


INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA
Departamento de Engenharia Eletrotécnica Energia e Automação



Redes Neurais Artificiais na Previsão do Consumo de Energia

FÁBIO FILIPE DA SILVA RODRIGUES
(Licenciado em Engenharia Eletrotécnica e Automação)

Trabalho Final de Mestrado para obtenção do grau de Mestre
em Engenharia Eletrotécnica

Orientador:

Prof.º Eduardo Adelino Mateus Nunes Eusébio

Júri:

Presidente: Prof. Dr. Luís Manuel dos Santos Redondo


Vogais:

Prof. Dr. João Hermínio Ninitas Lagarto

Prof. Eduardo Adelino Mateus Nunes Eusébio

Maio de 2023

INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA
Departamento de Engenharia Eletrotécnica Energia e Automação



Redes Neurais Artificiais na Previsão do Consumo de Energia

FÁBIO FILIPE DA SILVA RODRIGUES
(Licenciado em Engenharia Eletrotécnica e Automação)

Trabalho Final de Mestrado para obtenção do grau de Mestre
em Engenharia Eletrotécnica

Orientador:

Prof.º Eduardo Adelino Mateus Nunes Eusébio

Júri:

Presidente: Prof. Dr. Luís Manuel dos Santos Redondo

Vogais:

Prof. Dr. João Hermínio Ninitas Lagarto

Prof. Eduardo Adelino Mateus Nunes Eusébio

Maio de 2023

Dissertação realizada sob orientação de:

Professor Eduardo Adelino Mateus Nunes Eusébio

Professor Adjunto do Departamento
De Engenharia Eletrotécnica Energia e Automação

Resumo

A presente dissertação tem por objetivo aplicar o modelo de previsão, Redes Neurais Artificiais, aplicadas a séries de dados de consumo de energia elétrica em horizontes temporais de curto prazo.

Neste trabalho procura-se conhecer futuros valores de consumo de energia elétrica através de dados conhecidos relativos a acontecimentos passados, ou seja, conhecendo o comportamento da série de valores e seus respetivos parâmetros efetuar-se-á uma previsão do que irá acontecer. Alterando os vários parâmetros das Redes Neurais Artificiais se verificará qual estrutura terá um melhor desempenho na previsão do consumo de eletricidade em Portugal.

Os dados do passado relativo aos consumos verificados serão disponibilizados pela REN (Redes Energéticas Nacionais) e efetuar-se-á a análise do comportamento desta série temporal para posterior previsão da série temporal.

Como forma de validação da aplicabilidade das previsões serão calculados valores de erro absoluto, erro médio quadrático, erro percentual médio absoluto e intervalos de confiança para os valores a prever.

A metodologia aplicada nesta dissertação será a da previsão do consumo elétrico dos dias de semana e fins de semana para os períodos de 3,6,9 e 18 semanas de dados de entrada de 2008. Posteriormente avaliou-se a aplicação das Redes Neurais Artificiais a outros períodos temporais de 2018 e analisou-se a sua eficiência.

Para se conseguir uma boa gestão e produção de energia elétrica é cada vez mais importante ter um conhecimento prévio do comportamento futuro, o qual é impossível obter com exatidão.

Palavra-chave: Previsão

Série temporal

Energia Elétrica

Redes Neurais Artificiais

Abstract

This master's thesis aims to apply the prediction methodology, Artificial Neural Networks, applied to electrical energy consumption data series in short-term time horizons.

This work seeks to be able to predict the future values of electricity consumption through known data related to past events, that is, knowing the behavior of the series of values and their respective parameters will make a prediction of what will happen. Changing the various parameters of the Artificial Neural Network will verify which structure will have a better performance in forecasting electricity consumption in Portugal.

The Portugal electrical past consumption data were available by REN (Redes Energéticas Nacionais) and an analysis of the behavior of this time series will be carried out for subsequent forecast of the time series.

As a way of validating the applicability of the predictions, absolute error values, mean square error, mean absolute percentage error and confidence intervals for the values to be predicted will be calculated.

The methodology applied in this dissertation will be the forecast of the electric consumption of the weekdays and weekends for the periods of 3, 6, 9, and 18 weeks of input data from 2008. Subsequently, it was analyzed the application of Artificial Neural Networks to other time periods in 2018.

To achieve good electricity management and production, it is increasingly important to have prior knowledge of future behavior, which is impossible to obtain with exactness.

Keywords: Forecasting

Time series

Electrical Energy

Artificial Neural Networks

Agradecimentos

Ao professor Eduardo Eusébio, quero agradecer o acompanhamento e a supervisão indispensáveis à realização deste trabalho. De uma forma muito especial, agradecer toda a disponibilidade, dedicação, empenho e incentivo que tiveram comigo ao longo de todo este longo percurso.

O sincero agradecimento à minha família em especial aos meus Pais por todo o apoio e carinho e também pelo grande esforço que fizeram para que tudo isto fosse possível. Sempre me ensinaram que na vida é necessário esforço e dedicação para alcançar todos os nossos objetivos e que devemos tentar colocar o nosso melhor de nós no que fazemos.

Índice

1	Introdução.....	3
1.1	Enquadramento.....	3
1.2	Motivação.....	3
1.3	Objeto de Estudo.....	4
1.3.1	OBJETIVO/HIPÓTESES.....	4
1.4	Estrutura do Documento.....	5
1.5	Notação.....	5
2	Séries Temporais e Diagramas de Carga.....	8
2.1	Métodos de Previsão.....	8
2.1.1	MÉTODOS QUALITATIVOS.....	9
2.1.2	MÉTODOS QUANTITATIVOS.....	12
2.2	Diagramas de Carga.....	17
2.2.1	ANÁLISE DE DIAGRAMAS DE CARGA.....	18
3	Redes Neurais Artificiais.....	30
3.1	Introdução.....	30
3.2	Funções de Ativação.....	33
3.2.1	STEP UNITÁRIO (THRESHOLD).....	33
3.2.2	SIGMÓIDE.....	34
3.2.3	LINEAR POR PARTES.....	35
3.2.4	GAUSSIANA.....	35
3.3	Arquitetura.....	36
3.3.1	FEED-FORWARD.....	37
3.3.2	RECORRENTES.....	39
3.4	Treino/Aprendizagem da Rede.....	41
3.4.1	ERROR BACK-PROPAGATION.....	42
3.4.2	GENERALIZAÇÃO E <i>OVER-FITTING</i>	43
3.4.3	PARAGEM DO TREINO.....	44
4	Modelização.....	47

4.1	Séries de Dados (apresentar série de dados que vão ser utilizados)	47
4.2	Rede a utilizar	47
4.3	Casos de estudo	50
4.4	Redes utilizadas	51
4.4.1	DIAS DE SEMANA	53
4.4.2	FINS DE SEMANA	54
4.5	Medidas de Erro de Previsão	55
4.5.1	ERRO DE PREVISÃO	55
4.5.2	ERRO MÁXIMO	56
4.5.3	ERRO MÉDIO	56
4.5.4	ERRO MÉDIO ABSOLUTO	56
4.5.5	ERRO MÉDIO QUADRÁTICO	56
4.5.6	ERRO MÉDIO ABSOLUTO EM PERCENTAGEM	57
5	Casos de Estudo	60
5.1	Dias de Semana	60
5.1.1	3 SEMANAS	60
5.1.2	6 SEMANAS	63
5.1.3	9 SEMANAS	66
5.1.4	18 SEMANAS	69
5.2	Fins de Semana	72
5.2.1	3 SEMANAS	72
5.2.2	6 SEMANAS	75
5.2.3	9 SEMANAS	78
5.2.4	18 SEMANAS	81
5.3	Evolução do erro com alteração do número de Épocas	84
5.4	Comparação dos vários casos de Estudo	85
5.4.1	DIAS DE SEMANA	85
5.4.2	FIM DE SEMANA	92
5.5	Melhor tipologia encontrada aplicada noutras previsões (2018)	94
5.5.1	DIAS DE SEMANA 2018	94
5.5.2	FINS DE SEMANA 2018	96

5.6 Utilizando menos dados de entrada	98
6 Conclusões	103
6.1 Desenvolvimentos futuros	105
Referências Bibliográficas.....	108

Índice de Tabelas

<i>Tabela 4.1 - Formato da Série de Dados</i>	47
<i>Tabela 4.2- Parâmetros de Treino</i>	49
<i>Tabela 4.3 – Programa Matlab com comentários</i>	51
<i>Tabela 5.1 - Testes com a RNA escolhida – 3 Semanas (Dias úteis)</i>	61
<i>Tabela 5.2 - Testes para a construção da RNA – 3 Semanas (Dias úteis)</i>	63
<i>Tabela 5.3- Testes com a RNA escolhida – 6 Semanas (Dias úteis)</i>	64
<i>Tabela 5.4- Testes para a construção da RNA – 6 Semanas (Dias úteis)</i>	66
<i>Tabela 5.5- Testes com a RNA escolhida – 9 Semanas (Dias úteis)</i>	67
<i>Tabela 5.6- Testes para a construção da RNA – 9 Semanas (Dias úteis)</i>	69
<i>Tabela 5.7- Testes com a RNA escolhida – 18 Semanas (Dias úteis)</i>	70
<i>Tabela 5.8- Testes para a construção da RNA – 18 Semanas (Dias úteis)</i>	72
<i>Tabela 5.9- Testes com a RNA escolhida – 3 Semanas (Fim de semana)</i>	73
<i>Tabela 5.10- Testes para a construção da RNA – 3 Semanas (Fim de semana)</i>	75
<i>Tabela 5.11- Testes com a RNA escolhida – 6 Semanas (Fim de semana)</i>	76
<i>Tabela 5.12- Testes para a construção da RNA – 6 Semanas (Fim-de-semana)</i>	78
<i>Tabela 5.13- Testes com a RNA escolhida – 9 Semanas (Fim-de-semana)</i>	79
<i>Tabela 5.14- Testes para a construção da RNA – 9 Semanas (Fim de semana)</i>	81
<i>Tabela 5.15- Testes com a RNA escolhida – 18 Semanas (Fim de semana)</i>	82
<i>Tabela 5.16- Testes para a construção da RNA – 18 Semanas (Fim-de-semana)</i>	84
<i>Tabela 5.17- Testes Realizados com várias Épocas</i>	85
<i>Tabela 6.1- Composição das RNA com melhores resultados</i>	104
<i>Tabela 6.2- Resultados RNA com 1 e 2 semanas de dados de entrada</i>	105

Índice de Figuras

Figura 2.1 - Classificação dos métodos de previsão.....	9
Figura 2.2 - Diagrama de carga de 24h com discriminação dos parâmetros de caracterização.	18
Figura 2.3 - Padrões de consumo típicos, por classes de consumidores. [16].....	19
Figura 2.4 – Diagrama de carga semanal 168h (21/jan/2008 a 27/jan/2008).....	20
Figura 2.5 – Diagrama de carga semanal 120h, 2ª a 6ª feira (21/jan/2008 a 25/jan/2008).....	20
Figura 2.6 – Diagrama de carga fins de semana 48h (25/jan/2008 a 27/jan/2008) ..	21
Figura 2.7 – Diagrama de carga numa semana com feriado, sexta-feira (25/jan/2008 a 27/jan/2008).....	21
Figura 2.8 - Diagrama de carga de um dia de inverno (24/jan/2008) e de verão (20/ago/2008).	22
Figura 2.9 - Diagrama de carga de semanal de inverno (21/jan-27/jan) e de verão (18/ago-24/ago).	23
Figura 2.10 - Diagrama de carga anual, exemplo da sazonalidade anual.....	23
Figura 2.11 – Evolução da energia consumida num dia típico de inverno (2008-2012).....	24
Figura 2.12 – Evolução da energia consumida num dia típico de verão (2008-2012).....	24
.....	24
Figura 2.13 – Evolução da energia consumida numa semana típica de inverno (2008-2012).....	25
Figura 2.14 – Evolução da energia consumida numa semana típica de verão (2008-2012).....	25
Figura 2.15 – Evolução da energia anual consumida (2008-2019).....	26
Figura 2.16 – Potência média mensal (2008-2019).....	27
Figura 2.17 – Potência máxima em cada mês do ano (2008-2019).....	27
Figura 3.1 - Neurónio biológico e neurónio artificial: comparação.	31

Figura 3.2 - Neurónio artificial linear.....	31
Figura 3.3 - Neurónio artificial com função transferência não linear.	32
Figura 3.4 - Threshold Binário.	33
Figura 3.5 - Threshold Bipolar.	34
Figura 3.6 - Sigmóide.	34
Figura 3.7 – Linear Por Partes.	35
Figura 3.8 - Gaussiana.	35
Figura 3.9 - Redes Feed-Forward e Redes Recorrentes.	36
Figura 3.10 – Redes neuronais tipo feed-forward com uma unidade processadora. 38	
Figura 3.11 – Redes neuronais tipo feed-forward com multicamadas.	39
Figura 3.12 – Rede recorrente totalmente conectada.	40
Figura 3.13 – Rede recorrente desdobrada no tempo.	40
Figura 3.14 – Rede recorrente simples.	41
Figura 3.15 – Sentido da propagação do sinal funcional e do sinal de erro.	43
Figura 4.1 – Casos de Estudo	51
Figura 5.1 – Comparação Potência Real com o previsto RNA – 3 semanas (Dias úteis)	61
Figura 5.2 – Performance – 3 semanas (Dias úteis)	62
Figura 5.3 – Regression – 3 semanas (Dias úteis).....	62
Figura 5.4 – Comparação Potência Real com o previsto RNA – 6 semanas (Dias úteis)	64
Figura 5.5 – Performance – 6 semanas (Dias úteis)	65
Figura 5.6 – Regression – 6 semanas (Dias úteis).....	65
Figura 5.7 – Comparação Potência Real com o previsto RNA – 9 semanas (Dias úteis)	67
Figura 5.8 – Performance – 9 semanas (Dias úteis)	68
Figura 5.9 – Regression – 3 semanas (Dias úteis).....	68

Figura 5.10 – Comparação Potência Real com o previsto RNA – 18 semanas (Dias úteis)	70
Figura 5.11 – Performance – 18 semanas (Dias úteis)	71
Figura 5.1 – Regression – 18 semanas (Dias úteis).....	71
Figura 5.13 – Comparação Potência Real com o previsto RNA – 3 semanas (Fim de Semana)	73
Figura 5.14 – Performance – 3 semanas (Fim de Semana)	74
Figura 5.15 – Regression – 3 semanas (Fim de Semana).....	74
Figura 5.16 – Comparação Potência Real com o previsto RNA – 6 semanas (Fim de Semana)	76
Figura 5.17 – Performance – 6 semanas (Fim de Semana)	77
Figura 5.18 – Regression – 6 semanas (Fim de Semana).....	77
Figura 5.19 – Comparação Potência Real com o previsto RNA – 9 semanas (Fim de Semana)	79
Figura 5.20 – Performance – 9 semanas (Fim de Semana)	80
Figura 5.21 – Regression – 3 semanas (Fim de Semana).....	80
Figura 5.22 – Comparação Potência Real com o previsto RNA – 18 semanas (Fim de Semana)	82
Figura 5.23 – Performance – 18 semanas (Fim de Semana)	83
Figura 5.24 – Regression – 3 semanas (Fim de Semana).....	83
Figura 5.25 – Comparação vários resultados – Previsão de quarta-feira (Melhores resultados).....	90
Figura 5.26 – Comparação vários resultados – Previsão de quarta-feira (Piores resultados).....	91
Figura 5.27 – Comparação das MAPE nos diferentes casos verificados.	91
Figura 5.28 – Comparação vários resultados – Previsão de Domingo (Melhores resultados).....	92

Figura 5.29 – Comparação vários resultados – Previsão de Domingo (Piores resultados).....	93
Figura 5.30 – Comparação das MAPE nos diferentes casos verificados.	93
Figura 5.31 – Resultados com 3 semanas de dados, previsão dias de semana – Dados de entrada 2018.	94
Figura 5.32 – Resultados com 6 semanas de dados, previsão dias de semana – Dados de entrada 2018.	95
Figura 5.33 – Comparação MAPE – Dias de Semana.....	95
Figura 5.34 – Resultados com 3 semanas de dados, previsão fim de semana – Dados de entrada 2018.....	96
Figura 5.35 – Resultados com 6 semanas de dados, previsão fim de semana – Dados de entrada 2018.....	97
Figura 5.36 – Comparação MAPE – Fim de Semana.	97
Figura 5.37 – Resultados com 2 semanas de dados.....	98
Figura 5.38 – Resultados com 1 semanas de dados.....	99

Lista de Acrónimos e siglas

ARIMA	<i>Autoregressive integrated moving average</i>
MAPE	Erro percentual médio absoluto
ME	Erro médio
MEA	Erro médio absoluto
MSE	Erro médio quadrático
PCD	Padrão de carga diário
QME	Erro médio quadrático
REN	Redes energéticas nacionais
RNA	Redes neuronais artificiais
VE	Vetor de entrada

Lista de Símbolos

A	Vazio da noite
B	Vazio da tarde
ε_t	Erro
f	Função não linear
N	Número de dados
n	Número de observações
P	Ponta da tarde (MW)
P'	Ponta da manhã (MW)
t	número de instantes
u_k	Saída do neurónio
w_{km}	Peso sináptico
w_{kp}	Peso sináptico
x_m	Entrada do neurónio
X_t	Valor observação
\hat{X}_t	Valor da previsão
x_p	Entrada do neurónio
y_k	Saída do neurónio não linear

Capítulo 1

Introdução

Neste capítulo é elaborada uma introdução à problemática da previsão do consumo de energia elétrica. Apresenta-se o enquadramento da dissertação, algumas ideias fundamentais que motivaram a abordagem a esta temática e o objeto de estudo. Descreve-se ainda a forma como o texto está organizado, assim como a notação utilizada neste trabalho.

