, a função decide automaticamente o que usar para obter os melhores resultados.

Também o número de nós é deixado para a Rede definir, usando o argumento *hd.auto.type="set"*. A definição do horizonte temporal (24h), é definido num dos parâmetros da função *forecast*:

$$x <- \text{forecast}(\dots, h = 24, \dots) \quad (3.1)$$

Por fim, para obter a previsão é usada a função *forecast* e obtemos o seguinte resultado após o *plot* da Rede, figura 3.3.

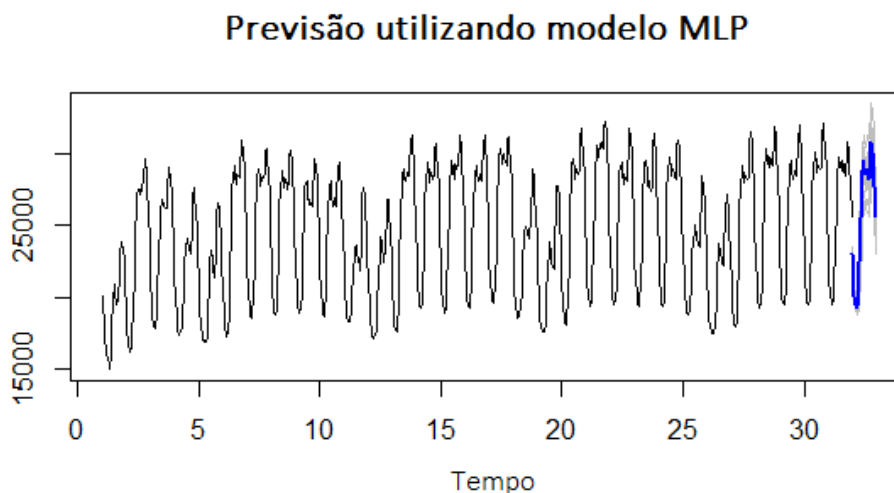


Figura 3.3: Previsão do dia seguinte através da função *forecast*

Através da figura anterior relativa à previsão usando a função *forecast*, percebemos que foi previsto o dia 1 do mês seguinte, partindo do princípio que os dados de treino são os primeiros 31 dias de Janeiro. Os valores previstos, a azul, da figura anterior, são apresentados no Anexo,

representados na tabela A.1 e comparados com os valores reais, figura A.1.

O modelo preconizado oferece liberdade na escolha e definição dos seus parâmetros, no entanto, segundo [49], [50] e [51], a alteração dos valores padrão do modelo, não implica diretamente uma melhoria nos resultados. Desta forma, o número de nós, número de repetições e o operador usados, foram os de padrão fornecidos pelo modelo. Os valores de *lags*, definidos para as variáveis binárias são apresentados no subcapítulo seguinte. Os feriados também serão considerados como variável binária, numa fase posterior, com o intuito de apresentar uma melhoria aos resultados obtidos inicialmente. Por fim, o horizonte temporal para a previsão, foi definido para as 24 horas seguintes.

Em seguida, serão apresentadas as metodologias bem como as implementações associadas à criação da Rede utilizada na previsão.

## 3.2 Criação da Rede

As metodologias mais recentes, apresentadas para previsão do consumo em diferentes horizontes, com modelos híbridos, revistas na literatura, assemelham-se em Redes Neurais Artificiais. A capacidade de generalização das Redes Neurais, é bastante útil na resolução de padrões complexos como os que existem nas séries temporais (como o consumo de energia), evitando decompor os processos estocásticos e modelar todas as suas componentes.

Em seguida será apresentada a implementação da Rede Neuronal no Rstudio, desconstruindo o processo de previsão, nas suas fases mais importantes.

### 3.2.1 Implementação no Rstudio

Para a constituição da Rede, foram definidas um conjunto de variáveis que são apresentadas ao longo deste capítulo. A figura 3.4, apresenta um fluxograma que descreve o processo da previsão.

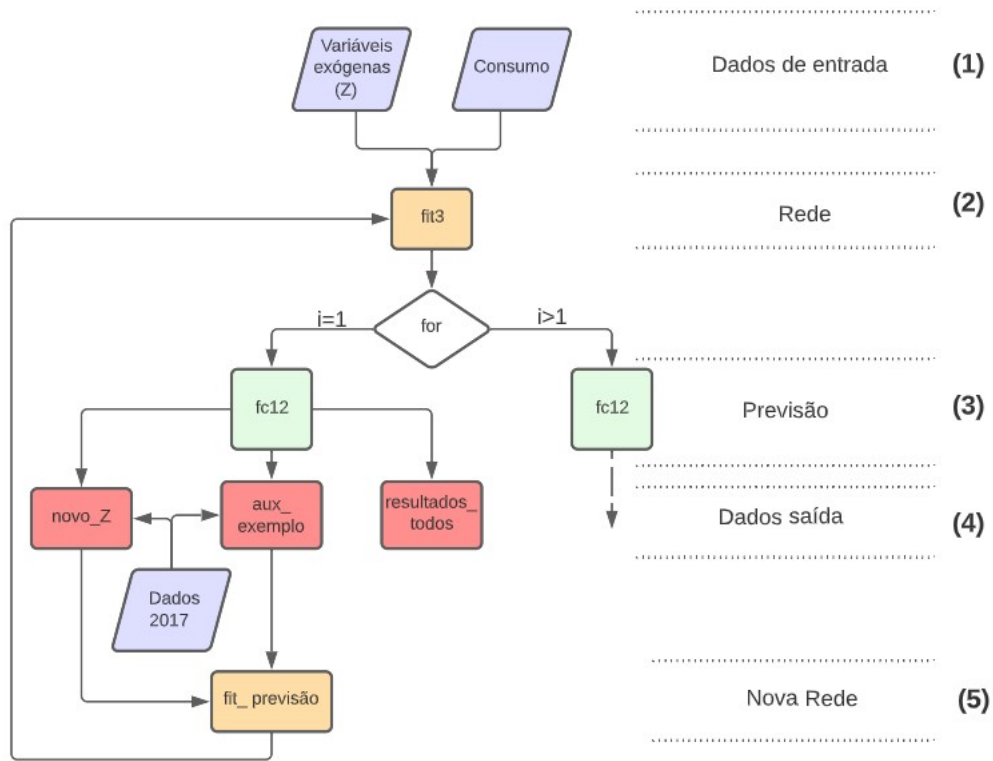


Figura 3.4: Fluxograma com processo da previsão

Os dados de entrada **(1)** da Rede são compostos pelos valores de consumos dos anos de 2014 a 2016 e são guardados na variável (ano2016.ts).

Nesta fase, foram também introduzidas as variáveis (Z), referentes à temperatura, ao dia da semana e ao mês, que sabemos que também influenciam o valor consumido de energia. No capítulo seguinte, será feita uma análise à influência das variáveis com os valores de consumo. As variáveis referidas foram introduzidas como variáveis exógenas, ou seja, variáveis que não dependem do modelo, tendo sido expostas como um *array* com o mesmo tamanho da série temporal, ficando definidas na Rede MLP como variáveis *xreg*.




Figura 3.5: Variáveis explicativas (*xreg*) a azul.

As referidas variáveis são introduzidas na Rede como um parâmetro *xreg.lags* que se resume a uma lista que contém os "atrasos" de cada uma das variáveis explicativas definidas, conforme referido no sub-capítulo anterior. A lista é criada no corpo da função e é representada da seguinte forma:

```
xreg=z,xreg.lags=list(c(1:10),0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0,0)
```

Figura 3.6: Lista das variáveis explicativas

O primeiro valor representa a variável da temperatura e está definido que a Rede terá em conta os 10 últimos dias como influência. Para as restantes variáveis, nomeadamente os dias da semana e os meses, os *lags* estão definidos a 0.

Em seguida **(2)** é definida a Rede (*fit3*), com os dados de entrada considerados, figura 3.8.

