

Instituto Superior de Engenharia do Porto

Departamento de Engenharia Eletrotécnica

Mestrado em Engenharia Eletrotécnica – Sistemas Eléctricos de Energia

Previsão do Diagrama de Carga de Subestações da REN utilizando Redes Neurais

Dissertação de Mestrado

Silvana Mafalda de Silva Rocha

Orientador: Professora Doutora Maria Teresa do Valle Moura Costa

Co-orientador: Professor Manuel João Dias Gonçalves

Porto,

Outubro de 2015



Departamento de Engenharia Eletrotécnica

Mestrado em Engenharia Eletrotécnica – Sistemas Eléctricos de Energia

Documento elaborado para a Unidade Curricular de DSEE – Dissertação do Mestrado em
Engenharia Eletrotécnica – Sistemas Eléctricos de Energia

Candidato(a): Silvana Mafalda da Silva Rocha, N° 1131360, 1131360@isep.ipp.pt

Orientação: Professora Doutora Maria Teresa do Valle Moura Costa

Co-orientação: Professor Manuel João Dias Gonçalves

Outubro, 2015



Dedico este trabalho aos meus pais, irmão, avós e namorado
que sempre me apoiaram e deram forças
para nunca desistir dos meus
sonhos e objetivos...



Agradecimentos

À minha orientadora, Professora Doutora Maria Teresa do Valle Moura Costa, e ao meu co-orientador Professor Manuel João Dias Gonçalves, um sincero obrigada por todo o apoio, orientação e conhecimento que me transmitiram ao longo de toda a dissertação.

Aos meus pais, ao meu irmão e ao meu namorado. Muito obrigada por todo o apoio, incentivo e ajuda, nos bons e nos maus momentos. Obrigada por me ajudarem a superar e a ultrapassar todas as barreiras.

À minha família e aos meus amigos. Muito obrigada por todo o apoio e carinho.

À REN e seus engenheiros, um sincero obrigado pelo apoio e disponibilização de dados que tornou possível a elaboração desta dissertação.



Resumo

A presente dissertação apresenta o estudo de previsão do diagrama de carga de subestações da Rede Elétrica Nacional (REN) utilizando redes neurais, com o intuito de verificar a viabilidade do método utilizado, em estudos futuros.

Atualmente, a energia elétrica é um bem essencial e desempenha um papel fundamental, tanto a nível económico do país, como a nível de conforto e satisfação individual. Com o desenvolvimento do setor elétrico e o aumento dos produtores torna-se importante a realização da previsão de diagramas de carga, contribuindo para a eficiência das empresas.

Esta dissertação tem como objetivo a utilização do modelo das redes neurais artificiais (RNA) para criar uma rede capaz de realizar a previsão de diagramas de carga, com a finalidade de oferecer a possibilidade de redução de custos e gastos, e a melhoria de qualidade e fiabilidade. Ao longo do trabalho são utilizados dados da carga (em MW), obtidos da REN, da subestação da Prelada e dados como a temperatura, humidade, vento e luminosidade, entre outros. Os dados foram devidamente tratados com a ajuda do *software Excel*. Com o *software MATLAB* são realizados treinos com redes neurais, através da ferramenta *Neural Network Fitting Tool*, com o objetivo de obter uma rede que forneça os melhores resultados e posteriormente utiliza-la na previsão de novos dados.

No processo de previsão, utilizando dados reais das subestações da Prelada e Ermesinde referentes a Março de 2015, comprova-se que com a utilização de RNA é possível obter dados de previsão credíveis, apesar de não ser uma previsão exata. Deste modo, no que diz respeito à previsão de diagramas de carga, as RNA são um bom método a utilizar, uma vez que fornecem, à parte interessada, uma boa previsão do consumo e comportamento das cargas elétricas.

Com a finalização deste estudo os resultados obtidos são no mínimo satisfatórios. Consegue-se alcançar através das RNA resultados próximos aos valores que eram esperados, embora não exatamente iguais devido à existência de uma margem de erro na aprendizagem da rede neuronal.

Palavras-Chave: Redes neurais artificiais, rede elétrica, previsão de diagrama de carga.



Abstract

This dissertation presents a study about forecasting electrical load diagram from substations in the national grid, specifically Rede Eléctrica Nacional (REN), using neural networks in order to verify the feasibility of this method in future studies.

Currently, electricity is an essential and plays a key role, both in the country economy, as for the comfort and well-being of individuals. With development of the electricity sector and the increase of producers becomes important to perform predictions of the load diagrams, contributing to the efficiency of these companies.

This dissertation aims to use the model of artificial neural networks (ANN) to create a network capable of predicting electrical load diagrams, in order to offer the possibility of reducing costs and expenses, and improve quality and reliability. Throughout this project are used load data (in MW), gathered by REN, from the substation in Prelada and data such as temperature, humidity, wind and luminosity, among others. All this data is treated using the software Excel. With the software MATLAB are performed trainings sessions with neural networks, using the tool Neural Network Fitting Tool, in order to obtain the network that provides the best results and thereafter use it to predict new data.

In the prediction process, using real data from substations in Prelada and Ermesinde for the month of March 2015, is verified that with the use of ANN it is possible to obtain reliable and satisfactory prediction data, although not an accurate prediction. Thus, with regard to the load diagram prediction, the ANN are a good method to use since they provide, to interested party, a good prediction of the consumption and behavior of electric loads.

With the completion of this study the results are, at least, satisfactory. Results close to the values that were expected can be achieved. Taking into account the fact that the values are not exactly like the original values, due to the existence of a margin of error in the neural network learning process.

Keywords: Artificial neural networks, electric grid, forecast of load diagrams.



Índice

Agradecimentos	vii
Resumo	ix
Abstract.....	xi
Índice de Figuras	xvii
Acrónimos	xxi
1. Introdução.....	1
1.1 Enquadramento	1
1.2 Objetivos.....	2
1.3 Organização da dissertação.....	2
2. Rede Elétrica Nacional.....	5
2.1 Energia Elétrica.....	5
2.2 Rede Elétrica Nacional	5
2.3 Sistema Elétrico Nacional.....	6
2.4 Previsão de Carga	14
3. Aplicação das Redes Neurais	17
3.1 Redes Neurais	17
3.2 Redes Neurais Artificiais	18
3.3 Aplicações.....	24
3.4 Aplicação das RNA no estudo de sistemas de energia	25
4. Método desenvolvido para a previsão de diagrama de carga de subestações da REN.....	29
4.1 Descrição e Funcionamento da ferramenta utilizada	29
4.2 Método desenvolvido.....	35
4.3 Análise e Conclusões	53
5. Previsão do Diagrama de Carga	59

5.1	Características das RNA utilizadas.....	59
5.2	Procedimento utilizado para a Previsão.....	61
5.3	Previsão de Diagrama de Carga do dia 18 de Março de 2015, da subestação da Prelada	62
5.4	Previsão de Diagrama de Carga da primeira semana de Março de 2015, da subestação da Prelada	64
5.5	Previsão de Diagrama de Carga para outras Subestações da REN.....	65
5.6	Conclusões.....	70
6.	Conclusões Finais e Trabalhos Futuros	73
6.1	Conclusões Finais	73
6.2	Trabalhos Futuros	75
7.	Referências Bibliográficas	77
	Anexo A – Tratamento dos dados utilizados na previsão, para Março de 2015	81
A.1	Dados Meteorológicos	81
A.2	Dados de carga da subestação da Prelada.....	83
A.3	Dados de carga da subestação de Ermesinde.....	84
	Anexo B – Previsão de diagrama de carga do mês de Março de 2015	85
B.1	Subestação da Prelada.....	85
B.2	Subestação de Ermesinde.....	86
	Anexo C – Carga utilizada na subestação de Ermesinde durante um ano	88
	Anexo D – Comportamento obtido nos treinos das várias redes neuronais artificiais (melhor rede obtida para um ano, utilizando os dados referidos, das subestações) ...	89
D.1	Todos os dados disponíveis, da Prelada	89
D.2	Todos os dados disponíveis, de Ermesinde	94
D.3	Dados do dia, mês, hora, feriados, dia da semana e Temperatura, da Prelada	98
D.4	Dados do dia, mês, hora, feriados, dia da semana, Temperatura e Humidade, da Prelada	103

D.5 – Dados do dia, mês, hora, feriados, dia da semana, Temperatura e Vento, da Prelada	107
D.6 – Dados do dia, mês, hora, feriados, dia da semana, Temperatura e Luminosidade, da Prelada.....	112
D.7 – Dados disponíveis, exceto feriados, da Prelada	116



Índice de Figuras

Figura 1 - Potência instalada em 2014 [7].	7
Figura 2 - Potência instalada e Ponta máxima anual (PRO + PRE) [7].	8
Figura 3 - Diagrama de carga do dia da ponta anual (Inverno) [7].	9
Figura 4 – Diagrama de carga de um dia característico de Primavera [7].	9
Figura 5 – Diagrama de carga de um dia característico de Verão [7].	9
Figura 6 – Diagrama de carga de um dia característico de Outono [7].	9
Figura 7 - Evolução do consumo semanal em 2014 [7].	10
Figura 8 - Ponta de consumo da Rede Nacional de Transporte (RNT) e na Rede Pública, 2014 [7].	10
Figura 9 – Diagrama de Carga dos Dias Característicos [7].	11
Figura 10 – Ponta máxima das subestações da RNT (apenas as com entrega à Rede Nacional de Distribuição (RND)) – Distribuição por Classes [7].	11
Figura 11 – Desempenho das linhas da RNT [8].	12
Figura 12 – Mapa da Rede Nacional de Transporte de Eletricidade, 2015 [4].	13
Figura 13 – Exemplo de um Diagrama de carga [11].	15
Figura 14 – Constituição de um neurónio [12].	17
Figura 15 – Esquema de uma Rede Neuronal Artificial [13].	18
Figura 16 – Modelo matemático utilizado pela RNA [14].	19
Figura 17 – Algoritmo <i>Backpropagation</i> [20].	21
Figura 18 – Esquema representativo da arquitetura da RN [30].	31
Figura 19 – Parâmetros de progresso durante o treino da RN e respetivos resultados finais [30].	32
Figura 20 – Estudo de Dados utilizados na dissertação, em função do tempo em dias.	34
Figura 21 – Estudo de dados da carga em função do tempo.	35
Figura 22 – Progressos e Resultados da melhor rede com 10 neurónios.	36
Figura 23 – Desempenho da melhor rede com 10 neurónios.	37
Figura 24 – Gráfico de Regressão da melhor rede com 10 neurónios.	37
Figura 25 – Progressos e Resultados da melhor rede com 20 neurónios.	38
Figura 26 – Desempenho da melhor rede com 20 neurónios.	38
Figura 27 – Gráfico de Regressão da melhor rede com 20 neurónios.	39
Figura 28 – Progressos e Resultados da melhor rede com 25 neurónios.	39
Figura 29 – Desempenho da melhor rede com 25 neurónios.	40

Figura 30 – Gráfico de Regressão da melhor rede com 25 neurónios.	41
Figura 31 – Progressos e Resultados da melhor rede com 30 neurónios.	41
Figura 32 – Desempenho da melhor rede com 30 neurónios.	42
Figura 33 – Gráfico de Regressão da melhor rede com 30 neurónios.	43
Figura 34 – Progressos e Resultados da melhor rede para as percentagens 75%, 15% e 10%, Treino, Validação e Teste, respetivamente.	44
Figura 35 – Desempenho da melhor rede.....	44
Figura 36 – Gráfico de Regressão da melhor rede.	45
Figura 37 – Progressos e Resultados da melhor rede, utilizando as melhores condições obtidas.	46
Figura 38 – Desempenho da melhor rede, utilizando as melhores condições obtidas.	46
Figura 39 – Progressos e Resultados da melhor rede com a humidade.	47
Figura 40 – Desempenho da melhor rede com a humidade.	48
Figura 41 – Progressos e Resultados da melhor rede com o vento.	48
Figura 42 – Desempenho da melhor rede com o vento.....	49
Figura 43 – Progressos e Resultados da melhor rede com a luminosidade.....	50
Figura 44 – Desempenho da melhor rede com a luminosidade.	50
Figura 45 – Progressos e Resultados da melhor rede com todos os dados.	51
Figura 46 – Desempenho da melhor rede com todos os dados.	52
Figura 47 – Progressos e Resultados da melhor rede sem feriados.	52
Figura 48 – Desempenho da melhor rede sem feriados.	53
Figura 49 – Fluxograma do processo desenvolvido para o treino das RNA.....	54
Figura 50 – Gráfico de resultados da melhor RN da 1ª Etapa, com 30 neurónios.....	55
Figura 51 – Gráfico de resultados da melhor RN da 2ª Etapa.....	55
Figura 52 – Gráfico de resultados da melhor RN da 4ª Etapa, com todos os dados.	56
Figura 53 – Estrutura da Rede Neuronal.	60
Figura 54 – Esquema da arquitetura de uma RNA treinada na <i>nftool</i>	61
Figura 55 – Função calcular saídas.	62
Figura 56 – Gráfico de Previsão de Diagrama de Carga do dia 18 de Março de 2015.....	63
Figura 57 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados do dia 18 de Março de 2015.	63
Figura 58 – Gráfico de previsão de diagrama de carga da primeira semana de Março de 2015.....	64

Figura 59 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados da 1ª semana de Março de 2015.....	65
Figura 60 – Progressos e Resultados da melhor rede para a subestação de Ermesinde.	66
Figura 61 – Desempenho da melhor rede para a subestação de Ermesinde.	66
Figura 62 – Gráfico de previsão de diagrama de carga do dia 30 de Março de 2015, da subestação de Ermesinde.	67
Figura 63 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados do dia 30 de Março de 2015, na subestação de Ermesinde.....	68
Figura 64 – Gráfico de previsão de diagrama de carga da 2ª semana de Março de 2015, da subestação de Ermesinde.	69
Figura 65 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados da 2ª semana de Março de 2015, na subestação de Ermesinde.....	69



Acrónimos

RN	-	Redes Neurais
RNA	-	Redes Neurais Artificiais
REN	-	Rede Elétrica Nacional
MSE	-	Erro Médio Quadrático
BT	-	Baixa Tensão
MT	-	Média Tensão
AT	-	Alta Tensão
MAT	-	Muito Alta Tensão
SEN	-	Sistema Elétrico Nacional
PRO	-	Produção em Regime Ordinário
PRE	-	Produção em Regime Especial
RNT	-	Rede Nacional de Transporte
RND	-	Rede Nacional de Distribuição
SEE	-	Sistema de Energia Elétrica
SI	-	Unidade de Sistema Internacional
ISEP	-	Instituto Superior de Engenharia do Porto



1. Introdução

A presente dissertação foi desenvolvida no âmbito do Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia, na unidade curricular Dissertação, no Instituto Superior de Engenharia do Porto.

Ao longo desta dissertação é apresentado o estudo realizado para a previsão de diagrama de carga, utilizando a metodologia das redes neuronais artificiais.

Este capítulo apresenta um enquadramento e os principais objetivos, assim como a estrutura apresentada nesta dissertação.

1.1 Enquadramento

Nos dias que correm a energia elétrica desempenha um papel fundamental, tanto a nível económico do país, como a nível de conforto e satisfação individual.

A eletricidade, atualmente, é produzida com recurso a diferentes tecnologias e a diferentes fontes primárias de energia, como o carvão, gás natural, água, vento, sol, entre outras. Em Portugal continental o número de produtores tem aumentando muito tendo em conta a origem de novas centrais no âmbito da cogeração ou da produção de origem renovável, que são centrais de menor potência em comparação com as centrais mais antigas, como as térmicas e hídricas que são de grandes dimensões [1].

Com o aumento dos produtores e a utilização de novas fontes primárias de energia os diagramas de carga têm sofrido modificações, devido ao carácter volátil de energias como o vento [2]. Deste modo, torna-se ainda mais importante o estudo de uma metodologia de previsão de diagramas de carga.

As Redes Neuronais Artificiais (RNA) são técnicas computacionais muito utilizadas em estudos de previsão. São um modelo de aprendizagem estatístico, com base no funcionamento de uma rede neuronal biológica, e que têm como objetivo estimar valores de saída com base em vários dados de entrada.

Esta dissertação pretende utilizar as RNA para a previsão dos diagramas de carga, usando todos os dados de entrada disponíveis com o intuito de obter os melhores resultados.

1.2 Objetivos

Esta dissertação tem como objetivo criar um modelo, utilizando redes neuronais artificiais, para previsão de diagramas de carga. Com o desenvolvimento desta dissertação, pretende-se que o modelo estudado permita, posteriormente, efetuar uma previsão de diagramas de carga mais eficiente, oferecendo assim a possibilidade de redução de custos e gastos e a melhoria de qualidade e fiabilidade.

1.3 Organização da dissertação

Esta dissertação é composta por 6 capítulos, que dizem respeito à introdução, à rede elétrica nacional, à aplicação das redes neuronais, ao método desenvolvido para a previsão de diagrama de carga de subestações da Rede Elétrica Nacional (REN), à previsão do diagrama de carga e à conclusão, respetivamente. Cada capítulo é composto por alguns subcapítulos e sub-subcapítulos.

O presente capítulo apresenta uma breve introdução ao tema em estudo.

No segundo capítulo é descrito, de um modo geral, a rede elétrica nacional. Tendo em atenção aspetos como a sua constituição e o seu funcionamento, demonstrando alguns gráficos e tabelas que fornecem informação recente sobre a caracterização da rede nacional de transporte.

O terceiro capítulo descreve a composição, funcionamento e aplicações das redes neuronais artificiais, bem como uma pequena introdução às redes neuronais biológicas.

Quanto ao quarto capítulo, encontra-se a descrição de todo o processo desenvolvido para alcançar as melhores redes, com o menor erro. Este capítulo é composto por várias etapas,

que foram desenvolvidas com o intuito de obter os melhores parâmetros e posteriormente as redes com melhores resultados.

No capítulo cinco está presente todo o processo elaborado para realizar a previsão de diagramas de carga. Inicia-se este capítulo com a explicação do processo desenvolvido para a previsão, seguindo a demonstração dos resultados obtidos e a sua análise.