1 Introdução

1.1 Enquadramento

A energia elétrica tornou-se nas últimas décadas um bem cada vez mais essencial para a sociedade, com o desenvolvimento tecnológico e a crescente industrialização.

Contrariamente ao que acontece com outros produtos, a energia elétrica tem de ser consumida imediatamente após a sua produção, uma vez que esta não pode ser armazenada em grande escala, numa situação ideal cada um produziria a energia que necessitasse. Devido a esta particularidade é extremamente importante para produtores, operadores do sistema e comercializadores preverem com a melhor exatidão possível o consumo de energia elétrica.

Devido à situação económica atual e à grande concorrência entre organizações existentes nos dias de hoje, torna-se vital desenvolver métodos que permitam otimizar os recursos existentes. Consequentemente, nasce a necessidade de desenvolver métodos de previsão aplicados ao comportamento do consumo num futuro próximo. Com o desenvolvimento destes métodos é possível obter uma elevada qualidade na previsão o que permitirá uma redução de custos, através da otimização da energia produzida e também de uma melhor distribuição do consumo pelas fontes produtoras existentes no sistema elétrico nacional.

Este trabalho enquadra-se no âmbito da previsão do consumo de energia elétrica em Portugal recorrendo a redes neuronais artificiais, este método tem a capacidade de modelar séries temporais não-lineares através de um conjunto de dados de entrada e de saída. A rede neuronal artificial consiste num grande número de unidades de processamento que trabalham em paralelo para resolver um problema e que podem ser implementadas com a utilização de um software. Pela sua facilidade de trabalhar com um elevado número de dados e robustez o método é utilizado em várias áreas e em especial no consumo de energia.

1.2 Motivação

Atualmente há uma grande necessidade de aumento de eficácia nos sistemas, e o sistema elétrico não é exceção. Hoje em dia, é cada vez mais importante para as empresas

distribuidoras e produtoras que exista uma previsão do consumo de energia elétrica, para que haja uma boa gestão e operação dos sistemas elétricos.

Na previsão do consumo de energia é necessário conhecer com antecedência os parâmetros que influenciam os padrões de consumo de forma a satisfazer as necessidades energéticas, sendo que toda a energia produzida tem de ser consumida. Como ainda não é possível produzir energia e apenas usufruir dela muito tempo após a sua produção, é imperante a previsão do comportamento da carga para maior eficácia da gestão energética.

A nível económico esta temática é de extrema importância, sendo que quanto menor for o erro na previsão menor será a necessidade energética, ou seja, obtêm-se uma maior eficiência energética. Um menor erro faz com que haja uma redução de reserva girante dos geradores e, conseqüentemente, uma redução nos custos da energia, havendo um aumento da competitividade económica de todos os setores.

Pelas razões anteriormente indicadas, a problemática da previsão de consumo de energia é um dos grandes desafios atuais, tanto para racionalizar os recursos existentes, como para as empresas produtoras, distribuidoras ou de comercialização.

1.3 Objeto de Estudo

Inicialmente será definida a formulação do problema, que dará origem aos objetivos propostos para esta dissertação, a pretensão será realizar a previsão do consumo nacional de energia elétrica, através da implementação de redes neuronais artificiais. Desta forma, o objeto da dissertação consistirá nas seguintes questões:

- Realizar uma previsão de curto prazo do consumo de energia de 24h.
- Selecionar o tipo de rede mais adequada na previsão do consumo de energia elétrica.

1.3.1 Objetivo/Hipóteses

O objetivo da Dissertação é realizar uma previsão de consumo de eletricidade, analisando e verificando a influência da alteração de vários parâmetros das redes neuronais. Sendo que, o objetivo final será através da alteração dos vários parâmetros produzir bons resultados de previsão, com a implementação do *Matlab/Excel*.

1.4 Estrutura do Documento

Esta dissertação está organizada em 6 capítulos distintos, partindo de uma abordagem geral para o aprofundar do tema em estudo de capítulo para capítulo.

No capítulo 1 é feito um enquadramento à temática da previsão, é ainda referida a motivação o objeto de estudo e o objetivo deste trabalho. De maneira a facilitar a compreensão e leitura da dissertação é apresentada a notação usada neste documento.

No capítulo 2 é apresentada a descrição de alguns métodos de previsão, e também é feito um aprofundamento do panorama e um perfil da sua sazonalidade dos consumos energia elétrica em Portugal.

No capítulo 3 é apresentado uma explicação das características e os vários processos necessários para a construção de uma rede neuronal artificial.

No capítulo 4 é apresentado a construção dos vários casos de estudo e como será avaliada a sua eficácia como modelo de previsão.

No capítulo 5 são apresentadas várias análises e resultados com a alteração dos vários parâmetros da rede neuronal verificando a sua eficácia e adequação para a previsão do consumo.

No capítulo 6 são apresentadas as principais conclusões acerca do trabalho realizado nos capítulos anteriores e apresentada a proposta de desenvolvimento futuro.

1.5 Notação

A identificação de referências bibliográficas será representada entre parênteses retos [], da mesma forma a numeração de expressões é apresentada entre parênteses curvos () e terá dois algarismos, o primeiro referente ao número do capítulo em que este se encontra e o segundo representa o número da equação em cada capítulo. Em relação às figuras e tabelas estas são apresentadas igualmente com dois algarismos com referência ao capítulo em que são apresentadas e numeradas de forma sequencial. Posteriormente, ao índice de tabelas e figuras são apresentadas as listas de acrónimos e símbolos.

As referências bibliográficas estão indicadas de acordo com a norma IEEE.

Capítulo 2

Séries Temporais e

Diagramas de Carga

Neste capítulo é feita uma abordagem sobre a evolução dos métodos de previsão ao longo da história, tal como a classificação dos mesmos. É, também, apresentada a descrição de alguns métodos, com especial atenção para os de alisamento exponencial utilizadas nesta dissertação.

2 Séries Temporais e Diagramas de Carga

2.1 Métodos de Previsão

Em todos os domínios científicos surgem fenómenos onde a incerteza é um fator presente. Estes impedem o conhecimento exato do comportamento futuro, o que leva à necessidade de produzir previsões. Os métodos de previsão constituem ferramentas fundamentais para a projeção e planeamento de possíveis situações ou acontecimentos futuros. A previsão tem uma grande aplicabilidade e pode ser utilizada em diversas áreas, necessitando apenas de bases de dados de informação que mapeiem os comportamentos passados e os quantifiquem. Através da previsão é possível efetuar um melhor planeamento de atividades ou de processos, ou seja, desenvolver estratégias, nas atividades que dela dependem. Para tal, é imperativo a constituição de bases de dados de informação nas quais sejam identificadas, descritas e quantificadas os elementos necessários para a respetiva previsão. Os métodos de previsão utilizam esses dados recolhidos para preverem ou projetarem possíveis comportamentos no futuro. Através destas previsões é possível tomar decisões mais assertivas e fundamentadas nas áreas aplicadas.

A previsão de valores numa série cronológica pode ser realizada por diferentes tipos de metodologias, consoante o tipo de utilização, a sua extensão, longa, média ou de curto prazo e a disponibilidade de dados.

O horizonte de longo prazo é associado a previsões superiores a um ano e são utilizadas, por exemplo, no planeamento estratégico empresarial.

Relativamente ao horizonte de médio prazo é associado a previsões com um espaço temporal de um mês a um ano e são normalmente aplicadas em calendarização de procedimentos periódicos.

Por último, em relação ao horizonte de curto prazo é associado a previsões inferiores a um mês e são utilizadas na gestão ou operação corrente.

Os métodos de previsão podem ser classificados em dois grupos: os quantitativos e os qualitativos (Figura 2.1).

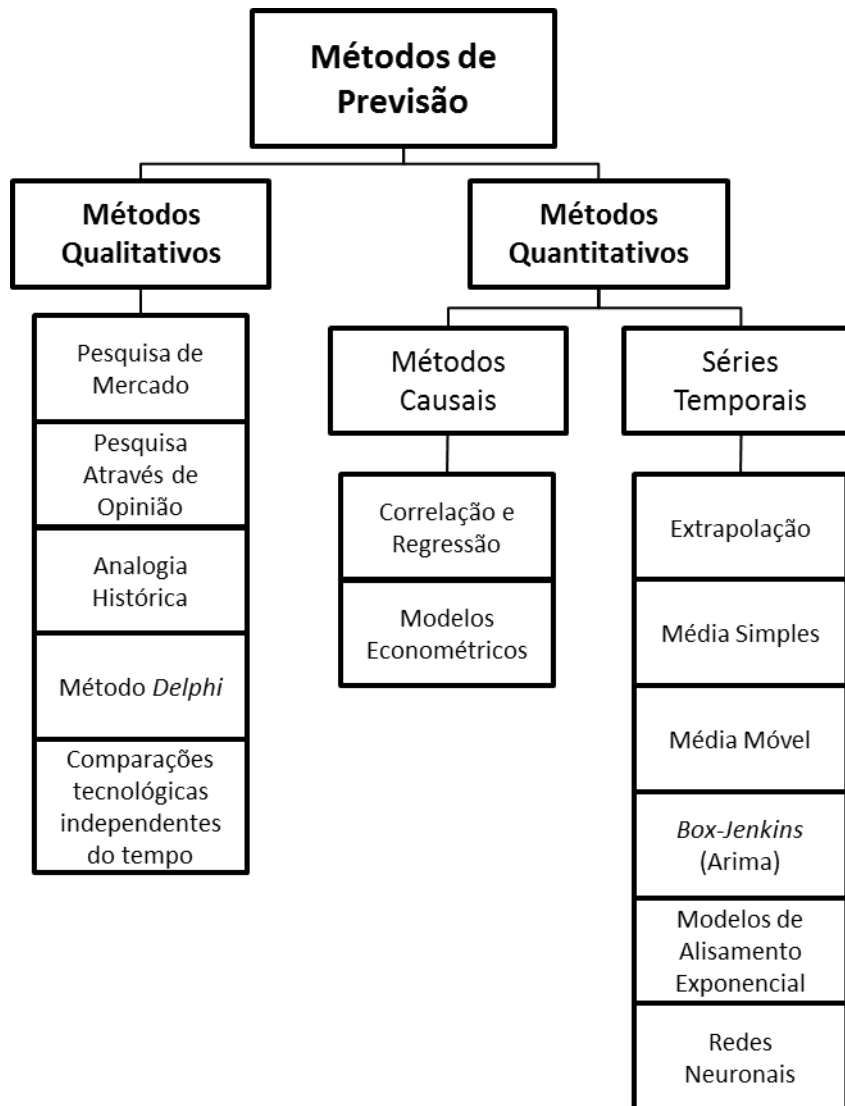


Figura 2.1 - Classificação dos métodos de previsão

Os métodos quantitativos baseiam-se na manipulação matemática de dados históricos quantificados para projetar no futuro padrões de comportamento que foram identificados nos dados referidos. Os métodos qualitativos têm por base juízos subjetivos, especulações e intuições. Estes dispensam os dados quantitativos e estabelecem cenários ou paralelismos com as situações semelhantes ocorridas [1].

2.1.1 Métodos Qualitativos

Os métodos qualitativos valem-se da comparação de pesquisas ou técnicas com o intuito de prever situações relativas ao futuro utilizando as opiniões para prever eventos de forma subjetiva. Sendo que estes métodos são normalmente utilizados quando não existem dados históricos ou que, caso hajam, não sejam relevantes para a previsão. Devido à natureza do

modelo não ser científica é de difícil validação a sua exatidão. Por exemplo, considerando a situação em que um novo produto vai ser lançado no mercado, não existe um historial de vendas para o produto. Para prever as vendas deste novo produto, a empresa deve basear-se na opinião de pessoas com experiência, em determinadas áreas, como os colaboradores do departamento de vendas ou analistas de mercado.

Outra situação em que possa não existir dados históricos disponíveis é quando se tenta prever a descoberta de uma nova tecnologia e quando será a sua aplicação.

Devido à sua complexidade, os métodos qualitativos são quase exclusivamente empregues em formulação de estratégias de médio e longo prazo ou na previsão de novos produtos. São, também, utilizados para prever mudanças nos padrões históricos, a utilização de dados históricos para prever o futuro tem por base o facto de que esses dados se irão manter, logo as alterações nestes padrões históricos não podem ser previstas com base nos mesmos padrões [2].

Em seguida será feita uma breve descrição sobre alguns métodos qualitativos de previsão normalmente utilizados tais como:

- Pesquisa de mercado;
- Pesquisa através de opinião;
- Analogia histórica;
- Método de *Delphi*;
- Comparações tecnológicas independentes do tempo.

Pesquisa de Mercado

Este método pode ser entendido como a expectativa das necessidades de compra dos consumidores, tendo em conta as previsões de negócios estimados por órgãos ou empresas de pesquisa ou mesmo por meios de pesquisas conduzidas pela própria empresa, através dos seus vendedores.

Uma das dificuldades que se encontra é a obtenção de informações conclusivas acerca das intenções de compra, uma vez que a pesquisa é feita a um número reduzido de entrevistados. Para além disso, se a amostragem não for representativa do panorama geral do mercado, a pesquisa é influenciada por um erro de amostragem. Outra dificuldade do

método está no facto de que em economias instáveis é difícil qualquer futura previsão, mesmo para bens industriais como máquinas e equipamentos [3].

Pesquisa através de Opinião

Este método pode ser explicado através do seguinte exemplo: um vendedor com base na sua expectativa de vendas realiza uma estimativa de vendas da empresa para o próximo ano. O somatório das previsões dos vários vendedores fornece a previsão global das vendas, uma vez que são os elementos da empresa que mais conhecimentos têm do mercado.

A principal vantagem deste método é o aproveitamento do conhecimento dos vendedores, fazendo com que tenham mais confiança nos critérios estabelecidos das quotas que lhes são atribuídas, comprometendo e responsabilizando os vendedores no cumprimento das previsões. Sendo que esta situação apresenta o inconveniente de serem dadas hipóteses abaixo das possibilidades de vendas, de forma a reduzir o valor da quota de vendas fixada através da previsão de vendas [3].

Analogia Histórica

Quando se quer prever as vendas de um novo produto que se pretende lançar no mercado é comum considerar o conhecimento sobre o ciclo de vida de um produto antigo e similar. Normalmente são considerados três estágios para a venda de um produto: crescimento, maturidade e declínio. No estágio de crescimento as vendas começam por crescer até ser atingido o estágio de maturidade onde existe uma estabilização das vendas e finalmente no estágio final existirá um declínio nas vendas. Deste modo, é possível obter uma previsão de vendas para o novo produto [2].

Método de Delphi

Neste método, desenvolvido pela *RAND Corporation*, o objetivo é capturar o conhecimento de especialistas numa determinada área com o intuito de chegar a um consenso sobre a probabilidade e o momento de ocorrência de eventos futuros específicos [4].

Um grupo de especialistas é consultado para produzir previsões acerca de uma questão específica como, por exemplo quando ocorrerá um novo desenvolvimento tecnológico. A aplicação deste método assume que o grupo de especialistas tem experiência comprovada no campo de aplicação e, também, que o conhecimento combinado dos vários membros produzirá previsões tão precisas como se fossem apenas produzidas por um dos membros.

O método *Delphi* tenta evitar problemas de pressão social, mantendo os membros separados fisicamente. Após cada participante completar a sua previsão é comparada à previsão do grupo tentando obter-se um consenso. E no fim de várias rondas de questionários pode ser usado como previsão. Salienta-se que o método *Delphi* não requer necessariamente um consenso, em vez disso tenta perceber o porquê das diferentes opiniões para se chegar a uma unanimidade [2].

Comparações Tecnológicas Independentes do Tempo

Neste método, que é normalmente usado para prever alterações tecnológicas, o investigador tenta determinar o padrão de mudança numa área, chamada tendência primária, que este supõe que essa alteração provocará um desenvolvimento noutra determinada área. Considerando, por exemplo, que o investigador supõe que o desenvolvimento de um novo metal está relacionado com a potenciação do programa espacial, então, seguindo os avanços na metalúrgica no programa espacial, o investigador pode prever quando ocorrerão situações semelhantes na indústria.

Este método tem dois problemas básicos:

- 1) O investigador tem de identificar uma primeira tendência que irá usar para prever futuras situações.
- 2) O investigador tem de usar a experiência para determinar a relação entre a primeira tendência e as futuras previsões [2].