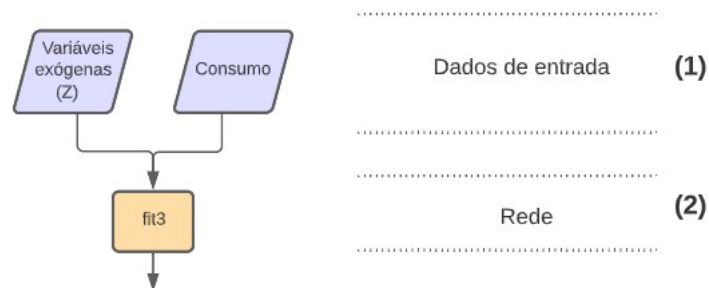


Figura 3.7: Criação da Rede (2)

```
fit3<-mlp(ano2016.ts, reps = 20, hd.auto.type="set", xreg=z)
```

Figura 3.8: Definição da Rede

Por forma a automatizar o processo de treino dos dados e de previsão foi criado um ciclo *for*, vide figura 3.10, onde são feitas as previsões (fc12) e atualização das variáveis (3).

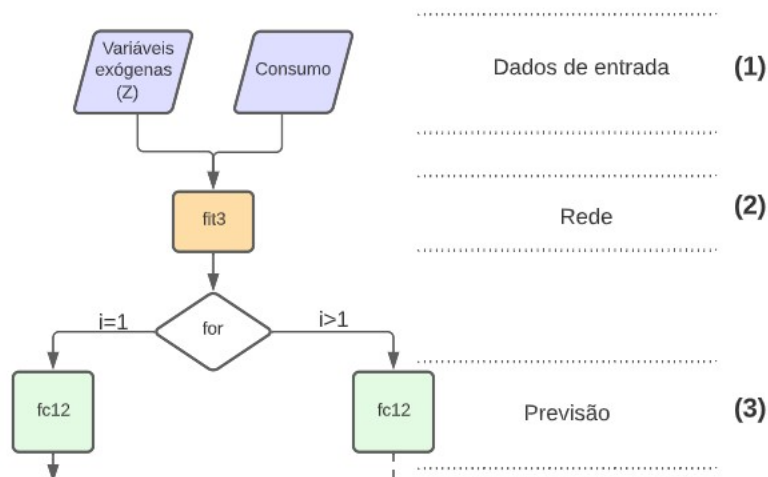


Figura 3.9: Previsão guardada na variável fc12

A primeira iteração é diferenciada das restantes, isto porque, para a função MLP, as variáveis explicativas necessitam de ter mais observações que a série temporal em uso.

```

for(i in 1:31){

  ifelse (i==1, fc12<-forecast(fit3, h=24, xreg = z), fc12<-forecast(fit_previsao, h=24, xreg = novoZ))
  resultados_todos<-c(resultados_todos,as.vector(fc12$mean))
  auxexemplo<-c(ano2016$consumo,ano2017[1:(i*24), 4])
  ano2016.ts<-ts(auxexemplo,start=c(1,1),frequency=24)
  novoZ<-rbind(z,ano2017xreg[1:(i*24), ])
  fit_previsao<-mlp(ano2016.ts,model=fit3,xreg=novoZ)

  print(i)
}

```

Figura 3.10: Ciclo *for* criado para prever o mês de janeiro

Após a previsão, são obtidos os dados de saída **(4)**, sendo que, os valores de consumo são guardados na variável (*resultados\_todos*). Ao fim de cada iteração, as variáveis exógenas são atualizadas com novos dados do ano de 2017. É simultaneamente criada, uma variável (*aux\_exemplo*), que contém os dados de consumos originais e é atualizada com os dados de consumo de 2017.

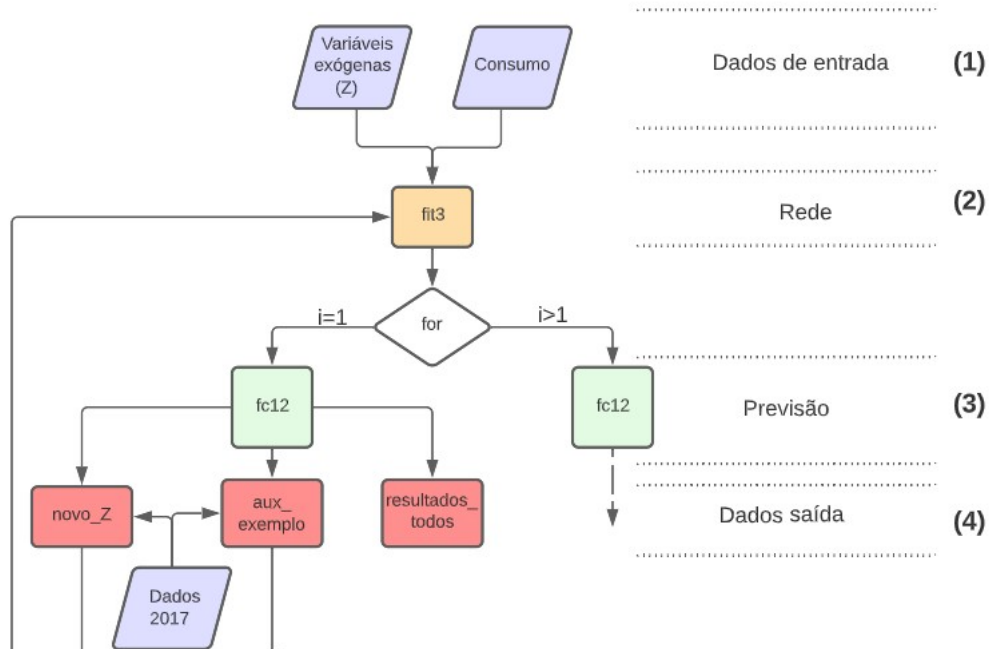


Figura 3.11: Dados de saída e atualizações das variáveis

Por fim, a Rede é atualizada e é criada uma variável (*fit\_previsão*) **(5)**,

terminando o fluxograma da figura 3.4. Dado o número elevado de dados e tempo de computação, torna-se inviável treinar a Rede a cada iteração, pelo que a Rede "fit3" é definida e criada fora do ciclo *for* e utiliza-se o parâmetro *model*, presente na função MLP, que permite utilizar uma Rede previamente treinada.

Querendo prever o mês de janeiro de 2017, por exemplo, o ciclo *for* "corre" entre 1 e 31 dias, ou seja, teremos 24h x 31 dias de observações. Sendo assim, para a primeira iteração é usada a variável "z" que contém todas as observações das variáveis explicativas referentes aos anos de treino, mais um dia, neste caso o dia 1 de Janeiro de 2017. No fim do ciclo, esta variável é atualizada com os dados conhecidos, reais, e denomina-se agora "novoZ". Assim como as variáveis explicativas são atualizadas ao longo do ciclo, também a Rede recebe novos valores a cada iteração, valores esses que são dados já conhecidos de consumo do ano que estamos a prever.

Ainda na figura 3.10 é referida uma variável com o nome "resultados-todos", inicializada a zero antes do ciclo *for* e que é, também, atualizada a cada iteração. Esta variável tem a função de guardar os valores previstos, referentes à função de previsão, "fc12".

Ainda pertencente ao ciclo *for*, a variável "aux-exemplo" é responsável por atualizar a série temporal de base, "aux2016", com os dados reais, não previstos, de 2017, para que em cada previsão, a série temporal tenha os últimos registos de consumo.

A variável "fit\_previsão" torna-se, à semelhança da "novoZ", a nova Rede introduzida a partir da segunda iteração no ciclo, tomando como base a Rede previamente criada "fit3".

Para avaliar o grau de precisão e o erro obtido com a previsão, é necessário comparar o valor previsto, guardado na variável "resultados-todos", com o valor real conhecido.

### 3.2.2 Métricas para avaliar o erro

Os dados previstos são avaliados através de funções de medida de precisão que, para cada ensaio, são retirados valores que nos permitem perceber o quão preciso o valor previsto é, quando comparado com o

valor real. Desta forma, é possível a criação de uma tabela de Performance da Previsão em que as funções de medidas (indicadores) são, *mean squared error* (MSE), *root mean squared error* (RMSE), *mean absolute error* (MAE) e *mean absolute percentage error* (MAPE), obtidas através da função *accuracy*. As fórmulas para a obtenção dos indicadores apresentam-se abaixo:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (3.2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (3.3)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (3.4)$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{e_t}{y_t} \right| \quad (3.5)$$

A variável  $e_t$  representa a diferença entre o valor real e o valor previsto e  $n$  representa o número de observações.

