

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



**Previsão dos consumos na RNT
considerando a produção distribuída –
Desenvolvimento de um procedimento
de apoio à decisão do Gestor do sistema**

Ricardo Daniel Silva Machado Rodrigues

Mestrado Integrado em Engenharia Electrotécnica e de Computadores

Orientador: António Carlos Sepúlveda Machado e Moura (Prof. Doutor)

Co-Orientador: Ricardo Vasco Fernandes (Eng.º)


20 de Fevereiro de 2014

A Dissertação intitulada

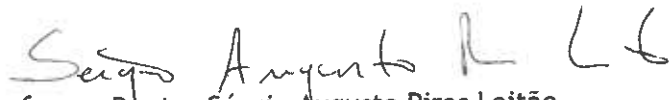
“Previsão dos Consumos na RNT Considerando a Produção Distribuída -
Desenvolvimento de um Procedimento de Apoio à Decisão do Gestor do Sistema”

foi aprovada em provas realizadas em 10-02-2014

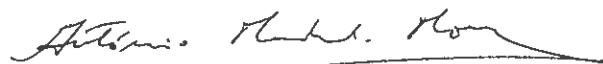
o júri



Presidente Professor Doutor João Paulo Tomé Saraiva
Professor Associado do Departamento de Engenharia Eletrotécnica e de
Computadores da Faculdade de Engenharia da Universidade do Porto

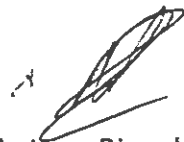


Professor Doutor Sérgio Augusto Pires Leitão
Professor Auxiliar Departamento de Engenharias da Faculdade de Ciências e
Tecnologia da Universidade de Trás-os-Montes e Alto Douro



Professor Doutor António Carlos Sepúlveda Machado e Moura
Professor Catedrático do Departamento de Engenharia Eletrotécnica e de
Computadores da Faculdade de Engenharia da Universidade do Porto

O autor declara que a presente dissertação (ou relatório de projeto) é da sua
exclusiva autoria e foi escrita sem qualquer apoio externo não explicitamente
autorizado. Os resultados, ideias, parágrafos, ou outros extratos tomados de ou
inspirados em trabalhos de outros autores, e demais referências bibliográficas
usadas, são corretamente citados.



Autor - Ricardo Daniel da Silva Machado Rodrigues

Resumo

O Gestor de Sistema (GS) da Rede Elétrica Nacional (REN) depara-se atualmente com uma mudança no paradigma da Rede Nacional de Transporte, neste âmbito surge a necessidade de criar uma ferramenta que possa facilitar a análise do sistema, para que a programação das indisponibilidades dos transformadores de cada subestação assuma valores mais próximos da realidade, diminuindo assim o erro de previsão.

A programação de indisponibilidades de transformadores de potência do GS, para que seja feita de forma eficaz necessita de prever a carga nestes elementos do sistema, de forma a garantir a alimentação dos consumos, margens de reserva adequadas e o escoamento de produção dispersa nas redes de distribuição.

A produção distribuída, resultado do desenvolvimento e expansão de produtores de eletricidade em regime especial, criando um novo modelo de exploração da rede, que introduz uma distribuição bidirecional do trânsito de potência nos transformadores das subestações da REN. Esta distribuição alterou a decomposição do trânsito nos transformadores, onde anteriormente era vista como o consumo real, hoje em dia é desagregada em dois parâmetros, sendo estes a carga natural e a soma de todos os produtores agregados à subestação. Surge assim a necessidade de previsão de carga natural de forma a fortalecer o GS de uma informação mais precisa para que o possa ajudar na tomada de decisão.

A técnica de previsão usada foi a Rede Neuronal, que permite através de uma rede previamente treinada com um conjunto de dados, obter uma previsão no "neurónio" de saída. Este conjunto de dados utilizados para as variáveis de entrada foram alvo de uma análise, procurando perceber quais as variáveis justificativas do diagrama de carga. Depois de testadas várias estruturas para o treino da rede, optou-se pela que melhor desempenho apresentou, obtendo-se uma previsão de carga natural para diversas subestações.

Os resultados obtidos apresentaram melhorias significativas em comparação com o método de previsão existente no GS, evidenciando que o uso de Redes Neurais é uma importante mais valia.

O passo final deste trabalho foi desenvolver e implementar uma ferramenta de utilização simples e intuitiva, recorrendo à aplicação gráfica do *Matlab*. Esta ferramenta permite ao GS prever com eficácia a carga natural de uma determinada subestação num horizonte de sete dias e com baixo erro, constituindo desta forma uma importante ferramenta de apoio à decisão do GS.

Palavras-chave: Indisponibilidade de transformadores, Previsão de carga em curto prazo, Produção distribuída, Subestações, Redes Neurais, Inteligência Artificial.

Abstract

Nowadays, the Managing System (MS) of the Rede Elétrica Nacional (REN) is facing a change occurring in the National Transportation Network. This creates the need to build a tool that can ease the system analysis so that the downtime programming of the power transformer of each substation can assume more realistic values, making the prediction errors much less frequent.

In order to make things more efficiently, the programming of the downtime of the power transformer needs to predict the charge of these elements in the system in order to guarantee the proper consuming supplies, reservation margin, and production outflow dispersed in the distribution networks.

The distributed production, result of the development and expansion of energy producers in special regime, created a new network exploration model, making production closer to charges, introducing a bidirectional distribution of traffic charges in power transformers of REN's substations. This distribution changed the decomposition of traffic charges in power transformers; we changed from Real Power Consumption to splitting it into two disaggregated parts: Natural Charge and the sum of all producers aggregated to the substation. With this process, the need to predict the natural charge is created in order to give the Managing System a more reliable information so that it can be used as a helping tool in the decision making.

The prediction technique used was the Neural Network, which allows, through a network previously trained with a set of data, to obtain a prediction in the output 'neuron'. The data used for the input variables were put through an analysis, searching for what were the most significant influences on the charge diagram. After testing various structures in the training of the network, the one with the best performance was chosen, getting a natural charge prediction to all the different substations.

The results obtained from the tests showed significant improvement compared to the previous prediction system in the Managing System, showing that the efficient use of Neuronal Networks can really be important in situations where the data's complexity is high.

The final step of this thesis was to develop and implement a simple tool that allows the MS to efficiently predict the natural charge present in a determined substation for the next seven days, anticipating the maximum and minimum charge values with a low error margin.

Keywords: Short-term Load forecasting, Outage of the Transformers, Neural Networks.

Agradecimentos

Esta execução de trabalhos com vista à obtenção do Grau de Mestre revelou-se desafiante, exigindo de mim empenho e dedicação. Ao longo deste caminho fui-me apercebendo o quanto sou afortunado por ter em meu redor pessoas que todos os dias de uma forma ou de outra tornaram este percurso mais simples. A estes estou imensamente grato!

Gostaria de agradecer, ao meu orientador, o Professor Doutor António Machado e Moura, pelos conselhos prestados, por todo o apoio demonstrado ao longo deste período em que estive envolvido na realização deste trabalho e acima de tudo pela sua atitude alegre e positiva com que encara o dia-a-dia, contagiando todos à sua volta.

Ao meu coorientador, o incansável Eng. Ricardo Vasco Fernandes, pela sua disponibilidade total, pelos seus conselhos e claro, pela sua paciência, quero deixar um forte obrigado.

Quero também agradecer ao Engenheiro Vieira Couto, pela disponibilização das ótimas condições de trabalho que dispus durante a execução deste trabalho. Aos restantes elementos do COR, o meu muito obrigado pelo apoio demonstrado todos os dias.

Agradeço também ao Professor José Nuno Fidalgo, pela sua total disponibilidade em responder a todas as questões.

Um obrigado enorme a todos os meus amigos que direta ou indiretamente me apoiaram, sem vocês este caminho seria penoso. Os momentos vividos e os conhecimentos partilhados estão guardados para sempre em mim. Não quero destacar individualmente nenhum com medo de não referir algum mas a lista felizmente, seria vasta.

À Bárbara, pela cor que dá à minha vida, pelas borboletas diárias, pela partilha de sonhos, por todo o carinho, pelo apoio que sempre me deste e pela paciência, o meu especial agradecimento.

Aquilo que sou, em grande parte se deve à fantástica família que tenho, vocês são o meu suporte e o meu porto de abrigo. O meu muito obrigado em especial à minha pequena mas ENORME Mãe e aos meus irmãos, Nuno e Diogo, por me aturarem e me ajudarem a ultrapassar os obstáculos da vida. Por vocês quero sempre ir mais além!

A todos, o meu sincero Obrigado!

Ricardo Rodrigues

“Vê mais longe a gaivota que voa mais alto”

Richard Bach

Conteúdo

1	Introdução	1
1.1	Motivação e Objetivos	1
1.2	Estrutura do Documento	3
1.3	Dados Utilizados na Dissertação	3
2	Rede Nacional de Transporte	5
2.1	Transporte de Energia Elétrica	5
2.1.1	Elementos da Rede Nacional de Transporte	8
2.1.2	Sistema Eleprodutor	10
2.1.2.1	Produção Eólica	11
2.2	REN - Concessionária da RNT	13
2.2.1	Operação da Rede	13
2.2.1.1	Funções	14
2.2.1.2	Aquisição de dados	15
2.2.1.3	Coordenação de indisponibilidades	16
2.3	Subestações	17
2.3.1	Enquadramento	17
2.3.2	Caraterização dos Transformadores	20
2.3.2.1	Incentivo ao aumento de disponibilidade dos elementos da RNT	21
2.3.2.2	Reserva N-1 de carga de uma subestação	22
2.3.2.3	Análise de Indisponibilidades de Transformadores	22
2.3.2.4	Cargas Máximas Admissíveis	23
2.4	Caraterização das Subestações	24
3	Previsão de Carga	29
3.1	Previsão de Carga - Curto Prazo	29
3.1.1	Séries Temporais	31
3.1.2	Modelos de Regressão	31
3.1.3	Redes Neurais Artificiais	32
3.1.3.1	Estrutura de um neurónio	32
3.1.3.2	Tipos de redes neuronais	34
3.1.3.3	Treino da rede neuronal	34
3.1.3.4	Construção de uma rede neuronal	35
3.1.4	Comparação entre técnicas de previsão	36
3.2	Previsão da Produção Eólica	36
3.3	Carga Elétrica	37
3.3.1	Diagrama de Carga	38
3.4	Fatores que condicionam o diagrama de carga	39