2.1.2 Métodos Quantitativos

Os métodos quantitativos têm por base a análise de dados históricos de forma a prever os futuros valores de uma variável de interesse e assentam numa hipótese de estabilidade. É nessa hipótese é que irão prevalecer no futuro as condições que determinaram no passado a evolução da variável. Nos modelos causais assume-se que se irão manter estáveis as

relações entre as variáveis explicativas e a variável explicada. Para as séries temporais, assume-se que no futuro se irão manter os padrões de comportamento que foram identificados no passado [1].

2.1.2.1 Modelos Causais

Os modelos causais envolvem a identificação de variáveis que possam estar relacionadas com a variável de previsão, uma vez que identificadas as variáveis poderá ser criado um modelo causal para a identificação da variável de previsão.

A vantagem deste método é que permite avaliar o impacto de várias políticas alternativas, o que ajuda a que se tenha uma visão global do sistema. Porém, este tem algumas desvantagens, tais como, são difíceis de desenvolver, requerem dados históricos de todas as variáveis incluídas no modelo e, também, a previsão depende da habilidade do investigador para prever as variáveis independentes [2].

Em seguida será feita uma breve descrição sobre alguns métodos causais:

- Correlação e Regressão;
- Modelo Econométrico.

Correlação e Regressão

A regressão é uma das técnicas estatísticas mais eficazes e de utilização mais frequente. A análise da regressão pode envolver desde fatores simples (regressão simples) ou até múltiplos fatores (regressão múltipla). Os fatores envolvidos apresentam uma relação de correlação que pode ser linear ou não linear.

No caso da análise de regressão linear simples assume-se que uma variável dependente tem uma relação linear com uma variável independente. A análise de regressão linear tem por objetivo encontrar a equação de uma reta que melhor se ajuste a um conjunto de observações.

A qualidade do ajuste desta análise é medida através do coeficiente de determinação que representa a relação entre a soma dos quadrados dos desvios dos resultados obtidos pela regressão, a média das observações e a soma dos quadrados dos desvios das observações.

De modo que a equação seja considerada, é necessário que o coeficiente de determinação seja superior a 0,5 [3].

A qualidade de uma regressão linear é normalmente medida através do coeficiente de correlação que representa a raiz quadrada do coeficiente de determinação e que demonstra o tipo de relação que as variáveis apresentam entre si. De modo que o modelo de regressão seja credível é necessário que o coeficiente de correlação seja menor que -0,7 ou maior que 0,7. O coeficiente de correlação pode variar de -1 a 1, onde 0 representa a ausência de correlação [3].

A regressão múltipla é similar à regressão simples principal diferença está relacionada com o facto de associar mais do que uma variável independente à mesma variável dependente.

Nos modelos de regressão simples e múltipla observa-se que apresentam apenas uma equação, isto significa que todos os elementos dessa mesma equação são tratados de forma endógena, ou seja, apenas são considerados os resultados da variável endógena (variável dependente), ignorando-se assim a interferência de outros fatores que se imiscuem com a variável.

Modelos Económicos

Num modelo económico são consideradas as variáveis endógenas e as variáveis exógenas (variáveis independentes), assim como fatores exteriores à variável a prever. Tal facto permite que este tipo de modelos apresente resultados com maior precisão, relativamente aos modelos de regressão [3].

2.1.2.2 Séries Temporais

Os modelos de séries temporais baseiam-se no pressuposto que o futuro é uma função do passado, ou seja, baseiam-se em dados históricos para prever valores de uma série temporal.

O propósito destes métodos é identificar um padrão básico existente nos dados históricos da série e através destes prever valores futuros. Trata assim, o sistema como uma caixa negra. Para que o método não apresente limitações espera-se que as condições se

mantenham inalteradas no futuro. Estes métodos simples têm uma grande popularidade, uma vez que são simples de programar e o custo computacional é muito pequeno e obtém-se uma previsão razoável.

Em seguida será feita uma breve descrição sobre alguns métodos de séries temporais:

- Extrapolação;
- Média simples;
- Média móvel;
- *Box-Jenkins* (Arima);
- Métodos de alisamento exponencial;
- Redes Neurais.

Extrapolação

Os métodos estatísticos de extrapolação baseiam-se na análise das sazonalidades e dos ciclos passados formando assim a previsão. É um método para previsões com um horizonte temporal de curto prazo ou que se mantenham estáveis ao longo do tempo [3].

Média simples

O método da média simples consiste em fazer a previsão a partir da média aritmética dos dados históricos.

A média simples apresenta as desvantagens de ser influenciada pelos dados que sejam discrepantes e considera o mesmo peso para os dados históricos da série temporal [3].

Média móvel

O método da média móvel utiliza-se para previsões de curto prazo com a suavização de curvas de tendências e sazonalidade.

Este método consiste na média dos N dados, os dados podem ser fornecidos anualmente ou mensalmente consoante o tipo de dados, ou seja, média móvel de N anos ou N meses.

A média móvel produz previsões que dependem de N . Utilizando um valor de N baixo, a média poderá estar a adicionar valores aleatórios com grande discrepância. Por outro lado, se o valor dos N dados for elevado a média não será muito sensível às variações.

O método tem as desvantagens de considerar o mesmo peso para todos os dados no cálculo da previsão e de necessitar de um grande número de dados para a obtenção de bons resultados [3].

Box-Jenkins (ARIMA)

No modelo de *Box-Jenkins* são feitas várias análises à série temporal, entre as quais, a análise da autocorrelação e autocorrelações parciais e, em seguida, é calculada uma estimativa dos parâmetros minimizando, dessa forma, o erro médio quadrático. Esta é uma das grandes vantagens deste método, uma vez que através da análise da autocorrelação é possível efetuar um diagnóstico dos resíduos de maneira que os parâmetros estimados apresentem o erro médio quadrático mínimo.

Este modelo, apesar de ser uma das ferramentas estatísticas com maior precisão, é, também, bastante complexo o que pode levar a ser necessário despender grande quantidade de tempo para a construção do modelo [3].

Modelos de Alisamento Exponencial

Os modelos de alisamento exponencial podem ser entendidos como uma aplicação particular da média móvel, porque estes modelos são baseados na premissa de que os dados disponíveis para o cálculo da previsão tornam-se cada vez menos relevantes conforme o aumento da sua idade, o que não acontece na média móvel. Este modelo procura associar pesos mais altos aos dados mais recentes, diminuindo esse peso exponencialmente para os dados mais antigos [3].

Redes Neurais Artificiais

As RNA são sistemas de computação adaptativos inspirados nas características de processamento de informação encontradas no nosso sistema nervoso e, como tal, adquirem conhecimento através da experiência. À semelhança do sistema nervoso, uma

RNA é composta por várias unidades de processamento que são conectadas pelos canais de comunicação que têm um determinado peso.

Este modelo tem as vantagens de ter uma grande capacidade de aprendizagem e de modelar sistemas complexos de difícil percepção como se tratasse de uma caixa preta, na qual se desconhece o seu funcionamento, na medida em que o objetivo da RNA é prever o comportamento do sistema e não como este funciona. Em contrapartida, é impossível saber o motivo que levou a RNA a chegar a determinadas conclusões [5].

2.2 Diagramas de Carga

As cargas elétricas variam com o tempo, e a produção e a distribuição tem que se adaptar às variações de carga que podem ocorrer a qualquer tempo. Atualmente os fornecedores de eletricidade necessitam de prever essas variações com exatidão, sejam essas alterações de curto prazo ou de longo prazo. Sendo que a previsão é necessária para:

- 1) que haja um preço mais reduzido da energia,
- 2) para planeamento de futuras centrais produtoras,
- 3) para o planeamento de tudo o que envolve a distribuição (subestações, linhas).

Os diagramas de carga são normalmente utilizados na engenharia para a análise de cargas elétricas, e são construídos através do valor médio de carga num determinado período de tempo, este período é normalmente medido numa hora como mostra a Figura 2.2, mas também pode ser medido em intervalos de 15 minutos, 30 minutos, diariamente, mensalmente ou anualmente.

A variação da potência produzida/consumida ao longo de um tempo, $P(t)$, usualmente é desingada por padrão de carga diário (PCD). O valor médio de potência consumida neste intervalo de tempo é dado pela potência acumulada dividida pela dimensão do mesmo e pode ser representado graficamente para qualquer ponto da rede (aparelhos de uso final, consumidor, postos de transformação, subestações e unidades de produção).




Figura 2.2 - Diagrama de carga de 24h com discriminação dos parâmetros de caracterização

O diagrama de carga representa o padrão de carga num determinado intervalo de tempo. Para um melhor entendimento deste tipo de diagramas é importante explicitar alguns conceitos largamente divulgados. Observando a Figura 2.2, a ordenada máxima P é normalmente designada por ponta do diagrama de carga no intervalo em estudo. Embora a designação do termo “ponta” seja usualmente aplicada a todos os máximos locais do diagrama.

Deste modo, pode-se observar duas pontas relevantes, P representa a ponta da tarde e P' a ponta da manhã (Figura 2.2). Em contraste com as “pontas” pode-se designar de “vazio”, as depressões encontradas no PCD. Sendo que A representa o vazio da noite e B representa o vazio da tarde [6] [7].

2.2.1 Análise de Diagramas de Carga

Normalmente os dados de carga que são necessários não estão disponíveis diretamente e por isso os valores de carga devem ser estimados e previstos usando todas as informações disponíveis, devendo-se tirar partido das informações que os diagramas de carga fornecem.

O consumo de energia varia consoante o tipo de consumidor, mas existe, no entanto, alguns padrões de consumo, o que permite que os consumidores possam ser caracterizados de três formas:

- 1) consumidores residenciais,
- 2) consumidores comerciais,
- 3) consumidores industriais.

O padrão de carga típico dos respetivos consumidores encontra-se representado na Figura 2.3. Quando se fala do consumo de energia global de um determinado país estas três classes encontram-se agregadas.




Figura 2.3 - Padrões de consumo típicos, por classes de consumidores [7]

Este tipo de diagramas apresenta comportamentos cíclicos, que podem ser classificados como sendo: anuais, semanais e diários. A repetição diária está relacionada com o comportamento igual entre dias homólogos, o que é consequência de hábitos e certas rotinas diárias que se prendem com necessidades diárias de consumo.

2.2.1.1 Sazonalidades Semanais

Além da sazonalidade diária vista na Figura 2.2 existe também a sazonalidade semanal e este comportamento cíclico pode ser aferido na Figura 2.4, onde se verifica um comportamento semelhante nos dias úteis semanais e uma quebra no consumo de energia no fim de semana, devido à praticamente inexistente atividade industrial nesses dias.




Figura 2.4 – Diagrama de carga semanal 168h (21/jan/2008 a 27/jan/2008) [6]

Dentro da sazonalidade semanal existe a sazonalidade dos dias da semana e a sazonalidade dos fins de semana (Figura 2.5 e Figura 2.6). São sazonalidades particulares dentro da sazonalidade semanal (168h).

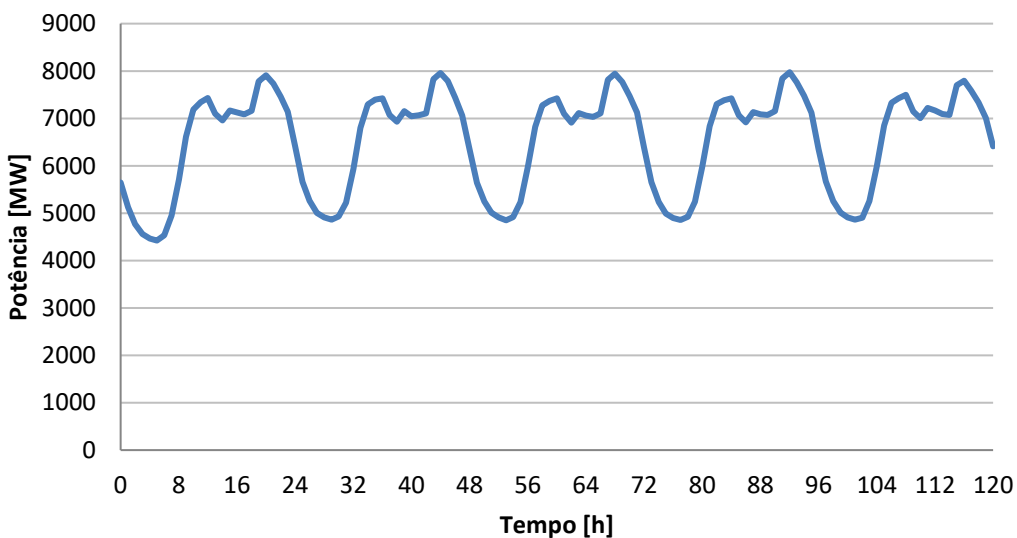


Figura 2.5 – Diagrama de carga semanal 120h, 2ª a 6ª feira (21/jan/2008 a 25/jan/2008) [6]




Figura 2.6 – Diagrama de carga fins de semana 48h (25/jan/2008 a 27/jan/2008) [6]

Podem existir alguns fatores que desequilibram a periodicidade diária e semanal, que estão relacionados essencialmente com a ocorrência de dias com rotinas distintas das verificadas normalmente, tais como, feriados, greves ou pontes. Se este tipo de dias acontecer nas proximidades de um fim de semana, originam períodos mais alargados de redução da atividade económica e, conseqüentemente, a um menor consumo de energia. Na Figura 2.7 está representado um bom exemplo de um diagrama de carga semanal atípico, ou seja, com a existência de um dia feriado na sexta-feira.




Figura 2.7 – Diagrama de carga numa semana com feriado, sexta-feira (25/jan/2008 a 27/jan/2008) [6]

2.2.1.2 Diferenças dos diagramas de carga no inverno e no verão

O padrão de carga sofre também algumas alterações significativas consoante a época do ano, consequência natural dos hábitos e das rotinas diárias que dependem da altura do ano. Por exemplo, no verão é mais usual o funcionamento dos sistemas de ar condicionado para refrigeração, especialmente nas horas de maior calor. Já no inverno, a ponta da noite é mais prolongada devido ao normal decréscimo da temperatura e, conseqüentemente, existir a necessidade de recorrer a sistemas de aquecimento. Na Figura 2.8 observa-se a diferença entre o consumo de energia elétrica num dia de verão relativamente a um dia de inverno em Portugal.




Figura 2.8 - Diagrama de carga de um dia de inverno (24/jan/2008) e de verão (20/ago/2008) [6]

As diferenças apontadas ao diagrama de 24 horas de inverno e verão também se refletem nas periodicidades semanais, como se pode observar na Figura 2.9. Verificando-se que existe um valor superior de consumo no inverno.

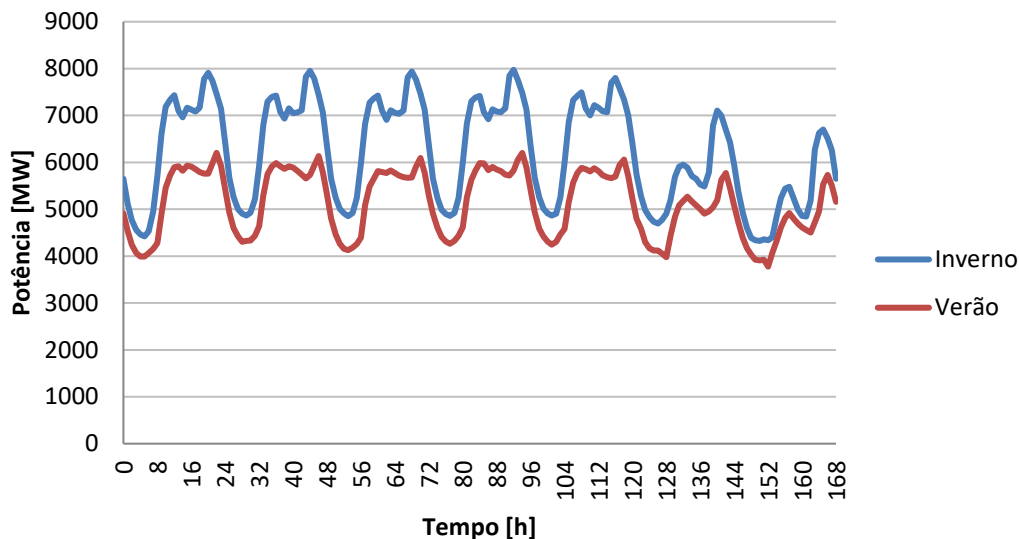


Figura 2.9 - Diagrama de carga de semanal de inverno (21/jan-27/jan) e de verão (18/ago-24/ago) [6]

A forma e os valores médios da potência consumida é fortemente influenciada pelas estações climáticas. Ao visualizar-se a

Figura 2.10, diagrama de carga do ano 2008, verifica-se que no padrão de consumo é notória uma alteração da potência sempre que ocorre uma transição de estação, seja das estações quentes para as frias ou vice-versa, havendo um maior consumo nas épocas frias. Sendo que nas estações frias há um consumo superior de energia.