O indicador MSE (3.2), à semelhança do MAE, calcula a média de diferença entre o valor previsto e o valor real, sendo que a diferença é elevada ao quadrado, ou seja, quanto menos o valor do indicador, melhor é a previsão. O RMSE (3.3) aplica a raiz quadrada ao MSE, tornando o resultado com as mesmas unidades que os dados de origem. O indicador MAE (3.4) mede a média da diferença entre o valor real e o valor previsto. Por fim, O indicador MAPE (3.5) indica a percentagem de erro da previsão, em relação aos valores reais.

A figura 3.12, apresenta a função *accuracy*, utilizada para comparar o mês previsto de janeiro de 2017, com os valores conhecidos desse mês.

```
> accuracy(resultados_todos[1:744], ano2017$Consumo[1:744])
      ME      RMSE      MAE      MPE      MAPE
Test set 100.1411 1201.997 842.4216 0.4689429 3.324467
```

Figura 3.12: Comparação dos dados previstos com os dados reais, usando a função *accuracy*

Ao longo das iterações e das alterações feitas à Rede, são os indicadores mencionados que indicam o erro existente e servem como termo de comparação necessário para a criação de uma Rede o mais otimizada possível.

Após cada iteração, as previsões tendem a ser cada vez mais exatas, no entanto, existe a necessidade de comparar os resultados obtidos com outros métodos de referência.

### 3.3 Modelo *naive*

O modelo utilizado para fazer a comparação com o modelo MLP, foi o *naive*.

O modelo *naive* tem no seu nome a sua definição e representa uma técnica na qual o último período de dados é usado como o próximo período de previsão, sem ajuste nos valores ou em quaisquer parâmetros. Este modelo, apenas toma por base os valores anteriormente observados.

Sendo que o objetivo deste trabalho é a previsão do dia seguinte, o modelo *naive* foi aplicado em concordância, ou seja, foi modelado para prever o dia seguinte através de um modelo diário e semanal, isto é, a previsão das próximas 24h terão em conta o dia anterior (modelo diário) ou o dia correspondente da semana anterior (modelo semanal). Exemplificando, para o modelo diário, querendo prever as 24h o dia 10 de janeiro de 2017 (terça-feira), o modelo terá em conta as 24h do dia anterior, ou seja, para prever a hora 5 dessa terça-feira, o modelo utiliza o valor observado na hora 5 da segunda-feira anterior, e assim sucessivamente até completar o dia. Para o modelo semanal, utiliza-se para previsão a hora homologa da semana anterior, ou seja, para prever, por exemplo, a hora 5 do mesmo dia 10 de junho, o modelo irá utilizar o valor observado na hora 5 da terça-feira da semana anterior.

No capítulo seguinte serão apresentados e comparados os resultados de previsão, resultantes da Rede criada.

# Capítulo 4

## Apresentação e Análise de Resultados

Este capítulo apresenta a análise feita aos dados, os resultados obtidos com as previsões e uma comparação dos mesmos com o modelo de referência *naive*.

### 4.1 Pré-processamento e Análise dos dados

Os dados recolhidos pela REN, referentes aos consumos de energia em Portugal entre os anos de 2014 a 2017, foram, numa primeira instância, analisados no *Excel*, por forma a garantir que não existiam duplicações de valores ou dados omissos.

Os dados de origem apresentavam os consumos em intervalos de 15 minutos, mas para diminuir o número de dados e conseqüentemente tornar o processo de previsão mais leve e mais rápido, aqueles dados foram retificados para intervalos de 1 hora. No *Rstudio*, a função "*cut*", disponibiliza um argumento chamado "*break*", que permite criar intervalos de uma hora, dentro do conjunto de dados.

Posteriormente, procedeu-se a uma análise estatística dos dados, a fim de obter alguns indicadores descritivos tais como a média, mediana, desvio padrão e *outliers*. Na tabela seguinte são apresentados alguns índices estatísticos relativos aos dados de 2014 a 2016.

Tabela 4.1: Índices estatísticos dos anos 2014 a 2016

Índices	Consumo [MW]	Temperatura [°C]
Máximo	8618	40,8
Mínimo	3289	0
Média	5590	16,19
Mediana	5592	15,4
Desvio-padrão	964	6,36

Para o ano de 2017, foi feita uma análise isolada, apresentada na tabela abaixo.

Tabela 4.2: Índices estatísticos de 2017

Índices	Consumo [MW]	Temperatura [°C]
Máximo	8771	37,4
Mínimo	3332	0
Média	5666	16,77
Mediana	5648	16,12
Desvio-padrão	971	6,6

Nesta fase não foram detetados *outliers* nos dados relativos aos consumos e temperatura.

Na figura 4.1 é apresentado um histograma com os valores de consumo referentes aos 4 anos em estudo e na figura 4.2 os valores da temperatura dos mesmos anos.




Figura 4.1: Consumo de energia nos anos 2014 a 2017




Figura 4.2: Valores de temperatura nos anos 2014 a 2017

O valor médio de consumo registado em Portugal, ao longo dos 4 anos, foi de 5590 MWh e a mediana 5598 MWh. O desvio padrão é de 960 kWh.

O valor médio de temperatura registada em Portugal, ao longo dos 4 anos, foi de 16°C e a mediana 15°C. O desvio padrão é de 6,34°C.

Nas figuras 4.3 e 4.4, são apresentados os comportamentos das duas variáveis ao longo dos 3 anos (2014 a 2016).




Figura 4.3: Consumo de 3 anos em Portugal




Figura 4.4: Variação da temperatura ao longo de 3 anos

Como base de treino da Rede Neuronal, foram utilizados os dados dos 3 primeiros anos, de 2014 a 2016. O ano de 2017 foi usado como teste. A diferença entre dados de treino e dados de teste é a quantidade de dados usada para cada um, sendo que o conjunto de dados que se reserva para o treino é muito superior. Por norma, costuma-se alocar cerca de 70% da amostra para o conjunto de treino, sendo que no presente trabalho foram

escolhidos 3 anos (2014, 2015 e 2016) dos 4 (2014, 2015, 2016 e 2017) existentes como dados, o que representa 75%.

Os dados de treino são usados para ajustar o modelo, ou seja, ajustam os parâmetros do modelo aos dados. O conjunto destinado à validação é usado durante a fase de treino do modelo e serve para avaliar a *performance* do modelo, durante o ajuste dos parâmetros, sendo que o mês de janeiro de 2017 serviu para este efeito.

Durante esta fase, são consultados indicadores que representam o quão bem o modelo está a realizar a previsão e dão uma noção das alterações e ajustes necessários para se melhorarem os resultados. Como os dados de validação modelam em grande parte o modelo para a sua versão final, convém guardar ainda um outro conjunto de dados, chamados de dados de teste, que vão testar por fim o modelo e a sua precisão, em que cerca de 10% dos dados são alocados para teste, representados pelos dados do ano 2017.

Posto isto, sendo o ano de 2017 o ano de teste, foi feita uma caracterização dos dados temporais em tendência e sazonalidade, realçando as diferenças referentes aos valores de consumo, em meses de Verão e Inverno.

Através da figura 4.5, percebemos a existência de tendência e sazonalidade nos dados.




Figura 4.5: Consumo nos primeiros 6 meses do ano de 2017 em Portugal

Percebemos ainda, pela mesma figura, que o valor de consumo vai diminuindo à medida que passamos de meses frios para meses mais quentes.

A figura 4.6, inclui à variação do consumo, a variação da temperatura no mesmo intervalo temporal.




Figura 4.6: Comportamento do consumo e da temperatura

Através da figura 4.7, verifica-se a diferença de valores no consumo, quando comparados meses de Inverno e Verão. A temperatura máxima em janeiro de 2017 foi de 19°C e em Agosto foi de 37°C. O consumo máximo registado em Janeiro foi de 8771 MW e em Agosto foi de 6972MW. Curiosamente, o valor máximo de consumo em Janeiro, foi também o máximo de todo o ano de 2017.




Figura 4.7: Consumo entre Janeiro e Agosto de 2017

As curvas de consumo das duas figuras são semelhantes, no entanto, a variação dos valores de consumo no mês de Janeiro é superior à variação de consumo no mês de Agosto, ou seja, nos meses do maior calor, os consumos tendem a variar menos ao longo do dia.

Através de uma análise mais pormenorizada, são apresentadas nas figuras 4.8 e 4.9, duas semanas genéricas referentes aos meses de Janeiro e Agosto respetivamente.