3.4.1	Dados Temporais	39
3.4.1.1	Análise de uma semana antes em cada período	40
3.4.1.2	Análise de duas semanas antes em cada período	42
3.4.1.3	Análise de três semanas antes em cada período	44
3.4.1.4	Conclusão de dados temporais	46
3.4.2	Temperatura e humidade	47
3.4.3	Feridos	50
4	Treino e validação das estruturas de previsão	55
4.1	Escolha das subestações	55
4.2	Procedimentos	56
4.2.1	Metodologia de trabalho	56
4.2.2	Recolha de dados	57
4.2.3	Tratamento de dados	59
4.2.4	Estandardização de dados	60
4.2.5	Treino da rede neuronal	60
4.2.6	Análise de desempenho da rede	63
5	Resultados obtidos para cada teste	65
5.1	Falagueira	65
5.1.1	Escolha da rede	72
5.1.2	Análise da rede escolhida	74
5.2	Resultados para outras subestações	74
5.3	Análise de resultados	74
5.4	Comparação de resultados com o método de previsão atual	75
5.5	Erro alcançado	79
5.5.1	Limitações	79
5.5.2	Medidas de minimização de limitações	80
6	Conclusões e Desenvolvimentos Futuros	81
6.1	Conclusões Finais	81
6.2	Desenvolvimentos Futuros	83
	Referências	85
A	Manual de utilizador da aplicação PrevCarga	89
A.1	Requisitos	89
A.2	Exemplo de Utilização	92
B	Comparação entre Métodos	97
B.1	Caraterização de Subestações REN	103
B.2	Mapas	107

Lista de Figuras

2.1	Cadeia de valor da SEN	6
2.2	Evolução da potência instalada em Portugal desde 2004 até ao final de 2013	7
2.3	Síntese dos principais equipamentos da RNT	8
2.4	Evolução da RNT de 2003 até 2012 [1]	9
2.5	Previsão da evolução do número de subestações e postos de corte na RNT previsto de 2014-2017 [2]	9
2.6	Evolução do Consumo [1]	11
2.7	Evolução do Consumo por componente de produção [1]	12
2.8	Potência eólica total ligada [REN]	12
2.9	Comparação entre a potência eólica e a potência do SEN [REN]	13
2.10	Estrutura da unidade de negócio de Eletricidade da REN [REN]	14
2.11	Diagrama de comunicação do COR com outras entidades	17
2.12	Exemplo de rede	18
2.13	Carga presente em duas subestação de 24 de Outubro até dia 30 de Outubro de 2013	19
2.14	Idade dos transformadores presentes na RNT	20
2.15	Previsão da Evolução da potência de transformação até 2017 [2]	21
3.1	Técnicas de previsão de consumo em curto-prazo mais utilizadas	31
3.2	Diagrama representativo de uma rede neuronal	32
3.3	Estrutura de um neurónio	33
3.4	Diagrama de Carga (kW) em 4 de Dezembro de 2012 na subestação de Vermoim	39
3.5	Período C	40
3.6	Período B	40
3.7	Período A	40
3.8	Gráfico de dispersão entre valores do diagrama de carga da hora alvo e uma semana antes para diferentes períodos	40
3.9	Diagrama de carga comparando a carga da hora alvo com a carga à mesma hora na semana anterior em diferentes períodos	41
3.10	Período C	42
3.11	Período B	42
3.12	Período A	42
3.13	Gráfico de dispersão entre valores do diagrama de carga da hora alvo e duas semanas antes para diferentes períodos	42
3.14	Diagrama de carga comparando a carga da hora alvo com a carga à mesma hora duas semanas antes em diferentes períodos	43
3.15	Período C	44
3.16	Período B	44
3.17	Período A	44

3.18	Gráfico de dispersão entre valores do diagrama de carga da hora alvo e três semanas antes para diferentes períodos	44
3.19	Diagrama de carga comparando a carga da hora alvo com a carga à mesma hora três semanas antes em diferentes períodos	45
3.20	Correlação dos diagramas de carga nas séries temporais analisadas	46
3.21	Diferenças percentuais dos diagramas de carga nas diversas séries temporais	47
3.22	Temperatura média diária em (graus <i>Celsius</i>) e humidade relativa em percentagem de Março de 2012 até Fevereiro de 2013	48
3.23	Gráficos de correlação em Portugal e na cidade do Porto	49
3.24	Em Portugal continental	50
3.25	Em Portugal continental	50
3.26	Na subestação de Vermoim	50
3.27	Na subestação de Vermoim	50
3.28	Gráfico de dispersão entre valores de temperatura e humidade relativa com o valor de carga em diferentes locais	50
3.29	Comparação do consumo de carga na semana de 22 a 28 de Abril e a semana de 15 a 21 de Abril de 2012	51
3.30	Comparação do consumo de carga na semana de 29 de Setembro a 6 de Outubro e a semana de 7 a 13 de Outubro de 2012	51
3.31	Comparação do consumo de carga na semana de 10 a 16 de Junho e a semana de 17 a 23 de Junho de 2012	52
3.32	Comparação do consumo de carga na semana de 1 a 7 de Abril e a semana de 8 a 14 de Abril de 2012	53
4.1	Diagrama da metodologia adotada	57
4.2	Metodologia de teste da rede neuronal	61
5.1	Estrutura da rede 1	66
5.2	Esquema da RN 1A	67
5.3	Esquema da RN 1B	67
5.4	Esquema da RN 1C	68
5.5	Estrutura da rede 2	68
5.6	Esquema da RN 2A	69
5.7	Esquema da RN 2B	69
5.8	Esquema da RN 2C	70
5.9	Estrutura da rede 3	71
5.10	Esquema da RN 3A	71
5.11	Esquema da RN 3B	73
5.12	Esquema da RN 3C	74
5.13	Gráfico referente aos desempenhos da melhor rede de cada estrutura utilizada	75
5.14	Comparação da carga natural real e prevista entre 30 de Julho de 2012 e 5 de Agosto de 2012	76
5.15	Comparação da carga natural real e prevista entre 29 de Outubro e 4 de Novembro de 2012	76
5.16	Comparação da carga natural real e prevista entre 1 e 7 de Outubro de 2012	77
5.17	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos entre 1 e 7 de Outubro de 2012	79
A.1	Diretório da aplicação	89

A.2	Interface do PrevCarga	90
A.3	Importar ficheiro de entrada	91
A.4	Dados de temperatura inseridos pelo utilizador	91
A.5	Gráfico da carga natural prevista com a reserva n-1 associada à subestação.	92
A.6	Informação relativa à subestação escolhida	92
A.7	Escolha da subestação da Valdigem	93
A.8	Informação relativa à subestação da valdigem	93
A.9	Dados de temperatura inseridos pelo utilizador	94
A.10	Diagrama de carga natural obtido do PrevCarga	94
A.11	Diagrama de carga comparando o valor de carga natural e o previsto	95
B.1	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Rio Maior	97
B.2	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação da Falagueira	98
B.3	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Tunes	99
B.4	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Sines	100
B.5	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Ferreira do Alentejo	101
B.6	Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação da Valdigem	102
B.7	Exemplo da folha de caracterização das subestações REN	104
B.8	Exemplo da folha de caracterização das subestações REN	105
B.9	Exemplo da folha de caracterização das subestações REN	106
B.10	Mapa com a distribuição da potência eólica gerada por distritos [3].	108
B.11	Mapa da localização dos parques eólicos diferenciados por classes de potência instalada [3].	109
B.12	Mapa da RNT [4].	110

Lista de Tabelas

2.1	Quantidade de transformadores nas instalações REN	21
2.2	Quantidade de autotransformadores nas instalações REN	21
2.3	Cargas máximas admissíveis nos transformadores	23
3.1	Comparações entre os diversos momentos temporais analisados	46
3.2	Diferenças percentuais e a sua correlação no diagrama de carga entre os diversos dias em 2012	53
4.1	Excerto de tabela com possíveis candidatas a entradas da rede neuronal	58
4.2	Excerto de tabela com possíveis candidatas a variáveis de entradas depois da estandardização	60
5.1	Resultados do desempenho para cada RN do teste 1A	67
5.2	Resultados do desempenho para cada RN do teste 1B	67
5.3	Resultados do desempenho para cada RN do teste 1C	68
5.4	Resultados do desempenho para cada RN do teste 2A	69
5.5	Resultados do desempenho para cada RN do teste 2B	69
5.6	Resultados do desempenho para cada RN do teste 2C	70
5.8	Resultados do desempenho para cada RN do teste 3B	71
5.7	Resultados do desempenho para cada RN do teste 3A	72
5.9	Resultados do desempenho para cada RN do teste 3C	72
5.10	Comparação de desempenhos para a melhor rede de cada estrutura utilizada	72
5.11	Amostra dos resultados da rede para cada subestação	78
5.12	Comparação de desempenho dos dois métodos em dois períodos distintos	78

Abreviaturas e Símbolos

AT	Alta Tensão
BT	Baixa Tensão
COR	Centro de Operação da Rede
DGEG	Direção geral de energia e geologia
EDP-D	Energias de Portugal - Distribuição
ERSE	Entidade Reguladora dos Serviços Energéticos
GS	Gestor do Sistema
GSOR	Departamento de Operação da Rede da direção do Gestor do Sistema
MT	Média Tensão
MAT	Muito Alta Tensão
MIEEC	Mestrado Integrado em Engenharia Eletrotécnica e de Computação
MS	Managing System
PdE	Ponto de Entrega
PDIRT	Plano de desenvolvimento e investimento na rede de transporte
PRE	Produção em Regime Especial
PRO	Produção em Regime Ordinário
REN	Rede Elétrica Nacional
RN	Rede Neuronal
RND	Rede Nacional de Distribuição
RNT	Rede Nacional Transporte
SCADA	Supervisory Control and Data Acquisition
SEN	Sistema Elétrico Nacional
TR	Transformador
W	Unidade de Potência ativa
VA	Unidade de Potência aparente
V	Unidade de Tensão

Capítulo 1

Introdução

O presente trabalho foi elaborado no âmbito da disciplina Dissertação do Mestrado Integrado em Engenharia Eletrotécnica e de Computadores da Faculdade de Engenharia da Universidade do Porto. O tema abordado é a previsão dos consumos na Rede Nacional de Transporte (RNT) considerando a Produção Distribuída – Desenvolvimento de um procedimento de apoio à decisão do Gestor de Sistema (GS), mais concretamente no departamento de Operação da Rede.

A entidade concessionária da RNT em Portugal é a Rede Energética Nacional (REN), sendo que a Gestão técnica do sistema elétrico nacional está no âmbito dessa concessão.

O panorama da produção de energia nos últimos anos tem mudado bastante, em particular aquela que está ligada na rede de distribuição, que tem obrigado a RNT a adaptar-se a essa nova realidade. Parte desta adaptação prende-se com a maior necessidade de previsão das cargas presentes nas subestações de Muito Alta Tensão/Alta Tensão (MAT/AT) uma vez que esta produção, predominantemente eólica, está em grande parte dependente de condições climáticas.

Considerando que a missão do Gestor de Sistema da Operação da Rede (GSOR) é assegurar a alimentação ininterrupta dos consumos, garantindo a qualidade de serviço que lhe é exigível, é fundamental compreender de que forma é possível auxiliar o GS na sua tomada de decisão relativamente às solicitações de indisponibilidades programadas e fortuitas de transformadores, sem colocar em risco os consumos, garantindo ao mesmo tempo margens de reserva de carga dos transformadores adequados.

O desafio lançado pela REN, prende-se com a necessidade de criar uma ferramenta eficaz que apoie o (GS) da RNT na decisão da programação de indisponibilidades.