Por fim, o capítulo seis contém as conclusões finais de todo o estudo realizado e indica algumas propostas de desenvolvimentos futuros.



2. Rede Elétrica Nacional

2.1 Energia Elétrica

A energia é um conceito abstrato, normalmente define-se este conceito como a capacidade de produzir trabalho. A energia toma diversas formas e, deste modo, muitas classificações diferentes [3].

Pode ser classificada como energia armazenável ou energia não armazenável. Armazenável é por exemplo, a energia contida nos combustíveis fósseis, como o carvão, petróleo e o gás natural ou a energia nuclear dos materiais cindíveis. Não armazenável pode ser a energia cinética do vento ou da água de um rio e a energia térmica transmitida pelo sol [3].

Outro tipo de classificação que a energia pode tomar é como energia primária ou energia final. Onde a energia primária diz respeito aos recursos naturais não convertidos, como a energia química dos combustíveis, a energia potencial e cinética das águas, a energia nuclear, a energia solar, a energia eólica, entre outras. Quanto à energia final, diz respeito às formas de energia obtidas através da conversão da energia primária, ou seja, a energia elétrica, a energia térmica e a energia mecânica [3].

Nos dias de hoje a classificação mais usual para a energia é não renovável ou renovável. A energia não renovável é aquela que demora muito tempo a ser reposta, como os combustíveis fósseis ou a energia nuclear dos materiais cindíveis. A energia renovável pode ser reposta facilmente, como a energia eólica, solar, das ondas, da biomassa, entre outras [3].

2.2 Rede Elétrica Nacional

Qualquer rede elétrica tem como objetivo garantir a transmissão de energia desde as instalações de produção até aos consumidores finais. Estas redes podem ser classificadas

de diversas formas. Por exemplo, uma rede elétrica pode ser classificada quanto à tensão nominal, quanto à função e quanto à topologia [3].

Em relação à tensão nominal, determina a capacidade de transporte e fixa as dimensões das linhas e da aparelhagem das subestações. A tensão nominal está dividida em quatro classes, Baixa Tensão (BT), abaixo dos 1000 V; Média Tensão (MT), entre 1 e 45 kV; Alta Tensão (AT), entre 45 e 110 kV; e Muito Alta Tensão (MAT), acima dos 110 kV [3].

Quanto à função, é o que o sistema deve garantir, ou seja, a rede de distribuição deve garantir que leva a energia até ao cliente/consumidor; a rede de transporte em muito alta tensão deve assegurar o trânsito de elevadas quantidades de energia; e as redes de interligação devem garantir a ligação entre as redes de transporte e por vezes entre as de distribuição também [3].

Por fim, a topologia da rede em que o mais importante é manter a fiabilidade, devendo estar sempre pronta para resolver possíveis problemas em caso de falhas. Os problemas refletem-se em custos, deste modo é necessário saber a melhor topologia a adotar de forma a entrar num “acordo” entre os custos de investimento e os benefícios que trazem para saber qual a melhor estrutura a utilizar [3].

Atualmente, a REN é constituída por 8371 km de comprimento de circuito total, sendo este circuito composto por 65 subestações, 13 postos de corte, 190 transformadores e 1298 painéis. Em que 2236 km de comprimento de circuito correspondem às linhas de 400 kV, 3492 km correspondem às linhas de 220 kV e 2643 km correspondem às linhas de 150 kV [4].

2.3 Sistema Elétrico Nacional

O Sistema Elétrico Nacional (SEN) desenvolve as suas atividades tendo sempre em conta os princípios de racionalidade e eficiência na utilização de recursos ao longo de toda a cadeia de valores, ou seja, desde o momento que a eletricidade é produzida até ao momento em que é consumida [5]. O SEN tem como principal objetivo a disponibilização de energia elétrica de forma adequada às necessidades dos consumidores, quer qualitativa quer quantitativa [6].

Este sistema encontra-se dividido em seis grandes áreas sendo elas, Produção, Transporte, Distribuição, Mercados, Comercialização e Consumo [4][5].

2.3.1 Produção de Eletricidade

A produção de eletricidade é desenvolvida num contexto de concorrência e encontra-se dividida em dois regimes, o regime ordinário e o regime especial. A Produção em Regime Ordinário (PRO) corresponde à produção de eletricidade com base em fontes tradicionais não renováveis e em grandes centros electroprodutores hídricos. A Produção em Regime Especial (PRE) é relativa à cogeração e à produção elétrica a partir da utilização de fontes de energia renováveis [4][5].

Em 2014, o valor total da potência de produção instalada, no fim do ano, era de 17834 MW, em que 11222 MW era de origem renovável. Quanto às centrais de PRO a potência total teve um registo de 10855 MW, registo este inferior ao ano anterior, e a potência relativa à PRE foi de 6979 MW, onde existiu um aumento de 217 MW desde 2013, tal como se pode verificar na figura 1 [7].

Potência Instalada no Final do Ano [MW]	2014	2013
TOTAL	17 834	17 751
RENOVÁVEL	11 222	10 898
Hídrica	5 684	5 653
<i>Mini-hídrica</i>	415	415
Eólica	4 541	4 364
Térmica	601	597
<i>Cogeração</i>	343	343
Solar	396	283
NÃO RENOVÁVEL	6 612	6 853
Carvão	1 756	1 756
Gás Natural	4 718	4 759
<i>Cogeração</i>	888	930
Outros	138	339
<i>Cogeração</i>	125	161
Produtores em Regime Ordinário	10 855	10 989
Produtores em Regime Especial	6 979	6 762

Figura 1 - Potência instalada em 2014 [7].

A figura 2 permite uma visão mais ampla do sucedido nos últimos cinco anos, apresentando uma comparação entre a potência instalada e a linha de ponta máxima anual da produção. Pode-se verificar que a ponta máxima de produção, em 2010, era de 9403 MW e em 2014 passou a ser de 8313 MW, ou seja, houve um decréscimo de 1090 MW de produção, em cinco anos, existindo uma maior utilização de energia eólica e solar.




Figura 2 - Potência instalada e Ponta máxima anual (PRO + PRE) [7].

Os diagramas de carga permitem uma visualização do comportamento da carga ao longo de um determinado tempo, nas figuras que se seguem é possível verificar o comportamento de um diagrama de carga da rede pública ao longo de um dia para cada uma das estações do ano, dando assim uma perspetiva do comportamento da carga ao longo do ano nas diferentes estações.




Figura 3 - Diagrama de carga do dia da ponta anual (Inverno) [7].




Figura 4 – Diagrama de carga de um dia característico de Primavera [7].




Figura 5 – Diagrama de carga de um dia característico de Verão [7].




Figura 6 – Diagrama de carga de um dia característico de Outono [7].

2.3.2 Consumo de Eletricidade

Relativamente ao consumo de eletricidade no país pode-se afirmar “*Em Portugal Continental existem quase 6,1 milhões de consumidores, sendo a sua esmagadora maioria em Baixa Tensão, 23500 em Média Tensão e cerca de 350 em Alta e Muito Alta Tensão, que em 2013 consumiram mais de 49 mil milhões de kWh.*” (REN – O Setor Elétrico), esta afirmação demonstra que os consumidores são a razão de ser do SEN, sem eles este sistema não era possível [4].

No ano de 2014, o consumo de eletricidade teve um total de 48,8 TWh. A figura 7 mostra a evolução desse consumo e as respectivas fontes de energia que foram utilizadas para gerar a energia elétrica consumida.




Figura 7 - Evolução do consumo semanal em 2014 [7].

Em 2014, a potência máxima verificada pelo SEN foi de 8313 MW, ocorrida num dia de Fevereiro, e o valor máximo de consumo diário foi de 162,5 GWh, ocorrido nesse mesmo dia. A potência máxima registada teve um decréscimo de 1000 MW em relação ao valor registado em 2010. As figuras seguintes mostram o consumo do SEN ao longo do ano de 2014 e o diagrama de carga do consumo dos dias característicos (Inverno, Primavera, Verão e Outono), respetivamente [7].




Figura 8 - Ponta de consumo da Rede Nacional de Transporte (RNT) e na Rede Pública, 2014 [7].




Figura 9 – Diagrama de Carga dos Dias Característicos [7].

Através da figura 10 é possível ter uma perspetiva comportamental da potência máxima verificada ao longo dos últimos cinco anos. Na figura verifica-se que tanto para 2013 como para 2014 a classe mais representativa é onde a ponta máxima se encontra entre 100 MW e 250 MW [7].




Figura 10 – Ponta máxima das subestações da RNT (apenas as com entrega à Rede Nacional de Distribuição (RND)) – Distribuição por Classes [7].

2.3.3 Transporte de Eletricidade

Através de uma concessão atribuída pelo Estado Português o transporte de eletricidade, em muito alta tensão (150, 220 e 400 kV), é efetuado através da Rede Nacional de Transporte (RNT). A concessão inclui diversas funções, desde planeamento a manutenção da RNT e também planeamento e gestão do SEN, de forma a garantir o bom funcionamento das infraestruturas tal como a continuidade de serviço e a segurança do abastecimento de energia elétrica [4][5].

Nos últimos anos as linhas da RNT tiveram um desempenho, a nível geral, satisfatório, em 2014 os principais congestionamentos estiveram associados a indisponibilidades de elementos da rede mas foram facilmente solucionados [7]. A figura 11 demonstra o desempenho das linhas de 2009 a 2013:



Figura 11 – Desempenho das linhas da RNT [8].

Para que uma sociedade moderna tenha um bom funcionamento, a rede elétrica é uma infraestrutura indispensável. Para uma conceção, construção e operação de qualidade, a rede elétrica, requer um elevado investimento e uma engenharia sofisticada [3].

Na figura 12 encontra-se o mapa da rede nacional de transporte, que se encontra em serviço exclusivo da empresa REN.

Rede Nacional de Transporte de Electricidade

Rede de Muito Alta Tensão



2015

Portugal continental 1 janeiro

A localização das subestações e o traçado das linhas são indicativos, não estando georreferenciados.
The location of infrastructures and the layout of the lines are indicative, not being georeferenced.



Oceano Atlântico
Atlantic Ocean



Espanha
Spain

Legenda / Map key

Introdução em 31 de dezembro de 2015 a proposta de implementação da infraestrutura de transporte de muito alta tensão - infraestrutura de dezembro 2015, 2015 e não representada no plano de fundo da rede nacional.

Consultar o site www.ren.pt. For further information, please refer to the website.

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

Correção (Ordem de prioridade) / Color (Designation of priority)

REN

REN-Rede Eléctrica Nacional, S.A.
Av. E.U.A., 55
1749-061 Lisboa
Tel. 21 001 3500
Fax 21 001 3100

www.ren.pt

norvia
CONSULTORES DE PROJEÇÃO, S.A.

www.norvia.pt

Base Cartográfica cedida por ESRI Portugal.
Cartographic Base by courtesy of ESRI Portugal.

Figura 12 – Mapa da Rede Nacional de Transporte de Eletricidade, 2015 [4].

2.4 Previsão de Carga

Em qualquer empresa do setor elétrico a previsão de consumos ou cargas é um bem essencial para a existência de um negócio com qualidade e fiabilidade. A previsão é um processo que pode ter diversos objetivos e diferentes formas, tendo também em conta horizontes temporais ou espaciais distintos [9].

Em horizontes temporais a previsão pode ser efetuada de três formas [10]:

- ✓ Previsão a longo prazo, em que a previsão da ponta, da energia e do número de consumidores para um horizonte varia de 5 a 25 anos.
- ✓ Previsão a médio prazo, em que a previsão da ponta e da energia é realizada para os próximos meses ou próximos anos.
- ✓ Previsão a curto prazo, em que é realizada a previsão do diagrama diário (hora a hora) para os próximos dias, ou a previsão da ponta para as semanas seguintes.

A evolução da carga pode ser facilmente influenciada por diversos fatores, como por exemplo, económicos, cronológicos, meteorológicos, demográficos, comportamentais sociais, tecnologias de consumo e fatores geográficos [10].

Para efetuar previsões podem ser usados muitos modelos. Ao longo desta dissertação será utilizado o modelo das redes neuronais artificiais que se trata de um dos modelos mais utilizados para a previsão de cargas, no entanto existem também modelos como os de regressão, os estocásticos de séries temporais ou “Box e Jenkins”, entre outros [10].

2.4.1 Diagrama de Carga

O consumo de energia contém características que impõem a modulação da energia consumida no tempo através de uma função designada por diagrama de carga. O diagrama de carga traduz a variação do consumo ao longo das horas do dia e dos dias do ano [11].




Figura 13 – Exemplo de um Diagrama de carga [11].

Geralmente o diagrama de carga segue o modelo de uma linha padronizada ao longo das 24 horas diárias, mesmo que possa estar situado em locais de diferentes consumos (maioritariamente residencial, industrial ou rural) [2].

Ao longo de um diagrama de carga é normal existir uma zona designada por horas de vazio, outra por horas de cheias e ainda as horas de ponta. As horas de vazio correspondem às horas em que o consumo de eletricidade é mais barato, ou seja, horas do período noturno ou de fim-de-semana. As horas de cheias começam principalmente quando se inicia as horas de trabalho da população, provocando assim um aumento no consumo de eletricidade. Por fim, as horas de ponta dizem respeito às horas onde o consumo de eletricidade é mais caro.

É importante referir que existem condições que influenciam a forma do diagrama de carga, assim sendo é conveniente ter esse aspeto em atenção de forma a conseguir prever um diagrama de carga o mais exato possível. As condições que podem influenciar um diagrama de carga são [11]:

- ✓ Época do ano;
- ✓ Dia da semana;

-
- ✓ Hora do dia;
 - ✓ Condições atmosféricas;
 - ✓ Acontecimentos especiais;
 - ✓ Legislação adequada.

Um Sistema de Energia Elétrica (SEE) fornece energia aos consumidores que a utilizam, de forma a garantir o nível de potência necessário para alimentar o conjunto dos equipamentos ligados, isto é, a carga do sistema [3].

Matematicamente, a relação entre a potência e a energia é descrita como [3]:

$$P = \frac{dW}{dt} . \quad (1)$$

onde W corresponde à energia, unidade do Sistema Internacional (SI) é o *joule* (J) ou na prática o *watt.hora* (Wh), P corresponde à potência, unidade SI é o *watt* (W), e t corresponde ao tempo, unidade SI é o segundo (s) [3].

Uma vez que a potência é a derivada da energia em ordem ao tempo, tem-se [3]:

$$W = \int P . dt . \quad (2)$$

A carga de um SEE varia significativamente ao longo do dia, acompanhando a atividade humana. Num diagrama de carga define-se *utilização diária da ponta* – h_d – como sendo a relação entre a energia e a potência máxima (ou potência de ponta), usando a seguinte expressão [3]:

$$h_d = \frac{W}{P_{máx}} . \quad (3)$$

Define-se, ainda, *fator de carga diário* – f_d – como a relação entre a potência média e a potência máxima, também pode ser visto como a relação entre a utilização diária da ponta e o número de horas do dia, expressa em percentagem, isto é [3]:

$$f_d \frac{W}{P_{máx} \times 24} \times 100 . \quad (4)$$

3. Aplicação das Redes Neurais

3.1 Redes Neurais

As Redes Neurais (RN) são estruturas cujo processamento da informação passa por um enorme conjunto de neurónios, estima-se que o cérebro humano tenha cerca de 100 bilhões de neurónios interligados [12]. Os neurónios são células que constituem a rede neuronal e que são as responsáveis pelo funcionamento de todas as funções e movimentos do organismo [12][13].

Os neurónios são as “peças” mais importantes do sistema nervoso. Cada um recebe estímulos vindo de outros neurónios, ou seja, sinapses que são o local por onde os neurónios transmitem os impulsos nervosos. Estes sinais são transmitidos pelo axónio que posteriormente irão estimular outros neurónios. A figura seguinte demonstra a constituição de um neurónio [12][13][14].




Figura 14 – Constituição de um neurónio [12].

3.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são técnicas computacionais que apresentam um modelo matemático inspirado na RN real e que adquirem conhecimento através da experiência [2][13][14].

Estas redes são constituídas por muitas unidades de processamento, designadas por neurónios artificiais. Essas unidades estão ligadas a canais de comunicação que se encontram associados a um determinado peso. Os neurónios artificiais consideram as várias entradas possíveis, realizam o processamento da informação multiplicando o sinal recebido na entrada pelo peso, que indica a sua influência na saída, realiza de seguida a soma ponderada dos sinais que produz um determinado nível de atividade e por fim se esse nível exceder um certo limite a unidade produz uma resposta [2][13][14].




Figura 15 – Esquema de uma Rede Neuronal Artificial [13].

A figura 15 mostra um diagrama esquemático de uma RNA, geralmente a arquitetura destas redes é composta por uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída. Regra geral, cada neurónio é ligado aos outros neurónios da camada anterior através de pesos adaptáveis [14][15].

O diagrama seguinte, figura 16, permite ter uma ideia melhor da constituição do modelo matemático utilizado pela RNA.




Figura 16 – Modelo matemático utilizado pela RNA [14].

O Bias é uma unidade especial, semelhante aos pesos, que permite realizar uma melhor adaptação dos conhecimentos que a rede adquire, através do Bias é possível fazer “andar” a fronteira de decisão, gerada pelos pesos, e assim obter melhores resultados [14].

As RNA podem ter vários tipos de funções de transferência, no entanto as mais utilizadas são [16]:

- Linear: O nível de atividade é proporcional à soma pesada das entradas.
- Limite: É definido o valor limite, que uma vez ultrapassado, faz com que a célula produza atividade.
- Sigmoides: A saída varia de acordo com a função sigmoide.

As RNA podem ter dois tipos de arquitetura, unidirecionais (*feedforward*) ou recorrentes (*feedback*), sendo as redes unidirecionais as mais usuais em que o sentido de circulação é sempre da entrada para a saída. Nas recorrentes a circulação não tem apenas um sentido, isto é, existem ligações entre neurónios em sentido contrário. As redes unidirecionais podem ser de uma só camada ou de multicamadas [17].