Figura 4.8: Variação do consumo ao longo de uma semana de Janeiro de 2017




Figura 4.9: Varição do consumo ao longo de uma semana de Agosto de 2017

Na semana de Janeiro, os valores nas horas de ponta ultrapassam os 8000 MW, enquanto que em Agosto, também em horas de maior consumo, não ultrapassam os 7000 MW. A variação de valores de consumo, ocorridos na semana de Janeiro foi de 3706 MW e em Agosto foi de 2240 MW.

A título de exemplo, vejamos a diferença entre uma segunda-feira de Janeiro, figura 4.10 e uma segunda-feira de Agosto, figura 4.11.



Figura 4.10: Varição do consumo numa segunda-feira em Janeiro




Figura 4.11: Variação do consumo numa segunda-feira em Agosto

O valor máximo atingido na segunda-feira de Janeiro é de 7349 MW, às 20h. No exemplo de Agosto, o máximo que se atingiu foi de 6562 MW, às 22h.

As figuras anteriores mostram que, não só os consumos registados em meses frios são superiores aos consumos em meses quentes, mas também que em dias de semana, independentemente da estação do ano, os consumos são superiores que os consumos registados aos fins de semana.

Para demonstrar esta diferença de consumos ao longo da semana, a figura 4.12 e figura 4.13 apresentam o consumo ao longo de uma semana genérica, agora no mês de Abril.




Figura 4.12: Diferença de consumo entre os dias da semana




Figura 4.13: Consumo ao fim de semana e durante a semana

É perceptível, através das curvas do gráfico anterior, que os momentos de maior consumo se dão no início e fim do dia e que os valores de consumo durante o fim de semana são mais baixos que durante a semana. Tal acontecimento pode ser justificado com o facto das pessoas

não estarem tanto tempo em casa durante o fim de semana.

Tendo em conta estas variações nos níveis de consumo, será previsível que, quando se procure prever os consumos de uma segunda-feira, o erro na previsão seja mais elevado, isto porque os consumos de domingo são bastante díspares dos consumos de segunda-feira. Este acontecimento é mitigado através de variáveis explicativas, referidas no sub-capítulo seguinte.

Os dados mostram tendência e sazonalidade nos valores de consumo registados ao longo dos anos. Os gráficos das curvas de consumo realçam a diferença de valores entre os meses frios e quentes, bem como entre os dias de semana e os fins de semana. Atendendo a estas características dos dados, o modelo preconizado deverá moldar-se e aprender os padrões, por forma a reproduzir uma boa previsão.

## 4.2 Resultados obtidos

Ao longo deste sub-capítulo, serão apresentados erros absolutos relativos (também referidos como desvios), que visam medir a precisão da previsão. Calculando a média destes erros, obtemos o indicador MAPE. Os erros então foram determinados, partindo da fórmula do MAPE (3.5).

O modelo preconizado para prever o consumo de energia apresenta valores de MAPE de 3%, ao longo de todo o ano previsto de 2017. É perceptível, através dos valores obtidos e que serão apresentados, que o modelo tem maior dificuldade em prever certos dias e certas horas do dia, tanto em casos pontuais, como é o caso dos feriados, como consecutivamente, como é o caso das horas de ponta.

Os resultados obtidos mostram que existem várias variáveis que são necessárias ter em conta para se realizar uma boa previsão. Neste modelo, foram estudadas as variáveis da temperatura, dia da semana, feriados e o mês. A previsão foi então feita para todo o ano 2017 e a tabela seguinte, auxiliada pela figura 4.14, apresenta os indicadores de erro para cada mês.

Tabela 4.3: Indicadores de erro para os meses do ano de 2017

Mês	ME [MW]	RMSE [MW]	MAE [MW]	MPE [%]	MAPE [%]
Janeiro	100,1	1201,0	842,0	0,5	3,32
fevereiro	275,5	921,4	636,7	1,1	2,66
março	466,0	1109,0	780,0	2,0	3,34
abril	443,2	1293,9	847,5	2,1	4,12
maio	605,9	1407,0	760,9	2,9	3,58
junho	311,2	1159,5	799,8	1,2	3,54
julho	443,3	924,4	682,1	1,9	2,95
agosto	364,1	999,5	702,1	1,6	3,16
setembro	435,7	827,0	602,3	1,9	2,65
outubro	397,8	1033,8	720,4	1,7	3,27
novembro	396,5	1042,8	715,9	1,6	3,15
dezembro	717,3	2168,4	1286,3	3,0	5,40




Figura 4.14: Indicador MAPE ao longo do ano de 2017

Os meses de Abril e Dezembro obtiveram os piores resultados de MAPE, por serem meses com vários feriados. Os dias de feriados, são especialmente importantes porque apresentam valores de consumo significativamente diferentes, quando comparados com os dias homólogos em

questão. De acordo com os dados obtidos da previsão, também os dias subsequentes ao feriado apresentaram valores de erro consideráveis e por vezes superiores ao próprio dia de feriado.

O mês de Abril tem 3 feriados (Sexta-feira Santa, Páscoa e Dia da Liberdade), em que cada um apresenta médias de erro na ordem 6%, 10% e 9%, respetivamente. Os dias subsequentes aos feriados, também apresentam altos valores de erro, na ordem dos 9%, 21% e 4%, respetivamente, curiosamente dois deles superiores aos feriados em si.

A figura 4.15, mostra os valores de erro obtidos ao longo do mês de abril.




Figura 4.15: Erro relativo calculado na previsão do mês de abril do ano 2017

Entre o dia 15 e o dia 16, Páscoa, é onde acontece o maior pico de erro na previsão, chegando a atingir 48% de erro entre o consumo previsto e o consumo real. Os consumos do dia 15, começam a ter uma maior diferença a partir das 13h até às 24h.

De notar que o modelo adaptou-se aos consumos reais assim que houve a transição entre a véspera de feriado, dia 15, e o feriado propriamente dito. Na hora 24h do dia 15, a percentagem de erro era de 45%, no entanto, à 1h da manhã do dia 16, a percentagem de erro já era de

apenas 1%, como demonstra a figura 4.16.




Figura 4.16: erro entre dia 15 e 16 de Abril de 2017

Este fenómeno de rápida adaptação, mostra que o modelo reconhece bem os dias de feriado, mas apresenta dificuldades nos dias que antecedem os mesmos.

A figura 4.17 apresenta o comportamento dos dias seguintes ao feriado da Páscoa. No dia 16, domingo de Páscoa, os valores de consumo previstos apresentaram uma ordem de erro de 10%, no entanto, a terça-feira, dia 18 de Abril, apresentou erros na ordem dos 13%. Pelo gráfico da mesma figura, percebemos que ao longo de todo o dia 18 de Abril, os valores das previsões estão bastante abaixo dos valores reais de consumo, visto que os erros são elevados. Em contraste, no dia seguinte, quarta-feira, os valores de erro baixam para uma média de 2%. Mais uma vez, o modelo adapta-se melhor ao feriado do que aos dias que antecedem e sucedem o mesmo.



Figura 4.17: Comportamento da previsão desde dia 16 de Abril (feriado) até dia 19, no ano de 2017

Continuando a análise do feriado de Páscoa, na figura 4.18 é apresentada uma comparação mais detalhada ao longo do dia, do consumo previsto e real para este dia. As diferenças entre os valores previstos e reais tomam valores médios de 17% entre as 10h e as 12h e de 21% entre as 20h e as 24h. Observa-se que, mesmo no final do dia, nas últimas horas, a diferença ainda é significativa pelo facto de o dia seguinte ter sido usado, provavelmente, como ponte.




Figura 4.18: Comparação do consumo previsto e real para o dia 16 de Abril (Páscoa), no ano de 2017

Fazendo o mesmo exercício para os 3 dias seguintes à Páscoa, percebe-se que a linha de consumo previsto só toma diferenças significativas no dia 18, terça-feira, com cerca de 13% de erro, face aos valores reais.




Figura 4.19: Comparação do consumo previsto e real para os 3 dias seguintes à Páscoa

Na verdade, o comportamento observado anteriormente dos dados, pode ser transportado para os restantes feriados existentes ao longo do ano em questão.

O gráfico da figura 4.20 apresenta os valores de MAPE, para os feriados do ano de 2017. Apesar do dia de Carnaval e o dia 14 de fevereiro não serem feriados, são, apesar de tudo, datas comemorativas.




Figura 4.20: Desvio em feriados e festividades no ano de 2017

Exceto o dia 14 de fevereiro (dia dos namorados), todos os outros dias apresentam percentagens de erro superiores a 3%, sendo que o dia que o modelo teve mais dificuldade em prever foi o feriado correspondente ao dia do trabalhador (1º de maio).