1.1 Motivação e Objetivos

A motivação deste trabalho prende-se com a necessidade de fornecer ao GS uma ferramenta que possa auxiliar na programação das indisponibilidades dos transformadores.

Como o trânsito de potência nos transformadores de uma subestação MAT/AT não traduz a real carga elétrica por eles alimentados, é decisivo separar a componente de carga da de geração distribuída na RND. Assim surge o conceito de Carga Natural (CN), que corresponde ao valor

efetivo do consumo numa subestação, e que resulta da soma algébrica do trânsito nos transformadores com o da geração distribuída. Dito por outras palavras, e do ponto de vista da REN, a carga natural é aquela que deve ser abastecida pela RNT caso haja uma falha local da produção distribuída, permitindo, em particular, aferir a adequação da potência de transformação instalada e de abastecimento dos consumos. Assim, o objetivo principal desta dissertação é a previsão da CN para cada subestação da REN num horizonte temporal de 7 dias.

Não está no âmbito desta dissertação a realização de previsão de geração distribuída, nomeadamente a eólica. Refira-se que a REN elabora previsão de produção eólica baseada em valores de velocidade do vento há alguns anos, reunindo uma vasta experiência nesta matéria. Contudo, para efeitos de análise histórica e de cálculo da CN, consideram-se os valores de geração distribuída ligadas às subestações da REN.

A determinação dessas previsões decorre da realização de um conjunto complexo de tarefas, seguindo uma metodologia e respeitando uma série de pressupostos, abordados, ao pormenor, no desenvolvimento deste documento. Numa perspetiva sucinta, o conjunto de tarefas a realizar é o seguinte:

1. Caracterização da RNT e dos seus principais constituintes, considerando o histórico recente e a perspetiva de evolução futura;
2. Caracterização das subestações da REN;
3. Extração e tratamento de dados relativos ao trânsito de potência nos transformadores MAT/AT e de valores meteorológicos nacionais;
4. Análise das variáveis justificativas, realizando um estudo dos fatores que influenciam os diagramas de carga (dados temporais, feriados e eventos meteorológicos) através de métodos estatísticos;
5. Estudo dos diversos modelos de previsão de carga, nomeadamente de redes neuronais;
6. Criação de uma metodologia de treino para múltiplas Redes Neuronais;
7. Treino de várias estruturas baseando-se em Redes Neuronais;
8. Previsão da carga natural para as subestações selecionadas;
9. Desenvolvimento de uma aplicação de apoio ao GS na tomada de decisão;
10. Justificar e validar as várias etapas da metodologia.

Pretende-se que a metodologia apresentada e aplicada neste trabalho permita, à ferramenta que se pretende desenvolver, adicionar outras redes devidamente treinadas, possibilitando assim a inclusão de mais subestações nesta aplicação, tornando-a mais flexível.

Portanto, esta dissertação tem como objetivo perceber como tratar em *EXCEL* os dados recebidos de forma a conceber e implementar um programa para obtenção automática da previsão de

carga das subestações. Todas estas operações e funções serão programadas e implementadas neste software.

A programação é baseada em linguagem *Matlab* e inclui uma **interface** gráfica, desenvolvida a partir da ferramenta *Guide* do *Matlab*.

1.2 Estrutura do Documento

O documento elaborado com o intuito de responder ao desafio anteriormente exposto está dividido em 6 capítulos, sendo a sua estrutura apresentada, de forma sucinta, nos seguintes parágrafos.

O capítulo 1 enquadra o leitor no tema, apresentando de seguida os objetivos deste documento assim como a motivação que levou à realização deste documento.

No capítulo 2 é feito um enquadramento da Rede Nacional de Transporte no Sistema Elétrico Nacional (SEN), mostrando os seus elementos constituintes assim como as suas tendências recentes. O sistema electroprodutor em geral associado a esta rede é caracterizado, havendo um foco maior na produção eólica. Apresenta-se a concessionária da RNT, a REN, definindo as suas funções e seus constituintes, evidenciando a sua estrutura funcional e enquadramento do GS. Neste capítulo são ainda analisadas as subestações associadas à REN, nomeadamente no que diz respeito aos seus transformadores e indisponibilidades destes elementos da rede. Efetuando um caso de estudo onde são caracterizadas as subestações.

No capítulo 3 é feito um estudo do diagrama de carga presente nas subestações MAT/AT e a sua previsão, analisando os fatores que podem condicionar este diagrama. São enunciadas as diversas técnicas de previsão de carga em curto prazo existentes, privilegiando as redes neuronais como foco deste estudo. É também realizada uma abordagem acerca da previsão de produção eólica presente na REN.

O capítulo 4 apresenta a metodologia para o treino das estruturas de previsão, usando as redes neuronais, pormenorizando todos os passos na concretização desta metodologia.

O capítulo 5 mostra os resultados tendo em conta as diversas estruturas. Apresenta também os resultados para a melhor rede encontrada para as restantes subestações. Assente nos resultados obtidos é feita uma comparação com um trabalho anterior [5] de previsão de carga nas subestações de forma a averiguar se os resultados obtidos foram satisfatórios.

O sexto e último capítulo refere as conclusões obtidas neste trabalho desenvolvido a nível académico e implementado na centro de operação na rede, destacando os aspetos mais importantes que foram atingidos e enunciando perspetivas de desenvolvimento futuro.

1.3 Dados Utilizados na Dissertação

Os dados utilizados no desenvolvimento desta dissertação provêm da mesma fonte que é utilizada pelo GS;

- SCADA

- A temperatura nas subestações da REN que possuem essa medição;
- Telecontagem
 - Dados históricos de potência ativa nos transformadores das subestações MAT/AT, em amostras de 15 minutos de potência ativa;;
 - Dados históricos de produção em Regime Especial (potência ativa) por Ponto de Entrega (PdE) REN;
- IPMA [6]
 - Previsão da temperatura para os próximos 7 dias;
- AccurWeather [7]
 - Dados históricos de temperatura;

Capítulo 2

Rede Nacional de Transporte

A Rede Nacional de Transporte, ao abrigo de uma concessão exclusiva atribuída pelo Estado Português está concedida à REN, Rede Elétrica Nacional, S.A., de acordo com o artigo número 69 do Decreto-Lei 29/2006 e no seguimento da atribuição de concessão à REN Rede Elétrica Nacional constante no artigo número 64 do Decreto-Lei 182/95, de 27 de Julho [8].

Desta forma a REN é responsável por toda a infraestrutura associada à rede bem como pelo seu planeamento, implementação e operação de todas as conexões necessárias ao correto funcionamento da RNT [8].

O SEN, atualmente encontra-se dividido em diversas áreas como a produção de energia, transporte, distribuição, comercialização, operação do mercado elétrico e consumo. Estas atividades devem ser desenvolvidas em concordância com princípios de racionalidade e eficiência na utilização de recursos ao longo de toda a cadeia de valor e de acordo com os princípios de concorrência e sustentabilidade ambiental, procurando assim aumentar a eficiência do SEN, sem prejuízo das obrigações de serviço público [4].

O desafio lançado pela Rede Energética Nacional (REN) que resultou na elaboração deste documento, exige que se compreenda como está caracterizada a RNT, neste capítulo é feita a sua caracterização e as suas tendências.

2.1 Transporte de Energia Elétrica

A principal função da RNT é interligar os grandes centros produtores às subestações que servem de interface com a empresa distribuidora de energia elétrica, além de garantir a interligação do país com a restante rede europeia síncrona, a ENTSO-E. A interligação de redes trás grandes vantagens para cada membro, pela melhoria da segurança, garantindo o apoio recíproco em caso de perda de geração, o que também permite reduzir as reservas de geração; além disso, permite a existência de mercados de eletricidade alargados pela troca comercial de energia elétrica entre diversas áreas de controlo distintas através do vasto sistema europeu interligado [8] [9].

A RNT possui alguns grandes consumidores ligados à rede de MAT. Estes são as siderurgias nacionais (Seixal e Maia), as unidades fabris de grande dimensão (Autoeuropa em Palmela) e algumas subestações de tração elétrica (REFER), que utilizam energia elétrica de forma intensiva.

Em Portugal, a rede de transporte apresenta uma topologia fortemente malhada, e utiliza a Muito Alta Tensão, nomeadamente os níveis de 150, 220 e 400 kV. Esta topologia é exigida pelo papel preponderante que a RNT tem no equilíbrio dinâmico entre a produção e consumo, pelo que em todo o momento deverá suportar a perda de um elemento de rede sem que isso viole nenhum limite estabelecido (critério N-1). Além disso, a REN é gestora de toda a infra-estrutura técnica, garantindo ainda o livre e indiscriminado acesso à rede a todos os que cumpram os requisitos necessários [10].

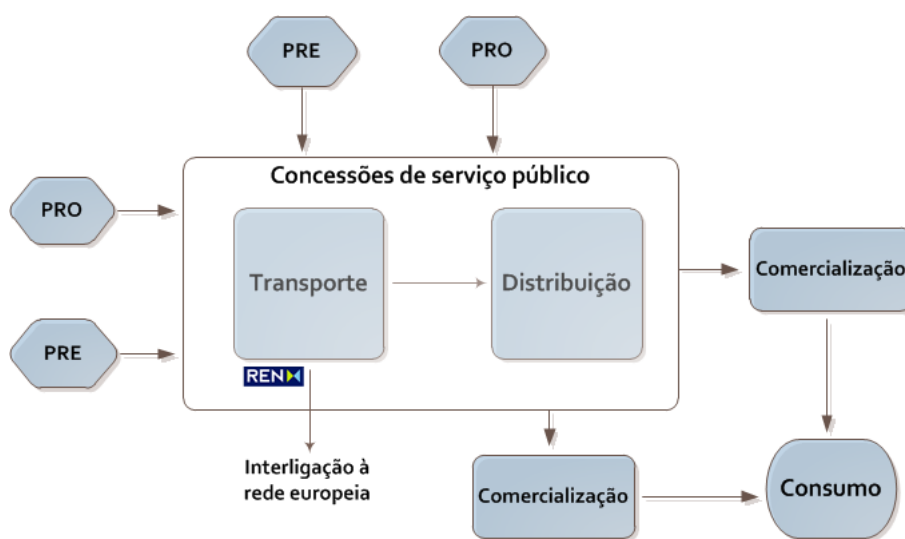


Figura 2.1: Cadeia de valor da SEN

A cadeia de valor de SEN tem mudado o seu formato de forma a adaptar-se melhor aos novos paradigmas, isto é, há uns anos atrás quando não havia componente Produção em Regime Especial (PRE) no sistema, a eletricidade era apenas produzida a montante da rede de transporte e conduzido até ao seu consumidor final através de um diagrama bem definido, sendo este processo unidirecional, nesta altura a produção de eletricidade era feita exclusivamente em regime ordinário (PRO). Hoje em dia o processo é bastante diferente com a inclusão da produção em regime especial, que poderá introduzir na rede a eletricidade a partir da rede de distribuição, mudando desta forma o padrão seguido anteriormente, tornando o processo multi-direcional. Na figura 2.1 está presente a cadeia de valor que se verifica hoje em dia [11].