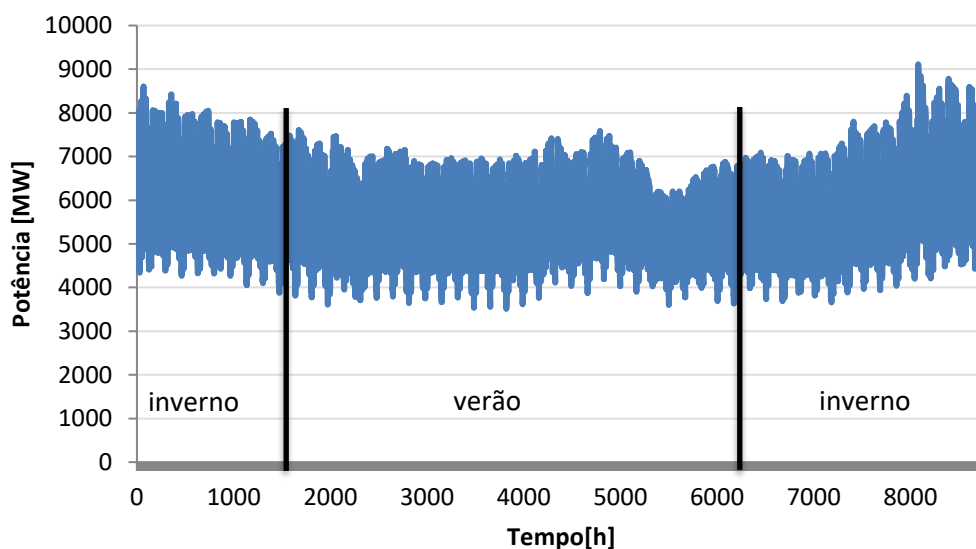


Figura 2.10 - Diagrama de carga anual, exemplo da sazonalidade anual [6]

2.2.1.3 Evolução energética ao longo dos anos

Através da análise da energia consumida é possível verificar a evolução da energia consumida em Portugal nos vários anos, seja a nível diário, semanal ou anual.

Observando-se as Figura 2.11 e Figura 2.12, é possível verificar a evolução do consumo de energia num dia típico de Inverno e de Verão.




Figura 2.11 – Evolução da energia consumida num dia típico de inverno (2008-2012) [6]




Figura 2.12 – Evolução da energia consumida num dia típico de verão (2008-2012) [6]

Observando-se a Figura 2.13 e Figura 2.14, é possível verificar a evolução do consumo de energia numa semana típica de inverno (4ª semana do ano) e de verão (29ª semana do ano).




Figura 2.13 – Evolução da energia consumida numa semana típica de inverno (2008-2012) [6]




Figura 2.14 – Evolução da energia consumida numa semana típica de verão (2008-2012) [6]

Em seguida, seguem três análises anuais muito utilizadas para a análise económica e de desenvolvimento de um país. Com a análise destes gráficos é possível perceber o nível de crescimento económico de um país. O gráfico mais comumente utilizado é um gráfico com a evolução da energia num ano, como apresentado na Figura 2.15, onde é possível verificar os consumos dos vários anos, tentar entender a tendência dos anos que se seguem e analisar o que mais influência o consumo de energia de um ano.




Figura 2.15 – Evolução da energia anual consumida (2008-2019) [6]

Através da análise dos gráficos apresentados nas Figura 2.15 e Figura 2.16, verifica-se que de 2011 a 2015 a energia consumida tem vindo a diminuir, o que se deveu à crise vivida na Europa e principalmente em Portugal, uma vez que foi em abril de 2011 que Portugal solicitou ajuda financeira internacional e em maio de 2014 a Troika se retirou de Portugal. Por outro lado, foi em 2010 que se atingiu o maior consumo de energia bem como, a maior potência média.




Figura 2.16 – Potência média mensal (2008-2019) [6]

Na Figura 2.17 apresenta-se a evolução da ponta máxima mensal ao longo dos anos em estudo e verifica-se que também o valor máximo de potência de ponta foi atingido no ano de 2010, mas especificamente 9403 MW, atingido no dia 11/01/2010.




Figura 2.17 – Potência máxima em cada mês do ano (2008-2019) [6]

Capítulo 3

Redes Neurais Artificiais

Neste capítulo é feita uma abordagem sobre as redes neuronais artificiais, em que se apresenta as suas principais características.

3 Redes Neurais Artificiais

3.1 Introdução

A rede neuronal artificial, normalmente referida apenas como rede neuronal, é uma poderosa ferramenta de modelização de dados que é capaz de capturar e representar um complexo sistema de entradas e saídas relacionadas. A motivação para o desenvolvimento das RNA foi a necessidade de desenvolver um sistema artificial que fosse adaptativo e pudessem executar tarefas “inteligentes” semelhantes às executadas pelo cérebro humano. As RNA assemelham-se ao cérebro humano da seguinte forma:

- A RNA adquire conhecimento através da aprendizagem;
- O conhecimento da RNA é armazenado dentro das conexões do inter-neurónio conhecidas como pesos sinápticos.

O verdadeiro poder e vantagem das RNA reside na sua capacidade de representar tanto relações lineares e não-lineares e na sua habilidade de aprender essas relações diretamente através dos dados modelados.

As RNA adotam uma abordagem de processamento paralelo, ou seja, contêm uma rede de processadores (conhecida como neurónios) que trabalham em paralelo, permitindo-lhe operar com uma grande velocidade, sendo uma vantagem para computações complexas.

Para uma melhor compreensão das RNA é necessário conhecer o seu conceito básico que é imitar o cérebro humano. Em outros termos, o cérebro humano é como uma rede neuronal natural. [8]

As semelhanças entre o neurónio humano e o artificial estão assinaladas na Figura 3.1.




Figura 3.1 - Neurónio biológico e neurónio artificial: comparação [9]

Uma RNA consiste numa interligação de unidades de processamento (neurónios) com uma configuração semelhante às dos neurónios cerebrais.

As entradas e saídas das unidades de processamento (UP) correspondem, em semelhança, às sinapses e axónios dos neurónios cerebrais. Cada nova entrada apresentada é, assim, ponderada por um “peso” sináptico, w_n , que é o indicador da relevância da ligação. Cada UP realiza operações muito simples, desde logo a começar pela soma ponderada das entradas, x_n , pelos pesos das respetivas ligações resultando, deste modo, na ativação das UP.

As funções de ativação inseridas nas UP, são indispensáveis nas camadas intermédias, ou neurónios intermédios, sendo que através deste tipo de funções é possível a introdução de não-linearidades na rede neuronal.

De seguida é apresentada na Figura 3.2 a explicitação de um neurónio artificial linear.

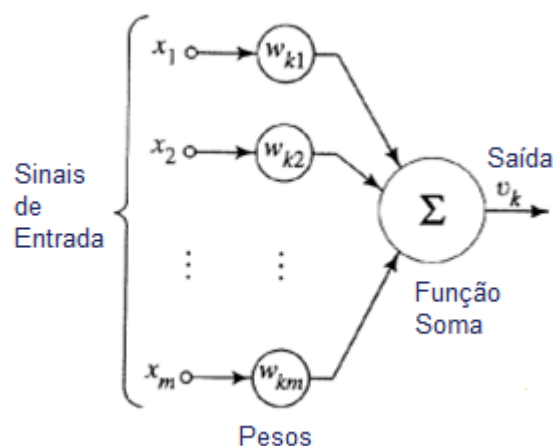


Figura 3.2 - Neurónio artificial linear

Assim, a formulação matemática que advém da figura anteriormente apresentada, correspondente à saída do modelo neuronal é expressa na seguinte equação:

$$u_k = \sum_{m=1}^n x_m \cdot w_{km} \quad (3.1)$$

Sendo que as constantes de ponderação, w_{km} , representam as conexões sinóticas biológicas que intermediam a interação entre neurónios vizinhos, x_m é o estímulo proveniente do neurónio vizinho m , e o resultado u_k representa o estímulo global (com as devidas ponderações relativas) recebido pelo neurónio de todos os seus vizinhos.

Em seguida é apresentada na Figura 3.3 um neurónio artificial não linear com função de ativação.

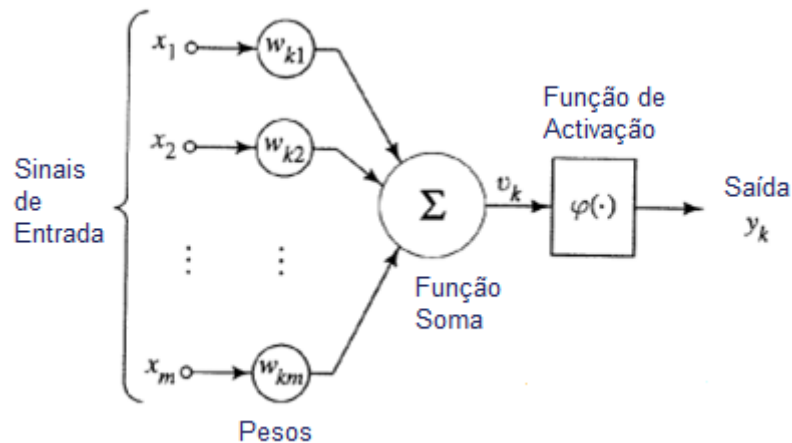


Figura 3.3 - Neurónio artificial com função transferência não linear

Sendo que o que corresponde à saída do modelo neuronal é:

$$y_k = f \left(\sum_{m=1}^n x_m \cdot w_{km} \right) \quad (3.2)$$

De acordo com o valor da variável u_k e com a função transferência à qual essa variável é aplicada (ou também conhecida como função de ativação), o modelo não linear fornecerá uma saída, y_k , em resposta aos estímulos x_m .

Na sua forma mais simples a função transferência não linear f pode ser binária (discreta), como no caso do modelo conhecido como Perceptrão de Rosenblatt.

3.2 Funções de Ativação

Como referido anteriormente, uma parte importante na construção de uma rede neuronal é a definição das suas funções de ativação. A função de ativação traduz os sinais de entrada para sinais de saída. Os quatro tipos de funções de ativação mais utilizados são: *Step Unitário (Threshold)*, *Sigmóide*, *Linear Por Partes* e *Gaussiana*.

3.2.1 Step Unitário (Threshold)

A função ativação Threshold pode ser do tipo binário ou do tipo bipolar como apresentado de seguida (Figura 3.4 e Figura 3.5).




Figura 3.4 - Threshold Binário




Figura 3.5 - Threshold Bipolar

Estes tipos de função de ativação são úteis para esquemas de classificação binária. Por outras palavras, quando se pretende identificar um padrão de entrada em um ou dois grupos, pode-se utilizar uma função de ativação de Threshold para a sua identificação.

3.2.2 Sigmóide

A função sigmóide é uma função não linear curvada em forma de S que consiste em duas funções, função logística e tangencial (Figura 3.6).




Figura 3.6 - Sigmóide

A função de ativação sigmóide apenas produz números entre 0 e 1. A sigmóide é mais útil para dados de treino que sejam entre 0 e 1. É uma das funções de ativação mais utilizadas.

3.2.3 Linear por partes

A função de ativação linear por partes é também chamada de função de saturação linear. Tendo uma extensão binária ou bipolar nos seus limites de saturação. A sua saída é proporcional à saída total dos pesos ponderados (Figura 3.7).




Figura 3.7 – Linear Por Partes

3.2.4 Gaussiana

O gráfico de uma Gaussiana é uma característica simétrica “curva do sino” forma que rapidamente cai para o mais ou menos infinito (Figura 3.8).




Figura 3.8 - Gaussiana

O valor da função gaussiana é máximo quando não há ativação, ou seja, quando o valor é zero. O valor da função vai diminuindo com o aumento do valor absoluto da ativação.

Este tipo de função pode ser utilizado quando é necessário um controlo mais preciso sobre o intervalo de ativação.

3.3 Arquitetura

A forma como os neurônios artificiais podem ser agrupados é uma importante característica que define o tipo de arquitetura das RNA.

As RNA são geralmente dispostas em camadas e cada camada tem uma finalidade específica ou desempenha uma função específica. A camada à qual as entradas são apresentadas é designada como camada de entrada e a camada referente às saídas da rede é designada de camada de saída. Entre as camadas de entrada e saída são muito frequentemente, utilizadas uma ou mais camadas definidas como camada escondida. As camadas escondidas atuam como transdutores entre as camadas a que estão conectados [10].

As redes que possuem uma única camada são as redes que possuem um nó, um neurónio entre uma entrada e uma saída da rede. Este tipo de rede é indicado para a solução de problemas linearmente separáveis. Já as redes multicamadas possuem uma ou mais camadas entre as camadas de entrada e saída.

Existem essencialmente duas arquiteturas para RNA: redes *feed-forward* e redes recorrentes. A Figura 3.9 apresenta uma rede *feed-forward* simples e uma rede recorrente.




Figura 3.9 - Redes Feed-Forward e Redes Recorrentes

Ambas as redes *feed-forward* e recorrentes são compostas de unidades interligadas, ou neurónios, geralmente dispostos em camadas. Nas redes *feed-forward*, os sinais de ativação movem-se numa direção: a partir da camada de entrada para a camada de saída. Em redes recorrentes alguns dos sinais de ativação viajam de volta para uma das camadas anteriores e tornam-se sinais de entrada para essas unidades [10].

3.3.1 Feed-Forward

A rede *feed-forward* foi a primeira e, possivelmente, o tipo de RNA mais simples inventada. Nesta rede a informação move-se em apenas uma direção, para a frente. Move-se dos nós de entrada e passa através da camada escondida, se houver, para a camada de saída. Não há ciclos ou *loops* na rede e pode ser construída a partir de diferentes tipos de unidades, por exemplo o perceptrão.

3.3.1.1 Única Camada Feed-Forward Network

No caso mais simples de redes em camadas (*layers*), tem-se uma camada de entrada com neurónios cujas saídas alimentam a última camada da rede. A rede *feed-forward* é composta por uma única camada de pesos, sendo que esta camada é referente à camada de nós de computação de saída. As entradas são conectadas diretamente à saída.

Geralmente, os neurónios de entrada são propagadores puros, ou seja, estes simplesmente repetem o sinal de entrada na sua saída distribuída. Por outro lado, as unidades de saída costumam ser unidades processadoras, como apresentado na Figura 3.10. A propagação de sinais nesta rede é puramente unidirecional (*feed-forward*): os sinais são propagados apenas da entrada para a saída, e nunca vice-versa. Esta arquitetura está ilustrada na Figura 3.10 [11].




Figura 3.10 – Redes neuronais tipo *feed-forward* com uma unidade processadora

3.3.1.2 Rede Multicamada *Feed-Forward* (MLP)

A rede *feed-forward* multicamada distingue-se pela presença de uma ou mais camadas intermediárias ou escondidas (camadas em que os neurónios são efetivamente unidades processadores, mas não correspondem à camada de saída). Adicionando-se uma ou mais camadas intermediárias, aumenta-se o poder computacional de processamento não-linear da rede. O conjunto de saídas dos neurónios de cada camada da rede é utilizado como entrada para a camada seguinte. A Figura 3.11 ilustra uma rede *feed-forward* de múltiplas camadas intermediárias [11].




Figura 3.11 – Redes neurais tipo *feed-forward* com multicamadas

3.3.2 Recorrentes

As redes recorrentes distinguem-se das redes *feed-forward* pela existência de pelo menos um *loop* de recorrência (*feedback*), ou seja, ao contrário das redes *feed-forward*, as redes recorrentes são modelos com fluxo de dados bidirecional. Enquanto uma rede *feed-forward* propaga dados linearmente da entrada à saída, as redes recorrentes também propagam dados de estágios de processamento posteriores às etapas anteriores.

3.3.2.1 Back-Propagation Through Time

Back-Propagation Through Time envolve desdobramento da operação temporal de uma rede recorrente totalmente conectada em uma rede multicamada *feed-forward*, o que resulta numa rede maior e com um novo conjunto de camadas para cada intervalo de tempo, mas com os mesmos pesos utilizados para cada etapa de tempo. Um exemplo desta técnica é apresentado nas Figura 3.12 e Figura 3.13.

A Figura 3.12 mostra a rede recorrente original, com três unidades cada, com cada uma delas com bias modificáveis (bias-neurônio com uma saída constante) e com ligações modificáveis entre a própria unidade e entre outras.

A Figura 3.13 apresenta a rede desdobrada em dois intervalos de tempo. Os valores de bias para as correspondentes unidades escondidas e unidades de saída são idênticos para cada intervalo de tempo, bem como os pesos das entradas são para a correspondente unidade escondida e de saída [10] [12].




Figura 3.12 – Rede recorrente totalmente conectada




Figura 3.13 – Rede recorrente desdobrada no tempo

3.3.2.2 Simple Recurrent Networks

Simple Recurrent Networks, Rede recorrente simples apresenta a recorrência à rede através da adição de um conjunto de unidades chamadas unidades de contexto. Redes recorrentes simples têm o mesmo número de unidades de contexto e unidades escondidas, com as unidades de contexto a serem ativadas na base um-para-um pelas unidades escondidas. As camadas ocultas adicionais entre a camada de entrada e a principal camada

escondida ou entre a camada principal e a camada oculta de saída podem ser utilizadas para comprimir os vetores de entrada e de saída. Unidades de contexto têm um peso fixo de 1. A Figura 3.14 é um exemplo de uma rede de recorrente simples [10].