A nível de aprendizagem numa RNA o treino é essencial para o bom funcionamento de uma rede. O treino permite definir de forma automática os pesos das ligações existentes, através de um dos vários algoritmos de aprendizagem. Alguns dos diferentes tipos de treino são [2][16]:

- Aprendizagem supervisionada: é quando se utiliza um agente externo que indica à rede a resposta desejada para o padrão de entrada.
- Aprendizagem não supervisionada: é quando não existe um agente externo indicando à rede a resposta desejada para o padrão de entrada.

-
- Aprendizagem por retropropagação (*backpropagation*): é o método de aprendizagem supervisionada mais utilizado.
 - Aprendizagem pelo método de Perceptrão: é do tipo aprendizagem supervisionada. A função de transferência das unidades computacionais das redes de perceptrões não é diferenciável, pelo que a aprendizagem supervisionada é realizada por funções discretas.
 - Aprendizagem por reforço: é quando um crítico externo avalia a resposta fornecida pela rede.

3.2.1 Algoritmo de aprendizagem por retropropagação – *Backpropagation*

Para treinar redes neuronais compostas por mais do que uma camada é mais comum utilizar o método conhecido por *Backpropagation* [15][18]. Este método é essencialmente composto por dois passos, um em frente e outro para trás. O primeiro consiste na propagação (em frente), ou seja, inicia-se o treino com um vetor fornecido na entrada e a atividade é propagada de camada em camada até que é gerada uma resposta na camada de saída. A resposta gerada é comparada com a resposta pretendida e assim ocorre o próximo passo, a retropropagação (para trás), pois depois de comparados os vetores é gerado o erro, e este será propagado para as camadas anteriores, ou seja, da camada de saída para a de entrada. Os valores dos pesos são ajustados de acordo com o resultado do erro obtido na última etapa. Este processo é repetido múltiplas vezes até o erro global entre o que é atingido na saída e o que é esperado seja minimamente obtido [14][19].




Figura 17 – Algoritmo *Backpropagation* [20].

Este método tem algumas limitações, por exemplo as redes neurais que utilizam o algoritmo tendem a ser vistas como “caixas negras”, uma vez que o modelo não apresenta justificáveis, não se sabe explicar como se chega ao resultado [15][21]. Outra limitação é o tempo. O tempo de treino das redes que utilizam *Backpropagation* tende a ser muito lento [14][19].

3.2.2 Algoritmo *Levenberg-Marquardt*

O algoritmo *Levenberg-Marquardt* foi desenvolvido por *Kenneth Levenberg* e publicado por *Donald Marquardt*, foi criado para resolver problemas de minimização de funções, em geral, não-lineares pelo método de mínimos quadrados [20][22]. Hoje em dia é dos algoritmos mais utilizados [20][22].

Este algoritmo encontra-se, de certo modo, entre o algoritmo Gauss-Newton e o algoritmo de gradiente descendente. É também considerado mais robusto que o algoritmo de Gauss-Newton, uma vez que mesmo começando longe de um mínimo final ele consegue encontrar uma solução. No entanto, para funções regulares tende a ser mais lento [22][23][24][25].

O algoritmo de gradiente descendente é um método geral de minimização que atualiza os valores dos dados na direção contrária à inclinação da função objetivo. Este método é reconhecido como um algoritmo altamente convergente no que diz respeito a encontrar o mínimo de funções objetivo simples. Em problemas com inúmeros dados este algoritmo é por vezes o método mais viável [22][24][25].

O algoritmo de Gauss-Newton é um método para minimizar a soma dos quadrados de uma função objetivo. Para problemas de tamanho moderado, o método de Gauss-Newton, converge, regra geral, muito mais rápido do que o método do algoritmo de gradiente descendente [22][23].

Quando uma função tem a forma de soma de quadrados, o que é comum em redes *feedforward*, o algoritmo de *Levenberg-Marquardt* determina que a matriz Hessiana toma a seguinte forma:

$$\mathbf{H} = \mathbf{J}^T \mathbf{J} . \quad (5)$$

E o gradiente pode ser calculado como $\mathbf{g} = \mathbf{J}^T \mathbf{e}$, em que \mathbf{J} é a Matriz Jacobiana, constituída pelas primeiras derivadas dos erros da rede, tendo em conta os pesos e as bias, e \mathbf{e} é o vetor de erros da rede.

A expressão utilizada pelo algoritmo de *Levenberg-Marquardt* para a atualização dos pesos é [20][26]:

$$\mathbf{x}_{k+1} = \mathbf{x}_k - [\mathbf{J}^T \mathbf{J} + \mu \mathbf{I}]^{-1} \mathbf{J}^T \mathbf{e} . \quad (6)$$

ou

$$\mathbf{x}_{i+1} = \mathbf{x}_i - (\mathbf{H} + \lambda \mathbf{I})^{-1} \nabla f(\mathbf{x}_i) . \quad (7)$$

Onde \mathbf{x} é o vetor dos pesos, ∇f é o gradiente do erro médio quadrático, \mathbf{H} é a matriz Hessiana e λ (ou μ) é o fator de ajuste [20][26].

É de notar que esta atualização tem em consideração tanto a inclinação da superfície do erro, correspondente ao método do gradiente descendente, como a curvatura da superfície, que diz respeito ao método de Gauss-Newton. O fator de ajuste ajuda a perceber qual o método predominante, isto é, para um fator de ajuste grande o método do gradiente descendente é mais forte, por outro lado, quando o fator de ajuste é mais pequeno o método predominante é o de Gauss-Newton [20].

3.2.3 Regressão Linear e Erro Médio Quadrático

A regressão tem origem na tentativa de relacionar um conjunto de observações de certas variáveis, designadas por X_k ($k = 1 \dots p$), com as leituras de uma certa grandeza Y . Uma regressão linear pode ser apresentada por [27][28]:

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_pX_p . \quad (8)$$

onde a, b_1, b_2, \dots, b_p são os parâmetros da relação linear procurada.

A aplicação deste método pode ter o objetivo de ser explicativo ou preditivo. Nesta dissertação, o fim a que se destina a utilização do método de regressão é preditivo, ou seja, obter uma relação que nos permita, perante futuras observações das variáveis X_k , prever o respetivo valor de Y , sem ser necessário realizar a sua medição. O facto de as variáveis X_k tentarem explicar as razões da variação de Y levam-nas, independentemente do objetivo, a serem designadas por variáveis explicativas [27][28].

Dispondo de n conjuntos de medidas com as correspondentes observações, a utilização do modelo terá sempre uma parcela de erro [27].

$$y_i = a + b_1x_{i1} + b_2x_{i2} + \dots + b_px_{ip} + e_i \quad i = 1 \dots n . \quad (9)$$

A versão da regressão linear apresentada consiste em estimar os valores dos parâmetros a, b_1, b_2, \dots, b_p através da minimização do erro médio quadrático (MSE). O MSE também pode ser utilizado como uma medida do erro de previsão [28]. É determinado através da soma dos erros da previsão ao quadrado, e_t^2 , e dividido pelo número de erros, n , utilizado no cálculo e pode ser expresso da seguinte forma [27]:

$$MSE = \frac{\sum_{t=1}^n e_t^2}{n} . \quad (10)$$

O erro de previsão, e_t , é determinado através da diferença entre o valor real para esse período, y_t , e o valor previsto para esse período, \hat{y}_t [27].

$$e_t = y_t - \hat{y}_t . \quad (11)$$

3.3 Aplicações

As redes neuronais artificiais são utilizadas em diversas áreas. Esta técnica torna-se uma boa opção para diversos estudos pelo facto de ser boa a trabalhar com conjunto de dados incompletos, informação distorcida e problemas complexos e mal definidos. As RNA são capazes de aprender através de exemplos e sabem lidar com problemas não lineares [12].

Abaixo estão descritas algumas das aplicações, mais importantes, em que as RNA foram testadas com sucesso [12][17]:

- Classificação
 - ✓ Reconhecimento de padrões;
 - ✓ Reconhecimento de sons e fala;
 - ✓ Análise de Eletromiografia e outras análises médicas;
 - ✓ Identificação de alvos militares.

- Previsão
 - ✓ Tempo e tendências do mercado;
 - ✓ Prever locais de exploração mineral;
 - ✓ Previsões de carga elétrica e térmica.

- Sistemas de Controlo
 - ✓ Controlo adaptativo;
 - ✓ Controlo robótico.

- Otimização e tomada de decisão
 - ✓ Sistemas de engenharia;
 - ✓ Gestão.

3.4 Aplicação das RNA no estudo de sistemas de energia

Com base na pesquisa realizada para a elaboração desta dissertação é possível afirmar que as RNA são utilizadas em diferentes casos de estudo dentro dos sistemas de energia. De modo a dar a conhecer outros tipos de aplicações desta técnica computacional encontram-se descritos, abaixo, alguns temas recentemente estudados.

✓ *“Desenvolvimento de uma metodologia baseada em redes neuronais para o cálculo de energia produzida por aerogeradores”* (José Macedo. ISEP, 2012), [19]:

O estudo deste tema tinha como objetivo estimar a energia produzida pelos aerogeradores quando existiam falhas, ou avarias, de comunicação com o contador interno, uma vez que a existência deste tipo de ocorrência não permite a monitorização da energia produzida e esta é fundamental para o controlo económico do funcionamento do parque [19].

Com o desenvolvimento deste tema foi possível concluir que os resultados obtidos com a aplicação de RNA, no método de cálculo da energia produzida por aerogeradores, demonstravam que é possível estimar o valor da energia produzida, independentemente do período de indisponibilidade da informação dessa energia [19].

✓ *“Previsão de carga – Comparação de técnicas”* (Tiago Barros. FEUP, 2014), [13]:

O principal objetivo deste tema era comparar o desempenho de diferentes técnicas de previsão de carga, a curto prazo. As técnicas utilizadas foram a análise clássica de séries temporais (*Box-Jenkins*), as redes neuronais e máquina de suporte vetorial. As conclusões finais foram retiradas com base na comparação entre os modelos utilizados nas diferentes técnicas [13].

Segundo os resultados obtidos as máquinas de suporte vetorial apresentam melhores resultados do que o 1º modelo de RN que demonstra ser melhor em estudos de previsão. Contudo, esta comparação entre técnicas mostrou que o melhor desempenho foi obtido

através do 3º modelo de RN standardizado, que dizia respeito a tratar feriados como domingos [13].

✓ Aplicações de RNA para sistemas de energia (artigo de Soteris A. Kalogirou, 2000), [12]:

Este artigo tinha como objetivo apresentar diversas aplicações de RN em problemas energéticos, mostrando a capacidade de RNA como ferramentas de previsão de energia e modelagem [12]. Foram analisados problemas como modelagem de um gerador de vapor solar, sistemas de aquecimento solar de água, sistemas de aquecimento, ventilação e ar condicionado, previsões de radiação solar e velocidade do vento, modelagem e controle em sistemas de geração de energia, previsão e refrigeração [12].

Através do estudo elaborado neste artigo chegaram à conclusão de que as RNA oferecem um método alternativo que não deve ser subestimado [12].

✓ *“Previsão dos consumos na RNT considerando a produção distribuída – Desenvolvimento de um procedimento de apoio à decisão do Gestor do sistema”* (Ricardo Rodrigues. FEUP, 2014), [2]:

O caso em análise pretende criar uma ferramenta que possa facilitar a análise do sistema, uma vez que o Gestor de Sistema da REN se depara com uma mudança de padrão da RNT [2]. A criação desta ferramenta tinha como finalidade que a programação das indisponibilidades dos transformadores de cada subestação assumisse valores mais próximos da realidade, diminuindo assim o erro de previsão. Para que a programação desta ferramenta seja feita de forma eficaz necessita de prever a carga nos transformadores de potência e para tal utilizou as RNA [2].

Com a finalização da previsão, os resultados obtidos apresentaram melhorias significativas em comparação com o método de previsão existente no Gestor de Sistema, mostrando que as RN são uma mais-valia [2]. Para terminar criou-se a ferramenta desejada que permite ao Gestor de Sistema prever com eficácia a carga de uma certa subestação num horizonte de sete dias e com um baixo erro [2].

✓ Integração de redes neurais artificiais e algoritmos genéticos para prever o consumo de energia elétrica (artigo de Azadeh, Ghaderi, Tarverdian e Saberi. 2006), [17]:

Este artigo utilizou o método das RNA e do algoritmo genético para estimar e prever a procura/consumo da eletricidade, utilizando métodos estocásticos. O caso em estudo utilizou como referência o consumo de eletricidade no setor da agricultura iraniana [17].

Os resultados deste estudo mostraram que o erro relativo do método do algoritmo genético foi significativamente menor do que o do método de regressão e a curva da estimativa da procura de eletricidade usando algoritmo genético e dados reais mostra muita semelhança, e bons resultados. Posteriormente, o consumo de eletricidade foi previsto por RNA e mostrou que esta técnica domina abordagens de séries temporais e além disso é um bom método para obter melhores previsões do consumo de energia [17].

✓ Prevendo o consumo de energia elétrica: Uma comparação da análise de regressão, árvore de decisão e redes neurais (artigo de Geoffrey Tso e Kelvin Yau. 2006), [28]:

Este estudo apresenta três técnicas de modelagem para previsão de consumo de energia elétrica, a tradicional análise de regressão e também a técnica da árvore de decisão e das RNA. Este tema ilustra como este conceito pode ser utilizado para prever o consumo de energia elétrica em Hong Kong [28].

No final, comparando a precisão na previsão, verifica-se que o modelo da árvore de decisão e das RNA são melhores do que outros modelos nas fase de verão e inverno. De um modo geral as diferenças no erro médio quadrático entre os três modelos utilizados são muito pequenas, demonstrando que as três técnicas de modelação são geralmente idênticas na previsão de consumo de energia [28].



4. Método desenvolvido para a previsão de diagrama de carga de subestações da REN

Neste capítulo o objetivo principal é o desenvolvimento de uma RNA. Aqui será descrito todo o processo necessário para encontrar a rede ideal, definindo as entradas e saídas respectivas para executar o treino dessa mesma rede. Posteriormente pretende-se fazer o estudo de todos os resultados obtidos ao longo deste processo de modo a atingir o objetivo principal, cumprindo todos os critérios de avaliação definidos.

O método desenvolvido nesta dissertação tem como base os valores da subestação da Prelada, no entanto todo o processo é facilmente adaptável a qualquer outra subestação, desde que o conjunto de dados de entrada e saída sejam referentes a essa subestação.

4.1 Descrição e Funcionamento da ferramenta utilizada

No desenvolvimento desta dissertação foi utilizado o *software Microsoft Excel* para o tratamento, filtragem e análise de dados e resultados, foi também utilizado o MATLAB, versão R2010a, incluindo a sua ferramenta *Neural Network Fitting Tool* (comando *nftool*) para a realização do treino da RNA.

O MATLAB é uma linguagem de computação técnica, de alto nível. Esta linguagem é utilizada por inúmeros engenheiros e cientistas, uma vez que permite explorar e visualizar diversas ideias e áreas, como processamento de imagens e sinais, comunicações, sistemas de controlo, entre outros, e ainda oferece suporte para operações vetoriais e matriciais permitindo uma rápida execução e desenvolvimento [29].

As principais características desta linguagem são [29]:

-
- ✓ Linguagem de alto nível para computação numérica, visualização e desenvolvimento de aplicações.
 - ✓ Ambiente interativo.
 - ✓ Funções matemáticas para diversas áreas, como álgebra, estatística, otimização, entre outras.
 - ✓ Diversos tipos de ferramentas para criação de aplicações, de desenvolvimento, gráficos personalizados, entre outras.
 - ✓ Possibilidade de interagir com outras aplicações externas e linguagens, como C, Java, Excel.

O MATLAB contém ferramentas que permitem criar, treinar e simular rede neurais. Nesta dissertação, tal como já foi referido, será utilizada a ferramenta *Neural Networks Fitting Tool*. As ferramentas de redes neurais disponíveis no MATLAB fornecem funções e aplicativos para modelar sistemas não-lineares complexos e permitem realizar estudos de reconhecimento de padrões, previsões de séries temporais ou de cargas elétricas, ajuste de dados, entre outros [29].

As *Toolboxes* representam um grande conjunto de funções capazes de resolver de forma rápida e eficaz determinadas classes/categorias de problemas bastante complexos em diversas áreas, como por exemplo, as redes neurais artificiais ou otimização.

4.1.1 Neural Network Fitting Tool - Funcionamento

A *Tool* utilizada nesta dissertação, (*Neural Networks Fitting Tool*), resolve problemas de ajuste de *input-output* de uma rede neuronal *feedforward* de duas camadas, utilizando o algoritmo de *Levenberg-Marquardt backpropagation*.

Antes de iniciar esta *Toolbox* é aconselhável importar para o *workspace* os ficheiros de *Excel* necessários para a elaboração do treino, isto é, *Inputs* e *Targets*. Na janela de comando do MATLAB “chama-se” a função “nftool”. Na figura 18 está presente o esquema representativo da arquitetura da rede neuronal, composto pelos dados de entrada (*Input*), uma camada oculta (*Hidden Layer*), com neurónios ocultos ativados pela função

tangente hiperbólica, uma camada de saída (*Output Layer*), com neurónios de saída ativados pela função linear, e finalmente pelos dados de saída (*Output*).




Figura 18 – Esquema representativo da arquitetura da RN [30].

O próximo passo passa por definir os *Inputs* e *Targets*, como já foram importados para o *workspace* é só selecionar e colocar as “amostras” com a mesma orientação.

Antes de se iniciar o treino da RN o conjunto de dados selecionados é dividido em 3 subconjuntos, “Treino”, “Validação” e “Teste”, respetivamente, onde é possível determinar a percentagem de cada subconjunto a utilizar. Nesta fase ao determinar as percentagens a *Tool* vai gerar, aleatoriamente, as amostras de cada subconjunto, ou seja, treinar repetidas vezes vai gerar sempre conjuntos de saída diferentes devido às diferentes condições de entrada e de amostragem.

Os dados correspondentes ao treino vão sendo apresentados à RN e esta vai ajustando os pesos consoante o erro. Os dados de validação são utilizados para monitorizar a evolução do erro, num conjunto independente do treino. Este subconjunto serve também como medida de paragem do treino, antes que este atinja um *overfitting*. Quanto ao conjunto de dados de teste não tem qualquer tipo de consequência no treino, dando uma medida independente do desempenho da rede durante e após o treino, ou seja, é uma medida da capacidade de generalização da rede.