Tendo em conta que a RNT é muito influenciada pela produção distribuída, de seguida analisa-se de que forma a evolução desta componente a tem afetado.

Atualmente assiste-se a um fenómeno onde a componente de produção renovável tem cada vez mais preponderância sobre a rede, onde dantes apenas existiam centrais que recorriam a recursos hídricos e fósseis que se encontravam longe dos centros de consumo, a produção distribuída na rede de distribuição alterou um pouco esse paradigma, tornando-a mais dispersa, obrigando desta

forma a uma adaptação da rede e motivando assim a criação de novas ligações de forma a conectar os novos produtores em regime especial.

A figura 2.2 mostra a evolução da potência instalada em Portugal, sendo possível verificar um crescimento notório desde 2004, dentro deste crescimento verifica-se também um aumento da componente PRE, nomeadamente da produção eólica.




Figura 2.2: Evolução da potência instalada em Portugal desde 2004 até ao final de 2013

A partir da figura 2.2 é possível aferir que em Portugal existe quase o dobro de potencia instalada comparando-a com a ponta de consumo, o que confere ao sistema ter uma boa reserva [2].

A RNT liga os diversos centros electroprodutores à Rede Nacional de Distribuição (RND) através de subestações MAT/AT, que fazem a transformação do nível de tensão para AT a 60kV.

A criação de um mecanismo de incentivo ao aumento de disponibilidade dos elementos da RNT por parte da Entidade Reguladora do Setor Energético (ERSE), faz com que se promova a fiabilidade da rede de transporte, perspetivando assim o aumento da qualidade de serviço associado ao desempenho da RNT, como tal a REN, reporta periodicamente à ERSE as indisponibilidades ocorridas. Este tema assume um especial interesse, uma vez que através de diversas ferramentas procura-se obter uma coordenação mais eficaz das indisponibilidades dos transformadores, aumentando a qualidade de serviço da RNT [12].

Para que seja feita uma evolução da RNT de forma concertada, as questões de ordenamento de território e ambientais também fazem parte dos compromissos da RNT, expandindo assim a rede de transporte de forma a reduzir os impactos ambientais dos seus equipamentos. Um dos exemplos deste compromisso é materializado na reutilização dos corredores de linha em fim de vida, usando ações de *uprating* e *upgrading* das linhas de forma a aumentar a sua capacidade de transporte [2].

2.1.1 Elementos da Rede Nacional de Transporte

A RNT é constituída na sua grande maioria por linhas aéreas, nos níveis de tensão de 400kV, 220kV e 150kV, e as interligações a Espanha fazem-se em oito pontos, sendo que cinco interligações são a 400kV e três a 220kV. Nas regiões de Lisboa e do Porto existe transporte de energia em cabo subterrâneo explorado a 220kV [10].

Hoje em dia, a RNT contempla 65 subestações, 10 postos de corte, 2 de seccionamento, 1 de transição e um conjunto de linhas de transporte que ascende aos 8534km, como se pode ver na figura 2.3.

	2012-12-31	2011-12-31
Comprimento de linhas em serviço (km)	8 534	8 371
400 kV	2 333	2 236
220 kV	3 521	3 492
150 kV *	2 680	2 643
Potência de transformação em serviço (MVA)	33 915	33 777
Autotransformação	13 410	13 410
Transformação	20 505	20 367

* Inclui 9,0 km do troço português da linha de interligação internacional a 132 kV Lindoso-Conchas.

Figura 2.3: Síntese dos principais equipamentos da RNT

A evolução da RNT na última década tem sido enorme, como se constatar na figura 2.4, tendo-se verificado um crescimento da potência de transformação perto dos 100% desde 2003 até à atualidade, indicando que a complexidade da rede aumenta de forma a corresponder à necessidade de manter os níveis adequados de segurança na alimentação dos consumos, criando consequentemente melhores condições para a receção de PRE [1].

A tendência para os próximos anos indica que no geral o número de subestações irá aumentar, sendo mais notada uma subida nos 400kV e 220kV, em contraponto com as subestações de 150kV onde se prevê um decréscimo do número destas unidades, tal como indica a figura 2.5 [2].

O trânsito de potência dos transformadores das subestações RNT têm uma grande variação, dependendo não só do diagrama de cargas mas também da presença de centros electroprodutores, devido à sua hidraulicidade e eolicidade. Este trânsito é influenciado também pela circulação natural de energia que se estabelece entre a RNT e a rede de transporte espanhola.

De forma a dar resposta à necessidade de interligar novas produções, em particular de PRE, prevê-se um crescimento do comprimento dos circuitos elétricos de linha, estando estes localizados na sua maioria em traçados de linhas já existentes através da reconversão das linhas mais antigas para outras de maior capacidade, fazendo essa medida parte da política de racionalização




Figura 2.4: Evolução da RNT de 2003 até 2012 [1]

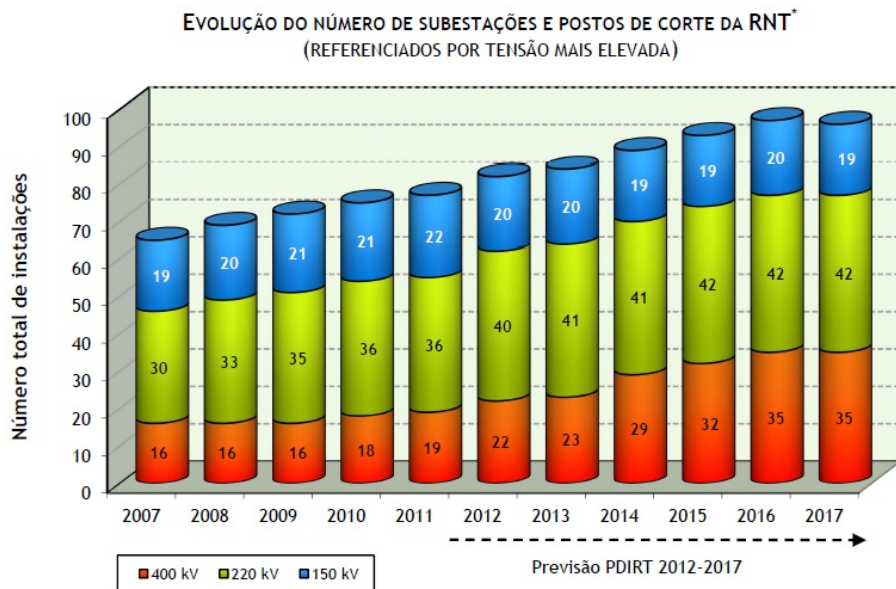


Figura 2.5: Previsão da evolução do número de subestações e postos de corte na RNT previsto de 2014-2017 [2]

da REN. Apesar deste esforço por parte da REN em reduzir os traçados de linhas MAT, é inevitável o seu crescimento devido ao momento que se vive hoje em dia no SEN, fundamentalmente consequência de dois fatores: o primeiro que se prende com necessidade de cobertura do país com rede MAT onde esta ainda não existe, e o segundo com a necessidade de expansão da rede MAT até novos centros electroprodutores, exigindo por vezes linhas muito longas.

De acordo com a perspectiva do [2], o crescimento do sistema elétrico nacional irá verificar-se de forma a corresponder cada vez melhor a todas as exigências da rede, não só no aumento do número de subestações MAT/AT mas também com a extensão da rede MAT até zonas esta onde ainda não existe. A esta ampliação da RNT acresce o aumento da componente PRE e a necessidade de garantir um nível de segurança mais elevado. Assim, a análise eficaz da indisponibilidade dos transformadores torna-se fulcral de forma a acompanhar esta evolução da PRE.

2.1.2 Sistema Eleprodutor

Em termos mundiais a energia elétrica continuará a contribuir cada vez mais para a crescente procura de energia, sendo que as previsões indicam que este consumo tenderá a crescer mais que o consumo de combustíveis líquidos, gás natural ou carvão, em todos os setores de utilização final, excetuando na área dos transportes [13].

A nível nacional, este crescimento tem abrandado como indica a figura 2.6, onde se pode verificar que a partir de 2009 o crescimento do consumo de eletricidade foi negativo em contraste com anos anteriores, sendo o ano de 2010 atípico uma vez que o crescimento foi positivo. Apesar deste decréscimo no consumo, a potência instalada tem evoluído, nomeadamente a nível de produção em regime especial. No ano de 2013 a produção renovável em Portugal contribuiu em 57% para a produção total de eletricidade, tornando 2013 no ano em que houve mais contribuição renovável de sempre [1].

Em Portugal existem dois regimes de produção, que estão enumerados como sendo Produção em Regime Ordinário (PRO) e Produção em Regime Especial (PRE), estando caracterizado a PRO como sendo uma produção de eletricidade com base em fontes tradicionais não renováveis e em grandes centros eletroprodutores e considerando-se a PRE como sendo a produção de eletricidade com base em energias renováveis, em resíduos e em processos de cogeração, a microprodução também se caracteriza por estar associada a este regime, sendo a sua produção de eletricidade em muito pequena escala (potência instalada inferior a 5.75kW), seja através de uma fonte de energia renovável ou cogeração a biomassa. Os grandes aproveitamentos hidroelétricos, apesar de terem como base uma fonte renovável, são considerados no regime ordinário.

Nos últimos anos, verificou-se um crescimento da PRE entregue à rede bastante notório, onde se destaca a produção eólica. As vantagens ambientais e o regime de apoio à PRE por parte do Estado Português são os fatores mais fortes para que esta tendência se tenha apurado. No ano de 2012, a PRE teve um contributo de 38% para a satisfação do consumo, sendo que 53% deste valor foi de origem eólico [10].




Figura 2.6: Evolução do Consumo [1]

2.1.2.1 Produção Eólica

Na última década, com a evolução das fontes renováveis foi criado um novo paradigma no *mix* de produção elétrica nacional, principalmente com o aumento do número de parques eólicos. A evolução da produção eólica tem sido assinalável, sendo encarada como uma das mais promissoras fontes de energia [14].

A figura 2.7 mostra a evolução que a componente eólica tem tido no consumo, aumentando a sua contribuição de ano para ano.

O fato desta energia possuir um carácter inconstante e não controlável devido ao vento, introduz no SEN um novo paradigma, criando uma maior volatilidade na produção de energia que necessitará de ser estimado de forma a serem criadas boas condições de trabalho na RNT. Relativamente a este fator deve-se ter em consideração a previsão do crescimento desta energia, que necessitará de um controlo maior sobre a produção de energia eólica de forma a não afetar o bom funcionamento da rede.

A potência instalada em território nacional no final de 2012 totalizava 4464 MW, distribuídos por 220 parques, sendo que a potência efetivamente ligada à rede era de 4194 MW uma vez que a potência total instalada inclui sobreequipamento em vários parques. Apesar de estar a ocorrer um abrandamento no crescimento, em comparação com os últimos anos, os parques eólicos continuam a crescer, aumentando a sua contribuição de energia na RNT. A figura 2.8 mostra a potência total ligada em comparação com a evolução anual, sendo notório um crescimento mais baixo desde 2010 [1].