Figura 3.14 – Rede recorrente simples

3.4 Treino/Aprendizagem da Rede

A capacidade de aprendizagem é uma das características principais das RNA. Uma RNA aprende, basicamente, através de um processo iterativo de ajuste de pesos e bias. Em função disso, as conexões entre os neurônios artificiais de uma rede são normalmente programáveis, a partir da qual a rede incorpora experiência através dos exemplos que lhe são apresentados.

O objetivo de qualquer algoritmo de aprendizagem é permitir que a RNA possa ajustar os pesos e as bias que estão associados aos neurônios que compõem a rede, de modo que uma entrada apresentada nas unidades de entrada faça com que seja ativada a saída correta e, assim, seja aperfeiçoada a saída [10].

O conceito de adaptação da rede face a uma descrição do problema que se pretende resolver através de exemplos dá origem às expressões que aparecem com frequência no contexto de RNA: “redes neuronais aprendem através de exemplos” ou “a rede extrai informações através dos padrões que lhe são apresentados”. O que ocorre numa RNA é que os pesos são ajustados de forma que um dado mapeamento entrada/saída desejado (descritas por um conjunto de entrada/saída chamados de exemplo de treino) seja obtido.

Os pesos são ajustados através de um algoritmo de adaptação ou aprendizagem, que tenha características boas em termos de viabilizar a aprendizagem de um leque amplo de diferentes mapeamentos entrada/saída.

Os algoritmos de aprendizagem podem ser divididos em dois grandes grupos: algoritmos de aprendizagem supervisionada e algoritmos de aprendizagem não supervisionada.

Nos algoritmos de aprendizagem supervisionada, os dados são apresentados nas unidades de entrada e a saída da rede é comparada com um padrão de saída esperado. Trata-se de um paradigma de aprendizagem, no qual um supervisor possui conhecimento sobre o ambiente em que a rede está inserida. A análise da aprendizagem é aferida segundo o erro que é calculado com base na diferença entre os padrões de saída reais e esperadas, conforme equação (3.3), e esse erro é utilizado para ajustar os pesos e desvios da rede.

$$\varepsilon_t = X_t - \hat{X}_t \quad (3.3)$$

A aprendizagem supervisionada é iterativa até que a rede considere que o treino tenha sido suficiente [10].

No processo de aprendizagem não supervisionada não existe um supervisor para avaliar o desempenho da rede em relação ao conjunto de treino, ou seja, os dados são não-rotulados. O objetivo é categorizar ou descobrir as características nos dados de treino.

Os algoritmos de aprendizagem supervisionada mais conhecidos são a “Regra Delta”, para o perceptrão simples, e o “*Error Back-propagation*”, para as redes *feed-forward* multicamadas.

3.4.1 Error Back-Propagation

A regra de *back-propagation*, também conhecida como a regra delta generalizada, é um exemplo de aprendizagem supervisionada. Como o objetivo da rede é produzir a saída correta ou esperado na camada de saída dado alguma contribuição apresentada na camada de entrada, o objetivo da operação de treino deve ser o de reduzir a diferença entre o resultado esperado e os resultados reais.

A fim de treinar a rede, um conjunto definido de exemplos de treino, é apresentado à rede, geralmente muitas vezes. À medida que o conjunto de dados de treino é apresentado, o

valor da função de erro para a rede é iterativamente reduzido, ajustando os pesos da rede por uma certa quantidade determinada pelo valor da função de erro.

Os dados de treino completos apresentados à rede são chamados de época.

O *back-propagation* envolve duas fases de computação. A primeira fase, conhecida como a passagem para a frente, envolve o cálculo da ativação de cada neurónio. Os sinais de ativação prosseguem em frente da camada de entrada, através das camadas intermédias até que a saída é calculada na camada de saída. Durante a fase de passagem para a frente os pesos da rede permanecem inalterados. A segunda fase, conhecida como o passe para trás, envolve o cálculo de erro e ajuste dos pesos para cada neurónio. Este passe para trás começa na camada de saída e propaga-se para o resto da rede. O tamanho da gama de regulação do peso para qualquer neurónio depende do valor da função de erro e é determinado a contribuição desse neurónio para o valor do erro (Figura 3.15) [10].

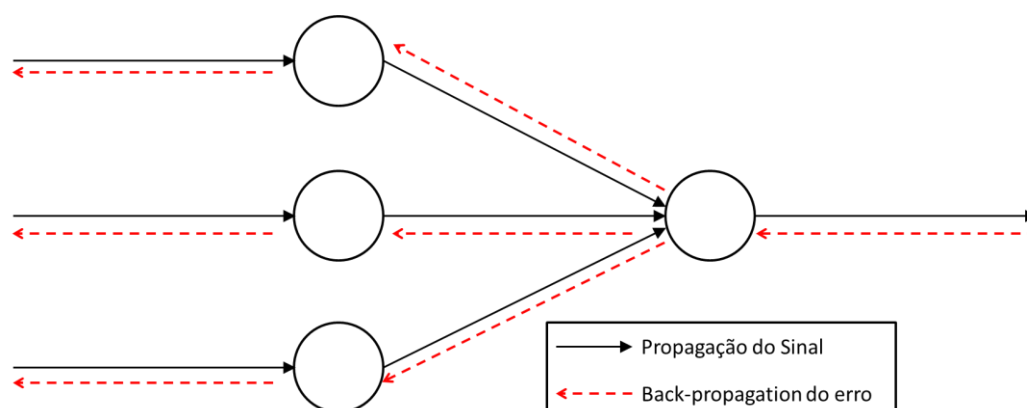


Figura 3.15 – Sentido da propagação do sinal funcional e do sinal de erro

3.4.2 Generalização e *Over-fitting*

Um benefício oferecido pelas redes neuronais é a sua capacidade de generalizar. Normalmente, o objetivo de utilizar uma rede neuronal é de treinar a rede com os dados conhecidos, a fim de que a rede possa prever o resultado nos casos em que este ainda não é conhecido. Um problema na formação de redes neuronais para a generalização é o fenômeno do sobre-ajuste (*over-fitting*), a rede perde a capacidade de generalizar, ou seja, decora os resultados. O sobre-ajuste é a tendência para uma rede neuronal aprender a essência dos dados de treino tão bem que consegue um valor extremamente baixo para a função de erro durante o treino, mas é incapaz de prever dados com os quais não foi treinada com algum grau de precisão. Essa tendência de se concentrar na essência dos

dados de treino pode fazer com que a rede ignore outras características importantes dos dados e, assim, perca a capacidade de uma boa generalização.

Uma técnica conhecida para resolver esse problema é a paragem do treino ou paragem precoce. Esta técnica é geralmente utilizada numa tentativa de ultrapassar o problema de sobre-ajuste.

Existem vários métodos para a estimativa do erro de generalização com mais precisão (estas técnicas, contudo, não são geralmente usados em métodos de paragem precoce). Dois desses métodos são *k-fold* e *leave-one-out* de validação cruzada.

No método *k-fold* de validação cruzada os dados são divididos em k subconjuntos de tamanhos iguais. A formação é realizada em todos menos um dos subconjuntos de dados e o restante subconjunto é utilizado como conjunto de validação. A rede é treinada k vezes utilizando em cada um subconjunto diferente de dados como conjunto de validação.

No método *leave-one-out* de validação cruzada é apenas *k-fold* de validação cruzada com k igual ao número de exemplos de treino no conjunto de treino [10].

3.4.3 Paragem do Treino

Como o *over-fitting* é um problema quando se treina redes neuronais, é importante determinar o ponto correto em que se deve parar o treino. Provavelmente a técnica mais comum é conhecida como paragem precoce.

O método de paragem precoce emprega validação *split-sample* e envolve o treino da rede até o ponto em que aprende os dados de treino suficientemente bem e, então, é capaz de prever com precisão os resultados para os dados inéditos. Os dados disponíveis são tipicamente divididos em dois grupos: os dados de treino e os dados de teste, com os dados de teste a serem usados depois de a rede ser treinada para medir a capacidade de generalização da rede. Na validação *split-sample* os dados de treino são divididos em dois grupos, o conjunto de treino e o conjunto de validação, e durante o processo de formação do conjunto de validação é utilizado para medir a qualidade da rede. A formação da rede é interrompida quando o erro para o conjunto de validação atinge um valor mínimo. Para ser considerado válido qualquer teste que use este método nenhuma informação sobre os dados de teste ou o desempenho da rede nos dados de teste deve estar disponível durante o processo de treino [10].

Capítulo 4

Modelização

Neste capítulo é feita uma abordagem à metodologia utilizada para efetuar a previsão do consumo de energia elétrica para um horizonte de curto prazo em Portugal continental. Apresentam-se as principais características que compõem a modelização, aprofundando os modelos que melhor se adaptam aos casos de estudo.

4 Modelização

4.1 Séries de Dados

Para a previsão com RNA é necessário apresentar à rede dados de entrada e de saída, e esses dados irão garantir que a rede tem informação para aprender, ou seja, que seja capaz de extrapolar.

Os dados que foram utilizados no programa realizado para esta dissertação foram fornecidos pela REN, sendo dados de 2008 a 2012, e estão compostos da seguinte forma:

Tabela 4.1 - Formato da Série de Dados

Dados de Entrada				Dados de Saída
Estação do Ano	Hora	Dia	Mês	Potência

A série de dados foi alterada de modo a separar os dias de semana dos fins-de-semana e normalizando os dias de feriado para que se possam utilizar na simulação. A metodologia de separar os dias de semana dos fins-de-semana serviu para que se possa fazer um programa onde a previsão dos dias de semana e dos fins-de-semana fosse em programas separados, uma vez que quanto mais se altera o padrão mais complicado se torna realizar a previsão.

4.2 Rede a utilizar

Para a construção da rede utilizou-se o software, MATLAB, versão 7.8, que é um software bastante comum, prático e acessível, que permitirá realizar as simulações e retirar ilações sobre os resultados obtidos.

Depois de escolhido o software, foi necessário compreender se desenvolveria esta dissertação diretamente no editor do software, linhas de comando, ou se utilizaria ferramentas adicionais, como é o caso do Simulink Library Browser, no qual existe a Neuronal Network Toolbox.

Inicialmente utilizou-se a Neuronal Network Toolbox, uma vez que é a ferramenta de mais fácil utilização e de simples implementação, mas após várias tentativas de implementação concluiu-se que a ferramenta era bastante limitativa podendo apenas

alterar poucos parâmetros da RNA, e que seria possível alterar mais parâmetros da RNA, se esta fosse criada no editor, em vez de se utilizar a Toolbox, optando-se por a escolha do Editor face à Toolbox.

Para treinar a rede foi necessário selecionar os dados de treino e os dados de teste que se iriam utilizar, dependendo do caso existem vários tipos de dados.

Primeiro foi necessário proceder a uma normalização dos valores das matrizes dos dados que se iriam utilizar como dados de entrada/saída, sendo parametrizados numa escala entre [-1, 1] a fim de a rede proceder a um melhor processamento dos valores temporais e de potência, para tal foi necessário utilizar o comando “mapminmax”, que é aplicada de acordo com a equação (4.1):

$$y_{normalizada} = \frac{(y_{max} - y_{min}) * (x - x_{min})}{x_{max} - x_{min}} + y_{min} \quad (4.1)$$

Existem vários tipos possíveis para a criação de uma RNA na linha de comandos, sendo elas:

- Newlin- cria uma rede linear;
- Newp- cria uma rede perceptron;
- Newff- cria uma rede “feed-forward backpropagation”.

Para a criação da RNA foi escolhido o tipo de rede Newff, em seguida a fórmula do Matlab:

```
Net=newff (P,T,[S1 S2...S(N-1)},{TF1 TF2...TFN1}, BTF,BLF,PF)
```

Sendo:

- P- Matriz com os dados de entrada de treino;
- T- Matriz com os dados de saída de treino;
- Si- Número de neurónios na camada escondida e número de camadas escondidas;
- TF_i- Função Transferência das camadas escondidas e camada de saída (Default = 'tansig' para as camadas escondidas e 'purelin' para a camada de saída);
- BTF- 'Backpropagation network', função de treino dos neurónios (Default = 'trainlm');
- BLF- 'Backpropagation weight/bias', função de aprendizagem dos pesos (Default = 'learngdm');
- PF- Função de Performance (Default = 'mse').

Concluída a criação da rede foi necessário fornecer os parâmetros de treino à rede, como a taxa de amostragem da progressão do treino, o número de iterações, o erro associado, a taxa de aprendizagem, o momento constante e o gradiente mínimo.

Os parâmetros de treino são os seguintes:

Tabela 4.2- Parâmetros de Treino

Parâmetros de Treino	Valores Predefinidos	Significado
net.trainParam.epochs	10	Número máximo de épocas de treino
net.trainParam.goal	0	Objetivo
net.trainParam.lr	0.01	Taxa de aprendizagem
net.trainParam.max_fail	5	Máximas falhas de validação
net.trainParam.mc	0.9	Constante de momento
net.trainParam.min_grad	1,00E-10	Gradiente mínimo objetivo
net.trainParam.show	25	Épocas entre amostragem dos progressos
net.trainParam.showCommandLine	0	Gerar a saída na linha de comando
net.trainParam.showWindo	1	Apresentação do treino GUI
net.trainParam.time	infinito	Tempo máximo para treinar em segundos

O método para treinar a RNA no matlab é o seguinte:

$$[\text{net}, \text{tr}, \text{Y}, \text{E}, \text{Pf}, \text{Af}] = \text{train}(\text{Net}, \text{P}, \text{T}, \text{Pi}, \text{Ai})$$

Os parâmetros que a função recebe:

- NET- Rede;
- P- Matriz dos dados de entrada, valores com a informação da data para treino;
- T- Matriz dos dados de saída, valores de potência para treino;
- Pi- Condições de atraso iniciais das entradas (Default = zero);
- Ai- Condições de atraso iniciais das camadas (Default = zero).

Os parâmetros que a função retorna:

- net- Nova rede neuronal;
- tr- Relatório de treino;
- Y- Saída da Rede Neuronal;
- E- Erros da Rede Neuronal;
- Pf- Condições atraso finais dos valores entrada;
- Af- Condições atraso finais da camada.

Após se parametrizar a RNA é necessário testá-la para aferir a sua aptidão, erro da RNA criada comparando o valor de potência encontrado com o valor real de potência.

A fórmula para testar a RNA é a seguinte:

$$[t,x,y] = \text{sim}(\text{model}, \text{timespan}, \text{options}, \text{ut});$$

Sendo:

- t- Matriz do vetor de tempo da simulação;
- x- Matriz do vetor de entrada, usado como input da RNA, data de teste;
- y- Matriz do vetor de saída encontrado, potência;
- model- RNA criada, alvo de simulação;
- timespan- Tempo de simulação, início e paragem;
- options- Parâmetros opcionais de simulação;
- ut- Entradas externas opcionais.

Após se ter testado a RNA criada é necessário voltar a colocar os valores encontrados no formato que sejam de fácil análise, como falado no início foi necessário normalizar os valores entre [-1, 1] para treinar a rede, sendo agora necessário reverter o processo. Podendo assim, serem analisados na previsão de consumo de energia elétrica.

4.3 Casos de estudo

Os casos de estudo foram divididos em dois modelos, diferenciados pelos dados de entrada que serão utilizados para treinar a rede, no primeiro caso serão apenas colocados os dias de semana (2ª a 6ª) e no segundo caso serão colocados os fins de semana (Sábado e Domingo). Foi considerada esta opção de diferenciação dos modelos porque nas tentativas realizadas, contemplando as duas opções juntas nos dados de entrada, não foi possível obter resultados satisfatórios.

Para cada um dos modelos foi estudada cada uma das redes com várias dimensões de dados de entrada, sendo o número de casos os seguintes:

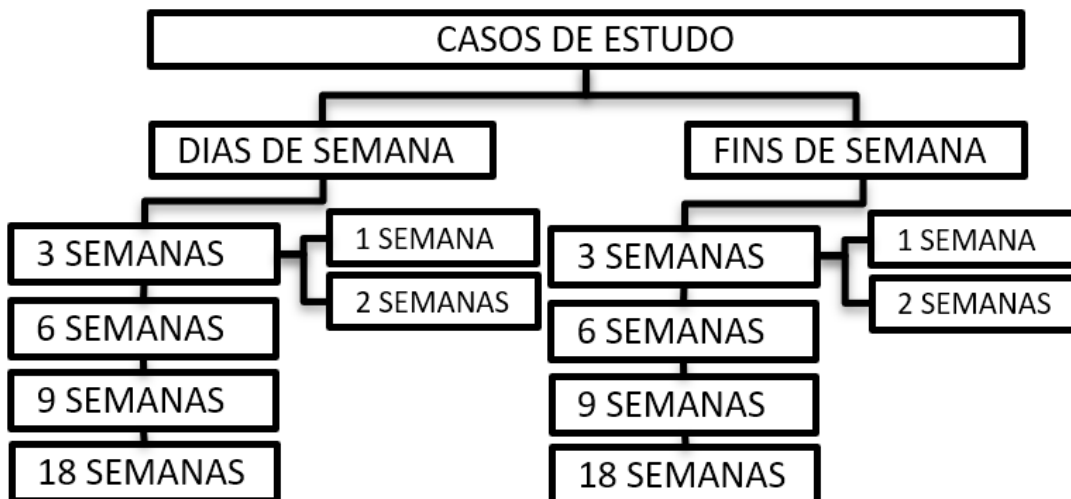


Figura 4.1 – Casos de Estudo

O objetivo destes modelos será a previsão do consumo de eletricidade num dia da semana e fim de semana, verificando o seu erro e métodos de melhoria da RNA.