Destaca-se do gráfico da figura 4.20, para além do dia do trabalhador, o Natal e a Páscoa com erros de 13% e 10% respetivamente.

Também os dias que sucedem os feriados têm desvios significativos, em média 12%, em que alguns casos o erro desse dia supera o próprio feriado, como referido anteriormente, como é o caso do dia 26 de Dezembro com um erro na ordem dos 40%, de acordo com a figura 4.21.




Figura 4.21: Desvio em dias que sucedem feriados no ano de 2017

A tabela seguinte apresenta uma correspondência entre o feriado, o dia da semana e o mês correspondente.

Tabela 4.4: Feriado, dia da semana e mês correspondente

Feriado	dia da semana	mês
Dia de Ano Novo	domingo	Janeiro
Sexta-Feira Santa	sexta-feira	Abril
Páscoa	domingo	Abril
Dia da Liberdade	terça-feira	Abril
Dia do Trabalhador	segunda-feira	Maio
Dia de Portugal	sábado	Junho
Corpo de Deus	quinta-feira	Junho
Assunção de Nossa Senhora	terça-feira	Agosto
Implantação da República	quinta-feira	Outubro
Dia de Todos os Santos	quarta-feira	Novembro
Restauração da Independência	sexta-feira	Dezembro
Dia da Imaculada Conceição	sexta-feira	Dezembro
Natal	segunda-feira	Dezembro

É também interessante perceber, se as alturas do ano em que estes feriados se dão têm algum tipo de influência nos valores de consumo. Se o feriado for numa época do ano mais quente, as pessoas não passam tanto tempo em casa, por outro lado, em dias de Inverno os consumos serão maiores. Tomando como exemplo os feriados dos dias 1 de Maio (Primavera), 15 de Agosto (Verão) e 1 de Dezembro (Inverno), a figura 4.22 apresenta os valores de temperatura que se registaram ao longo desses mesmos dias.




Figura 4.22: Temperaturas de 3 feriados ao longo do ano de 2017

A figura 4.23, apresenta os consumos registados nos mesmos 3 dias.




Figura 4.23: Consumo de 3 feriados ao longo do ano de 2017

Quando comparados os dois gráficos, percebemos que não será só a temperatura que influencia os consumos registados visto que, no dia 1 de Maio as temperaturas foram mais baixas que no feriado de 15 de Agosto, mas o consumo também foi mais baixo. Já o feriado de dezembro teve as temperaturas mais baixas dos 3 e foi também nesse que se registaram os maiores consumos.

Como proposta de solução para a evidente dificuldade do modelo em prever os consumos em vésperas e dias de feriados, foi criada uma nova Rede onde se introduziu, para além das *dummies* já referidas, uma variável *dummi* para os dias de pontes. Neste caso, foi criada uma Rede com menos dados ( meses de Abril e Maio ) referentes aos anos de 2014, 2015 e 2016. O mês previsto foi Abril de 2017, que serviu como teste e validação. A figura 4.24, apresenta duas curvas de de erro para os dias 25 e 26 de Abril, previstos segundo a Rede original e a nova Rede proposta.




Figura 4.24: Variação do erro usando uma nova dummie para dias de pontes

Durante o dia 25 de Abril, a nova Rede já apresenta melhorias face à previsão original, mas onde esta alteração realmente se faz notar é no dia seguinte ao feriado. A média de erro, ao longo do dia 26 para a Rede original é de 9% enquanto que na nova Rede é de 2%. Nas horas de maior consumo, onde a primeira Rede apresenta erros na ordem dos 15%, a nova Rede apresenta previsões exatas, com 0% de erro.

Em geral, durante os dias previstos, a nova Rede apresenta valores de erro abaixo da Rede original, confirmando que a introdução de mais uma variável para os dias de pontes afeta de maneira positiva a previsão.

A relação entre o consumo e a temperatura foi novamente estudada, agora para dias úteis. Foram escolhidos 3 dias, novamente pertencentes a 3 estações do ano diferentes, sendo eles o 9 de Janeiro (Inverno), 5 de Julho (Verão) e 9 de Outubro (Outono). A figura 4.25, apresenta os valores de temperatura que se registaram ao longo desses mesmos dias.




Figura 4.25: Temperaturas de 3 dias úteis ao longo do ano de 2017

A figura 4.26, apresenta os consumos registados.




Figura 4.26: Consumo de 3 dias úteis ao longo do ano de 2017

Em dias úteis, é evidente a semelhança entre as curvas de consumo dos 3 dias. Quando comparados com as curvas de temperatura, o dia

mais frio foi o dia que registou maiores consumos, assim como o dia menos frio foi o que registou menores consumos de energia.

Como averiguado, o modelo apresenta uma maior dificuldade em prever os valores de consumo nos dias festivos ou de feriados (figura 4.21), no entanto, também em dias úteis se observam algumas dificuldades. Ao longo destes dias, a variação entre o valor real e o valor previsto toma valores mais acentuados nas horas de maior consumos, ou seja, nas primeiras horas da manhã (9h-11h) e no final do dia (18-23h). Analisando o gráfico de dispersão da figura 4.27, que contém todas as percentagem de erro anuais, reparamos em que horas é que o erro tem tendência a ser maior. A maior incidência de pontos recai nos períodos supra referidos.




Figura 4.27: Desvios ao longo do dia para todo o ano 2017

Os erros acima de 30% aparecem nos seguintes dias:

- 15 de Abril, sábado (Sexta feira Santa)
- 1 de maio, segunda feira (Dia do Trabalhador)
- 2 de maio, terça feira (ponte)
- 2 de dezembro, sábado

- 9 de dezembro, sábado
- 25 de dezembro, segunda-feira (Natal)
- 26 de dezembro, terça-feira (ponte)

Os dias 2 e 9 de dezembro são dias posteriores aos feriados de 1 e 8 de dezembro que, curiosamente, não tiveram erros significativos, o que pode provavelmente ser explicado por se tratarem de sextas-feiras.

Os erros maiores, acima de 50% encontram-se em dias que sucedem feriados, em pontes, nomeadamente 2 de maio, 9 de dezembro e 26 de dezembro.

O seguinte gráfico, da figura 4.28, apresenta o somatório do erro para todas as horas do ano de 2017.




Figura 4.28: Horas que apresentam uma maior percentagem de erro

As últimas horas do dia, entre as 21h e as 24h são as que têm um maior desvio face à realidade do consumo. É também perceptível, que o modelo erra mais na previsão do consumo na parte da tarde, do que na parte da manhã.

Para erros acima de 10%, os maiores desvios estão em maior número nas horas de ponta da manhã e, mais uma vez, nas últimas horas do

dia, conforme a figura 4.29. Este gráfico contempla os dias de feriados e pontes.




Figura 4.29: Número de erros acima de 10% em todo o ano de 2017

Para o mesmo estudo, retirando os dias de feriados e pontes, na figura 4.30 observa-se a mesma distribuição ao longo do dia, no entanto, os valores máximos são muito inferiores aos do gráfico anterior.



Figura 4.30: Número de erros acima de 10% em todo o ano de 2017, sem feriados e pontes

O desvio da previsão foi analisado tendo em conta o dia do mês e a hora, mas um outro indicador importante para que se perceba a tendência do erro é o dia da semana. Ao longo de uma semana genérica, a previsão é mais ou menos precisa consoante o dia da semana que está em causa.

Durante os dias úteis, o modelo tem mais facilidade em prever os valores de consumo visto que, é nestes dias em que as rotinas se evidenciam, tornando os dias mais repetitivos e fáceis de prever. Já os fins de semana criam uma maior instabilidade no modelo, seja pelo facto de as pessoas acordarem mais tarde num sábado ou por pouco tempo passarem dentro de casa num domingo, o que é certo é que os erros são efetivamente maiores durante os fins de semana.

Existe, no entanto, ainda dentro dos primeiros dias da semana, alguma dificuldade no modelo em prever também a segunda-feira e terça-feira devido ao facto do modelo relacionar os consumos com os dias anteriores. Ora, sendo o domingo o dia anterior à segunda-feira e sendo um dia de fim de semana com um dia de semana, a correlação entre ambos é bastante pequena.