Através da figura 2.9, verifica-se que no final de 2012 a potência eólica ligada à rede representava 23% da potência total ligada ao SEN, assumindo um valor bastante significativo e crescente




Figura 2.7: Evolução do Consumo por componente de produção [1]




Figura 2.8: Potência eólica total ligada [REN]

tendo em conta os últimos anos. Esta potência reparte-se por 48% na Rede de Transporte e 52% na Rede de Distribuição, assumindo este último valor uma grande importância neste documento, uma vez que esta potência à Rede de Distribuição tem uma grande influência nos trânsitos de potência verificados nos PdE.

	2012	2011	2010
[MW]			
SEN	18 546	18 894	17 895
Eólica	4 194	4 080	3 706
	23%	22%	21%

Figura 2.9: Comparação entre a potência eólica e a potência do SEN [REN]

2.2 REN - Concessionária da RNT

Em 1994 criou-se a REN – Rede Elétrica Nacional, S.A., na sequência da cisão com a EDP – Eletricidade de Portugal, S.A. de que fazia parte como Direção Operacional da Rede Elétrica.

A REN em Novembro de 2000 viria a sair do Grupo EDP. O prosseguimento do processo de privatização deste Grupo e a liberalização do mercado energético europeu, que, conforme orientação da diretiva 96/92/CE de 19 de Dezembro, veio impor a separação jurídica entre as empresas responsáveis pela gestão da rede de transporte e as empresas responsáveis pela produção e distribuição de eletricidade, levou o Governo a proceder à autonomização da Rede Elétrica Nacional consolidando a posição de concessionária da rede como entidade independente dos restantes operadores. Durante esta década até aos dias de hoje a REN tem assumido o seu papel no SEN, aumentando também a sua área de abrangência para o campo do gás natural em 2006, passando a denominar-se de REN – Redes Energéticas Nacionais, SGPS, SA. Desta forma a REN, tem aumentando a sua capacidade de adaptação à evolução do setor energético, procurando ser um dos mais eficientes operadores europeus de redes de transporte de energia, criando valor para os seus acionistas dentro de um quadro de desenvolvimento sustentável [15].

2.2.1 Operação da Rede

Sendo a área da eletricidade da REN o foco deste documento, é importante compreender como esta está estruturada, assim a unidade de negócio de eletricidade da REN apresenta o formato indicado na figura 2.10.

- Planeamento da Rede

A definição das estratégias de evolução da RNT e dos planos que a englobam fazem parte das responsabilidades desta unidade, que desenvolverá o seu trabalho no sentido de garantir que

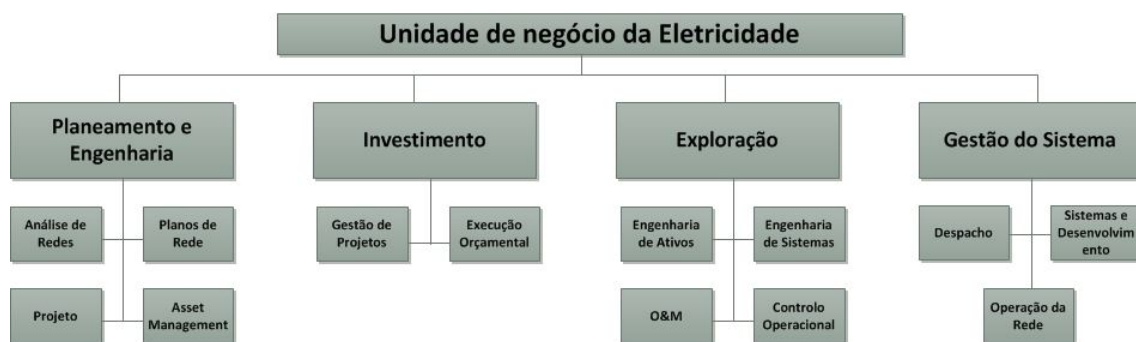


Figura 2.10: Estrutura da unidade de negócio de Eletricidade da REN [REN]

o desempenho da RNT esteja de acordo com as necessidades do SEN. É responsável pela elaboração do PDIRT - Plano de Desenvolvimento e Investimento da Rede de Transporte de Eletricidade [16].

- Investimento

Este Direção tem como função coordenar e controlar a execução dos projetos e obras do Plano de Desenvolvimento e Investimento da RNT, garantindo a entrada em funcionamento das infraestruturas elétricas nos prazos e custos definidos.

- Exploração

A coordenação e controlo da manutenção de todos os ativos materiais das subestações e linhas que constituem a Rede Nacional de Transporte é da responsabilidade da exploração, apoiando a integridade da RNT e a qualidade de serviço.

- Gestor do Sistema

O bom funcionamento do SEN é assegurado por este departamento, que de acordo com a legislação vigente procura garantir além do equilíbrio entre a produção, a segurança da RNT, a interligação à rede continental europeia e assegurar as condições necessárias para o funcionamento do mercado de eletricidade. A Direção da Gestão de Sistema está dividida em três departamentos: o do Despacho (GSDS), o dos Sistemas e Desenvolvimento (GSSD) e o de Operação da Rede (GSOR).

2.2.1.1 Funções

Pertencente ao Departamento de Operação da Rede, o Centro de Operação da Rede (COR) tem como principal missão garantir a continuidade do serviço e realizar a supervisão e operação remota da RNT com a qualidade de serviço exigível, em coordenação com as equipas de operação e manutenção local que prestam apoio às subestações e com as salas de comando das entidades externas ligadas à RNT (Centrais de Produção, Consumidores MAT, EDP Distribuição e REE – Rede Elétrica de Espanha) e em colaboração com o Centro de Controlo, da mesma Direção (GSDS) [17].

As principais funções do COR são:

- Supervisionar constantemente a RNT, de forma a reagir atempadamente às perturbações nas grandezas de tensão, frequência, corrente e temperatura, realizando as manobras necessárias para reposição das condições de operação normal;
- Em regime normal, executar por telecomando as manobras necessárias nas instalações da REN, efetuando as comunicações necessárias para assegurar a coordenação com as salas de comando das entidades externas e com equipas de operação local;
- Participar em processos de criação de condições de segurança para trabalhos na RNT, assumindo o papel de Responsável e efetuando a emissão/receção das Autorizações de Trabalho;
- Monitorizar permanentemente os equipamentos das instalações REN, fazendo diagnósticos de avarias, estabelecendo graus de gravidade e notificando os agentes necessários para as resolver;
- Participar na programação de trabalhos que impliquem indisponibilidades e regimes especiais de exploração em instalações da RNT. Participar na elaboração do plano anual de indisponibilidades;

É de salientar que o COR monitoriza todas as subestações a nível nacional, dispondo de telecomandos que permitem a atuação sobre os diversos elementos do sistema, tais como:

- Disjuntores;
- Reguladores Automáticos de Tensão;
- Tomadas dos transformadores;
- Operadores Automáticos;
- Dispositivos de comutação para Regime Especial de Exploração;
- Inibição das funções de religação rápida e religação lenta;

2.2.1.2 Aquisição de dados

Uma das ferramentas essenciais no COR é o SCADA (Supervisory Control and Data Acquisition), permitindo esta obter os dados das instalações e a emissão de comandos sobre as mesmas em tempo real. Através do SCADA obtêm-se vários tipos de dados, tais como:

- O número da tomada dos transformadores e a situação da regulação da tensão.
- As medidas da tensão nos nós da rede (subestações, postos de corte e centrais), os valores da potência ativa e reativa ou correntes nos ramos, sejam estas linhas, transformadores ou baterias de condensadores.
- Os estados dos órgãos de manobra (disjuntores e seccionadores).

2.2.1.3 Coordenação de indisponibilidades

De forma a minimizar o tempo em que os elementos da RNT estão fora de serviço e garantir uma coordenação eficaz entre as entidades promotoras, o COR realiza a programação dos seguintes tipos de trabalhos:

- Indisponibilidade (em curso, previstas e já finalizadas) – quando o elemento não está apto para realizar o serviço para que foi construído;
- Regimes Especiais de Exploração;
- Regimes de Intervenção em Serviço;
- Serviços condicionados;
- Ensaios;
- Transferências de carga entre subestações;

Este processamento procurará integrar o máximo número de trabalhos de diferentes departamentos, minimizando as saídas de serviço programadas, nomeadamente tendo em vista maximizar a taxa combinada de disponibilidades dos elementos da rede [18].

Estas indisponibilidades são classificadas como:

- FC – resultante de incidente;
- FT (fortuita) – indisponibilidade prevista com menos de 24 horas de antecedência;
- PL (planeada) – indisponibilidade que faz parte do Plano Anual de Indisponibilidades;
- PR (programada) – indisponibilidade que foi pedida com antecedência (pelo menos 24 horas);

O COR assume-se assim como o centro da programação de trabalhos, fazendo a comunicação entre todas as entidades envolvidas, sejam estas externas ou internas [11].

Em relação trabalhos existentes no SEN, existem dois tipos de tratamento:

- Plano Anual de Indisponibilidades (médio/longo prazo);
- Tratamento dos trabalhos a curto prazo (semana s+1);

O COR é responsável pela análise e autorização de indisponibilidades de transformadores de potência de entrega à distribuição. No processo de análise importa prever corretamente, durante o período de indisponibilidade, o trânsito máximo nos transformadores, mediante este esse valor poderá ser necessário requerer ao distribuidor uma transferência de carga para outros PdE por forma a limitar eventuais sobrecargas. Caso não haja essa possibilidade, poderá ser necessário alterar a



Figura 2.11: Diagrama de comunicação do COR com outras entidades

indisponibilidade para um período de carga mais baixo: fim de semana, feriados (e pontes), ou para uma estação do ano mais favorável (por exemplo a Primavera) com custo acrescidos.

Com base nestes dados é possível perceber a importância deste “*player*” no SEN, assim torna-se relevante o desenvolvimento de ferramentas que possam possibilitar uma melhor execução das suas funções.

2.3 Subestações

Nesta secção caracterizam-se as subestações tendo em conta o seu perfil e o local onde se encontram. É alvo de discussão a procura pelo aumento de disponibilidade assim como a análise das indisponibilidades dos transformadores onde são definidas as regras e os procedimentos a tomar em caso de incidente.

As características da potência de transformação presentes nas subestações MAT/AT são um dos temas deste documento, pelo que é necessário analisar as suas singularidades.

2.3.1 Enquadramento

Com a inclusão de produção em regime especial AT e MT criou-se um novo paradigma em relação ao trânsito de potência efetivo nos transformadores MAT/AT, sendo que a decomposição deste trânsito hoje em dia terá de ter em conta a produção a jusante e a montante da posição do transformador, ao contrário do que se verificava antes da inclusão deste tipo de produção, onde

se tinha apenas em consideração a produção a montante deste local, isto é, o processo era "Top-Down" onde o trânsito presente nos transformadores das subestações da RNT correspondia à carga real.