Por último seleciona-se o número de neurónios desejado, sendo aconselhável voltar a este ponto se o desempenho da rede não for o melhor, para alterar esse número. Nesta fase é apresentada a arquitetura final da RN a ser treinada, com o respetivo conteúdo de cada etapa, ou seja, o *Input* é composto por x linhas de valores, contém y neurónios na camada oculta, z camadas de saída e k conjuntos de resultados.

Com todos os parâmetros essenciais preenchidos é possível dar início ao treino. O treino pára automaticamente quando a generalização deixa de melhorar, como indicado pelo aumento no erro médio quadrático da amostra de validação.

O MATLAB utiliza o erro médio quadrático como critério de desempenho, quanto menor o erro melhor os resultados. Este erro é a diferença entre os valores de saída e os valores dos *Targets* (ou metas). Já a regressão é utilizada para medir a correlação entre as saídas e as metas, quanto mais perto de 1 estiverem estes valores melhor serão os resultados, ou seja, menor a diferença entre os valores em estudo.

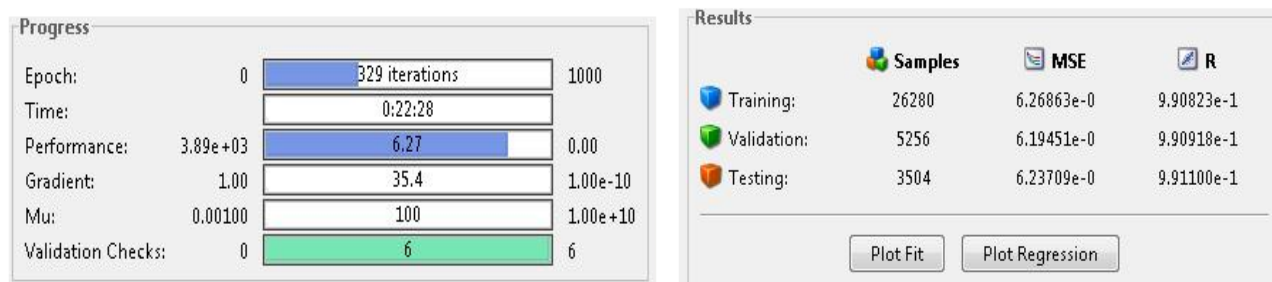


Figura 19 – Parâmetros de progresso durante o treino da RN e respectivos resultados finais [30].

Como é possível verificar na figura 19, durante o treino de uma rede pode-se acompanhar o progresso dos diferentes parâmetros do algoritmo de *Levenberg-Marquardt* que a ferramenta utiliza. A *Epoch*, que se trata do número de iterações, o tempo de treino, a performance alcançada, o gradiente, o Mu que representa o *momentum* da rede e por fim, o número máximo de aumentos do erro no conjunto de validação, que se encontra definido para 6.

No final de cada treino é possível guardar todos os resultados, desde gráficos de performance, regressão, entre outros, a valores de saída, erro e até a própria rede gerada. No entanto, se os resultados obtidos não forem os desejados pode-se voltar a treinar a rede, podendo também alterar a sua arquitetura, até encontrar resultados satisfatórios.

4.1.2 Tratamento dos dados

Antes de iniciar qualquer treino é necessário realizar o tratamento dos dados disponíveis, para minimizar possíveis erros. A fiabilidade do desempenho da RN depende da qualidade presente no conjunto de dados utilizados no treino [19].

Uma RN que seja bem treinada tem de ter a capacidade de generalizar, isto é, em contacto com dados que não estejam dentro do conjunto de treino tem de ser capaz de obter

resultados próximos do esperado. Se os conjuntos de dados tiverem erros ou ruídos a fiabilidade pode diminuir, isto porque a rede perde a capacidade de generalizar [19]. Deste modo, o conjunto de dados tem de ser cuidadosamente selecionado.

A REN disponibilizou valores do consumo de cargas no ano de 2013/2014, com a correspondência para os respetivos dias e horas. Como os dados disponibilizados são do mês de Dezembro de 2013 ao mês de Novembro de 2014 e para a realização dos treinos é necessário um conjunto de dados de um ano ao longo do estudo supõe-se que o mês de Dezembro de 2014 obteve resultados idênticos ao mês de Dezembro de 2013, garantindo assim um conjunto de dados de treino de um ano. Com esses conjuntos de dados e ainda os dados disponíveis no *site* de meteorologia do ISEP foi possível adquirir um conjunto de dados satisfatórios para posteriormente utilizar no treino da RN.

É importante referir que os dados disponíveis pela REN, e que serão utilizados nesta dissertação, dizem respeito à subestação da Prelada principalmente, e à subestação de Ermesinde (utilizada no capítulo 5, referente à previsão). Estes dados serão utilizados juntamente com os dados obtidos pelo *site* de meteorologia do ISEP, tal como já foi referido, deste modo é importante salientar que para o desenvolvimento deste método supôs-se que os valores meteorológicos são idênticos em todas as zonas estudadas, ou seja, supôs-se que apesar da distância existente entre as subestações da Prelada e de Ermesinde e o ISEP, os valores de temperatura, humidade, vento e luminosidade eram semelhantes nas três zonas.

Através dos dados da REN foi possível retirar dados como:

- Carga em MW da subestação da Prelada, e no capítulo 5 da subestação de Ermesinde;
- Dia do ano;
- Mês do ano;
- Horas;
- Dia da semana (representados de 1 a 7);
- Feriados (representados com 1 para Feriado e 0 quando não é).

Juntando aos dados referidos acima, os que foram adquiridos a partir do *site* de meteorologia do ISEP, Temperatura, Humidade, Vento e Luminosidade, totalizou um conjunto de 9 colunas de dados como *Inputs* e 1 coluna de dados como *Outputs*, no *Excel*.

Para evitar a existência de “maus” dados foi realizada uma análise pormenorizada dos mesmos com o intuito de evitar falhas e comprovar a qualidade dos dados. Através dos gráficos seguintes é possível garantir essa fiabilidade.

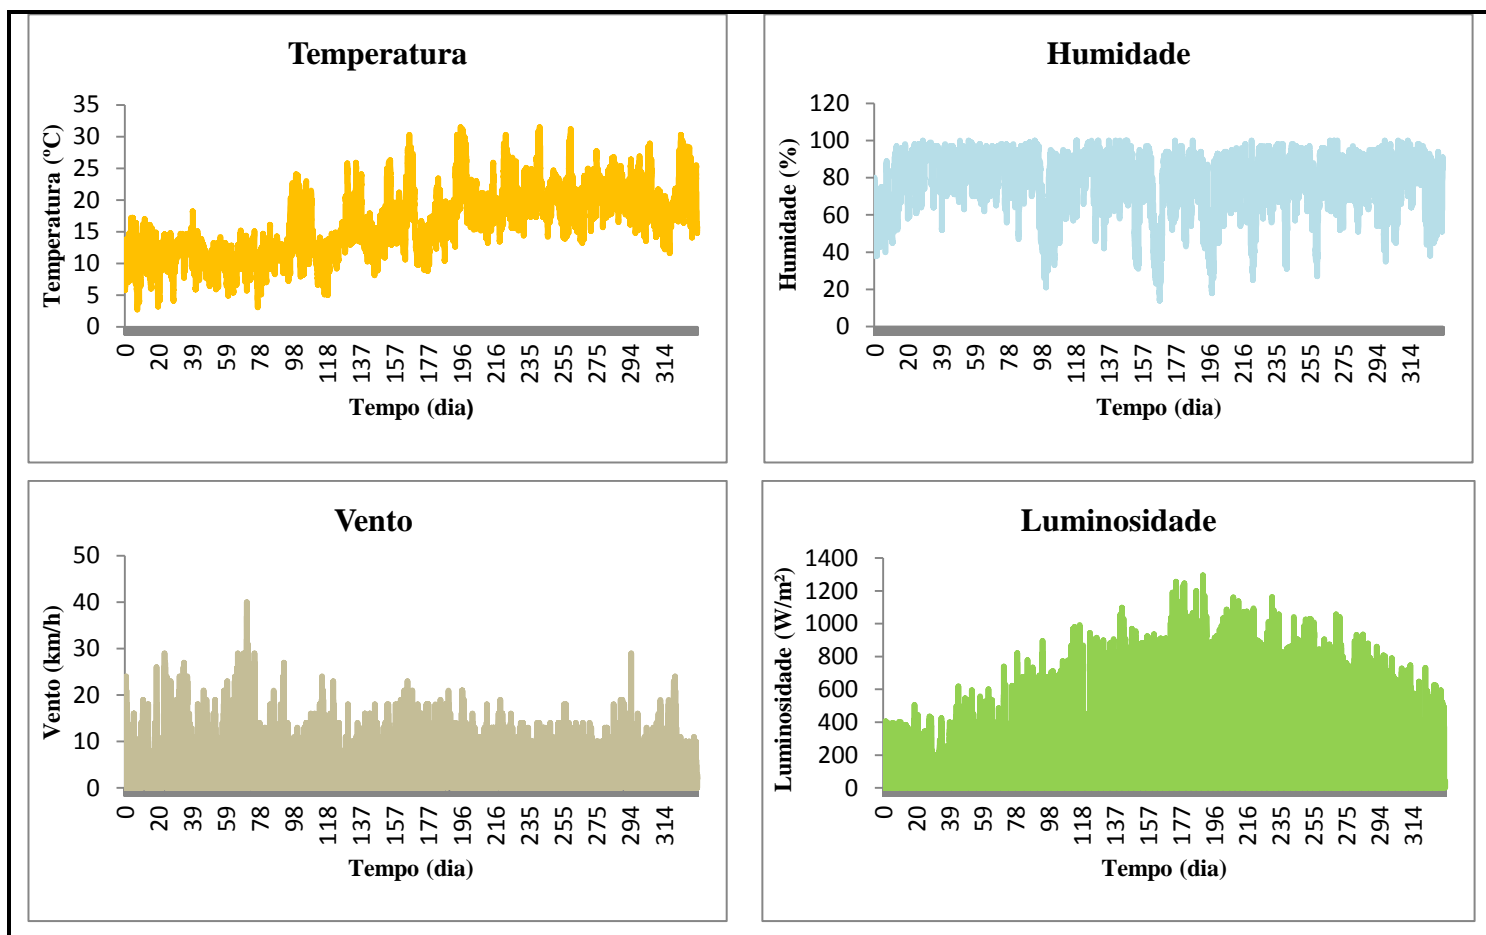


Figura 20 – Estudo de Dados utilizados na dissertação, em função do tempo em dias.

Os dados correspondentes à carga, depois de uma análise cuidadosa, também se encontram prontos a utilizar. Através do gráfico é possível verificar que os meses de inverno têm tendência a um maior consumo de energia.




Figura 21 – Estudo de dados da carga em função do tempo.

4.2 Método desenvolvido

Neste subcapítulo encontra-se descrito as várias etapas realizadas ao longo da dissertação com o objetivo de encontrar a rede ideal, criando um conjunto de opções diverso.

É importante referir que as redes serão treinadas tendo como horizonte os meses do ano, ou seja, para que uma rede permita, posteriormente, realizar a previsão de um determinado dia, semana ou mês é necessário ter um conjunto de estudo de pelo menos um ano, para que numa futura previsão a rede tenha parâmetros suficientes na sua aprendizagem de modo a conseguir prever os resultados pretendidos.

Para as primeiras três etapas é utilizado sempre o mesmo conjunto de *Inputs* e *Targets*, estes conjuntos contêm todos os dados com a exceção dos dados referentes à Humidade, Vento e Luminosidade que só serão utilizados a partir da 4ª etapa.

4.2.1 1ª Etapa – Encontrar o melhor número de neurónios

Nesta etapa definiu-se quatro números diferentes de neurónios, 10, 20, 25 e 30 respetivamente, e para cada um foram efetuados 5 treinos de modo a alargar o campo de opções e assim chegar a resultados melhores.

Todos os treinos contêm o mesmo conjunto de *Inputs* e *Targets* e a mesma percentagem, que por defeito está definida para 70% de Treino, 15% de Validação e 15% de Teste.

✓ Rede com 10 neurónios

Analisando todos os resultados obtidos no fim dos 5 treinos para redes de 10 neurónios conclui-se que a melhor rede alcançada contém um erro médio quadrático de 25,24726 para o treino.

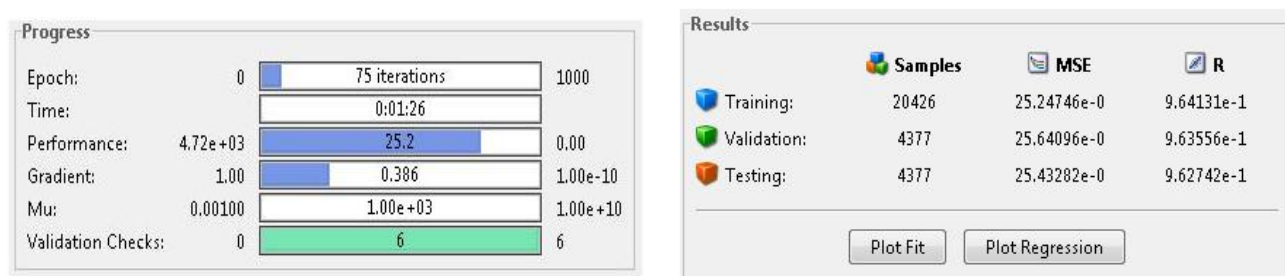


Figura 22 – Progressos e Resultados da melhor rede com 10 neurónios.

Esta rede executou um treino de 1min e 26s, com 75 iterações. A sua performance ao longo do treino foi idêntica para os três subconjuntos, atingindo o melhor desempenho de validação na iteração 69, com um erro de 25.641.




Figura 23 – Desempenho da melhor rede com 10 neurónios.

À medida que o treino procedia o coeficiente de correlação linear, R , ia medindo o grau de relacionamento linear entre os valores realizando assim uma análise dos dados de forma a estimar os valores que são esperados, ou seja, efetuando uma regressão linear.

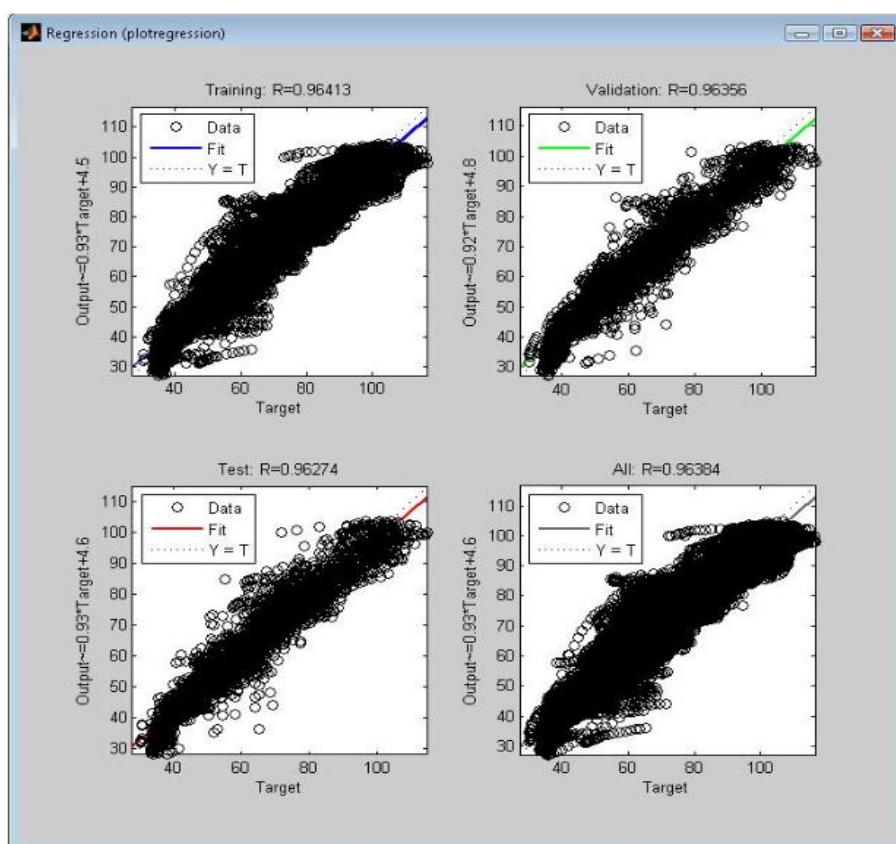


Figura 24 – Gráfico de Regressão da melhor rede com 10 neurónios.

✓ Rede com 20 neurónios

Para 20 neurónios a melhor rede encontrada demonstrou um erro médio quadrático de 9,25169 correspondente ao subconjunto treino. Na ferramenta em utilização para estes treinos 20 é o número de neurónios definido por defeito.

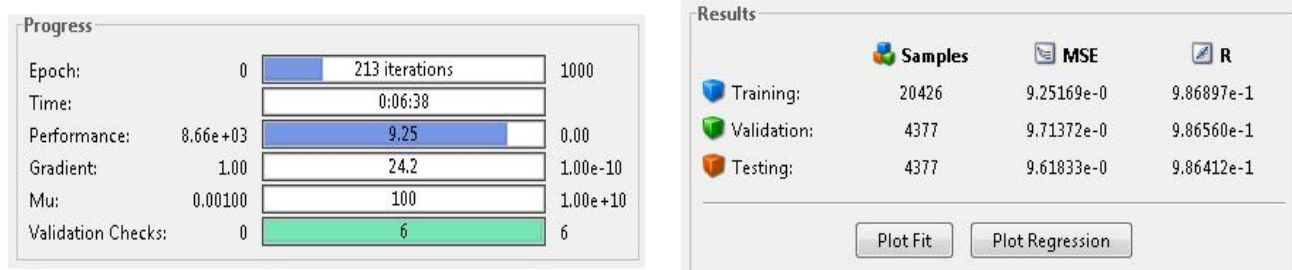


Figura 25 – Progressos e Resultados da melhor rede com 20 neurónios.