4.4 Redes utilizadas

As RNA que serão utilizadas na previsão dos casos de estudo selecionados têm uma base estrutural idêntica. Diferenciando-se consoante o caso de estudo, em caso de se estar a estudar um dia da semana ou um fim de semana, e do número de neurónios utilizados nas camadas escondidas, consoante a dimensão do vetor de entrada.

Para a construção da RNA foi utilizado editor do Matlab, em vez da Toolbox do Matlab.

Em seguida, um exemplo do código para um dos casos de estudo com a explicação à frente de cada linha:

Tabela 4.3 – Programa Matlab com comentários

Código do Programa	Comentários
Clc;	Limpar dados remanescentes de programas anteriores
Clear;	
<i>%Dados de entrada/saída</i>	
load teste3semanasentrada.txt;	Dados com informação da data para Treino
load teste3semanassaida.txt;	Dados de Potência para Treino
load teste24h14052008.txt;	Dados de com informação do dia e potência do dia a prever
p=teste3semanasentrada(1:360,1:3);	Matriz de Entrada (Inf. Da data) - Treino
T=teste3semanassaida(1:360,1);	Vector de Saída (Inf. De Potência) - Treino
a=teste24h14052008(1:24,1:3);	Vector Objetivo Entrada – Teste
s=teste24h14052008(1:24,4);	Vector Objetivo Saída – Teste Servirá para comparar com o fornecido pela RNA.

<pre>%Dispersão do conjunto de treino figure(1); hold on; tempo=teste3semanasentrada(1:360,2); dados=teste3semanassaida(1:360,1); plot(tempo,dados,'+'); title('Conjunto de dados para o treino');</pre>	<p>Desenha um gráfico com a dispersão dos dados de treino.</p> 
<pre>%Conversão em [-1,1] [pn,ps]=mapminmax(p'); [tn,ts]=mapminmax(T'); [an]=mapminmax(a'); [sn]=mapminmax(s');</pre>	<p>Parametrização dos valores das Matrizes entre -1 e +1.</p>
<pre>%Parâmetros da RNA show=1000; lr=0.1; epochs=1000; goal=0.001; L_1=30; L_2=15; L_3=5; L_4=1; mc=0.2; min_grad=5e-10;</pre>	<p>Parâmetros de treino</p> <p>Taxa de amostragem da progressão do treino</p> <p>Taxa de aprendizagem</p> <p>Número de iterações</p> <p>Erro máximo</p> <p>Nº de neurónios da 1ª camada escondida</p> <p>Nº de neurónios da 2ª camada escondida</p> <p>Nº de neurónios da 3ª camada escondida</p> <p>Neurónios na camada de saída</p> <p>Taxa de Momento</p> <p>Gradiente mínimo e o passo mínimo</p>
<pre>%Criação da RNA net=newff(minmax(pn),[L_1 L_2 L_3 L_4],{'tansig','tansig','tansig','pure lin'},'traingdx');</pre>	<p>Criação da rede</p> <p>Introdução do nº de camadas referidas acima e definição das funções transferências.</p>
<pre>%Parâmetros net.trainParam.show=show; net.trainParam.epochs=epochs; net.trainParam.goal=goal; net.trainParam.lr=lr; net.trainParam.mc=mc; net.trainParam.min_grad=min_grad;</pre>	<p>Introdução dos parâmetros anteriormente definidos.</p>
<pre>%Treino da RNA net=train(net,pn,tn);</pre>	<p>Treino da RNA</p> <p>Pn, Tn – Matrizes de Treino</p>
<pre>%Teste da RNA yn=sim(net,an);</pre>	<p>Teste da RNA</p>
<pre>%Normalização dos valores resultantes yt = mapminmax('reverse',yn,ts); y=yt.'</pre>	<p>Voltar a converter os valores de -1 e +1 para os valores Potência habituais</p> <p>Transposição do vector de saída</p>
<pre>figure(2); plot(an,y,'g',an,s,'b*'); title('Rede neuronal');</pre>	
<pre>%Gráfico comparativo Real vs Teórico plot(y,'r');</pre>	<p>Gráfico comparativo do valor de Potência Real vs Potência Teórico</p>

Hold;	
plot(s);	
%%%VERIFICAÇÃO-%%%	
%Calcular o erro médio quadrático (RMSE)	
d=[s-y].^2;	Quadrado da diferença do valor teórico com o valor calculado
[r c]=size(d);	Descobrir o número de linhas ou de colunas do vector D
RMSE=sqrt(sum(d)/r);	Cálculo do Erro Médio Quadrático
%Calcular o erro médio percentual absoluto (MAPE)	
MAPE=(1/r)*sum(sum(abs((s-y)/s)))*100;	Cálculo do Erro Médio Percentual Absoluto
%Calcular o Erro Absoluto	
ErroAbsoluto=sum(abs([s-y]))/r;	Cálculo do Erro Absoluto
%Calcular o Erro Máximo	
ErroMaximo=max(abs([s-y]));	Cálculo do Erro Máximo
%Visualização	Visualização dos valores dos Erros no Programa
display(Erro Absoluto);	
display(RMSE);	
display(Erro Máximo);	
display(MAPE);	

O código observado é um código genérico tendo de ser adaptado para cada um dos casos de estudo, caso se trate de Dias de Semana ou Fins de Semana, depois consoante o número de entradas que se fornece à RNA, caso sejam, 3 semanas, 6 semanas, 9 semanas ou 18 semanas de dados de entrada.

4.4.1 Dias de semana

Conforme informado no ponto anterior, agora será observado para cada caso de estudo as diferenças na parametrização da RNA para que se conseguisse o melhor resultado possível. No caso específico dos dias de semana para se encontrar o número de dados de entrada que serão utilizados em cada programa é necessário multiplicar o número de dias da semana (cinco dias) pelo número de semanas dos casos de estudo, sendo eles de 3, 6, 9 e 18 semanas.

$$\text{Dados de Entrada} = n^{\circ} \text{ dias da sem.} \times n^{\circ} \text{ de sem. no caso de estudo} \quad (4.2)$$

Em seguida virá uma descrição dos parâmetros que são diferentes na constituição de cada uma das RNA, sendo que para cada caso, consoante a variação do número de dados de entrada de cada rede é necessário ajustar a constituição das RNAs.

4.4.1.1 3 Semanas

No caso das 3 semanas de dados de entrada foram utilizadas 1000 épocas, com 30 neurónios na primeira camada escondida, 15 neurónios na segunda camada escondida e 5 neurónios na terceira camada escondida.

4.4.1.2 6 Semanas

No caso das 6 semanas de dados de entrada foram utilizadas 700 épocas, com 60 neurónios na primeira camada escondida, 25 neurónios na segunda camada escondida e 10 neurónios na terceira camada escondida.

4.4.1.3 9 Semanas

No caso das 9 semanas de dados de entrada foram utilizadas 500 épocas, com 300 neurónios na primeira camada escondida, 80 neurónios na segunda camada escondida e 20 neurónios na terceira camada escondida.

4.4.1.4 18 Semanas

No caso das 18 semanas de dados de entrada foram utilizadas 1000 épocas, com 40 neurónios na primeira camada escondida, 20 neurónios na segunda camada escondida e 5 neurónios na terceira camada escondida.

4.4.2 Fins de semana

No caso específico dos fins de semana para se encontrar o número de dados de entrada que serão utilizados em cada programa é necessário multiplicar o número de dias do fim de semana (dois dias) pelo número de semanas dos casos de estudo, sendo eles de 3, 6, 9 e 18 semanas.

4.4.2.1 3 Semanas

No caso das 3 semanas de dados de entrada foram utilizadas 1000 épocas, com 25 neurónios na primeira camada escondida, 15 neurónios na segunda camada escondida e 5 neurónios na terceira camada escondida.

4.4.2.2 6 Semanas

No caso das 6 semanas de dados de entrada foram utilizadas 700 épocas, com 50 neurónios na primeira camada escondida, 30 neurónios na segunda camada escondida e 10 neurónios na terceira camada escondida.

4.4.2.3 9 Semanas

No caso das 9 semanas de dados de entrada foram utilizadas 500 épocas, com 75 neurónios na primeira camada escondida, 45 neurónios na segunda camada escondida e 10 neurónios na terceira camada escondida.

4.4.2.4 18 Semanas

No caso das 18 semanas de dados de entrada foram utilizadas 1000 épocas, com 240 neurónios na primeira camada escondida, 120 neurónios na segunda camada escondida e 10 neurónios na terceira camada escondida.

4.5 Medidas de Erro de Previsão

Para a análise das várias RNA estudadas utilizou-se várias medidas de erro, erro máximo, erro médio absoluto, erro médio quadrático e erro médio absoluto em percentagem. Sendo que o objetivo seria encontrar qual das soluções produzirá um erro mais próximo de zero [8].

4.5.1 Erro de Previsão

O erro de previsão é a diferença entre o valor observado e o valor da previsão no mesmo instante t , descrito pela equação (4.3):

$$\varepsilon_t = X_t - \hat{X}_t \quad (4.3)$$

4.5.2 Erro Máximo

O erro máximo de previsão é o máximo valor entre a diferença do valor observado e o valor da previsão dos vários instantes t , descrito pela equação (4.4):

$$EMax = \text{Máx} \left(\sum_{t=1}^n |\varepsilon_t| \right) \quad (4.4)$$

O erro máximo será utilizado para a obtenção dos melhores modelos para que seja possível analisar o maior desvio de cada uma das RNA estudadas e assim comparar redes com um MAPE similar, mas com desvios máximos diferentes.

4.5.3 Erro Médio

O erro médio é o valor médio de todos os erros encontrados, sendo que esses valores podem ser positivos ou negativos, porém o critério de avaliação é o de que quanto mais próximo do valor zero, melhor será o método escolhido. O erro médio obtém-se pela seguinte equação (4.5):

$$ME = \frac{1}{n} \sum_{t=1}^n \varepsilon_t \quad (4.5)$$

4.5.4 Erro Médio Absoluto

O erro médio absoluto é semelhante ao erro médio, mas em valor absoluto. O seu cálculo obedece à expressão (4.6):

$$MAE = \frac{1}{n} \sum_{t=1}^n |\varepsilon_t| \quad (4.6)$$

4.5.5 Erro Médio Quadrático

O erro médio quadrático é a soma dos quadrados dos desvios, dividida pelo número de observações, este tipo de erro enfatiza os erros de maior valor. O seu cálculo obedece à equação (4.7):

$$MSE = \frac{1}{n} \sum_{t=1}^n \varepsilon_t^2 \quad (4.7)$$

O modelo do Matlab utilizará na simulação o MSE para verificar a performance da RNA gerada no momento da simulação.

4.5.6 Erro Médio Absoluto em Percentagem

O erro percentual médio absoluto é um indicador que verifica a relação entre o valor observado e o valor de previsão. Avalia-se que quanto mais próximo de zero, mais adequado será o método de previsão. O seu cálculo obedece à equação (4.8):

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{\varepsilon_t}{X_t} \times 100 \right| \quad (4.8)$$

O erro médio absoluto será utilizado como parâmetro principal na comparação das várias tipologias de RNA para selecionar o mais eficaz na previsão do consumo de eletricidade. Este parâmetro é um dos mais utilizados para estabelecer comparações entre os diferentes modelos de previsão.

Capítulo 5

Seleção da RNA

Neste capítulo são apresentados os diversos casos de estudo. Será apresentado o modo de seleção da rede e os vários resultados dos casos de estudo.

5 Casos de Estudo

Uma vez escrito o código da constituição da RNA, analisar-se-á para cada tipo de VE qual será a melhor tipologia da RNA.

Essa análise será realizada alterando-se o número de neurónios das várias camadas e o número de iterações. Os parâmetros de treino, parâmetros de aprendizagem e verificadores de performance serão utilizados os modelos standard do Matlab.

Para validação e seleção da RNA é analisado o erro absoluto, erro médio quadrático, erro máximo, erro percentual médio absoluto e o tempo computacional para cada análise.

Com a seleção da tipologia da RNA realizar-se-ão dez testes para ver a sua eficácia e verificar-se-á a média dos resultados e qual dos casos são eficazes na previsão.

5.1 Dias de Semana

Nos dias de semana serão utilizados dados desde as 18 semanas atrás até às 3 semanas anteriores a data que se irá prever.

O dia a prever será o dia 14/05/2008 (Quarta-feira).

Os vetores de entrada são os seguintes:

- 3 semanas - 21/04/2008 a 09/05/2008;
- 6 semanas - 31/03/2008 a 09/05/2008;
- 9 semanas - 10/03/2008 a 09/05/2008;
- 18 semanas - 07/01/2008 a 09/05/2008.

5.1.1 3 Semanas

5.1.1.1 Melhor tipologia de RNA

A tipologia de RNA com melhor resultado para o VE com 3 semanas, desde 21/04/2008 a 09/05/2008, é a seguinte:

- L1 – 30 neurónios;
- L2 - 15 neurónios;
- L3 - 5 neurónios;
- Epochs – 1000.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.1 - Testes com a RNA escolhida – 3 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	87,09	89,31	125,46	85,40	110,58	94,45	103,99	92,75	87,09	94,00	97,01
Erro Médio Quadrático	108,07	118,66	194,14	11,56	174,44	122,30	129,07	110,02	108,07	116,85	119,32
Erro máximo	245,20	258,59	714,44	248,90	632,65	239,43	228,63	236,44	245,20	234,00	328,35
Erro Percentual Médio Absoluto	1,27	1,30	1,83	1,24	1,61	1,37	1,51	1,35	1,27	1,37	1,41

Na tabela 5.1 no teste 4, a verde, é apresentado o teste realizado com um menor valor MAPE e a vermelho, teste 3, o teste realizado com o valor de MAPE superior. Na Figura 5.1 apresenta-se a comparação entre o teste 4, o de melhor resultado de potência prevista com a potência real verificada.




Figura 5.1 – Comparação Potência Real com o previsto RNA – 3 semanas (Dias úteis)

Na Figura 5.2 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático foi da ordem de 10^{-2} .




Figura 5.2 – Performance – 3 semanas (Dias úteis)




Figura 5.3 – Regression – 3 semanas (Dias úteis)

Na Figura 5.3 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Uma boa correspondência

como a representada indica que o modelo é capaz de generalizar e efetuar previsões precisas em novos dados que não foram inseridos durante o treino.

5.1.1.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.2 - Testes para a construção da RNA – 3 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	30	200	700	30	200	700	30	200	700	30	282
L2	15	75	350	15	75	350	15	75	350	15	133,5
L3	5	25	100	5	25	100	5	25	100	5	39,5
Epochs	1000	1000	1000	500	500	500	250	250	250	2000	725
Erro Absoluto	87,09	95,59	89,11	128,84	97,59	91,25	162,80	96,13	101,11	105,16	105,47
Erro Médio Quadrático	108,07	115,09	105,50	163,99	125,57	127,33	200,86	121,57	136,54	137,68	134,22
Erro máximo	245,20	225,24	220,70	394,09	247,99	351,86	500,17	294,55	338,19	297,42	311,54
Erro Percentual Médio Absoluto	1,27	1,39	1,30	1,87	1,42	1,33	2,37	1,40	1,47	1,53	1,53
TEMPO DE COMPUTAÇÃO	00:20	00:50	05:59	00:10	00:25	02:58	00:05	00:12	01:23	00:35	

5.1.2 6 Semanas

5.1.2.1 Melhor tipologia de RNA

A tipologia de RNA com melhor resultado para o VE com 6 semanas, desde 31/03/2008 a 09/05/2008, é a seguinte:

- L1 – 60 neurónios;
- L2 - 25 neurónios;
- L3 - 10 neurónios;
- Epochs – 700.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.3- Testes com a RNA escolhida – 6 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	266,24	193,72	215,56	240,02	243,72	203,59	216,84	204,36	203,95	202,57	219,06
Erro Médio Quadrático	306,85	277,85	306,39	316,59	335,73	294,12	290,94	304,65	274,64	287,68	299,55
Erro máximo	831,43	871,46	1058,00	1021,30	1021,60	1036,40	795,73	1049,80	878,86	955,99	952,06
Erro Percentual Médio Absoluto	3,29	2,82	3,14	3,49	3,55	2,96	3,16	2,97	2,97	2,95	3,13

Na tabela 5.3 no teste 2, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 5, o teste realizado com o valor de MAPE superior. Na Figura 5.4 apresenta-se a comparação entre o teste 2, o de melhor resultado de potência prevista com a potência real efetivamente verificada.