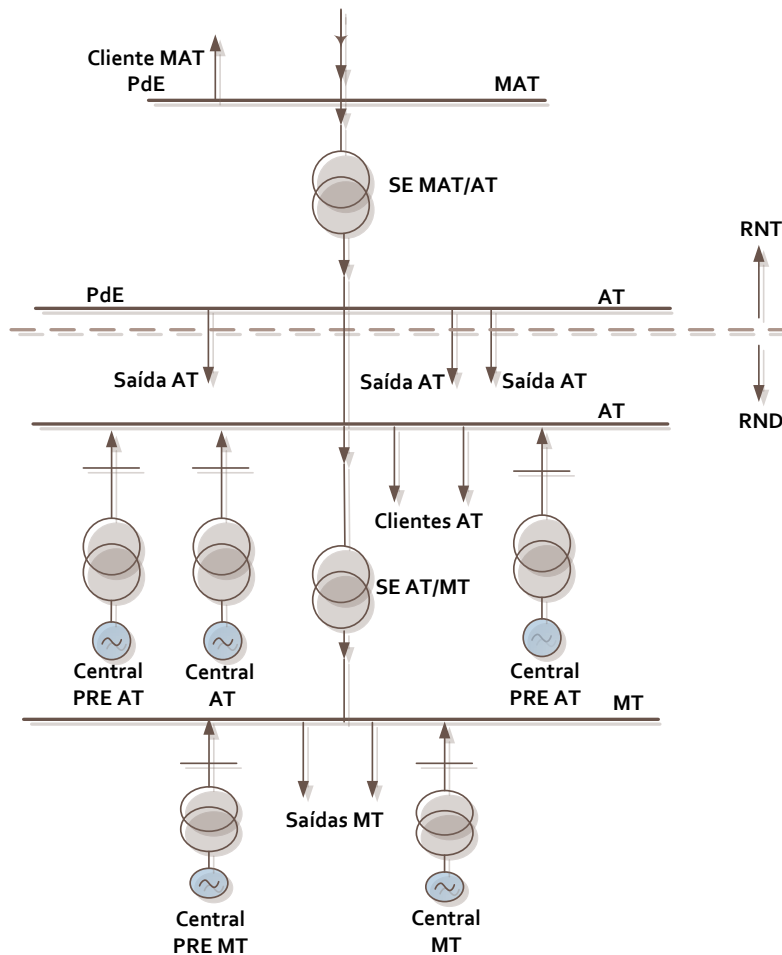


Figura 2.12: Exemplo de rede

Para ultrapassar este problema foi criado o conceito de carga natural associado a uma subestação, que é obtida através da soma do trânsito efetivo nos transformadores de potência da subestação e o total de produção distribuída que se pressupõe que liga àquela subestação, conforme se refere na equação 2.1.

$$CN = TR + Prod(RND) \quad (2.1)$$

A figura 2.12 mostra de que forma a rede está organizada, expondo de forma clara quais são as contribuições para o trânsito de potência verificado nos transformadores MAT/AT. Neste caso, é possível verificar que este não depende apenas daquilo que se encontra a montante mas também

do que se verifica a jusante, tais como os diversos consumidores e as diversas produções em regime especial.

De forma a compreender a dificuldade em perceber a carga natural presente em cada subestação, analisou-se o trânsito de potência de duas subestações distintas em termos de PRE, caso da subestação de Vermoim e de Valdigem. A nível global a potência de ligação da PRE a estas subestações é de 6.84% no caso da Valdigem e 1.43% em Vermoim, a potência de ligação de Valdigem é de 351.2 MVA e predominantemente eólica, em Vermoim a potência de ligação é de 73.3 MVA sendo esta predominantemente de cogeração.




Figura 2.13: Carga presente em duas subestação de 24 de Outubro até dia 30 de Outubro de 2013

Os gráficos 2.13a e 2.13b mostram claramente o impacto da PRE no trânsito de potência

verificado nos transformadores, onde a diferença entre a carga natural e o trânsito presente nos gráficos é exatamente a produção em regime especial recebida por cada subestação. Sendo notório neste caso que a Valdigem recebe uma fatia muito maior de PRE em comparação com a subestação de Vermoim.

Neste trabalho propõe-se a prever os níveis aproximados de carga natural, sendo aquela que deve ser abastecida pela RNT na hipotética falha local da geração distribuída em cada subestação permitindo aferir a adequação da potência de transformação instalada e de abastecimento da carga natural nas subestações RNT.

2.3.2 Caracterização dos Transformadores

Um dos desafios hoje em dia da REN em relação às subestações prende-se com a idade dos seus equipamentos, é necessário concretizar diversas remodelações nas instalações da RNT nos próximos anos para que estes não percam a sua eficácia. Outro dos objetivos relativos às subestações está ligada com a evolução da produção de eletricidade em regime especial, uma vez que devido à sua dispersão geográfica a RNT terá de adaptar as suas subestações a novos perfis de produção.

A figura 2.14 mostra a distribuição da população de transformadores de potência por idades, onde é notório que o número de transformadores instalados nos últimos 6 anos é bastante superior ao verificado em períodos anteriores. Apesar deste crescimento, o número de transformadores com mais de 25 anos é ainda cerca de metade do parque, surge assim a necessidade da REN em substituir equipamentos mais antigos que tecnicamente estejam mais degradados.

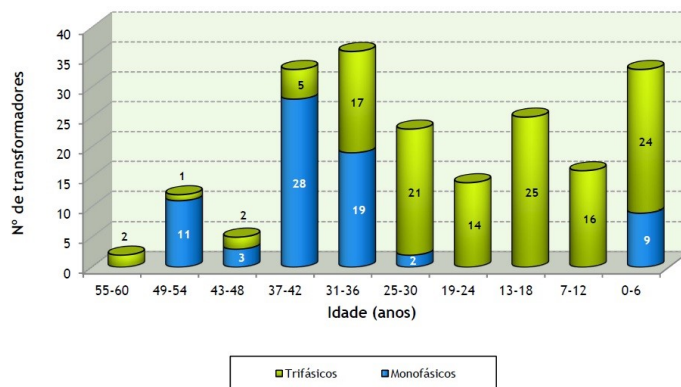


Figura 2.14: Idade dos transformadores presentes na RNT

A perspetiva é que a potência de transformação terá uma evolução significativa nos próximos anos de forma a adequar a segurança na alimentação dos consumos, assim como a criar condições para a receção de mais PRE. Na figura 2.15 pode-se verificar a evolução da potência total instalada de transformação e autotransformação [2].

Até a data de 31 de Agosto de 2013 a população total de transformadores na RNT era de 187, fazendo um total de 33815MVA de potência de transformação. Estes equipamentos estão

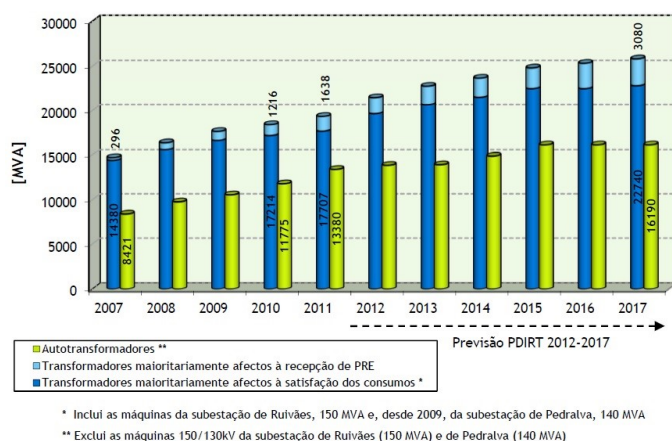


Figura 2.15: Previsão da Evolução da potência de transformação até 2017 [2]

distribuídos pelas diversas subestações, podendo ser analisados a sua distribuição no anexo B.1 com mais atenção.

Tabela 2.1: Quantidade de transformadores nas instalações REN

TRANSFORMADORES									
400/60kV		220/60kV		150/130kV		150/60kV		Total	Total
Nº	MVA	Nº	MVA	Nº	MVA	Nº	MVA	Potência	Equipamentos
20	3 400	82	11 323	1	140	49	5 692	20 555	152

Tabela 2.2: Quantidade de autotransformadores nas instalações REN

AUTOTRANSFORMADORES							
400/220kV		400/150kV		220/150kV		Total	Total
Nº	MVA	Nº	MVA	Nº	MVA	Potência	Equipamentos
15	6 750	14	5 540	6	970	13 260	35

O número de transformadores presentes nas instalações está presentes nas tabelas 2.1 e 2.2.

2.3.2.1 Incentivo ao aumento de disponibilidade dos elementos da RNT

Com o objetivo de promover a sua fiabilidade, enquanto fator determinante para a qualidade de serviço associada ao desempenho RNT, bem como à manutenção de equipamento em fim de vida útil de forma a criar condições técnicas para continuar a exploração, a ERSE introduziu no recém publicado Regulamento da Qualidade de Serviço do Setor Elétrico, de outubro de 2013 o mecanismo de incentivo ao aumento disponibilidade dos elementos da RNT. Refira-se, no entanto, que este mecanismo já estava em vigor na REN no âmbito do período regulatório (2009-2011), conforme estabelecido pelo Despacho n.º 18138/2009 da ERSE. O valor do incentivo à disponibilidade da rede de transporte irá depender do valor da taxa combinada de disponibilidade.

Desta forma torna-se cada vez mais importante aumentar a disponibilidade dos elementos de rede da RNT, tanto para a REN assim como para o SEN em geral [19].

2.3.2.2 Reserva N-1 de carga de uma subestação

Para compreender a secção 2.3.2.3 é necessário assimilar o conceito de reserva n-1. Como regime de contingência N-1, considera-se a falha de um qualquer elemento da RNT (linha simples, circuito de linha dupla, grupo gerador, autotransformador, transformador), devendo nos restantes elementos, sem exceção, não se verificarem violações dos critérios de tensão e de sobrecarga sem qualquer redespacho ou reconfiguração topológica nem interrupções no abastecimento de energia elétrica.

Assim, a reserva n-1 de transformadores resulta da aplicação do conceito de regime de contingência N-1, aplicado especificamente aos transformadores de potência. Assim, face a um valor de carga numa subestação, considera-se que esta possui reserva n-1 de transformadores se, após a perda do transformador de maior potência, cada um dos restantes ficar com um valor de carga menor ou igual à sua carga máxima admissível.

2.3.2.3 Análise de Indisponibilidades de Transformadores

De forma a garantir a segurança e a continuidade de serviço da rede o COR possui um conjunto de regras de análise das indisponibilidades dos transformadores. Assim sendo, e tendo em conta que os imprevistos podem acontecer a qualquer momento é necessário possuir um valor de reserva de forma a garantir um serviço ininterrupto. Para que este valor da reserva de carga se mantenha, o operador de sistema pode pedir à EDP para reconfigurar a rede e realizar transferências de carga entre pontos de entrega de forma a manter a potência de transformação dentro dos limites [20].