O treino desta rede realizou 213 iterações e durou 6min e 38s. Quanto ao seu desempenho, os subconjuntos acompanharam um progresso sem grandes discrepâncias e a melhor performance de validação foi atingida na iteração 207 com um erro médio quadrático de 9,7137.




Figura 26 – Desempenho da melhor rede com 20 neurónios.

À medida que o treino procedia, através de um estudo da regressão linear, era executada uma análise comparativa entre os valores dados de modo a estimar os que eram esperados. Os resultados desta regressão foram melhores que os apresentados na rede analisada

anteriormente para 10 neurónios. Pode-se verificar na figura 29 que a dispersão de dados é menor.

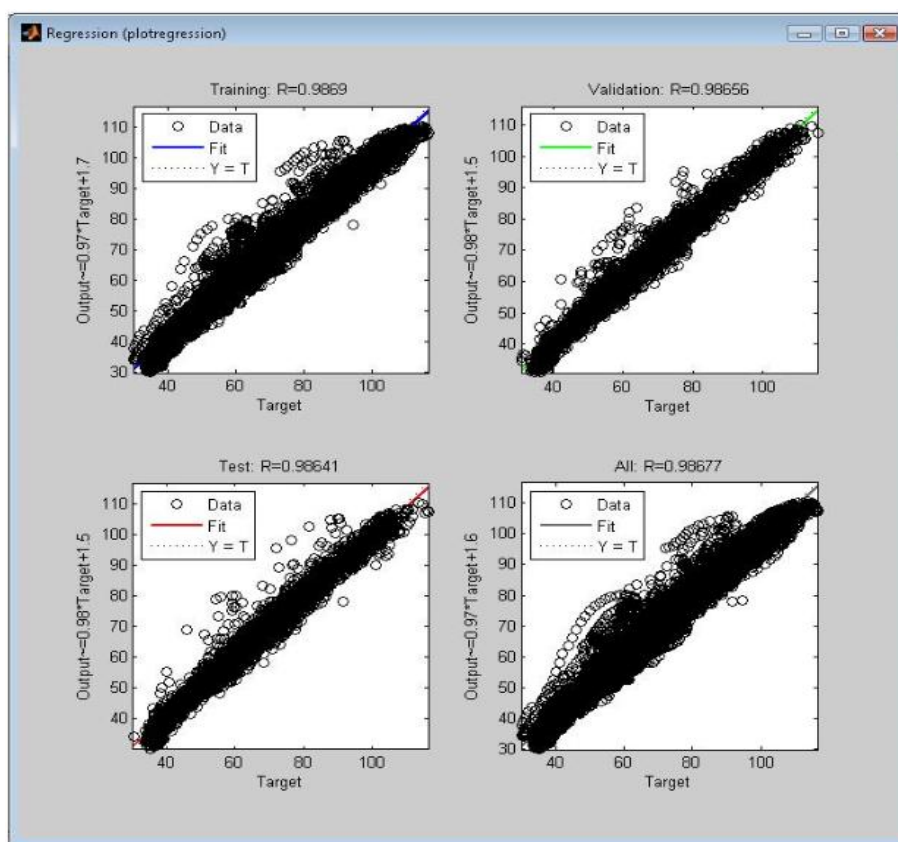


Figura 27 – Gráfico de Regressão da melhor rede com 20 neurónios.

✓ Rede com 25 neurónios

Entre os treinos efetuados para 25 neurónios, a melhor rede encontrada tem um erro médio quadrático de 7,23727 para o subconjunto treino, tendo um valor de erro próximo a esse nos restantes subconjuntos.

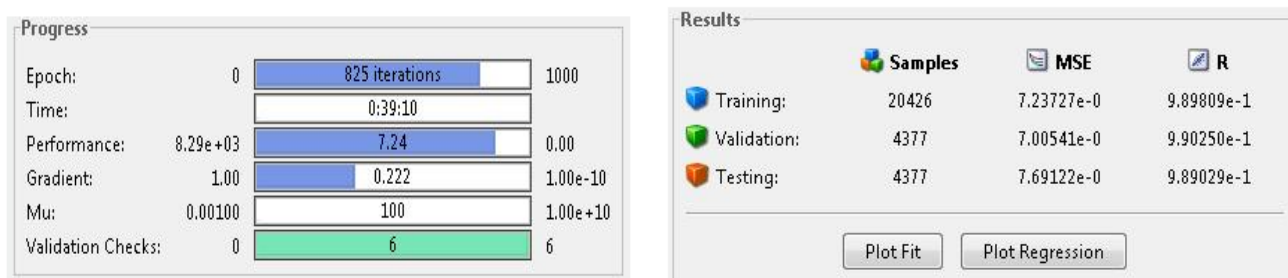


Figura 28 – Progressos e Resultados da melhor rede com 25 neurónios.

Esta rede efetuou, durante o seu treino, um total de 825 iterações em 39min e 10s. A sua melhor performance de validação foi alcançada na iteração 819, ou seja, pouco antes do treino terminar, com um erro de 7,0054.




Figura 29 – Desempenho da melhor rede com 25 neurónios.

No decorrer do treino é realizada, através de regressão linear, uma análise dos dados fornecidos de modo a estimar os valores esperados. O coeficiente de correlação, R, mede não só o relacionamento entre os valores como a intensidade e a direção da relação linear.

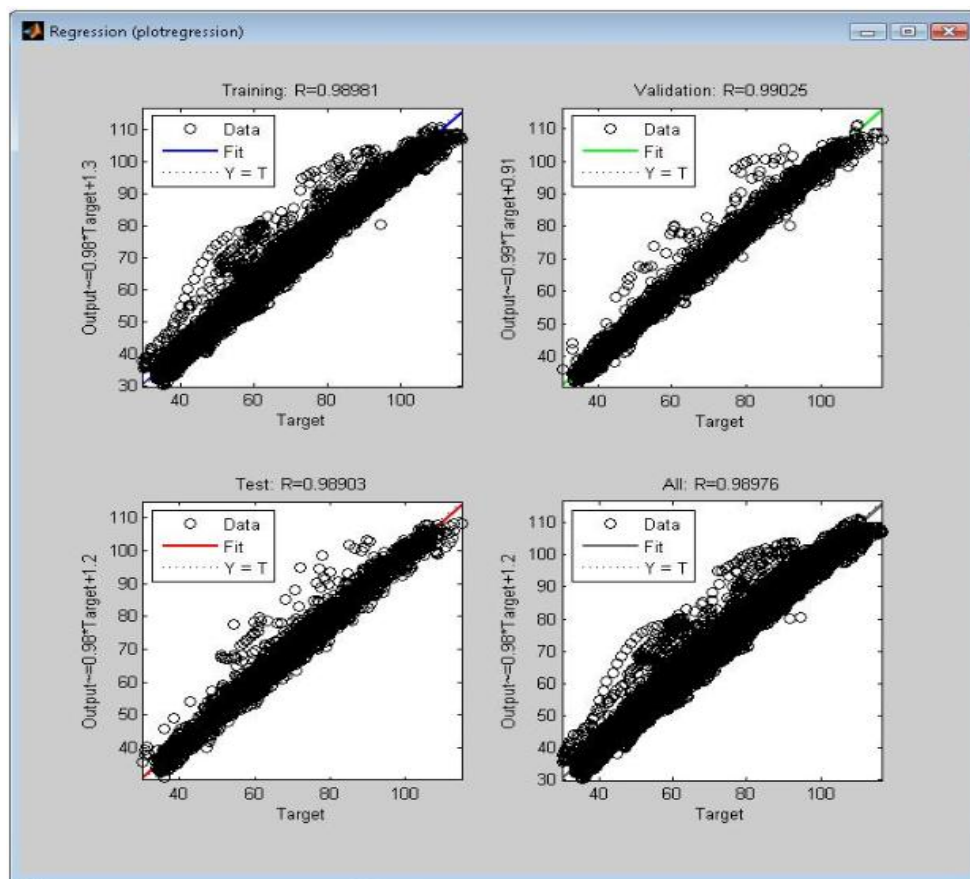


Figura 30 – Gráfico de Regressão da melhor rede com 25 neurónios.

✓ Rede com 30 neurónios

Por fim, no estudo da rede com 30 neurónios, o melhor treino ou a melhor rede encontrada atingiu, no subconjunto de treino, um erro médio quadrático de 6,94868 como se pode verificar na figura 31.

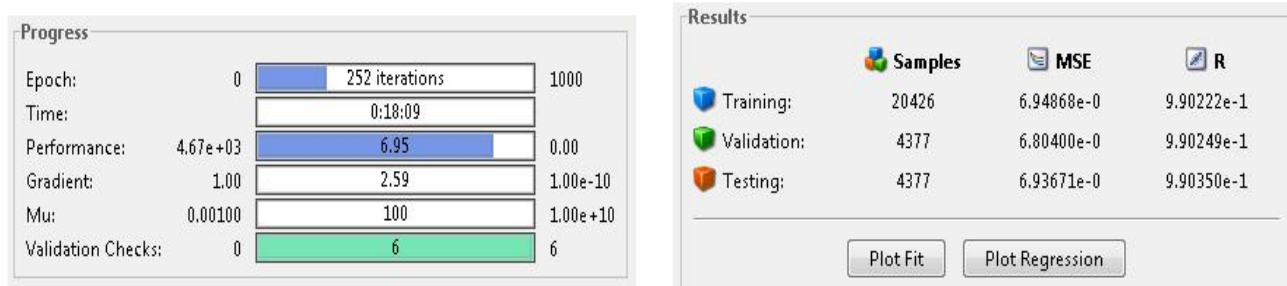


Figura 31 – Progressos e Resultados da melhor rede com 30 neurónios.

O treino desta rede finalizou com um total de 252 iterações em 18min e 09s. Relativamente à melhor performance de validação, esta foi obtida na iteração 246, com um erro médio quadrático de 6,804.




Figura 32 – Desempenho da melhor rede com 30 neurónios.

Quanto à análise da regressão linear, este caso foi o que atingiu os valores mais próximos de 1, que é o melhor caso. Todos os subconjuntos, treino, validação e teste, atingiram valores de regressão idênticos.

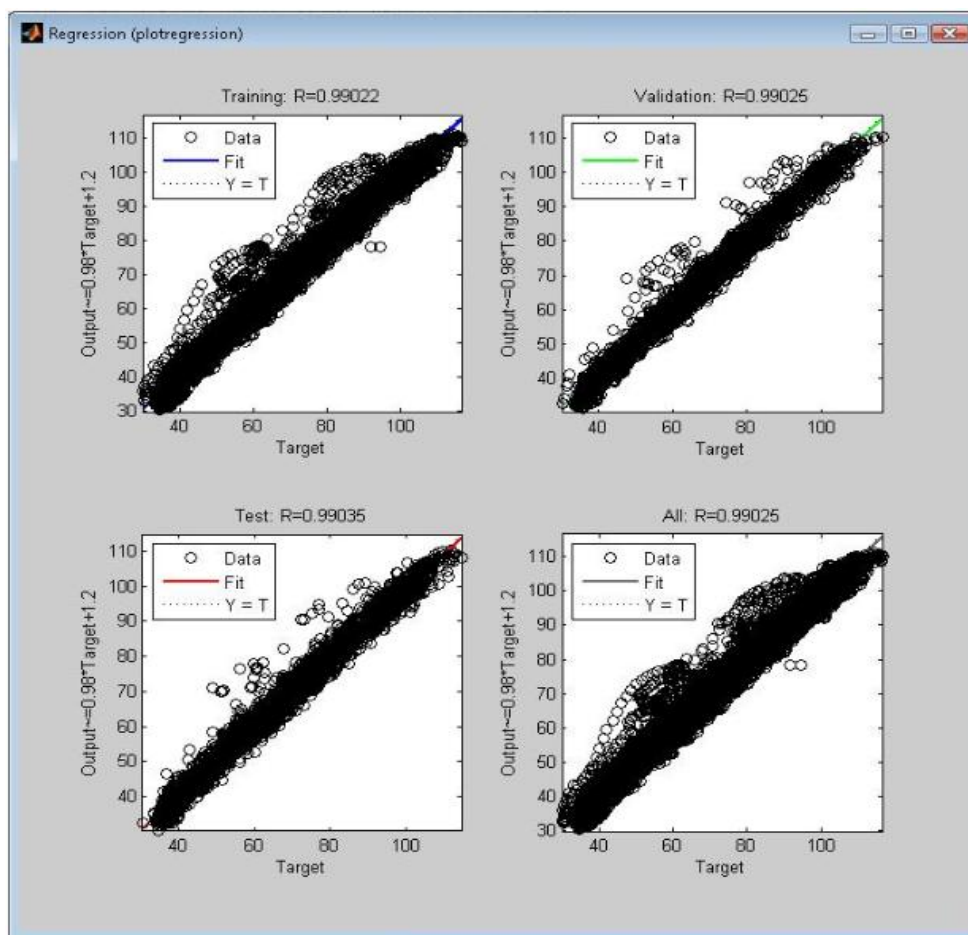


Figura 33 – Gráfico de Regressão da melhor rede com 30 neurónios.

4.2.2 2ª Etapa – Encontrar a melhor percentagem

Após a conclusão da etapa anterior, esta fase consiste na escolha das percentagens de Treino, Validação e Teste. Utilizando o melhor número de neurónios escolhido e os mesmos *Inputs* e *Targets* em todos os treinos, serão realizados treinos para as diversas possibilidades de escolha de percentagens com o intuito de, no fim, comparar as várias opções e escolher a que melhor se adequa.

Depois da realização dos treinos para os casos possíveis a melhor opção de percentagens a utilizar é de 75% de Treino, 15% de Validação e 10% de Teste. Esta escolha foi tomada tendo em consideração os resultados obtidos em todos os treinos e o facto de o subconjunto de treino ser o mais relevante para alcançar uma boa rede.

A melhor rede com as percentagens referidas anteriormente obteve um erro médio quadrático de 6,11048. Este treino foi realizado em 8min e 21s e fez um total de 179 iterações.

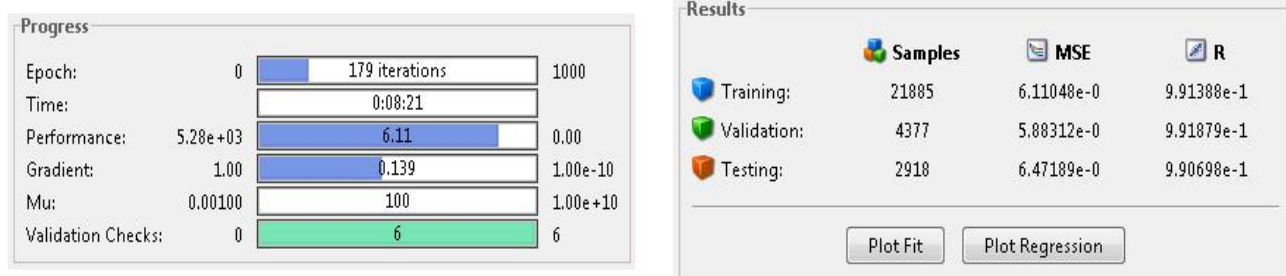


Figura 34 – Progressos e Resultados da melhor rede para as percentagens 75%, 15% e 10%, Treino, Validação e Teste, respetivamente.

A escolha desta rede entre as várias opções, com outras percentagens, foi feita de acordo com critérios como a escolha da rede com o menor erro e a percentagem de treino superior a 50%.

A rede escolhida teve o melhor desempenho de validação na iteração 173 com um erro de 5,8831.




Figura 35 – Desempenho da melhor rede.

Os gráficos de regressão linear apresentam bons resultados, tendo valores semelhantes nos três subconjuntos e muito próximo de 1.

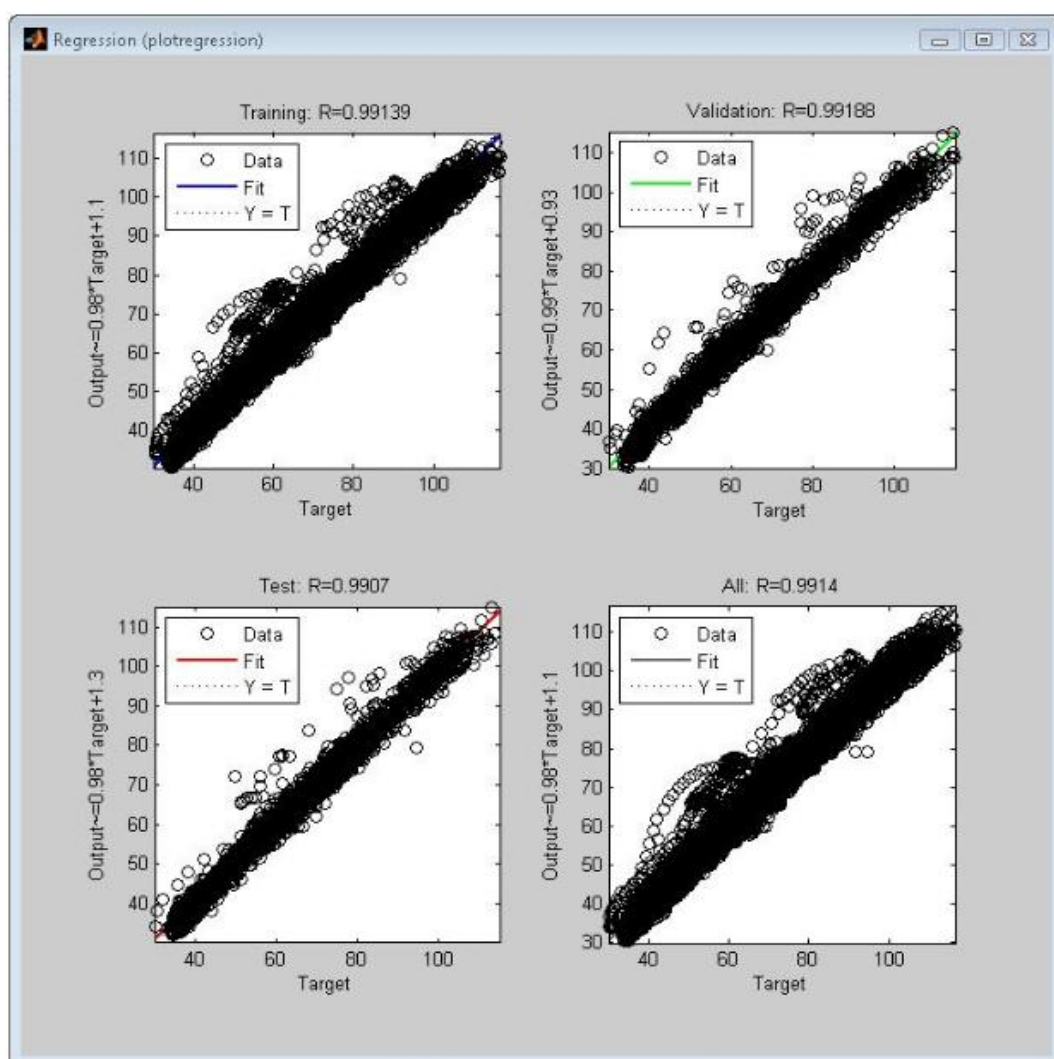


Figura 36 – Gráfico de Regressão da melhor rede.