Os dias da semana que apresentam uma maior discrepância face aos

valores reais, são o sábado e a segunda-feira, com erros na média dos 6% e 5% respetivamente. As terças-feiras aparecem logo de seguida.

A figura 4.31 apresenta o somatório dos erros para todos os dias da semana, ao longo do ano de 2017, exceto os dias de feriados e pontes.




Figura 4.31: erros nos dias de semana do ano de 2017, sem feriados e pontes

Através do gráfico, verifica-se que o sábado e a segunda-feira são, de facto, os dias que o modelo aparenta ter mais dificuldade em prever com exatidão e representam 42% da soma total dos erros do ano.

### 4.3 Comparação com resultados dos métodos *naive*

A tabela seguinte apresenta os valores de MAPE dos dois modelos, quando previsto todo o ano de 2017. A figura 4.32 ilustra, através de um gráfico de barras, os valores de erro obtidos ao longo do ano.

Os indicadores utilizados para comparar os dois modelos foram o MAPE e o RMSE.

Tabela 4.5: Tabela comparativa entre modelos usando indicador MAPE

Mês	MLP	<i>naive semanal</i>
Janeiro	3,32	4,68
Fevereiro	2,66	5,54
Março	3,34	5,6
Abril	4,12	6,15
Mai	3,58	3,41
Junho	3,54	5,56
Julho	2,95	3,99
Agosto	3,16	4,06
Setembro	2,65	2,34
Outubro	3,17	3,34
Novembro	3,15	3,73
Dezembro	5,40	7,49




Figura 4.32: Comparação do MAPE para MLP e Naive

Apenas nos meses de Maio e Setembro é que o modelo MLP teve uma pior performance do que o *naive* semanal. Para os valores de RMSE, de forma semelhante, são apresentados os valores na tabela seguinte e no gráfico de barras da figura 4.33.

Tabela 4.6: Tabela comparativa entre modelos usando indicador RMSE

Mês	MLP [MW]	<i>naive semanal</i> [MW]
Janeiro	1202	2637
Fevereiro	921	2221
Março	1109	2263
Abril	1294	2283
Maio	1407	2170
Junho	1160	2402
Julho	924	2386
Agosto	999	1660
Setembro	827	2234
Outubro	1034	2373
Novembro	1043	2390
Dezembro	2168	2439




Figura 4.33: Comparação do RMSE para MLP e Naive

Para o indicador RMSE, observa-se também uma melhor performance do modelo MLP face ao *naive* semanal. Os piores meses, neste caso, são o Maio e o Dezembro.

O modelo *naive*, tendo em conta a sua simplicidade, obtém resultados muito satisfatórios. O modelo MLP, dada a sua complexidade e parâmetros ajustáveis, apresenta resultados de previsão muito consistentes quando introduzidas variáveis externas ao consumo, como a temperatura, dia do mês, etc.

O método *naive* apresentado anteriormente, utilizado como referência, foi o semanal, visto apresentar melhores valores de previsão face ao método *naive* diário. Em seguida é apresentada a comparação entre os dois métodos *naive*.

Numa primeira instância, foram comparados os resultados dos dois métodos do modelo *naive* com os valores reais, quanto à sua precisão na previsão do mês de Janeiro de 2017. A figura 4.34 apresenta os resultados do método diário e a figura 4.35 os do método semanal.




Figura 4.34: Previsão usando método naive diário, MAPE: 6,72




Figura 4.35: Previsão usando método naive semanal, MAPE: 4,68

Através das figuras 4.34 e 4.35 temos uma percepção dos resultados obtidos através do método *naive* e percebemos que há uma ligeira melhoria do método semanal face ao diário, tendo em conta o indicador MAPE. Tanto o método diário como o semanal conseguem acompanhar bem as tendências dos dados, mas na sua generalidade existe um subajuste do modelo *naive*, causado possivelmente pelo baixo número de dados de entrada. A figura 4.36 compara os erros obtidos entre os dois métodos, ao longo da previsão do mês de Janeiro.




Figura 4.36: Comparação dos erros dos dois métodos do modelo *naive*

O método semanal mostra-se mais consistente ao longo de todo o mês. O método diário apresenta elevados picos de erro durante as horas de máximo consumo. Ambos mostram dificuldade em prever o início do mês sendo que, o método semanal estabiliza após a primeira semana.

Em termos comparativos, na figura 4.37 está representada a previsão, para o mesmo mês, através do modelo MLP.




Figura 4.37: Previsão usando método MLP, MAPE: 3,33

O método semanal do modelo *naive* apresenta melhores resultados do que o método diário, sendo assim, foram comparados os dois modelos (MLP e *naive* semanal) ao longo das 744h (24h x 31 dias), dos 31 dias de previsão do mês de Janeiro. O modelo MLP obtém melhores resultados em 473h das 744h totais, o que representa 57%, ou seja, o modelo aproxima-se mais vezes do valor real do que o modelo *naive*. A figura 4.38 e a figura 4.39, apresentam a previsão e o erro obtido, da 1ª semana de Janeiro, para os dois modelos.




Figura 4.38: Previsão e erro, usando método naive semanal




Figura 4.39: Previsão e erro, usando método MLP

Mais uma vez, há dificuldade dos dois modelos em prever o início do mês e também os últimos dias da semana, no entanto, o modelo MLP mostra uma maior aproximação aos dados reais do que o *naive* semanal. O erro do modelo MLP ao longo dessa semana foi de 1% e o do *naive* foi de 9%.

# Capítulo 5

## Conclusões e trabalho futuro

Com este trabalho foi proposto um método de previsão capaz de planejar o horizonte de planejamento, auxiliando os operadores de rede a obter o balanço energético.

Inicialmente foram analisados os dados dos consumos referentes aos anos de 2014 a 2017. Neste processo, foram identificados atributos da série temporal, que serviram como base para a definição da Rede Neuronal. Destes atributos destacam-se as correlações entre variáveis de temperatura, dia da semana e mês, que apresentam uma correlação elevada com os valores de consumo obtidos (ver figuras 4.24, 4.25 e 4.26).

Posteriormente, foi feita uma análise às curvas de consumo diárias, semanais e mensais, bem como às diferenças de consumos registadas em diferentes estações do ano. Desta forma, foram identificadas tendências e sazonalidades nos dados.

Tendo em conta as caracterizações e premissas obtidas nos passos anteriores, juntamente com a revisão de literatura efetuada, foi aplicado um método de previsão, que consiste numa Rede Neuronal de múltiplas camadas.

Os dados que serviram como teste (2014-2016), permitiram calibrar os parâmetros da Rede, bem como identificar nas variáveis de entrada disponíveis, quais permitiam uma melhor performance.

Ao criar a Rede, foram consideradas variáveis que afetam os valores de consumo, sendo elas a temperatura, o dia da semana, o mês e ainda os dias de feriados e pontes. Estas adições mostraram-se fundamentais para a melhoria da previsão (ver figuras 4.24, 4.25 e 4.26).

Os resultados provenientes das previsões geradas, foram avaliados através dos indicadores estatísticos (MAPE e RMSE) e mostram que existe uma maior dificuldade do modelo em prever meses que tenham mais dias com feriados, tabela 4.3 e figura 4.14. O mês de Abril e Dezembro apresentam valores de MAPE de 4,12% e 5,4%, sendo que os restantes não ultrapassam os 3,58. Para dias de feriados, os erros são consideravelmente superiores aos restantes dias (ver figura 4.15, relativa à previsão durante todo o mês de Abril, onde no dia de Páscoa se registaram erros de 48%). Foi ainda possível observar que o sábado e a segunda-feira se apresentam como os dias mais difíceis de prever, representando 42% da soma total dos erros obtidos durante todo o ano previsto de 2017 (ver figura 4.31). Estes valores devem-se ao facto de serem dias de transição nos regimes de consumo (semana para fim de semana e vice-versa).

No que toca à temperatura, nos meses mais frios registam-se maiores dificuldades na previsão, isto porque nestes meses existe um maior consumo e variabilidade (meses de Maio a Setembro registam as maiores temperaturas e os valores de MAPE vão decrescendo, ver figura A.3).

Através de uma análise mais fina, os intervalos do dia que apresentam maiores problemas ao modelo são das 7h-9h e das 21h-22h (ver figuras 4.29, 4.30 e 4.31).