As regras gerais desta análise são:

- Não deverá ser programada a indisponibilidade de um transformador sempre que implique a sobrecarga(s) de outro(s) transformador(es);
- Indisponibilidades simultâneas de transformadores de instalações que se possam socorrem mutuamente em caso de incidente não deverão ser programadas;
- As transferências de carga programadas de forma a inviabilizar a indisponibilidade de um transformador de uma dada instalação não deverá levar à perda de reserva na instalação que recebe essa carga;
- Na elaboração do plano anual de indisponibilidades, as indisponibilidades dos transformadores deverão ser colocadas nos períodos considerados mais favoráveis;

Num sentido lato, as regras gerais para a análise de indisponibilidades dos transformadores estão atrás citadas, no entanto existem regras em função do número de transformadores presentes nas subestações.

Em instalações com 5 ou 4 transformadores é possível indisponibilizar um TR em dia útil sem que haja perda de reserva n-1 de TR, assim não será autorizada a indisponibilidade que implique a perda de reserva. Caso ocorra um incidente com perda de 1 TR (indisponibilidade fortuita), tentar-se-á repor a reserva solicitando a transferência de carga necessária.

No caso de instalações com 3 transformadores, caso ocorra a indisponibilidade de um TR, esta apenas é autorizada na janela de oportunidade ou em períodos de carga reduzida como o fim-de-semana, feriados ou pontes. Nestas instalações a utilização da potência de transformação por norma é muito elevada, criando janelas de oportunidade, quando existem, de poucas semanas de duração. Por isso, poderão ser autorizadas indisponibilidades com perda de reserva.

Quando uma instalação possui 2 transformadores, a indisponibilidade de um deles resulta naturalmente na perda de reserva n-1, caso ocorra um incidente em que perca um TR que fica em serviço, toda a carga alimentada pela instalação é cortada. Nestes casos é necessário fazer uma análise detalhada das alternativas para a alimentação da totalidade da carga cortada através da rede de Distribuição.

Nas instalações com apenas um transformador, deve-se quanto possível, programar as indisponibilidades nos períodos anuais de carga baixa (Primavera/Outono). Esta programação deverá ser sempre realizada por acordo com a EDP Distribuição [20].

2.3.2.4 Cargas Máximas Admissíveis

Os limites de carga máximos não devem ser ultrapassados de forma a que uma indisponibilidade seja viabilizada, mesmo que a reserva n-1 seja ultrapassada e os transformadores se encontrem numa situação de sobrecarga.

Assim foram definidos os seguintes valores de carga máxima tendo em conta o período do ano e a classificação dos transformadores, apresentada na 2.3.

Tabela 2.3: Cargas máximas admissíveis nos transformadores

Classificação dos Transformadores	Inverno	Verão
Antigos	1.10xPn	Pn
Recentes Pn=ParrMáx	1.20xPn	1.05xPn
Recentes Pn<ParrMáx	ParrMáx	ParrMáx

Estas sobrecargas devem ser consideradas como tendo um limite temporal de uma hora, sendo o tempo suficiente para que se realize as transferências de carga de forma a anular a sobrecarga.

Neste caso é considerado o seguinte:

- No Verão a temperatura média diurna é maior que 20°C, período relativo a 1 de Abril a 30 de Setembro;
- No Inverno a temperatura média diurna é menor ou igual a 20°C, período relativo a 1 de Outubro a 31 de Março.

Caso se verifique temperaturas superiores a 20°C no Inverno, adotam-se valores de carga admissível do Verão, assim como se se verificar temperaturas menores ou iguais a 20°C no período de Verão, adotar-se-á valores de carga admissível de Inverno. É considerado “utilizável” a potência dos transformadores correspondentes ao regime de arrefecimento mais eficaz (ParrMáx).

2.4 Caracterização das Subestações

A rede elétrica nacional tem vindo ao longo dos últimos anos a sofrer diversas mudanças de forma a adaptar-se cada vez melhor à exigência do mercado energético, como tal é necessário adotar medidas que possam torná-la mais eficiente mantendo a sua fiabilidade, isto é, proporcionando alimentação ininterrupta para todos os consumidores.

Com este aumento da especificidade no sistema, sentiu-se a necessidade de caracterizar as diversas subestações uma vez que estas apresentam características singulares consoante o contexto onde estão inseridas. A identificação do perfil de cada PdE torna-se útil para o operador de sistema perceber de que forma a subestação irá comportar-se em determinada situação, sendo importante ainda para o estudo de previsão dos trânsitos de potência em cada estação.

Procurou-se então caracterizar as diversas particularidades de cada PdE, estando estas associadas ao tipo de consumo, ao número de transformadores e à geração distribuída (em Alta, Média e Baixa tensão) associada a estas. Este documento torna-se assim uma fonte de informação rápida acerca de cada subestação e as suas particularidades, definindo níveis de necessidade de previsão para cada instalação, e o seu risco de indisponibilidade. É possível verificar este documento no anexo B.1.

O documento referido baseia-se nas seguintes características.

Em relação ao tipo de consumo, centrou-se o estudo em:

- Valores de pico do consumo

Estudou-se os picos de consumo associado a cada PdE;

Tendo em conta a especificidade dos transformadores de cada subestação, analisou-se o seguinte:

- O número de transformadores e a sua potência aparente
- A reserva presente em cada subestação

O valor da reserva baseia-se no pressuposto da garantia de reserva n-1;

- Potência total de transformação de cada subestação

Potência associada à soma de todos os transformadores;

- A ponta máxima de carga do ano em vigor, isto é, o pico de trânsito que ocorreu no ano de carga para cada PdE;

- O nível de reserva associado a cada equipamento, estando caracterizado em 4 estados, sendo estes:

Reserva Nula - Quando a ponta máxima do trânsito de potência presente nos transformadores ultrapassa o valor da reserva;

Reserva Baixa - Quando o valor da ponta máxima do trânsito de potência presente nos transformadores está entre 75% e 100% do valor da reserva;

Reserva Média - Quando o valor da ponta máxima do trânsito de potência presente nos transformadores está entre 25% e 75% do valor da reserva;

Reserva Alta - Quando o valor da ponta máxima do trânsito de potência presente nos transformadores equivale a menos de +25% do valor da reserva;

No que diz respeito à geração associada a cada PdE, focou-se o estudo nas seguintes características:

- A potência total de ligação (MVA);
- Ao tipo de geração, tendo em conta a sua contribuição para o valor total;

Eólica;

Hídrica;

Cogeração;

Solar;

- A influência da quantidade de geração associada a cada PdE

Esta análise é feita para melhorar a percepção do peso da geração em cada subestação, sendo classificada em:

- Nula;

- Média;

- Alta;

- Muito Alta;

- Geração maioritária

Classifica-se a geração predominante em cada estação, tendo em conta os seguintes parâmetros:

- Se houver um contributo acima dos 75, a subestação é classificada como tendo uma geração predominante.

- Caso não haja um contributo acima dos 75, a subestação é denominada como “*Mix*”.

A transferência de carga de cada PdE é caracterizada tendo em conta os seguintes parâmetros:

- Carga transferível

É quantificado a carga total que pode ser transferível de cada subestação;

- Carga não transferível

É quantificado a carga total que não pode ser transferível para outra subestação;

- Nível de transferência

Este ponto demonstra o nível de transferência de cada subestação, sendo dividida em 3 níveis distintos:

- Baixo – Onde a carga transferível perfaz no máximo 25 da reserva de cada subestação.

- Médio – Onde a carga transferível situa-se entre os 25 e os 50 da reserva de cada subestação.

- Alto – Onde a carga transferível perfaz no mínimo 50 da reserva de cada subestação.

De forma a perceber a prevalência do consumo sobre a produção em cada PdE, distinguiu-se esta nos 3 seguintes princípios:

- Alta – Ocorre quando o valor de pico do consumo é maior que 50 do valor da potência total de ligação da geração;
- Média – Ocorre quando o valor de pico do consumo é maior até 50 do valor da potência total de ligação da geração;
- Não se verifica – Nesta situação o valor da potência total de ligação da geração é superior ao valor de pico do consumo, não se verificando a prevalência do consumo sobre a produção;

De forma a avaliar a necessidade de previsão de cada subestação, esta foi dividida em 4 parâmetros, tendo em conta o que está discriminado anteriormente;

- Baixa - Ocorre quando o nível de reserva é alto, a geração maioritária é hídrica ou solar e o nível de transferência presentes na subestação é alto.
- Média - Ocorre quando se conjugam fatores como um nível de reserva alto e um nível transferência de carga baixo independentemente da geração maioritária presente, em casos onde o nível de reserva seja baixo, apenas se irá conjugar com subestações onde haja uma transferência de carga alta.
- Alta - Ocorre quando o nível de reserva é baixo ou nulo, conjugado com um nível de transferência médio ou baixo, independentemente da geração maioritária.
- Muito Alta - Ocorre na maioria dos casos onde a reserva é nula, o nível de transferência de carga é baixa e a geração maioritária provem de cogeração ou eólica.

Desta forma é possível auxiliar o GS na perceção global do sistema e assim contribuir para a tomada de decisão. Para que este documento mantenha a sua utilidade, precisa de ser anualmente atualizado com os novos valores de consumo, de produção distribuída e com a entrada ou saída de serviço de transformadores.

Capítulo 3

Previsão de Carga

Atualmente a previsão de carga é um processo importante para os sistemas de gestão de energia, seja uma antecipação da carga em muito curto, curto, médio ou longo prazo. Este trabalho irá focar-se na previsão de carga em curto prazo (*short-term load forecast*) procurando melhorar o controlo do sistema elétrico de energia, fornecendo uma ferramenta útil ao operador de sistema na gestão da distribuição de energia [21]. A meta será encontrar a melhor previsão da transferência de carga presente em cada subestação para os próximos 7 dias.

A qualidade de cada previsão de carga natural tem, hoje em dia, um impacto forte sobre a eficiência das diversas tomadas de decisão por parte dos operadores, já que contribui para uma melhor gestão da energia, planeamento das indisponibilidades dos transformadores e transferências de carga, quanto maior for a qualidade da previsão da carga.

Neste capítulo irá estudar-se de que forma o diagrama de carga natural é influenciado, procurando identificar e perceber as suas tendências para que seja feita uma seleção lógica das variáveis de entrada, denominando estas de variáveis justificativas. Apresenta-se uma análise da correlação da carga tendo em conta as horas de consumo anteriores assim como o consumo nos mesmos dias em semanas anteriores, sendo também analisado o impacto das condições meteorológicas no consumo de carga.

As metodologias de previsão nos últimos anos evoluíram bastante, neste capítulo serão abordadas algumas dessas técnicas, privilegiando os sistemas baseados em inteligência artificial como as redes neuronais, como foi sugerido para este trabalho pela REN.

O trânsito efetivo nos transformadores está dependente de dois fatores, sendo estes a carga natural e produção em regime especial associada a determinadas subestações, como a produção eólica assume um papel dominante neste regime é abordado de que forma é feita a previsão da produção eólica por parte do Gestor do Sistema (GS) da REN.