4.2.3 3ª Etapa – Testar resultados anteriores

Esta etapa consiste em testar os resultados obtidos anteriormente, ou seja, utilizando o melhor número de neurónios e as melhores percentagens, realizou-se cinco treinos com o intuito de encontrar a rede com os melhores valores e assim testar se as condições obtidas no final das etapas anteriores são favoráveis.

A melhor rede obtida no final destes treinos obteve um erro médio quadrático semelhante nos dois primeiros subconjuntos e um pouco maior no terceiro, tal como o valor de

regressão. Este treino demorou cerca de vinte minutos, o que mostra que quando se trata de estudos com RN os parâmetros, tempo e resultados finais, são muito variáveis.

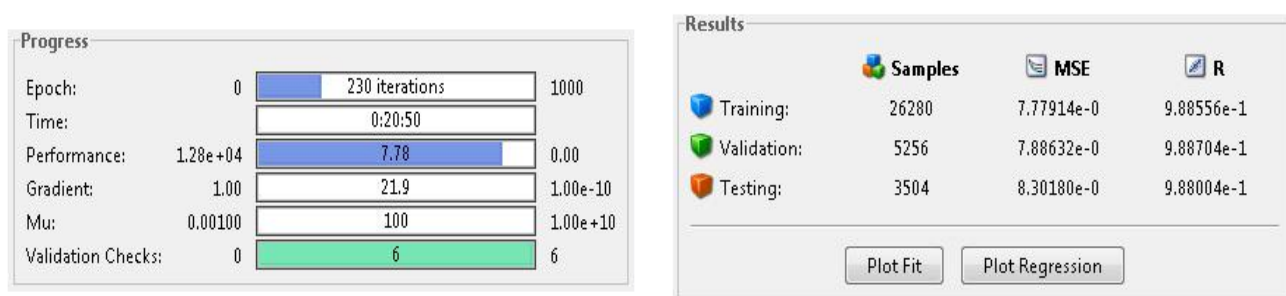


Figura 37 – Progressos e Resultados da melhor rede, utilizando as melhores condições obtidas.

A sua melhor performance foi obtida na iteração 224 com um erro médio quadrático de 7,8863. Neste caso o teste teve um valor de erro superior em comparação ao do treino e da validação.




Figura 38 – Desempenho da melhor rede, utilizando as melhores condições obtidas.

4.2.4 4ª Etapa – Encontrar a melhor rede para os diferentes conjuntos de dados

A etapa em questão tem como objetivo comparar os melhores resultados obtidos nos treinos com diferentes entradas, utilizando o melhor número de neurónios e as melhores percentagens, e assim verificar a importância/impacto que dados como Humidade, Vento, Luminosidade ou Feriados têm no treino de uma RN.

Antes de escolher a melhor rede dentro de cada conjunto de treino foram realizados pelo menos cinco treinos para existir um maior campo de opções e assim obter melhores resultados. As etapas realizadas até este ponto continham no ficheiro de entrada dados como, o dia, o mês, as horas, se era ou não feriado, dia da semana e a temperatura, na etapa presente foi acrescentado ou retirado em cada conjunto de treino um novo dado de entrada e no fim foram utilizados todos os dados.

✓ **Inputs utilizados até à etapa 3 mais Humidade**

No final dos vários treinos realizados com a utilização dos dados da humidade a melhor rede alcançada mediu um erro médio quadrático de 7,04082 relativamente ao subconjunto de treino, nos subconjuntos restantes o erro foi ligeiramente superior para o teste e inferior para a validação.

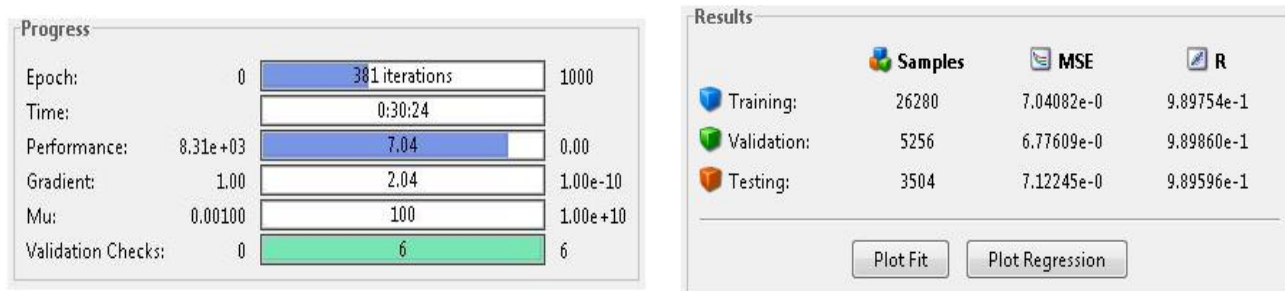


Figura 39 – Progressos e Resultados da melhor rede com a humidade.

Apesar de esta rede ter realizado 381 iterações o melhor desempenho de validação foi obtido na iteração 375 com um erro de 6,7761. Este subconjunto foi o que apresentou um valor de erro mais pequeno.




Figura 40 – Desempenho da melhor rede com a humidade.

Tendo em consideração os resultados obtidos na terceira etapa pode-se dizer que os valores de humidade têm um efeito positivo na procura da melhor rede. São valores importantes a ter em conta.

✓ **Inputs utilizados até à etapa 3 mais Vento**

Com a utilização dos dados do Vento a melhor rede, dentro dos treinos efetuados, alcançou um erro médio quadrático pior a nível de teste. No entanto, relativamente ao treino, conseguiu atingir um erro de 6,62342 e os valores de regressão foram próximos nos três subconjuntos.

Progress			
Epoch:	0	574 iterations	1000
Time:		0:31:38	
Performance:	3.05e+04	6.62	0.00
Gradient:	1.00	52.8	1.00e-10
Mu:	0.00100	100	1.00e+10
Validation Checks:	0	6	6

Results			
	Samples	MSE	R
Training:	26280	6.62342e-0	9.90347e-1
Validation:	5256	6.68089e-0	9.90060e-1
Testing:	3504	7.63422e-0	9.88925e-1

Plot Fit Plot Regression

Figura 41 – Progressos e Resultados da melhor rede com o vento.

Como é possível verificar na figura anterior a rede em análise efetuou um treino de 574 iterações, em 31min e 38s. Esta rede obteve o seu melhor desempenho na iteração 568, com o valor 6,6809 como erro.

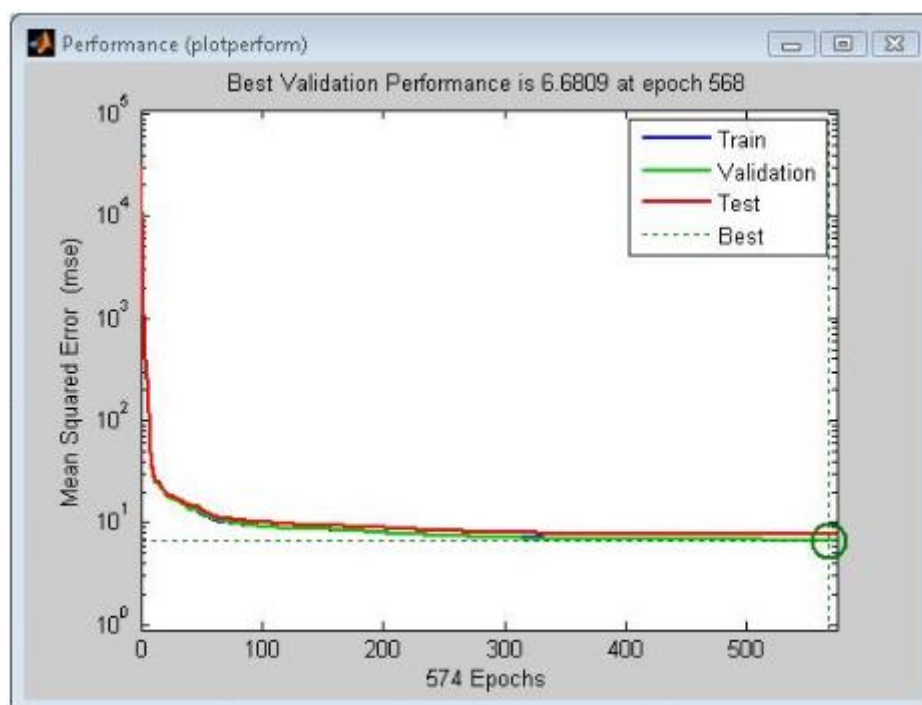


Figura 42 – Desempenho da melhor rede com o vento.

Comparando com a rede obtida na etapa número três mostra que os valores do vento podem vir a ser considerados como uma mais-valia, uma vez que foi possível obter resultados mais satisfatórios.

✓ **Inputs utilizados até à etapa 3 mais Luminosidade**

Utilizando dados como a luminosidade a melhor rede obtida, entre os treinos realizados, teve um erro médio quadrático de 6,08541 para o treino. Neste caso, a validação foi o subconjunto com o melhor erro.




Figura 43 – Progressos e Resultados da melhor rede com a luminosidade.

Em termos de desempenho esta rede desenvolveu-se ao longo de 478 iterações, num espaço de tempo de 52min e 03s, obtendo a melhor performance às 472 iterações, pouco antes de terminar o treino, com um erro médio quadrático de 5,9603.




Figura 44 – Desempenho da melhor rede com a luminosidade.

Os valores de luminosidade demonstraram, segundo os resultados obtidos, um impacto favorável para a criação de uma RN mais eficiente quando comparados com os valores atingidos na etapa três, o que pode ser esperado tendo em conta que a iluminação natural ou a falta dela é um fator importante para o uso de energia elétrica.

✓ Todos os dados

Este ponto, que se trata da utilização de todos os dados adquiridos para a presente dissertação, representa a rede mais importante de todo o trabalho. A melhor rede obtida, entre todos os treinos realizados, será utilizada na última etapa desta dissertação para a realização da previsão.

Com a conclusão dos treinos nesta fase, a melhor rede encontrada contém um erro de 6,26863 correspondente ao treino e um valor de regressão de 0,990823 para o mesmo subconjunto. Os valores obtidos em todos os subconjuntos são relativamente próximos, entre si e comparando com todos os casos estudados até ao momento é das redes com melhores resultados.

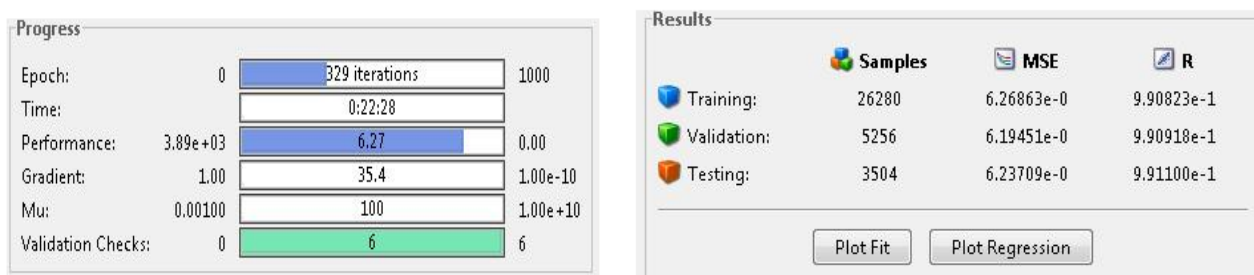


Figura 45 – Progressos e Resultados da melhor rede com todos os dados.

A nível de desempenho, como se pode verificar na figura 46, a prestação dos três subconjuntos foi idêntica salientando uma pequena diferença existente a nível da validação. A melhor performance obtida quanto à validação está presente na iteração 323 com um erro de 6,1945.

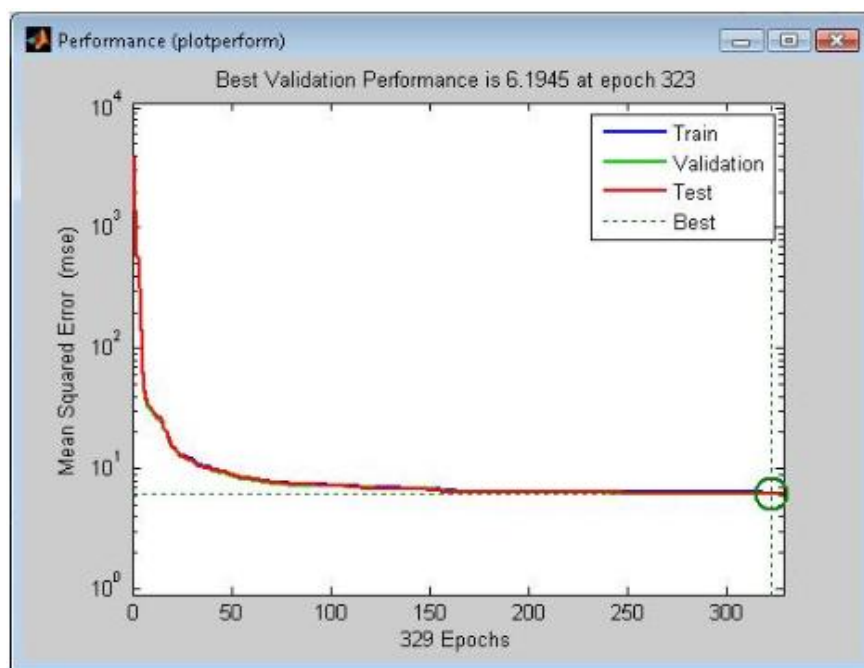


Figura 46 – Desempenho da melhor rede com todos os dados.

Ao longo desta etapa verificou-se que nem todos os dados, em separado, obtinham resultados proeminentes, no entanto utilizados ao mesmo tempo foi possível atingir valores bastante satisfatórios.

✓ Todos os dados exceto feriados

Este último ponto permite observar a diferença que causa a utilização de feriados na previsão de cargas. A melhor rede obtida, entre os treinos realizados para este ponto, contém um erro médio quadrático de 10,99393 no treino.

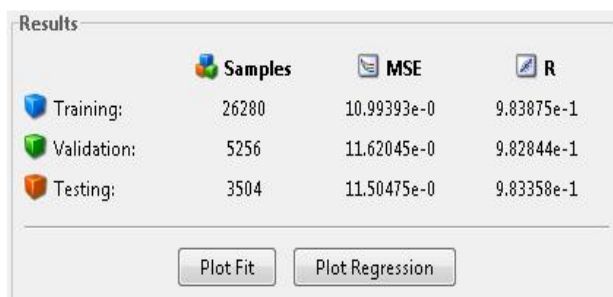



Figura 47 – Progressos e Resultados da melhor rede sem feriados.

Tendo em consideração todas as redes estudadas até ao momento, esta rede não é a que se encontra com melhor desempenho. A melhor performance de validação desta rede obteve um erro de 11,6205 na iteração 470.




Figura 48 – Desempenho da melhor rede sem feriados.

Analisando a rede em questão conclui-se que os feriados são dados relevantes para obter uma RN com resultados mais perto do esperado. Estes dados tornam-se muito importantes para a previsão do diagrama de carga.

4.3 Análise e Conclusões

De modo a ilustrar os vários passos executados para o desenvolvimento das redes utilizadas e a sua avaliação, a figura 49 apresenta o fluxograma de todo o processo de estudo desenvolvido nesta dissertação [19].

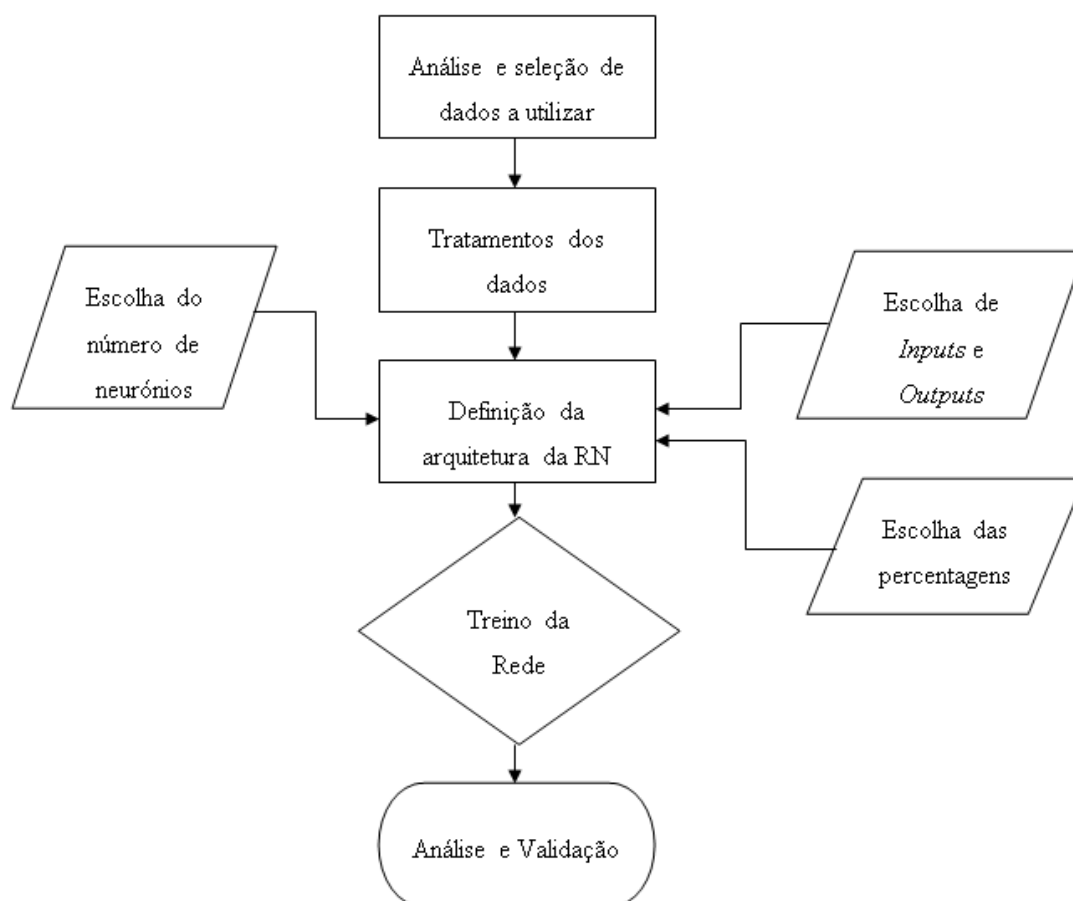


Figura 49 – Fluxograma do processo desenvolvido para o treino das RNA.