Por fim, foi feita uma comparação dos resultados obtidos do modelo proposto, com o modelo de referência *naive*. O modelo *naive*, para a sua previsão, usa como referência os valores passados e, apesar de não considerar variáveis externas ao consumo, os seus resultados comportam-se de maneira semelhante aos do modelo MLP (diferenças entre valores de MAPE dos dois modelos, inferiores a 3 em todos os meses), sendo que neste, a previsão é significativamente melhor. O modelo MLP apresenta uma melhor previsão em 10 meses do ano, no entanto, para os meses de Maio e Setembro as previsões foram piores (3,57 % e 2,65 % face a 3,41 % e 2,43 % do modelo *naive*, ver tabela 4.5 e figura 4.32 para MAPE e tabela 4.6 e figura 4.33 para RMSE). Para valores de RMSE, o modelo MLP não apresenta valores piores que o *naive*.

Os dois modelos apresentam dificuldades nas mesmas épocas do ano, no entanto, o modelo MLP demonstra ser significativamente mais preciso ao longo de todo o ano, como representado na tabela 4.3.

Como proposta de trabalho futuro, sugerem-se as seguintes possibilidades:

- introduzir novas variáveis ao modelo criado e apresentado, considerando porventura, os níveis de precipitação, as horas de sol, as estações do ano, entre outras variáveis, visto afetarem indiretamente os valores de consumo registrados.
- desagregar ao nível da subestação de forma a capturar a dinâmica da rede de distribuição (ex: basculamento de cargas) que podem alterar os trânsitos de energia locais de forma significativa.
- aumentar o número de anos de forma a aumentar o conjunto de treino da RNN .
- considerar a adição de outro modelo (k-nearest neighbor, por exemplo) ao processo, que facilite a identificação de padrões nos dados de consumo ao longo dos dias.

# Bibliografia

- [1] DGEG e ADENE. Em: *Energia em Números - Edição 2022* ().
- [2] Simon Haykin e Richard Lippmann. “Neural networks, a comprehensive foundation”. Em: *International journal of neural systems* 5.4 (1994), pp. 363–364.
- [3] Ajith Abraham. “Artificial neural networks”. Em: *Handbook of measuring system design* (2005).
- [4] Tiago Alexandre Mateus Peres. “Otimização de redes neuronais convolucionais em FPGA utilizando técnicas de compressão”. Tese de doutoramento. Instituto Superior de Engenharia de Lisboa, 2019.
- [5] SophieB SophieB. *An introduction to deep learning using flux part II: Multi-layer Perceptron*. Mar. de 2022. URL: <https://medium.com/@sophb/an-introduction-to-deep-learning-using-flux-part-ii-multi-layer-perceptron-32526b323474>.
- [6] Paulo Cortez e José Neves. “Redes neuronais artificiais”. Em: (2000).
- [7] José Pedro Ferreira Pelicano Paulos. “Previsão de Consumo de Energia Elétrica e do Preço da Eletricidade através de Redes Neuronais de Regressão Generalizada”. Em: (2017).
- [8] Qingzhi Zhao, Yang Liu, Wanqiang Yao e Yibin Yao. “Hourly rainfall forecast model using supervised learning algorithm”. Em: *IEEE Transactions on Geoscience and Remote Sensing* 60 (2021), pp. 1–9.
- [9] Ana Martins, João Lagarto, Hiren Canacsinh, Francisco Reis e Margarida GMS Cardoso. “Short-term load forecasting using time series clustering”. Em: *Optimization and Engineering* (2022), pp. 1–22.
- [10] Júlia Maria. *15 tipos de regressão mais frequentes*. 2018.
- [11] Ihab Taleb, Guillaume Guerard, Frédéric Fauberteau e Nga Nguyen. “A Flexible Deep Learning Method for Energy Forecasting”. Em: *Energies* 15.11 (2022), p. 3926.

- [12] Jui-Sheng Chou e Duc-Son Tran. “Forecasting energy consumption time series using machine learning techniques based on usage patterns of residential householders”. Em: *Energy* 165 (2018), pp. 709–726.
- [13] R Samsudin, A Shabri e P Saad. “A comparison of time series forecasting using support vector machine and artificial neural network model”. Em: *Journal of applied sciences* 10.11 (2010), pp. 950–958.
- [14] H.S. Hippert, C.E. Pedreira e R.C. Souza. “Neural networks for short-term load forecasting: a review and evaluation”. Em: *IEEE Transactions on Power Systems* (2001).
- [15] Carolina Linhares de Lima de Carvalho Seabra. “Previsão de consumos de eletricidade e gás em Portugal: análise, adaptação e evolução”. Tese de doutoramento. 2016.
- [16] Wenchao Lao, Ying Wang, Chen Peng, Chengxu Ye e Yunong Zhang. “Time series forecasting via weighted combination of trend and seasonality respectively with linearly declining increments and multiple sine functions”. Em: *2014 International Joint Conference on Neural Networks (IJCNN)*. IEEE. 2014, pp. 832–837.
- [17] Chris Chatfield. *Time-series forecasting*. Chapman e Hall/CRC, 2000.
- [18] Adriana Bruscato, Clélia Maria de Castro Tolo e Pedro Alberto Morrettin. “Modelo auto-regressivo de duração condicional com coeficientes variando no tempo”. Em: (2006).
- [19] Guy P Nason. “Stationary and non-stationary time series”. Em: *Statistics in volcanology* 60 (2006).
- [20] Bradley Wise. *Time series analysis with Arima: Part 2*. Mai. de 2023. URL: <https://blogs.cisco.com/analytics-automation/arima2>.
- [21] TTSW Advisory. *Random walk part 1 – a random walk down a dead-end street*. 2017.
- [22] Luis Hernandez, Carlos Baladron, Javier M Aguiar, Belén Carro, Antonio J Sanchez-Esguevillas, Jaime Lloret e Joaquim Massana. “A survey on electric power demand forecasting: future trends in smart grids, microgrids and smart buildings”. Em: *IEEE Communications Surveys & Tutorials* 16.3 (2014), pp. 1460–1495.
- [23] MS Abou-Hussien, MS Kandlil, MA Tantawy e SA Farghal. “An accurate model for short-term load forecasting”. Em: *IEEE Transactions on Power Apparatus and Systems* 9 (1981), pp. 4158–4165.

- [24] Mohamed A Abu-El-Magd e NK Sinha. “Modelling and Forecasting Short-term Load Demand: A Multivariate Approach”. Em: *IFAC Proceedings Volumes* 14.2 (1981), pp. 3073–3078.
- [25] James A Anderson, Jack W Silverstein, Stephen A Ritz e Randall S Jones. “Distinctive features, categorical perception, and probability learning: Some applications of a neural model.” Em: *Psychological review* 84.5 (1977), p. 413.
- [26] Kunihiro Fukushima. “Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position”. Em: *Biological cybernetics* 36.4 (1980), pp. 193–202.
- [27] Masood A Badri. “Neural networks of combination of forecasts for data with long memory pattern”. Em: *Proceedings of International Conference on Neural Networks (ICNN'96)*. Vol. 1. IEEE. 1996, pp. 359–364.
- [28] Seungwon Jung, Jihoon Moon, Sungwoo Park, Seungmin Rho, Sung Wook Baik e Eenjun Hwang. “Bagging ensemble of multilayer perceptrons for missing electricity consumption data imputation”. Em: *Sensors* 20.6 (2020), p. 1772.
- [29] Meha Desai e Manan Shah. “An anatomization on breast cancer detection and diagnosis employing multi-layer perceptron neural network (MLP) and Convolutional neural network (CNN)”. Em: *Clinical eHealth* 4 (2021), pp. 1–11.
- [30] Eluã Ramos Coutinho, Robson Mariano da Silva, Jonni Guiller Ferreira Madeira, Pollyanna Rodrigues de Oliveira dos Santos Coutinho, Ronney Arismel Mancebo Boly e Angel Ramon Sanchez Delgado. “Application of artificial neural networks (ANNs) in the gap filling of meteorological time series”. Em: *Revista Brasileira de Meteorologia* 33 (2018), pp. 317–328.
- [31] Zlatan Car, Sandi Baressi Šegota, Nikola Anđelić, Ivan Lorencin e Vedran Mrzljak. “Modeling the spread of COVID-19 infection using a multilayer perceptron”. Em: *Computational and mathematical methods in medicine* 2020 (2020).
- [32] Statinfer. *204.5.10 local vs. global minimum*. Jun. de 2017. URL: <https://statinfer.com/204-5-10-local-vs-global-minimum/>.
- [33] Diogo MF Izidio, Paulo SG de Mattos Neto, Luciano Barbosa, João FL de Oliveira, Manoel Henrique da Nóbrega Marinho e Guilherme Ferretti Rissi. “Evolutionary hybrid system for energy consumption forecasting for smart meters”. Em: *Energies* 14.7 (2021), p. 1794.