Figura 5.4 – Comparação Potência Real com o previsto RNA – 6 semanas (Dias úteis)

Na Figura 5.5 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático foi da ordem de 10^{-2} .

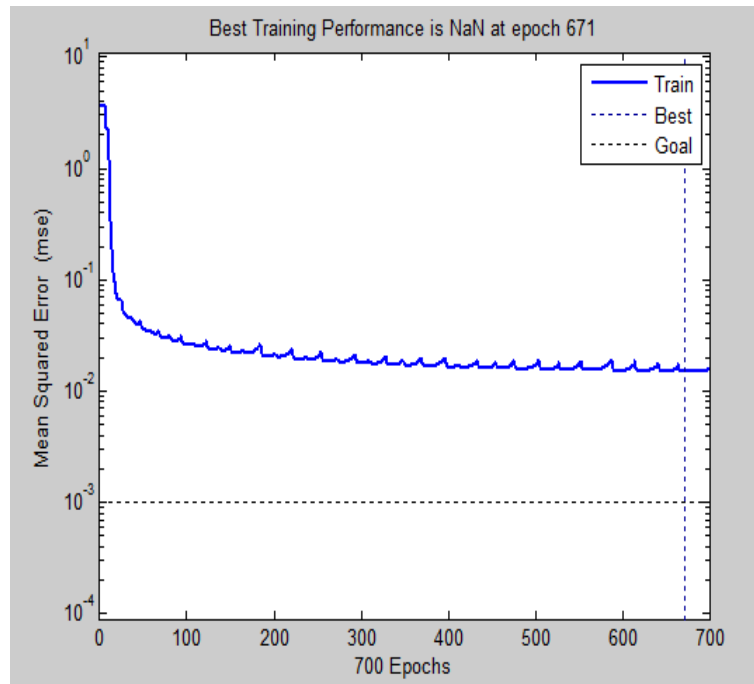


Figura 5.5 – Performance – 6 semanas (Dias úteis)

Na Figura 5.6 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Uma boa correspondência como a representada indica que o modelo é capaz de generalizar e efetuar previsões precisas em novos dados que não foram inseridos durante o treino.




Figura 5.6 – Regression – 6 semanas (Dias úteis)

5.1.2.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.4- Testes para a construção da RNA – 6 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	60	30	120	240	60	30	120	240	60	50	101
L2	25	15	50	100	25	15	50	100	25	20	42,5
L3	10	5	20	35	10	5	20	35	10	8	15,8
Epochs	700	700	700	700	350	350	350	350	1200	700	610
Erro Absoluto	193,72	218,73	226,59	244,74	211,99	275,25	260,39	275,83	199,47	224,27	233,10
Erro Médio Quadrático	277,85	269,92	272,81	300,15	264,18	354,95	318,44	354,82	267,84	290,63	297,16
Erro máximo	871,46	742,78	571,84	856,05	617,30	964,89	668,53	684,35	805,53	846,76	762,95
Erro Percentual Médio Absoluto	2,82	3,18	3,30	3,56	3,08	4,00	3,79	4,01	2,90	3,26	3,39
TEMPO DE COMPUTAÇÃO	00:21	00:16	00:45	01:24	00:12	00:09	00:26	00:55	00:51	00:23	

5.1.3 9 Semanas

5.1.3.1 Melhor tipologia de RNA

A tipologia de RNA com melhor resultado para o VE com 9 semanas, desde 10/03/2008 a 09/05/2008, é a seguinte:

- L1 – 300 neurónios;
- L2 - 80 neurónios;
- L3 - 20 neurónios;
- Epochs – 500.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.5- Testes com a RNA escolhida – 9 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	197,58	182,18	193,16	202,82	200,45	216,79	310,91	339,44	227,42	205,57	227,63
Erro Médio Quadrático	258,29	245,56	264,53	269,05	265,25	272,94	357,63	450,46	298,50	287,92	297,01
Erro máximo	607,27	654,31	650,37	678,32	709,23	621,82	637,16	1102,00	658,62	705,07	702,42
Erro Percentual Médio Absoluto	2,87	2,65	2,81	2,95	2,92	3,15	4,52	4,94	3,31	2,99	3,31

Na tabela 5.5 no teste 2, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 8, o teste realizado com o valor de MAPE superior. Na Figura 5.7 apresenta-se a comparação entre o teste 2, com o melhor resultado de potência prevista com a potência real.




Figura 5.7 – Comparação Potência Real com o previsto RNA – 9 semanas (Dias úteis)

Na Figura 5.8 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático foi da ordem de 10^{-2} .




Figura 5.8 – Performance – 9 semanas (Dias úteis)

Na Figura 5.9 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Uma boa correspondência como a representada indica que o modelo é capaz de generalizar e efetuar previsões precisas em novos dados que não foram inseridos durante o treino.




Figura 5.9 – Regression – 3 semanas (Dias úteis)

5.1.3.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.6- Testes para a construção da RNA – 9 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	300	150	400	600	300	150	400	600	230	230	336
L2	80	40	60	100	80	40	60	100	65	85	71
L3	20	10	25	40	20	10	25	40	15	18	22,3
Epochs	500	500	500	500	750	750	750	750	500	500	600
Erro Absoluto	182,18	189,47	199,11	191,97	181,46	206,29	186,07	207,14	196,31	331,29	207,13
Erro Médio Quadrático	245,56	250,89	262,02	258,35	242,13	283,95	260,72	261,47	262,36	373,29	270,07
Erro máximo	654,31	560,02	612,59	600,25	588,38	807,51	695,67	672,46	615,52	769,96	657,67
Erro Percentual Médio Absoluto	2,65	2,76	2,90	2,79	2,64	3,00	2,71	3,01	2,86	4,82	3,01
TEMPO DE COMPUTAÇÃO	01:27	00:44	01:41	02:37	02:18	01:17	02:32	04:04	01:25	01:35	

5.1.4 18 Semanas

5.1.4.1 Melhor tipologia de RNA

A tipologia de RNA para o VE com 18 semanas, desde 07/01/2008 a 09/05/2008, é a seguinte:

- L1 – 40 neurónios;
- L2 - 20 neurónios;
- L3 - 5 neurónios;
- Epochs – 1000.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.7- Testes com a RNA escolhida – 18 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	745,63	329,30	799,92	1189,10	1490,70	455,64	1143,60	1255,40	432,22	813,94	865,54
Erro Médio Quadrático	950,70	483,58	993,32	1302,00	1659,00	685,65	1332,50	1959,00	499,06	958,26	1082,31
Erro máximo	1874,80	1200,30	2021,70	1898,70	2960,50	1763,20	2259,90	3964,30	975,80	1774,10	2069,33
Erro Percentual Médio Absoluto	10,85	4,79	11,65	17,30	21,69	6,63	16,64	18,27	7,60	11,84	12,73

Na tabela 5.7 no teste 2, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 5, o teste realizado com o valor de MAPE superior. Na Figura 5.10 apresenta-se a comparação entre o teste 2, com o melhor resultado de potência prevista com a potência real efetivamente verificada.




Figura 5.10 – Comparação Potência Real com o previsto RNA – 18 semanas (Dias úteis)

Na Figura 5.11 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático ligeiramente superior a 10^{-2} .




Figura 5.11 – Performance – 18 semanas (Dias úteis)

Na Figura 5.12 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Verifica-se uma boa correspondência e capacidade de produzir boas previsões.




Figura 5.12 – Regression – 18 semanas (Dias úteis)

5.1.4.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.8- Testes para a construção da RNA – 18 Semanas (Dias úteis)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	40	80	120	600	40	40	80	120	600	1200	292
L2	20	40	60	100	20	20	40	60	100	620	108
L3	5	10	15	40	5	5	10	15	40	35	18
Epochs	1000	1200	1200	1200	1200	2500	2500	2500	2500	1200	1700
Erro Absoluto	329,30	1890,80	2372,40	1948,60	752,65	807,32	1266,10	852,16	2158,00	3,12E+07	3,12E+06
Erro Médio Quadrático	483,58	2253,10	2765,60	2138,20	963,92	1176,80	1492,00	1033,10	2432,80	3,87E+07	3,87E+06
Erro máximo	1200,30	3482,40	4484,00	3605,10	1918,10	2743,30	2906,40	1948,10	4202,90	7,23E+07	7,23E+06
Erro Percentual Médio Absoluto	4,79	27,51	34,52	28,35	10,95	11,75	18,42	12,40	31,40	4,54E+05	4,55E+04
TEMPO DE COMPUTAÇÃO	07:22	02:02	02:59	12:23	01:13	01:48	04:03	06:35	00:26:51	01:02:00	

5.2 Fins de Semana

Nos fins de semana serão utilizados dados desde as 18 semanas atrás até às 3 semanas anteriores a data que se irá prever.

O dia a prever será o dia 18/05/2008 (Domingo).

Os vetores de entrada são os seguintes:

- 3 semanas - 26/04/2008 a 11/05/2008;
- 6 semanas - 05/04/2008 a 11/05/2008;
- 9 semanas - 15/03/2008 a 11/05/2008;
- 18 semanas - 12/01/2008 a 11/05/2008.

5.2.1 3 Semanas

5.2.1.1 Melhor tipologia de RNA

A tipologia de RNA com melhor resultado para o VE com 3 semanas, desde 26/04/2008 a 11/05/2008, é a seguinte:

- L1 – 25 neurónios;
- L2 - 15 neurónios;
- L3 - 5 neurónios;
- Epochs – 1000.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.9- Testes com a RNA escolhida – 3 Semanas (Fim de semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	165,76	176,10	108,36	136,66	129,00	150,34	160,60	175,54	169,10	125,05	149,65
Erro Médio Quadrático	203,36	214,58	125,41	161,29	154,08	170,40	203,91	224,22	221,78	146,11	182,51
Erro máximo	453,56	542,79	292,46	313,83	342,84	369,74	476,83	509,11	657,86	295,54	425,45
Erro Percentual Médio Absoluto	2,91	3,10	1,91	2,40	2,27	2,64	2,82	3,09	2,97	2,20	2,63

Na tabela 5.9 no teste 3, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 2, o teste realizado com o valor de MAPE superior. Na Figura 5.13 apresenta-se a comparação entre o teste 3, com o melhor resultado de potência prevista com a potência real efetivamente verificada.




Figura 5.13 – Comparação Potência Real com o previsto RNA – 3 semanas (Fim de Semana)

Na Figura 5.14 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático da ordem de 10^{-1} . Na Figura 5.15 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T), onde se verifica uma razoável correspondência.




Figura 5.14 – Performance – 3 semanas (Fim de Semana)




Figura 5.15 – Regression – 3 semanas (Fim de Semana)

5.2.1.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.10- Testes para a construção da RNA – 3 Semanas (Fim de semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	25	50	75	25	50	75	25	50	75	15	46,5
L2	15	30	40	15	30	40	15	30	40	7	26,2
L3	5	10	12	5	10	12	5	10	12	2	8,3
Epochs	1000	1000	1000	500	500	500	1500	1500	1500	1000	1000
Erro Absoluto	107,77	112,02	116,36	123,53	114,29	135,18	109,05	137,27	121,84	162,50	123,98
Erro Médio Quadrático	118,69	126,85	128,58	139,57	145,55	169,00	120,78	160,63	134,78	189,31	143,38
Erro máximo	195,12	222,99	224,92	283,29	454,67	399,89	206,76	361,31	213,61	567,52	313,01
Erro Percentual Médio Absoluto	1,90	1,97	2,05	2,17	2,01	2,38	1,92	2,41	2,14	2,86	2,18
TEMPO DE COMPUTAÇÃO	00:14	00:17	00:19	00:08	00:09	00:12	00:19	00:19	00:22	00:21	

5.2.2 6 Semanas

5.2.2.1 Melhor tipologia de RNA

A tipologia de RNA para o VE com 6 semanas, desde 05/04/2008 a 11/05/2008, é a seguinte:

- L1 – 50 neurónios;
- L2 - 30 neurónios;
- L3 - 10 neurónios;
- Epochs – 700.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.11- Testes com a RNA escolhida – 6 Semanas (Fim de semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	199,37	201,73	204,88	226,28	193,64	197,03	226,56	220,57	222,89	238,39	213,13
Erro Médio Quadrático	239,45	234,72	235,23	256,85	230,27	229,75	259,02	257,20	254,49	262,28	245,92
Erro máximo	461,31	493,26	483,46	481,84	448,70	460,48	474,03	519,57	458,30	490,67	477,16
Erro Percentual Médio Absoluto	3,51	3,55	3,60	3,98	3,40	3,46	3,98	3,88	3,92	4,19	3,75

Na tabela 5.11 no teste 5, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 10, o teste realizado com o valor de MAPE superior. Na Figura 5.16 apresenta-se a comparação entre o teste 5, com o melhor resultado de potência prevista com a potência real efetivamente verificada.




Figura 5.16 – Comparação Potência Real com o previsto RNA – 6 semanas (Fim de Semana)

Na Figura 5.17 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático da ordem de 10^{-1} . Na Figura 5.18 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Uma boa correspondência como a representada indica que o modelo é capaz de generalizar e efetuar previsões razoáveis em novos dados que não foram inseridos durante o treino da rede.




Figura 5.17 – Performance – 6 semanas (Fim de Semana)




Figura 5.18 – Regression – 6 semanas (Fim de Semana)

5.2.2.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.12- Testes para a construção da RNA – 6 Semanas (Fim-de-semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	50	30	90	120	50	30	90	120	50	30	66
L2	30	15	45	65	30	15	45	65	30	15	35,5
L3	10	5	8	18	10	5	8	18	10	5	9,7
Epochs	700	700	700	700	1250	1250	1250	1250	350	350	850
Erro Absoluto	193,64	221,40	202,50	198,56	200,79	224,90	218,71	201,53	244,52	207,98	211,45
Erro Médio Quadrático	230,27	259,18	241,12	232,22	233,50	255,58	250,47	233,00	275,81	234,90	244,61
Erro máximo	448,70	529,96	456,76	433,76	469,50	470,04	513,88	488,56	562,64	405,00	477,88
Erro Percentual Médio Absoluto	3,40	3,89	3,56	3,49	3,53	3,95	3,85	3,54	4,30	3,66	3,72
TEMPO DE COMPUTAÇÃO	00:12	00:11	00:13	00:14	00:17	00:16	00:21	00:25	00:08	00:08	

5.2.3 9 Semanas

5.2.3.1 Melhor tipologia de RNA

A tipologia de RNA com melhor resultado para o VE com 9 semanas, desde 15/03/2008 a 11/05/2008, é a seguinte:

- L1 – 75 neurónios;
- L2 - 45 neurónios;
- L3 - 10 neurónios;
- Epochs – 500.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.13- Testes com a RNA escolhida – 9 Semanas (Fim-de-semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	321,36	323,53	303,15	271,06	313,36	305,38	296,35	296,07	296,91	311,81	303,90
Erro Médio Quadrático	364,78	385,76	346,43	231,49	360,85	341,62	333,20	340,24	337,20	353,10	339,47
Erro máximo	632,96	731,29	601,76	633,00	685,97	553,77	624,90	610,46	550,06	600,04	622,42
Erro Percentual Médio Absoluto	5,41	5,44	5,10	4,56	5,27	5,14	4,99	4,98	5,00	5,25	5,11

Na tabela 5.13 no teste 4, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 2, o teste realizado com o valor de MAPE superior. Na Figura 5.19 apresenta-se a comparação entre o teste 4, com o melhor resultado de potência prevista com a potência real efetivamente verificada.




Figura 5.19 – Comparação Potência Real com o previsto RNA – 9 semanas (Fim de Semana)

Na Figura 5.20 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático da ordem de 10^{-1} . Na Figura 5.21 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Uma boa correspondência como a representada indica que o modelo é capaz de generalizar e efetuar previsões de razoável qualidade.




Figura 5.20 – Performance – 9 semanas (Fim de Semana)




Figura 5.21 – Regression – 3 semanas (Fim de Semana)

5.2.3.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.14- Testes para a construção da RNA – 9 Semanas (Fim de semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	75	125	50	175	75	125	50	75	125	50	92,5
L2	45	67	30	86	45	67	30	45	67	30	51,2
L3	10	15	7	22	10	15	7	10	15	7	11,8
Epochs	500	500	500	500	1000	1000	1000	250	250	250	575
Erro Absoluto	271,06	312,07	328,93	312,01	292,55	299,86	289,73	307,20	344,60	289,53	304,75
Erro Médio Quadrático	231,49	378,72	365,46	349,85	330,15	336,10	345,13	376,96	410,65	335,18	345,97
Erro máximo	633,00	753,64	599,12	579,72	553,06	568,00	647,60	779,76	1007,00	656,64	677,75
Erro Percentual Médio Absoluto	4,56	5,25	5,53	5,25	4,92	5,05	4,87	5,17	5,80	4,87	5,13
TEMPO DE COMPUTAÇÃO	00:11	06:38	04:45	02:03	05:17	07:16	05:43	02:15	01:06	02:16	

5.2.4 18 Semanas

5.2.4.1 Melhor tipologia de RNA

A tipologia de RNA com melhor resultado para o VE com 18 semanas, desde 12/01/2008 a 11/05/2008, é a seguinte:

- L1 – 240 neurónios;
- L2 - 120 neurónios;
- L3 - 10 neurónios;
- Epochs – 1000.