4.3.1 Análise de Resultados

Relativamente à 1ª etapa, tem como objetivo obter o melhor número de neurónios a utilizar na RN, deste modo através dos treinos realizados torna-se possível concluir que quanto maior é o número de neurónios melhor são os resultados obtidos, no entanto os treinos têm tendência a demorar mais tempo. Dentro do campo de opções estudadas chega-se à conclusão de que o melhor número de neurónios a usar nos treinos seguintes é de 30.

A melhor rede obtida para este valor, apesar de ao longo do treino ter grandes picos de variação de erro, no final do desempenho demonstrou alcançar valores bastante próximos do esperado, como se pode verificar na pequena amostra de dados utilizados no gráfico da figura 50.




Figura 50 – Gráfico de resultados da melhor RN da 1ª Etapa, com 30 neurónios.

Este gráfico não utiliza todo o conjunto de dados usados no treino, apenas uma parte, de modo a se tornar mais visível a diferença entre os dois conjuntos de resultados.

Após a escolha do número de neurónios, a 2ª etapa permite obter as percentagens de Treino, Validação e Teste que permitem uma proximidade maior à rede desejada. Nesta etapa, ao analisar as diversas possibilidades conclui-se que a melhor opção passa pelas percentagens de 75% no Treino, 15% na Validação e 10% no Teste.




Figura 51 – Gráfico de resultados da melhor RN da 2ª Etapa.

Mais uma vez os resultados obtidos não tiveram grandes discrepâncias no entanto é visível na figura 51 que os valores resultantes do treino têm geralmente tendência a serem inferiores ao valores esperados.

Quanto à 3ª etapa, o objetivo assenta no treino de uma RN que coloca em estudo os resultados obtidos nas etapas anteriores e assim demonstra que as decisões tomadas até ao momento são aceitáveis, tendo em consideração os resultados alcançados.

Por outro lado, a 4ª etapa pretende, utilizando o número de neurónios e as percentagens escolhidas, acrescentar novos dados de entrada, ou excluir, e comprovar a sua utilidade. Tendo em atenção os resultados analisados anteriormente, pode-se afirmar que quando os dados são todos utilizados em conjunto é possível chegar a resultados melhores. Contudo, em separado, alguns dados não se mostram muito significativos, como por exemplo a utilização da temperatura apenas, e outros mostram ter uma grande influência nos resultados finais, como por exemplo os feriados.




Figura 52 – Gráfico de resultados da melhor RN da 4ª Etapa, com todos os dados.

O gráfico anterior contém uma comparação entre os resultados obtidos e os esperados, de parte dos dados utilizados, e através da sua análise verifica-se algumas discrepâncias entre os valores, no entanto existe uma grande semelhança entre ambos os conjuntos.

4.3.2 Conclusões

Tendo em consideração a análise de resultados e todo o procedimento utilizado ao longo deste capítulo, pode-se concluir que a ferramenta utilizada (*Neural Network Fitting Tool*) no desenvolvimento desta dissertação permite alcançar bons resultados.

O método desenvolvido passou por quatro etapas, em que as três primeiras foram essencialmente para obter as melhores características que a rede deveria possuir para alcançar a rede ideal e testar essas opções. No final destas primeiras etapas é possível concluir que a utilização de 30 neurónios e percentagens de 75%, 15% e 10% (Treino, Validação e Teste, respetivamente) são as melhores opções a utilizar, baseando esta escolha nos resultados obtidos. É importante salientar que um maior número de neurónios nem sempre é a escolha ideal para alcançar melhores resultados, ou seja, por vezes menos neurónios levam a melhores resultados, dependendo do estudo que esteja a ser efetuado e das suas variantes.

Relativamente à quarta etapa, é possível verificar que dados como feriados são essenciais, neste tipo de estudo, para alcançar resultados mais favoráveis, uma vez que a nível de treino da RN têm um grande impacto nos resultados obtidos. Esta etapa permite concluir que as opções atingidas nas etapas anteriores são favoráveis e que a utilização de todo o conjunto de dados disponíveis permite obter melhores resultados do que a utilização de alguns dados em separado.

Para o treino de uma RN quanto maior o número de dados disponíveis melhor, tornando-se mais fácil e eficiente a aprendizagem e criação de uma rede com valores mais próximos aos reais.



5. Previsão do Diagrama de Carga

Depois do estudo realizado no capítulo anterior, o presente capítulo tem como objetivo principal a previsão de diagramas de carga utilizando a melhor RN.

Ao longo deste capítulo será utilizada a melhor RNA encontrada, para cada subestação, através do estudo de todos os dados disponíveis, para um ano. Com a respectiva rede é feita a previsão para uma semana e para um dia, no mês de Março de 2015, das diferentes subestações, sendo posteriormente efetuada a comparação com os valores reais de modo a verificar a fiabilidade da RN.

5.1 Características das RNA utilizadas

A RN utilizada no processo de previsão, para cada subestação, é a rede com a melhor performance, obtida entre um conjunto de 5 treinos, utilizando todos os dados adquiridos para o estudo em questão.

Na figura 53 encontra-se representada a estrutura da rede neuronal, em utilização. Nesta rede foram definidas nove variáveis de entrada e uma de saída. As variáveis presentes no esquema têm o seguinte significado [2]:

- D – Dia, que representa o dia do mês (1, 2, 3,... 30, 31);
- M – Mês, que representa o mês em questão (1 = Janeiro, 2 = Fevereiro, ..., 12 = Dezembro);
- H – Hora do dia, em segundos (o estudo é feito com dados de 15 em 15 min);
- F – Feriados, que representa se o respetivo dia do mês é ou não feriado (1 = é feriado, 0 = não é feriado);
- DS – Dia da semana (1 = Domingo, 2 = Segunda-feira, ..., 7 = Sábado);

- Temp – Temperatura, representa a temperatura num determinado dia do mês à respetiva hora;
- Hum – Humidade, representa a humidade num determinado dia do mês à respetiva hora;
- Vent – Vento, representa a velocidade do vento num determinado dia do mês à respetiva hora;
- Lum – Luminosidade, representa a luminosidade num determinado dia do mês à respetiva hora.




Figura 53 – Estrutura da Rede Neuronal.

No funcionamento de uma rede neuronal artificial, cada uma das variáveis utilizadas na camada de entrada é ligada a um neurónio, ou seja, neste caso a camada de entrada é composta por 9 neurónios [19]. A informação contida na camada de entrada é, posteriormente, enviada para as camadas escondidas [19]. A camada escondida pode ser composta por várias camadas e essas podem conter vários neurónios [19].

Neste caso, utilizou-se apenas uma camada escondida, constituída por 30 neurónios, como é possível verificar na figura 54, que representa o esquema de uma RNA treinada através da ferramenta *Neural Network Fitting Tool (nftool)*.




Figura 54 – Esquema da arquitetura de uma RNA treinada na *nftool*.

5.2 Procedimento utilizado para a Previsão

Através de novos dados adquiridos pela REN, referentes às cargas utilizadas no mês de Março de 2015, pela subestação da Prelada, e utilizando a melhor rede obtida no capítulo anterior, para todos os dados, realizou-se a previsão para um dia e uma semana aleatórios do mês de Março. Além da subestação da Prelada, foi repetido o mesmo processo já descrito anteriormente para a subestação de Ermesinde, realizando também a previsão para um dia e uma semana aleatórios do mês de Março.

Para efetuar esta previsão é necessário, utilizando o MATLAB, importar para o *workspace* os novos *Inputs*, depois de devidamente tratados, e a melhor rede neuronal treinada para o conjunto das 9 variáveis.

Os dados de entrada têm de estar dispostos por linhas, por exemplo deve ser uma matriz de 9×96 e não uma matriz de 96×9 , deste modo os dados de entrada necessitam de ser transpostos para serem utilizados na previsão. Para realizar a transposta, na janela de comandos do MATLAB utiliza-se a função *transpose* da seguinte forma:

$$a = \text{transpose}(b); \quad (12)$$

Com os *Inputs* dispostos na ordem desejada, utiliza-se uma função criada para calcular saídas, ou seja, para através da rede desejada e dos *Inputs* calcular os *Outputs* e assim realizar a previsão.

A função criada para calcular as saídas encontra-se presente na figura seguinte.




Figura 55 – Função calcular saídas.

Com o ficheiro acima demonstrado, através da rede e dos dados de entrada desejados tem-se os elementos necessários para o próximo passo, o cálculo dos *Outputs*. Na janela de comandos do MATLAB utiliza-se a função para calcular as saídas do seguinte modo:

$$\text{Resultados} = \text{calcular_saidas}(\text{net}, \text{inputs}); \quad (13)$$

Assim, obtém-se a previsão de cargas utilizando a rede que obteve a melhor performance e novos dados de entrada, que foram tratados e organizados no mesmo formato que foi utilizado no processo de treino da rede escolhida de modo a garantir o bom funcionamento deste processo.

5.3 Previsão de Diagrama de Carga do dia 18 de Março de 2015, da subestação da Prelada

Utilizando o processo descrito no subcapítulo anterior, realizou-se a previsão de diagrama de carga do dia 18 de Março de 2015. Através dos resultados obtidos e dos valores que eram esperados obteve-se o gráfico seguinte.




Figura 56 – Gráfico de Previsão de Diagrama de Carga do dia 18 de Março de 2015.

Através da análise deste gráfico, figura 56, verifica-se que os valores obtidos através da previsão são próximos dos valores reais (esperados), no entanto têm tendência a serem ligeiramente inferiores.

Realizando a diferença entre os valores representados no gráfico de previsão obtém-se o erro existente entre eles. O erro obtido entre os dois conjuntos é, em média, 4,28, tendo uma variação entre 8,70 e 0,04.




Figura 57 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados do dia 18 de Março de 2015.

5.4 Previsão de Diagrama de Carga da primeira semana de Março de 2015, da subestação da Prelada

Para efetuar a previsão de diagrama de carga da primeira semana de Março de 2015 utilizou-se novamente o mesmo processo já descrito, no subcapítulo 5.2. De modo a comparar os valores obtidos na previsão com os valores reais criou-se um gráfico onde é possível analisar os resultados finais.




Figura 58 – Gráfico de previsão de diagrama de carga da primeira semana de Março de 2015.

Analizando o gráfico da figura 58 é possível afirmar que a utilização de redes neuronais pode ser uma ajuda na previsão de diagramas de carga uma vez que os resultados obtidos são muito próximos dos resultados reais, no entanto não prevê com exatidão devido a pequenas variações e ao erro que está presente no processo de aprendizagem que nunca chega a ser nulo.

O gráfico da figura 59 mostra a diferença existente entre os dados comparados, ao longo das 672 células de dados que cada conjunto contém, que representam os 7 dias.




Figura 59 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados da 1ª semana de Março de 2015.

Realizando a diferença entre todos os valores e a sua média, obtém um valor de 2,49 de erro médio. A variação de erro ocorre entre os valores 9,88 e 0,01.

5.5 Previsão de Diagrama de Carga para outras Subestações da REN

Supondo que os valores de Temperatura, Humidade, Vento e Luminosidade são idênticos na zona da subestação de Ermesinde, realizou-se a previsão, para um dia e uma semana no mês de Março de 2015, utilizando a melhor rede obtida entre os 5 treinos realizados e os novos dados de entrada. O processo para alcançar a melhor rede para os valores desta subestação foi igual ao processo realizado, anteriormente, na subestação da Prelada.

A melhor rede obtida através dos dados utilizados no treino, para a subestação de Ermesinde, atingiu um erro médio quadrático de 16,09205 no subconjunto de treino, alcançando a sua melhor performance de validação na iteração 619, com um erro de 17,1039.

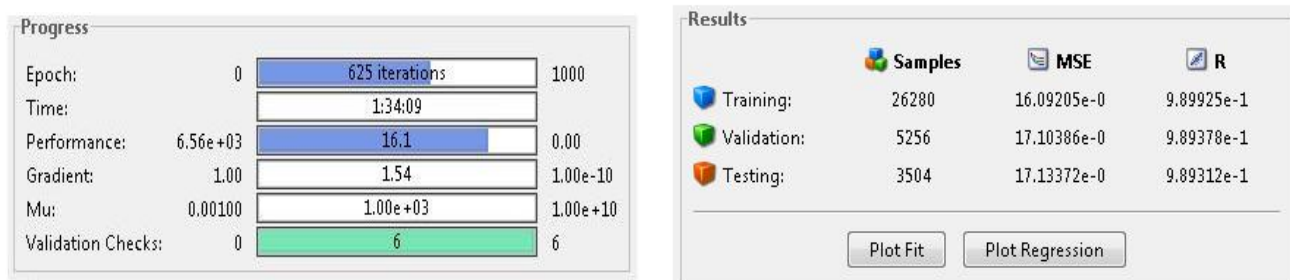


Figura 60 – Progressos e Resultados da melhor rede para a subestação de Ermesinde.




Figura 61 – Desempenho da melhor rede para a subestação de Ermesinde.

Apesar da rede em questão ter obtido um erro bastante superior, quando em comparação com a melhor rede obtida na subestação da Prelada, e ter demorando um longo período de tempo a terminar o processo de aprendizagem, no processo de previsão permitiu alcançar valores próximos dos esperados e o valor de erro médio das previsões tem, geralmente, apenas uma diferença de 3 valores, o que tendo em consideração a diferença de desempenho de aprendizagem, entre as duas subestações, não é muito discrepante.

5.5.1 Previsão do Diagrama de Carga do dia 30 de Março de 2015, na subestação de Ermesinde

Mais uma vez, utilizando o processo descrito no subcapítulo 5.2, referente à previsão, realizou-se a previsão de diagrama de carga do dia 30 de Março de 2015 da subestação de Ermesinde.




Figura 62 – Gráfico de previsão de diagrama de carga do dia 30 de Março de 2015, da subestação de Ermesinde.

Analisando o gráfico anterior, verifica-se que os valores obtidos na previsão têm tendência a serem superiores aos valores esperados, contrariamente ao que acontecia na subestação da Prelada. Pode-se verificar ainda um aumento do erro entre os dois conjuntos de dados à medida que o tempo aumenta, principalmente a partir das 17h, aproximadamente.




Figura 63 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados do dia 30 de Março de 2015, na subestação de Ermesinde.

O gráfico de variação do erro, figura 63, mostra que ao longo do conjunto de dados comparado o valor do erro demonstrou uma tendência de aumento, apesar da existência de constantes subidas e descidas. No entanto o erro médio atingido, neste dia, foi de 7,17, existindo uma variação entre um erro máximo de 24 e um erro mínimo de 0,01.

5.5.2 Previsão do Diagrama de Carga da segunda semana de Março de 2015, na subestação de Ermesinde

Utilizando o processo de previsão desenvolvido nesta dissertação, para prever diagramas de carga, realizou-se a previsão, na subestação de Ermesinde, para a segunda semana do mês de Março de 2015 com o intuito de comparar os valores obtidos na previsão com os valores reais.




Figura 64 – Gráfico de previsão de diagrama de carga da 2ª semana de Março de 2015, da subestação de Ermesinde.

Através do gráfico da figura 64 pode-se verificar que, mais uma vez, os valores alcançados na previsão tendem a ser ligeiramente superiores aos dados reais, no entanto seguem a linha dos resultados esperados, ou seja, têm tendência a ter um comportamento idêntico aos valores reais, apesar de existir uma pequena diferença entre os resultados.




Figura 65 – Gráfico de variação de erro entre resultados obtidos na previsão e os resultados esperados da 2ª semana de Março de 2015, na subestação de Ermesinde.

A variação do erro, nesta situação, ocorreu entre 19,75 e 0,005 o que calculou um erro médio de 5,01, um erro de, aproximadamente, 2,5 valores acima do que foi obtido na subestação da Prelada.

Analisando o gráfico de variação de erro e o respectivo gráfico de previsão, figuras 64 e 65, pode-se verificar que os principais picos, onde os valores de erro foram superiores, são quatro e ocorrem, geralmente, ao final da tarde do primeiro, segundo, terceiro e quarto dia.

5.6 Conclusões

Analisando o comportamento de todos os dados obtidos nas previsões em comparação com os dados reais é possível concluir que, apesar da existência de um erro de aprendizagem, as redes neurais permitem obter previsões credíveis e satisfatórias, uma vez que conseguem seguir sempre a tendência do comportamento dos valores reais.

No caso das previsões realizadas para a subestação da Prelada os valores obtidos têm tendência a serem inferiores aos valores reais, enquanto na subestação de Ermesinde acontece o oposto, a curva de valores obtidos tende a ser superior à curva dos resultados esperados.