- [34] Md Mijanur Rahman, Mohammad Shakeri, Sieh Kiong Tiong, Fatema Khatun, Nowshad Amin, Jagadeesh Pasupuleti e Mohammad Kamrul Hasan. “Prospective methodologies in hybrid renewable energy systems for energy prediction using artificial neural networks”. Em: *Sustainability* 13.4 (2021), p. 2393.
- [35] Imon Banerjee, Yuan Ling, Matthew C Chen, Sadid A Hasan, Curtis P Langlotz, Nathaniel Moradzadeh, Brian Chapman, Timothy Amrhein, David Mong, Daniel L Rubin et al. “Comparative effectiveness of convolutional neural network (CNN) and recurrent neural network (RNN) architectures for radiology text report classification”. Em: *Artificial intelligence in medicine* 97 (2019), pp. 79–88.
- [36] Aneesh Nair e SK Joshi. “Short term load forecasting using probabilistic neural network based algorithm”. Em: *2010 International Conference on Computational Intelligence and Communication Networks*. IEEE. 2010, pp. 128–132.
- [37] Hongze Li, Sen Guo, Huiru Zhao, Chenbo Su e Bao Wang. “Annual electric load forecasting by a least squares support vector machine with a fruit fly optimization algorithm”. Em: *Energies* 5.11 (2012), pp. 4430–4445.
- [38] Dana-Mihaela Petrosanu e Alexandru Pîrjan. “Electricity Consumption Forecasting Based on a Bidirectional Long-Short-Term Memory Artificial Neural Network”. Em: *Sustainability* 13.1 (2021).
- [39] Yuehjen E Shao e Shih-Chieh Lin. “Using a time delay neural network approach to diagnose the out-of-control signals for a multivariate normal process with variance shifts”. Em: *Mathematics* 7.10 (2019), p. 959.
- [40] Eurostat Eurostat. *Navigation*. URL: <https://ec.europa.eu/eurostat>.
- [41] PORDATA. *Base de Dados de Portugal*. 2022.
- [42] REN. “Caracterização da Rede nacional de Transporte para efeitos de acesso à rede”. Em: (2017).
- [43] Instituto Nacional de Estatística. *Consumo de Energia no Setor Doméstico*. 2020.
- [44] Maria Teixeira Alves. *Crise Energética. Maioria dos portugueses reduziu tempo de Utilização dos Aparelhos Elétricos*. Set. de 2022. URL: <https://jornaleconomico.pt/noticias/crise-energetica-maioria-dos-portugueses-reduziu-tempo-de-utilizacao-dos-aparelhos-eletricos-939009/>.

- 
- [45] ERSE-Entidade Reguladora dos Serviços Energéticos. *Guia de Medição, Leitura e Disponibilização de Dados de energia elétrica em Portugal continental*. 2011.
- [46] ERSE. *CARACTERIZAÇÃO DA PROCURA DE ENERGIA ELÉTRICA EM 2022*. 2021.
- [47] REN Datahub. *Datahub.ren.pt*. 2023.
- [48] Pedro Miguel Marques Alves. “Previsão de curto prazo do consumo de energia elétrica”. Tese de doutoramento. Instituto Superior de Engenharia de Lisboa, 2013.
- [49] Nikolaos Kourentzes. *Tutorial for the NNFOR R Package*. 2019.
- [50] Pedro Henrique Borghi, Oleksandr Zakordonets e João Paulo Teixeira. “A COVID-19 time series forecasting model based on MLP ANN”. Em: *Procedia Computer Science* 181 (2021), pp. 940–947.
- [51] Nikolaos Kourentzes, Devon K Barrow e Sven F Crone. “Neural network ensemble operators for time series forecasting”. Em: *Expert Systems with Applications* 41.9 (2014), pp. 4235–4244.

# Apêndice A

## Anexos

### Anexo A - Previsão do dia 1 de Fevereiro de 2017




Figura A.1: Previsão e consumo real das 24h seguintes

Tabela A.1: Valores previstos das 24h seguintes

Hora	Previsão [MW]	Real [MW]	Erro absoluto [%]
1	5680	5668	0
2	5279	5256	0
3	5074	5048	1
4	4936	4869	1
5	4875	4819	1
6	4953	4958	0
7	5301	5311	0
8	6003	5953	1
9	6817	6721	1
10	7322	7135	3
11	7549	7232	3
12	7587	7291	4
13	7436	7089	5
14	7331	6993	5
15	7462	7105	5
16	7265	7056	3
17	7155	7021	2
18	7110	7109	0
19	7582	7659	1
20	7781	7890	1
21	7632	7773	2
22	7296	7444	2
23	6854	7021	2
24	6121	6301	3




Figura A.2: Variação do erro ao longo do dia em todos os sábados, domingo e segunda do ano [real-previsto]




Figura A.3: Variação do MAPE com a temperatura para o ano previsto de 2017

## Anexo B - Programação usada no Rstudio

```
##-----  
##                      Bibliotecas a instalar                      --  
##-----  
  
{  
  library(readr)  
  library(ggplot2)  
  library(ggfortify)  
  library(forecast)  
  library(fBasics)  
  library(car)  
  library(nortest)  
  library(tsoutliers)  
  library(readxl)  
  library(lubridate)  
  library(nnet)  
  library(nnfor)  
}  
  
#####  
##                      Variáveis existentes no código                      ##  
#####  
  
# dados_raiz - dados originais com os anos 2014/2015/2016 e 2017.  
# ano2014 - dados orginiais com o ano de 2014  
# ano2017 - dados orginiais com o ano de 2014  
# z - variável que contém a temperatura, dias da semana e mês do ano  
# fit3 - corresponde à Rede Neuronal  
# fc12 - corresponde ao valor que se irá prever
```

```

#####
##          Criação das variáveis          ##
#####

ano2016<-
dados_raiz2[dados_raiz2$year=='2016'|dados_raiz2$year=='2014'|dados_raiz2$year=='2015',]

#nova variável para permitir que o xreg tenha mais observação que a variável temporal

anos<-dados_raiz2[dados_raiz2$year=='2016'|dados_raiz2$year=='2014'|dados_raiz2$year=='2015',]

ano2017<-dados_raiz2[dados_raiz2$year=='2017',]

#####
## incluir uma dummy para cada mês e para cada dia da semana ##
#####

library(fastDummies)

ano2016<- dummy_cols(ano2016,select_columns ="Classif",remove_first_dummy = TRUE)
ano2016<-dummy_cols(ano2016,select_columns ="month",remove_first_dummy = TRUE)

anos<- dummy_cols(anos,select_columns ="Classif",remove_first_dummy = TRUE)
anos<- dummy_cols(anos,select_columns ="month",remove_first_dummy = TRUE)

ano2017<- dummy_cols(ano2017,select_columns ="Classif",remove_first_dummy = TRUE)
ano2017<-dummy_cols(ano2017,select_columns ="month",remove_first_dummy = TRUE)

ano2017xreg<-ano2017[25:8760,8:25]
ano2017xreg<-cbind(ano2017[25:8760,5],ano2017xreg)
colnames(ano2017xreg)[1]<-c("z")

#####
##          Criação das variáveis xreg          ##
#####

z<-anos$Temp
z1<-anos[,8:26]
z<-cbind(z,z1) #variáveis explicativas, temperatura e dummies

z3<-ano2017[1:24,5:26]
z3[,2:3]<-NULL
colnames(z3)[1]<-c("z")
z<-rbind(z,z3)#colocar a variável Z (xreg) com o primeiro valor de temp do ano 2017

#####
##          Passar para variável temporal          ##
#####

ano2016.ts<-ts(ano2016$Consumo, start=c(1,1),frequency=24)

#####
##          Ciclo que irá treinar a rede neuronal e fazer as previsões dos dias          ##
#####

#          Explicação do ciclo abaixo          #

# Dentro do for coloco os dias que quero prever, por exemplo de 1:31 será o mês de janeiro
# De 60:91 será o mês de Março e assim sucessivamente. A variável fit3 corresponde à rede
neuronal,

```