Selecionada a RNA realizaram-se 10 testes para verificar a sua eficácia. Na tabela seguinte encontram-se os vários testes realizados.

Tabela 5.15- Testes com a RNA escolhida – 18 Semanas (Fim de semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
Erro Absoluto	706,70	611,14	956,20	1914,40	1178,20	871,92	522,71	1068,20	1683,20	432,22	994,49
Erro Médio Quadrático	926,21	677,61	1128,70	2235,20	1280,80	1043,70	623,19	1269,80	1748,10	499,06	1143,24
Erro máximo	1933,90	915,19	1909,10	3610,20	2142,40	1960,60	1410,40	2300,50	2294,20	975,80	1945,23
Erro Percentual Médio Absoluto	12,43	10,75	16,81	33,66	20,72	15,33	9,19	18,78	29,60	7,60	17,49

Na tabela 5.15 no teste 10, a verde, encontra-se o teste realizado com um menor valor MAPE e a vermelho, teste 4, o teste realizado com o valor de MAPE superior. Na Figura 5.19 apresenta-se a comparação entre o teste 10, com o melhor resultado de potência prevista com a potência real efetivamente verificada.




Figura 5.22 – Comparação Potência Real com o previsto RNA – 18 semanas (Fim de Semana)

Na Figura 5.23 observa-se o gráfico da performance onde é possível verificar que o erro médio quadrático da ordem de 10^{-1} . Na Figura 5.24 observa-se o gráfico da regressão onde é indicado o $Y=T$ que é a relação entre as saídas previstas (Y) pela RNA e as saídas reais (T). Fraca correspondência como a representada indica que o modelo embora generalizando as previsões efetuadas são de fraca qualidade.




Figura 5.23 – Performance – 18 semanas (Fim de Semana)




Figura 5.24 – Regression – 3 semanas (Fim de Semana)

5.2.4.2 Processo de construção da RNA

Para a construção da RNA foram alterados vários parâmetros até que se obtivesse uma RNA com bons resultados.

Abaixo estão os vários parâmetros alterados e os resultados que foram obtidos.

Tabela 5.16- Testes para a construção da RNA – 18 Semanas (Fim-de-semana)

Performance	Número de Testes Realizados										Média
	1	2	3	4	5	6	7	8	9	10	
L1	240	350	120	240	350	120	240	350	120	240	237
L2	120	175	60	120	175	60	120	175	60	120	118,5
L3	10	10	10	10	10	10	10	10	10	10	10
Epochs	1000	1000	1000	500	500	500	250	250	250	2000	725
Erro Absoluto	432,22	778,99	411,47	573,54	555,34	1047,60	518,53	1480,20	654,60	731,83	718,43
Erro Médio Quadrático	499,06	946,80	466,57	711,42	676,35	1137,70	605,04	1590,80	782,09	810,38	822,62
Erro máximo	975,80	1973,90	770,17	1396,00	1307,80	1837,50	1387,50	2347,40	1499,40	1352,40	1484,79
Erro Percentual Médio Absoluto	7,60	13,70	7,24	10,08	9,76	18,42	9,12	26,03	11,51	12,87	12,63
TEMPO DE COMPUTAÇÃO	01:10	01:36	00:33	00:30	01:01	00:18	00:25	00:31	00:11	02:00	

5.3 Evolução do erro com alteração do número de Épocas

Neste ponto pretende-se verificar a evolução do erro médio quadrático de uma RNA do caso de estudo quando se alteram o número de Épocas de aprendizagem.

A RNA selecionada para fazer a análise do erro é a RNA com 6 semanas de dados de entrada para o caso de dias úteis da semana.

Para esta análise serão realizados 20 testes para entender a evolução da RNA.

Conforme o capítulo 5.1 a RNA selecionada tinha as seguintes características:

- L1 – 30 neurónios;
- L2 - 15 neurónios;
- L3 - 5 neurónios;
- Epochs – 1000.

Foram realizados testes com o seguinte número de Épocas:

- 50
- 100
- 200
- 700
- 800
- 900
- 1000
- 1100
- 1900
- 2000
- 2100
- 2200
- 2600
- 2700
- 5000
- 5500
- 6000
- 7000
- 9000
- 10000

Destes testes realizados foram apenas selecionados os mais significativos para se analisar a evolução do MAPE.

Tabela 5.17- Testes Realizados com várias Épocas

Nº de Épocas	Testes Realizados											
	50	100	200	700	800	1000	1100	1900	2200	2700	5500	9000
MAPE	2,78	3,33	1,78	1,42	1,39	1,38	1,45	1,37	1,49	1,36	1,46	1,41

Como se pode verificar na tabela anterior, com o aumento do número de épocas há uma diminuição do MAPE, sendo que ao fim de aumentar o número de épocas e passar o ponto ótimo o aumento do número de épocas já não implica uma melhoria na capacidade de previsão da RNA.

5.4 Comparação dos vários casos de Estudo

Em seguida se comparará os resultados dos vários casos de estudo, quer para a previsão dos dias de semana como de fim de semana, apresentados nos subcapítulos 5.1 e 5.2.

Analisando as várias situações será possível analisar a evolução da MAPE conforme se aumente o nº de dados de entrada para as diferentes RNA estudadas.

5.4.1 Dias de Semana

O seguinte gráfico compara os resultados da potência real do dia 14/05/2008 com as melhores previsões das diferentes RNA estudadas.




Figura 5.25 – Comparação vários resultados – Previsão de quarta-feira (Melhores resultados)

O seguinte gráfico compara os resultados da potência real do dia 14/05/2008 com as piores previsões das diferentes RNA estudadas.




Figura 5.26 – Comparação vários resultados – Previsão de quarta-feira (Piores resultados)

Comparação dos melhores e piores resultados para os diferentes casos:




Figura 5.27 – Comparação das MAPE nos diferentes casos verificados

Com a comparação dos diferentes valores é possível observar que o aumento de dados de entrada nas RNA não se traduz num aumento de eficácia nas previsões. Analisando os melhores resultados e, também, a menor diferença entre o pior e melhor cenário a RNA com 3 semanas de dados de entrada é a que produz melhores resultados.

5.4.2 Fim de Semana

O seguinte gráfico compara os resultados da potência real do dia 11/05/2008 com as melhores previsões das diferentes RNA estudadas.




Figura 5.28 – Comparação vários resultados – Previsão de Domingo (Melhores resultados)

O seguinte gráfico compara os resultados da potência real do dia 11/05/2008 com as piores previsões das diferentes RNA estudadas.




Figura 5.29 – Comparação vários resultados – Previsão de Domingo (Piores resultados)

Comparação dos melhores e piores resultados para os diferentes casos:




Figura 5.30 – Comparação das MAPE nos diferentes casos verificados

À semelhança do verificado no subcapítulo 5.4.1 os melhores resultados ocorrem com um menor número de dados de entrada. Os fins de semana apresentam piores eficácias na

previsão RNA o que se poderá dever à maior variabilidade e imprevisibilidade de cenários que ocorrem.

5.5 Melhor tipologia encontrada aplicada noutras previsões (2018)

Utilizando as características das RNA analisadas anteriormente em 5.1 e em 5.2, se utilizarão agora para prever o dia de semana correspondente ao ano de 2018, em vez de utilizar o ano 2008.

5.5.1 Dias de Semana 2018

Com 3 semanas e 6 semanas de dados de entrada, pretendeu-se prever o dia 16/05/2018, quarta-feira.

No seguinte gráfico compara-se os melhores e piores resultados utilizando 3 semanas de dados de entrada.




Figura 5.31 – Resultados com 3 semanas de dados, previsão dias de semana – Dados de entrada 2018

No seguinte gráfico compara-se os melhores e piores resultados utilizando 6 semanas de dados de entrada.




Figura 5.32 – Resultados com 6 semanas de dados, previsão dias de semana – Dados de entrada 2018

Analisando ambos cenários pode-se verificar que o aumento da quantidade de dados de entrada não implica uma melhoria na capacidade de previsão. É possível verificar que a RNA produz resultados semelhantes as previsões efetuadas com os dados de entrada de 2008. No gráfico abaixo compara-se o MAPE de ambos os cenários.




Figura 5.33 – Comparação MAPE – Dias de Semana

5.5.2 Fins de semana 2018

Com 3 semanas e 6 semanas de dados de entrada, pretendeu-se prever o dia 27/05/2018, domingo.

No seguinte gráfico compara-se os melhores e piores resultados utilizando 3 semanas de dados de entrada.




Figura 5.34 – Resultados com 3 semanas de dados, previsão fim de semana – Dados de entrada 2018

No seguinte gráfico compara-se os melhores e piores resultados utilizando 6 semanas de dados de entrada.




Figura 5.35 – Resultados com 6 semanas de dados, previsão fim de semana – Dados de entrada 2018

Analisando ambos cenários pode-se verificar que o aumento da quantidade de dados de entrada não implica uma melhoria na capacidade de previsão. É possível verificar que a RNA produz resultados semelhantes as previsões efetuadas com os dados de entrada de 2008. No gráfico abaixo compara-se a MAPE de ambos os cenários.




Figura 5.36 – Comparação MAPE – Fim de Semana

5.6 Utilizando menos dados de entrada

Neste subcapítulo se verificará a evolução da performance da RNA com a diminuição dos dados de entrada prevendo todas as semanas do ano.

Se analisará a RNA com melhor performance de todos os casos estudados anteriormente, que é a RNA com 3 semanas de dados de entrada, prevendo os dias de semana.

Realizaram-se simulações ao longo de todo o ano 2018 alterando o vetor de dados de entrada.

Em seguida, serão apresentados os dois casos verificados o primeiro com 2 semanas de dados de entrada e o segundo com 1 semana. Utilizaram-se ambas as RNS para prever todas as 4ª feiras do ano de 2018, desde a semana 4 até à semana 49.




Figura 5.37 – Resultados com 2 semanas de dados

O MAPE médio obtido para a previsão de todas as quartas-feiras do ano 2018 desde a semana 4 até à semana 49 foi de 3,213.

Melhor Resultado: MAPE (semana 20) = 0,65.

Pior Resultado: MAPE (semana 36) = 7,78.




Figura 5.38 – Resultados com 1 semanas de dados

O MAPE médio obtido para a previsão de todas as quartas-feiras do ano 2018 desde a semana 4 até à semana 49 foi de 2,91.

Melhor Resultado: MAPE (semana 4) = 0,49.

Pior Resultado: MAPE (semana 16) = 10,16.

Com esta análise pode-se verificar que diminuindo os dados de entrada continua-se a obter bons resultados na previsão do consumo de eletricidade. Sendo que não se conseguem resultados constantes ao longo do ano, mas em média conseguem bons resultados.

Capítulo 6

Conclusões

Neste Capítulo são apresentadas as principais conclusões acerca do trabalho realizado nos capítulos anteriores, bem como apresentadas as perspectivas de evolução do trabalho e hipóteses de trabalhos futuros.

6 Conclusões

Nesta dissertação o objetivo foi realizar um estudo em como se poderão utilizar as Redes Neurais Artificiais na previsão do consumo de eletricidade em Portugal. Iniciou-se com a explicação da construção de uma RNA no capítulo 2 e seguiu-se para a construção de várias tipologias de RNA no capítulo 4. Decidiu-se estudar o quanto influência o número de dados de entrada numa RNA na produção de bons resultados.

Para a elaboração do VE optou-se por selecionar apenas a estação do ano, hora e mês. Inicialmente foi estudada outras alternativas, tais como dias do ano, mas tais não revelaram significância na produção de bons resultados.

Na elaboração dos casos de estudo nesta dissertação decidiu-se dividir entre dias de semana e fins de semana, pela diferença que existe nas curvas de consumo de cada uma delas. Seguindo-se a análise de cada RNA diferenciadas pelo número de camadas escondidas, número de épocas e o número de dados de entrada. Estudaram-se os seguintes casos com: 3 semanas de dados, 6 semanas, 9 semanas e 18 semanas de dados de entrada.

Para a construção de cada RNA foram analisados os números de neurónios em cada camada escondida e o número de épocas em que se realizava a aprendizagem da rede e para cada uma delas foi selecionada a RNA que produzia melhores resultados com um tempo de computação mais baixo. Esta análise foi realizada por tentativa e erro, onde para cada cenário se realizavam 10 testes e daí foram selecionadas as RNA. De uma forma geral, procurou-se manter o número de neurónios da camada intermédia, adotando o valor geralmente usado, de metade no número de entradas do modelo.

Em seguida uma tabela resumo com as RNA com melhores resultados:

Tabela 6.1- Composição das RNA com melhores resultados

Dados de Entrada		3 semanas	6 semanas	9 semanas	18 semanas
Dia de Semana	L1	30	60	300	40
	L2	15	25	80	20
	L3	5	10	20	50
	Epochs	1000	700	500	100
Fim de Semana	L1	25	50	75	240
	L2	15	30	45	120
	L3	5	10	10	10
	Epochs	1000	700	500	1000

Dos 4 casos estudados verificou-se que o aumento de dados de entrada não produzia um aumento de qualidade de previsão, sendo que quanto mais baixo o número de dados de entrada melhores resultados produzia a RNA.

Em seguida decidiu-se aumentar significativamente o número de épocas para se verificar que resultados produzia na RNA e constatou-se que a após se ultrapassar o ponto ótimo de épocas a capacidade de produzir bons resultados diminui.

Após se analisar todas as RNA decidiu-se aplicar as RNA que tinham conseguido melhores resultados, que foram as RNA com 3 e 6 semanas de dados de entrada em ambos os cenários de fim de semana e dia de semana, a dados de entrada de outros anos e verificar os seus resultados. Para esse cenário as RNA com 3 semanas de dados produziram resultados de MAPE <5, tanto nos dias de semana com fim de semana.

Em seguida como se verificou que em todos os cenários as RNA com menos dados se produziam bons resultados, decidiu-se testar o ano inteiro com a opção de 1 semana e 2 semanas de dados de entrada.

Os resultados foram bons em média, mas em alguns dias o resultado obtido foi muito díspar em relação ao que se pretendia. Sendo que os resultados foram os seguintes:

Tabela 6.2- Resultados RNA com 1 e 2 semanas de dados de entrada

Dados de Entrada		1 semana	2 semanas
Dia de Semana	MAPE Média	2,91	3,21
	Melhor resultado	0,49	0,65
	Pior Resultado	10,16	7,78

Com este resultado consegue-se verificar que a ferramenta é útil e poderá ser aplicado na previsão do consumo de energia, apresenta melhores resultados com uma menor quantidade de dados de entrada, sendo que quanto mais próximos estão os dados de entrada da rede da data que se pretende prever melhores serão os resultados da previsão.

6.1 Desenvolvimentos futuros

Como desenvolvimento para trabalhos futuros podem identificar-se os seguintes pontos:

- Implementar outros fatores que possam ser relevantes no VE.
- Utilizar as RNA para a previsão de outros consumos, sem ser apenas o consumo elétrico.
- Criação de uma RNA para prever consumos anuais e daí conseguir extrapolar os consumos futuros para Portugal.
- Melhorar a RNA para conseguir melhorar todas as previsões que possam ser muito diferentes, como é o caso de feriados e situações anormais de um determinado dia.

Referências

Bibliográficas

Referências Bibliográficas

- [1] A. A. Flambó, “Métodos de Previsão,” *Revista Científica Academia Militar*, pp. 113-127, 2010.
- [2] B. L. Bowerman e R. T. O’Connell, *Forecasting and time series:an applied approach*, Wadsworth, 1993.
- [3] T. Y. Lin, “Estudo de modelos de previsão de demanda”.
- [4] F. d. O. Lemos, *Metodologia para seleção de métodos de previsão de demanda*, Porto Alegre, 2006.
- [5] P. Cortez, J. Machado e J. Neves, “An Evolutionary Artificial Neural Network Time Series Forecasting System,” *Artigo Científico*, p. 4, 1996.
- [6] REN, “Redes Energéticas Nacionais,” [Online]. Available: www.ren.pt. [Acedido em 15 01 2016].
- [7] H. L. Willis e W. G. Scott, *Distributes Power Generation*, Basel: Marcel Dekker, 2000.
- [8] M. Jacob, C. Neves e D. V. Greetham, “Short Term Load Forecasting,” pp. 15-37, 26 09 2019.
- [9] A. Vinicius. [Online]. Available: <https://medium.com/@avinicius.adorno/redes-neurais-artificiais-418a34ea1a39>. [Acedido em 01 12 2021].
- [10] J. Riley, “An Evolutionary Approach to Training Feed-Forward and Recurrent Neural Networks,” *Master*, 1996.
- [11] A. Zanini, “Regulação Econômica No Setor Elétrico Brasileiro: Uma Metodologia Para Definição De Fronteiras De Eficiência E Cálculo Do Fator X Para Empresas Distribuidoras De Energia Elétrica,” *Tese*, pp. 60-75, 09 08 2004.
- [12] E. Hristev, “NARX neural networks for sequence processing tasks,” *Master*, 2012.