Tendo em consideração o que foi explicado no sub-subcapítulo 2.4.1 desta dissertação, que fala sobre as características do diagrama de carga pode-se analisar os seguintes pontos sobre os gráficos obtidos no presente capítulo:

➤ Analisando os gráficos das figuras 56, 58, 62 e 64 é possível comprovar a existência das horas de vazio, que dizem respeito essencialmente às horas do período noturno e fins-de-semana. Tal como se pode verificar, nas figuras 56 e 62 as horas de vazio encontram-se entre as 22h e as 8h o que era de esperar, pois é o tempo em que o consumo desce e a carga necessária é mais baixa. Nos gráficos das figuras 58 e 64, também é possível comprovar que essas horas são as que demonstram menor consumo, fazendo destaque para o fim-de-semana. É visível a diferença de consumo, relativamente aos restantes dias da semana, uma vez que estes dois dias (domingo e sábado) apresentam no geral uma diminuição de consumo durante as 24h do dia.

➤ As horas de cheia e de ponta também se encontram evidenciadas nas figuras referidas acima. As horas de ponta dão-se, regra geral, nas horas de início e fim do expediente, ou seja, de entrada e saída do emprego, e as horas de cheia representam o início do trabalho e o aumento de produção. Estas duas zonas representam o período de tempo em que o consumo de carga é superior. Geralmente os picos de carga presentes nos gráficos obtidos dizem respeito às horas de ponta.

➤ Os resultados obtidos na previsão, apesar de apresentarem um erro um pouco elevado, conseguem demonstrar da mesma maneira que os valores reais essas três zonas que fazem parte de um digrama de carga (Horas de vazio, Horas de Ponta e Horas de Cheia).

➤ Comparando os gráficos das figuras 56 e 62, pode-se afirmar que no início da semana a carga necessária é maior, ou seja, existe mais consumo/produção após o fim-de-semana. A figura 56 representa o diagrama de carga do dia 18 de Março que se trata de uma quarta-feira e demonstra um consumo inferior quando comparado ao consumo evidenciado no diagrama de carga da figura 62, que diz respeito ao dia 30 de Março, uma segunda-feira.

➤ Apesar da carga utilizada, nos gráficos das figura 56 e 62, ser bastante diferente o comportamento da carga é idêntico ao longo do dia, tal como o comportamento dos valores obtidos através da previsão, apesar da subestação de Ermesinde apresentar um erro maior e uma tendência a resultados superiores ao esperado.

➤ Relativamente aos gráficos das figuras 58 e 64 pode-se afirmar que a segunda semana do mês de Março de 2015 (figura 64) teve um maior consumo do que a primeira semana (figura 58). O diagrama de carga da figura 64 apresenta picos mais acentuados, nas horas de ponta.

Quanto ao valor médio dos erros obtidos, ao longo do processo de previsão, são um pouco elevados, quando comparados com outros temas semelhantes [2][13][15]. O valor do erro devia ser mais próximo de zero e para que tal sucedesse seria necessário aumentar o número de treinos realizados no capítulo 4, relativamente ao desenvolvimento de rede. Em vez de estipular apenas 5 treinos para cada fase seria aconselhável fazer mais para obter melhores resultados e assim menores erros.

Através da análise de todo o processo de previsão realizado, é possível concluir que as redes neuronais artificiais são uma boa opção para realizar previsões de diagramas de

carga, desde que seja sempre tido em conta o erro, uma vez que não é um método completamente eficaz.

6. Conclusões Finais e Trabalhos Futuros

Este capítulo encontra-se dividido em dois subcapítulos onde estão presentes as conclusões finais do estudo desenvolvido ao longo desta dissertação, bem como possíveis propostas para trabalhos futuros que possam dar continuidade ao tema estudado.

6.1 Conclusões Finais

Com o desenvolvimento desta dissertação pretendeu-se comprovar que as redes neuronais artificiais são técnicas computacionais que permitem realizar boas previsões e que conseguem aprender facilmente o comportamento de qualquer problema consoante o conjunto de dados que lhe é fornecido para esse processo.

As RNA têm diversas aplicações e em áreas diferentes como por exemplo, engenharia e medicina. São muitas vezes utilizadas em previsões, temporais, locais e de cargas elétricas.

Nesta dissertação o principal objetivo consistia na previsão de diagramas de carga de energia elétrica e com o desenvolver do estudo pode-se comprovar que através destes modelos computacionais (as RNA) é realmente possível realizar a previsão de cargas e obter bons resultados. Contudo as RNA não se tratam de modelos apropriados para problemas que necessitem de exatidão e uma elevada precisão, uma vez que existe sempre um erro de aprendizagem que nunca chega a ser nulo.

Para criar as RNA que se pretendem, de modo a obter bons resultados, é necessário ter acesso a um conjunto de dados reais e que demonstrem o comportamento passado do objetivo em estudo, ou seja, para criar a rede que fornece os resultados mais favoráveis é necessário ter dados reais e que já ocorreram anteriormente, com o intuito de criar uma rede treinada através desse comportamento. Posteriormente com a melhor rede obtida, através desse processo, é possível realizar a previsão utilizando dados reais atuais.

No decorrer desta dissertação, após a realização do método para adquirir as melhores redes, realizou-se a previsão de diagrama de carga para duas subestações da REN, Prelada e Ermesinde, de um dia e uma semana, diferentes, do mês de Março de 2015. Através dos resultados obtidos pode-se comprovar que as RNA são realmente um bom método para conseguir boas previsões, no entanto não são completamente eficazes pois apresentam sempre um erro de aprendizagem. No caso da subestação da Prelada os valores das previsões obtidas tinham, geralmente, tendência a serem inferiores aos valores reais. Já na subestação de Ermesinde acontecia o oposto, nesta subestação o erro médio na previsão era superior ao da Prelada, isto ocorre porque a melhor rede obtida no processo de aprendizagem tinha um erro médio quadrático bastante superior ao da melhor rede adquirida na subestação da Prelada.

Como a energia elétrica é cada vez mais importante e essencial para o quotidiano e tem vindo a desenvolver é importante ter em consideração os custos e a qualidade do serviço. Assim sendo, a previsão de diagramas de carga torna-se importante de modo a ajudar a prever a carga que será utilizada num determinado dia, semana ou mês com o intuito de garantir a qualidade e a possibilidade de redução nos custos.

Através da dissertação desenvolvida verificou-se que a utilização de RNA na previsão de diagrama de carga pode ser uma mais valia, uma vez que é possível ter uma noção de qual será o comportamento que a carga terá num determinado espaço de tempo e uma aproximação do valor de carga que será utilizada, desde que se tenha sempre em conta o erro.

O estudo realizado nesta dissertação pode vir a ser útil e aplicável para empresas como a REN, uma vez que este tipo de empresa trabalha diariamente com diagramas de carga e consumo, o que torna importante a utilização de novos recursos com o intuito de alcançar melhores resultados, isto é, previsões mais fiáveis que possam ajudar na redução de custos e aumento de qualidade.

Na realização desta dissertação utilizou-se o *software* Excel 2007, Word 2007 e MATLAB R2010a, através de um computador portátil INSYS, modelo 8746S, Processador Intel Pentium Dual CPU T3400, memória RAM 4GB e Sistema Operativo de 32 bits. Devido às características do computador é provável que seja esse o motivo de os treinos das redes ser mais lento, por vezes.

6.2 Trabalhos Futuros

A nível de propostas de desenvolvimento futuro será possível trabalhar noutros pontos de interesse dentro deste contexto, com o intuito de dar continuidade ou melhoria ao estudo desta dissertação. Por exemplo, o desenvolvimento de um método para otimizar a recolha de dados, tornando mais simples a sua obtenção e consequentemente o seu tratamento.

Quanto às RN, outro modo de melhorar ou testar esta dissertação passa pela criação de uma rede neuronal de raiz, através de programação em MATLAB, e testar para diferente número de camadas o estudo realizado. Programando uma RN é possível realizar estudos diferentes e assim tentar obter melhores resultados. Por exemplo, é possível determinar o número de camadas ocultas, estabelecer quando será melhor a rede parar, ou seja, definir um valor mínimo de erro admissível ou o número de iterações que a rede poderá executar até parar, utilizar algoritmos de treino diferentes e variar a taxa de aprendizagem.

Outro possível tema passa por efetuar o estudo comparativo com outros métodos de previsão, dando a possibilidade de comparar resultados e verificar qual o método que melhor se adequa à realização de previsão de diagramas de carga e quais as vantagens e desvantagens de cada um deles.

Por fim, a aplicação da mesma ferramenta a subestações com maior penetração de produção embebida. Ou seja, aplicar a previsão do diagrama de carga em zonas de rede com uma grande parcela de produção distribuída, que é feita na zona de distribuição. Esta situação fará com que o valor da carga seja diminuído, do ponto de vista da REN, se houver forte produção embebida.



7. Referências Bibliográficas

- [1] Rede Elétrica Nacional (REN). “O Setor Elétrico”. [Obtido a 23/04/2015]. Disponível em http://www.ren.pt/o_que_fazemos/eletricidade/o_setor_eletrico/#5
- [2] RODRIGUES, Ricardo. “Previsão dos consumos na RNT considerando a produção distribuída – Desenvolvimento de um procedimento de apoio à decisão do Gestor do sistema”. FEUP, Janeiro de 2014.
- [3] SUCENA PAIVA, José Pedro. “Redes de Energia Elétrica. Uma análise sistemática.”. 3ª Edição. Editora IST PRESS, Coleção Ensino da Ciência e da Tecnologia, 2012. Capítulo 1 – Introdução (pp 1-34) e Capítulo 2 – Conceitos básicos (pp 37 – 39).
- [4] Rede Elétrica Nacional (REN). [Obtido a 23/04/2015]. Disponível em <http://www.ren.pt/>
- [5] EDP. “Sistema Elétrico Português”. [Obtido a 12/03/2015]. Disponível em <http://www.edp.pt/pt/aedp/sectordeenergia/sistemaelectricoportugues/Pages/SistElectNacional.aspx>
- [6] Entidade Reguladora dos Serviços Energéticos (ERSE). “Eletricidade”. [Obtido a 12/03/2015]. Disponível em <http://www.erse.pt/PT/ELECTRICIDADE/Paginas/default.aspx>
- [7] REN – Rede Elétrica Nacional, S.A.. “Caracterização da Rede Nacional de Transporte para efeitos de acesso à rede. Situação a 31 de Dezembro de 2014”. REN, Março de 2015.
- [8] “Relatório & Contas 2013”. REN, 2013.
- [9] MIRANDA, Vladimiro. “Previsão de Cargas por séries temporais - tópicos”. FEUP, Outubro de 2002.
- [10] MONTEIRO, Cláudio. “Previsão de consumos. O problema da previsão de consumos”. FEUP.
- [11] BARBOSA, F. Maciel. “Gestão de energia. Gestão do diagrama de cargas.”. FEUP, 2004/2005.
- [12] KALOGIROU, Soteris A.. “Applications of artificial neural-networks for energy systems”. Department of Mechanical and Marine Engineering, Higher Technical Institute, Cyprus. Elsevier Science Ltd., 2000.
- [13] BARROS, Tiago. “Previsão de carga – Comparação de técnicas”. FEUP, Julho de

-
- 2014.
- [14] HAYKIN, Simon. “Neural Networks – A comprehensive Foundation”. 2ª Edição. Pearson Education, Canadá, 1999.
- [15] KALOGIROU, Soteris A.; BOJIC, Milorad. “Artificial neural networks for the prediction of the energy consumption of a passive solar building”. Department of Mechanical and Marine Engineering, Higher Technical Institute, Cyprus, e University of Kragujevac, Faculty of Mechanical Engineering, Department of Energy and Process Engineering, Yugoslavia. Elsevier Science Ltd., 2000.
- [16] GOMES, Nuno. “Outros métodos de Pesquisa”. UC: Otimização e Métodos de Decisão. ISEP, 2013.
- [17] AZADEH, A.; GHADERI, S.F.; TARVERDIAN, S.; SABERI, M.. “Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption”. Research Institute of Energy Management and Planning and Department of Industrial Engineering, Faculty of Engineering, University of Tehran, Iran e Department of Industrial Engineering, Faculty of Engineering, University of Bu Ali Sina, Hamedan Iran, Islamic Azad University Tafresh branch and Research Institute of Energy Management and Planning. Elsevier Inc., 2006.
- [18] EKICI, Betul Bektas; AKSOY, U. Teoman. “Prediction of building energy consumption by using artificial neural networks”. Department of Construction Education, Firat University, Turkey. Elsevier Ltd., 2008.
- [19] MACEDO, José. “Desenvolvimento de uma metodologia baseada em redes neuronais para o cálculo da energia produzida por aerogeradores”. ISEP, Julho de 2012.
- [20] WINANDY, Charles-Edouard, FILHO, Estillac Borges, BENTO, Lisânia. “Algoritmos para Aprendizagem Supervisionada”. CT215 – Inteligência Artificial. Seminários, 2007.
- [21] TU, Jack V.. “Advantages and Disadvantages of Using Artificial Neural Networks versus Logistic Regression for Predicting Medical Outcomes”. Institute for Clinical Evaluative Sciences, North York, Ontario, Canada, Department of Medicine, Sunnybrook Health Science Centre, University of Toronto, North York, Ontario, Canada, and Division of Health Policy Research and Education, Harvard University, Boston, Massachusetts. Elsevier Science, Inc., 1996.
- [22] GAVIN, Henri P.. “The Levenberg-Marquardt method for nonlinear least squares curve-fitting problems”. Department of Civil and Environmental Engineering, Duke

-
- University. October 9, 2013.
- [23] MARQUARDT, Donald W.. “An Algorithm for Least-Squares Estimation of Nonlinear Parameters”. Journal of the Society for Industrial and Applied Mathematics, Vol. 11, No. 2, 431-441. June, 1963.
- [24] LOURAKIS, M.I.A.. “A brief description of the Levenberg-Marquardt algorithm implemented by levmar”. Technical Report, Institute of Computer Science, Foundation for Research and Technology - Hellas, 2005.
- [25] MADSEN, K.; NIELSEN, N.B.; TINGLEFF O.. “Methods for nonlinear least squares problems”. Technical Report. Informatics and Mathematical Modeling, Technical University of Denmark, 2004.
- [26] Levenberg-Marquardt backpropagation – MATLAB trainlm. [Obtido a 16/04/2015]. Disponível em <http://www.mathworks.com/help/nnet/ref/trainlm.html>
- [27] MATOS, Manuel António. “Manual Operacional para a Regressão Linear”. FEUP, 1995.
- [28] TSO, Geoffrey K.F.; YAU, Kelvin K.W.. “Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks”. Department of Management Sciences, City University of Hong Kong, Tat Chee Ave, Kowloon, Hong Kong, China. 15 August 2005. Elsevier Ltd., 2006.
- [29] MathWorks. “Products and Services”. [Obtido a 29/07/2015]. Disponível em <http://www.mathworks.com/products/>
- [30] *Software* MATLAB, versão R2010a., *Neural Network Fitting tool*.






Anexo A – Tratamento dos dados utilizados na previsão, para Março de 2015


Este anexo contém o tratamento de dados como Temperatura, Humidade, Vento e Luminosidade em função do tempo. Contém ainda os gráficos das cargas, das subestações da Prelada e Ermesinde, em função do tempo.

Como os dados meteorológicos utilizados na previsão foram os mesmos, uma vez que se supôs que as condições meteorológicas eram idênticas em ambas as subestações, só é necessário realizar esse tratamento uma vez.


A.1 – Dados Meteorológicos








A.2 – Dados de carga da subestação da Prelada




A.3 – Dados de carga da subestação de Ermesinde



Anexo B – Previsão de diagrama de carga do mês de Março de 2015

Neste anexo encontram-se demonstrados os gráficos referentes à previsão de diagrama de carga das subestações da Prelada e de Ermesinde, para todo o mês de Março de 2015. E os respetivos gráficos de variação de erro.


B.1 – Subestação da Prelada




Erro médio: 3,64

Erro máximo: 17,92

Erro mínimo: 0,0003




B.2 – Subestação de Ermesinde



Erro médio: 4,77

Erro máximo: 24,37


Erro mínimo: 0,00002



Anexo C – Carga utilizada na subestação de Ermesinde durante um ano

Este anexo contém o gráfico da carga que a subestação de Ermesinde utilizou em cada dia de cada mês, durante um ano (iniciando no mês de Dezembro de 2013 e terminando no mês de Novembro de 2014).

Os dados presentes neste gráfico foram utilizados no processo de aprendizagem das redes neurais artificiais treinadas para encontrar a melhor rede, que posteriormente seria utilizada na previsão. Estes dados foram utilizados como *Targets* na ferramenta *Neural Network Fitting Tool*, do MATLAB, no processo de treino.




Anexo D – Comportamento obtido nos treinos das várias redes neuronais artificiais (melhor rede obtida para um ano, utilizando os dados referidos, das subestações)




O anexo em questão demonstra, nos vários gráficos, o comportamento que as melhores redes encontradas ao longo da dissertação tiveram. Os gráficos seguintes mostram uma comparação entre os valores fornecidos nos *Targets* e os *Outputs* obtidos no final do respectivo treino.




Cada rede teve um conjunto de dados para executar o treino, *Inputs* e *Targets*, em que os *Targets* dizem respeito aos valores reais, e que têm como objetivo fornecer à rede que está a ser treinada uma amostra dos valores que ela deve obter, e assim juntamente com os *Inputs* a rede pode gerar resultados perto do que seria esperado. Realizando um processo de aprendizagem.




De modo a facilitar a visualização dos dados obtidos, e uma vez que o conjunto de dados é muito grande (35040 células de dados para cada conjunto), dividiu-se os resultados em vários gráficos. Ou seja, para cada situação gerou-se 12 gráficos, um para cada mês do ano, tornando assim possível uma melhor visualização dos resultados.



D.1 – Todos os dados disponíveis, da Prelada























D.2 – Todos os dados disponíveis, de Ermesinde























D.3 – Dados do dia, mês, hora, feriados, dia da semana e Temperatura, da Prelada























D.4 – Dados do dia, mês, hora, feriados, dia da semana, Temperatura e Humidade, da Prelada























D.5 – Dados do dia, mês, hora, feriados, dia da semana, Temperatura e Vento, da Prelada























D.6 – Dados do dia, mês, hora, feriados, dia da semana, Temperatura e Luminosidade, da Prelada











D.7 – Dados disponíveis, exceto feriados, da Prelada