3.1 Previsão de Carga - Curto Prazo

Nos últimos anos foram muitos os investigadores que focaram os seus trabalhos neste campo da previsão, tendo como objetivo melhorar as técnicas de previsão conhecidas. Tal como se viu

anteriormente, estes desafios são complexos, uma vez que o consumo pode ser afetado por diversos fatores [22].

A grande diversidade de técnicas existentes indica que esta é uma área em que se deposita cada vez mais esforços de forma a serem obtidos melhores desempenhos. Modelos de regressão, redes neuronais, lógica *fuzzy* e algoritmos de aprendizagem têm sido usados para previsões de curto-prazo [23]. Os modelos que melhor interpretam os seus componentes, como a regressão linear continuam a ser muito usados, uma vez que ajudam os operadores de sistema a compreender melhor o comportamento do consumo, no entanto estas técnicas são ferramentas lineares e as séries de consumo que se tenta explicar são funções não-lineares de variáveis exógenas [22].

Hoje em dia vários estudos comprovam que a aplicação de redes neuronais em previsões de curto-prazo é mais eficaz em situações onde existe uma maior diversidade de dados de entrada, isto é, uma maior complexidade como é o caso em estudo [24]. Apesar desta técnica possuir um peso computacional considerável em comparação com outras técnicas (*ARIMA*, *Holt-Winters*), depois de estabelecido este sistema trabalha com a mínima intervenção humana [25]. Assim se o uso de redes neuronais for conveniente esta tenderá a aumentar a eficácia da sua previsão [26].

Os resultados obtidos com este método têm sido na maior parte dos casos bem sucedidos, embora seja necessário dotar estas redes de entradas ajustadas a cada situação, como valores passados de carga, dados meteorológicos assim como um indexante de eventos especiais que possam ter impactos fortes em determinada região, como um feriados ou uma época festiva que altere comportamentos de consumo [27]. É de destacar que o uso do algoritmo de *backpropagation* obteve um desempenho mais precisos em comparação com outros tipos de treino [27], [28], [29].

A investigação e melhoria destas ferramentas têm levado ao desenvolvimento de técnicas de previsão mais complexas, como é o caso das técnicas de inteligência artificial, nomeadamente de redes neuronais que têm a sua grande vantagem no facto de não ser necessário conhecer a natureza da série de dados, dado que o processo de aprendizagem adquire as características essenciais ao conjunto de dados. São considerados sistemas universais uma vez que as funções de ativação podem ser não lineares, permitindo assim aproximar funções independentemente da sua linearidade. Sendo também uma vantagem deste tipo de redes basearem-se em exemplos históricos, não sendo assim necessário o conhecimento especializado para tomada de decisões. O treino demorado da rede e a necessidade de uma boa preparação dos dados de entrada assim como de um grande volume de dados históricos para que esta faça uma boa aprendizagem são os pontos fracos desta ferramenta.

Nos últimos anos, a liberalização do setor elétrico em muitos países fez com que os métodos de previsão fossem cada vez mais importantes a nível económico e operacional, de forma a prever os preços da eletricidade, o consumo e a produção de energia com mais eficácia [30]. Em relação à previsão de consumo de energia hoje em dia as técnicas mais utilizadas estão presentes na figura 3.1.

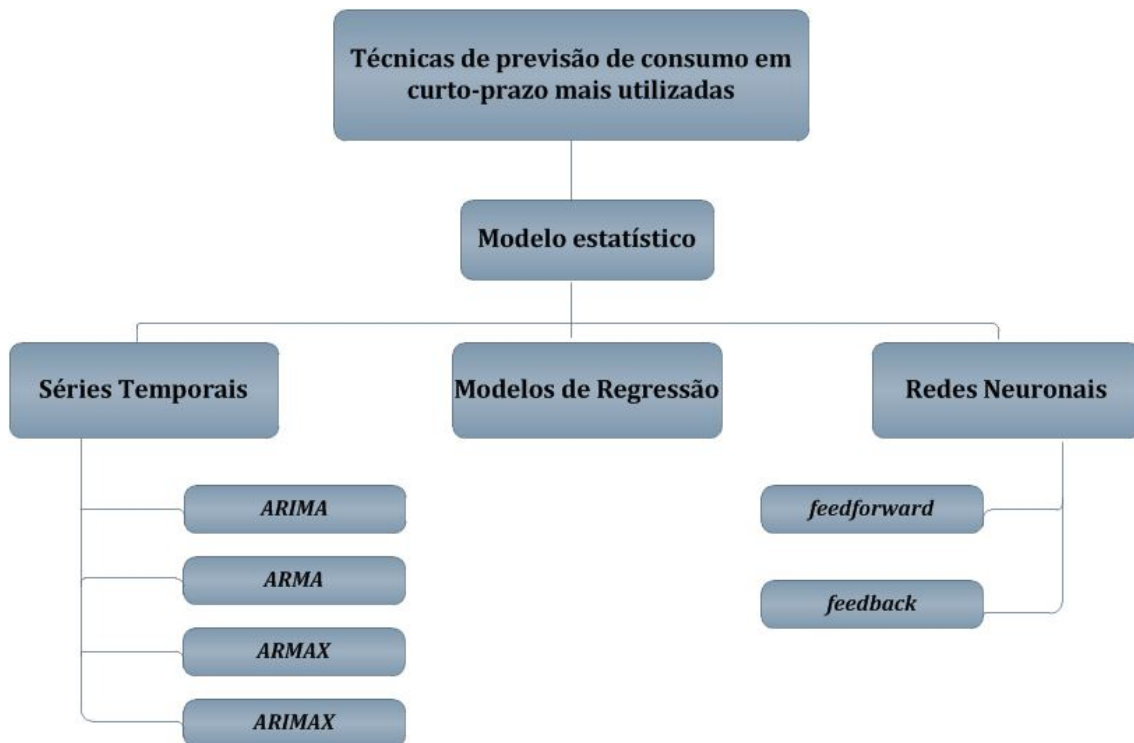


Figura 3.1: Técnicas de previsão de consumo em curto-prazo mais utilizadas

3.1.1 Séries Temporais

O uso destes modelos de previsão é mais comum em áreas como o processamento digital de sinais, em economia assim como na previsão de carga elétrica [31]. Este tipo de técnica assume que há auto-correlação, uma tendência nos dados usados, isto é, é necessário que a série a estudar tenha uma média e variância constantes.

Dentro destas séries temporais, os métodos mais usados são: ARMA (auto-regressivo de média móvel), ARIMA (auto-regressivo integrado de média móvel), ARMAX (auto-regressivo de média móvel com variáveis exógenas) e o modelo ARIMAX (auto-regressivo de média móvel com variáveis exógenas). Apesar de todos os modelos terem um uso satisfatório na previsão de carga elétrica, o ARIMAX é o mais utilizado uma vez que ao contrário dos restantes não usa a carga e o tempo como únicos parâmetros de entrada, acrescenta a estes fatores o clima, tornando-se assim mais adequada a sua utilização [31].

3.1.2 Modelos de Regressão

Estes modelos são dos métodos estatísticos mais usados para se compreender a relação entre variáveis, sendo usados em previsão em vários campos:

- Previsão da evolução temporal com base no histórico;
- Regressões univariáveis simples;

- Regressões multivariáveis, aplicadas a series temporais;
- Previsões de uma variável função das restantes (X,Y), geralmente multivariável;

Na aplicação destes modelos deve ser considerado que a reta de regressão é estimada usando valores históricos, logo esta reta poderá falhar a previsão caso haja alguma alteração na relação entre X e Y. Estas previsões possuem um carácter condicional uma vez que estão dependentes do valor da variável independente.

Na utilização eficaz deste tipo de modelos torna-se crucial haver uma boa escolha das variáveis, sendo importante haver uma análise criteriosa das mesmas. A experiência do utilizador na escolha das variáveis é decisiva, estas posteriormente serão analisadas com requisito a gráficos e testes de significância, eliminando as variáveis que não apresentarem qualquer tipo de relação [22].

3.1.3 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA) são um conjunto de técnicas computacionais que recorrem a um modelo matemático inspirado na estrutura neuronal de organismos inteligentes, adquirindo assim conhecimento através da experiência. Estes tipos de redes fazem um processamento massivamente paralelo e distribuído com propensão para armazenar conhecimento experimental, relacionando as informações de forma coerente.

3.1.3.1 Estrutura de um neurónio

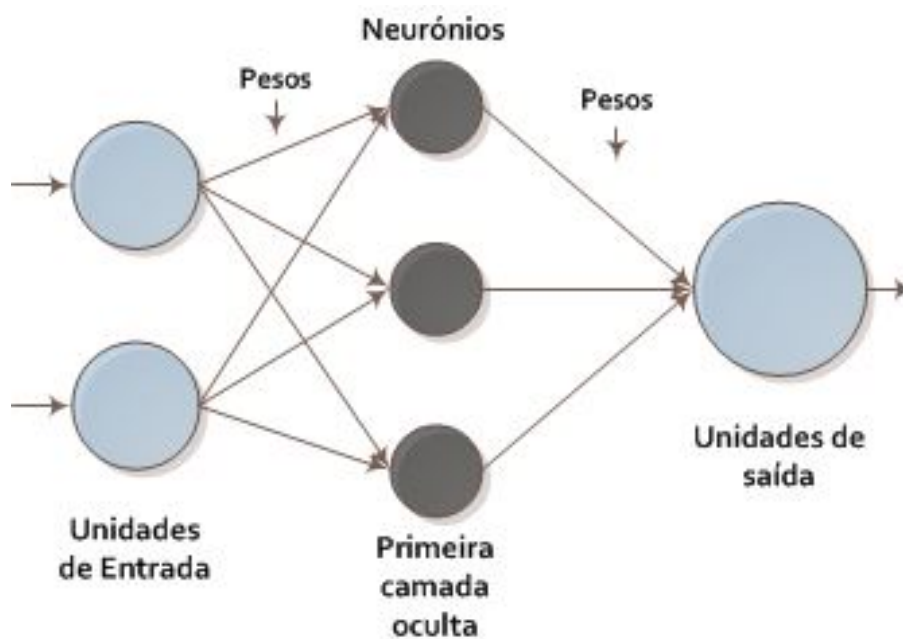


Figura 3.2: Diagrama representativo de uma rede neuronal

Estes sistemas de processamento de informação são constituídas por determinadas unidades de processamento simples, que realizam diversas funções matemáticas. Estas unidades, denominadas por neurónios, podem ser dispostas em uma ou várias camadas e estão interligadas entre si por canais de comunicação que estão associados a um determinado peso. Estes servem para armazenar o conhecimento obtido ao longo do processo de aprendizagem, são parâmetros ajustáveis, que conferem às estruturas neuronais a capacidade de aprendizagem e de colocação de informação na memória [32].

A obtenção da saída dá-se quando há a soma ponderada das entradas, transformada por uma função de ativação ou transferência.

De forma a haver um melhor entendimento deste tipo de redes, a figura 3.2 apresenta uma estrutura de uma rede neuronal.

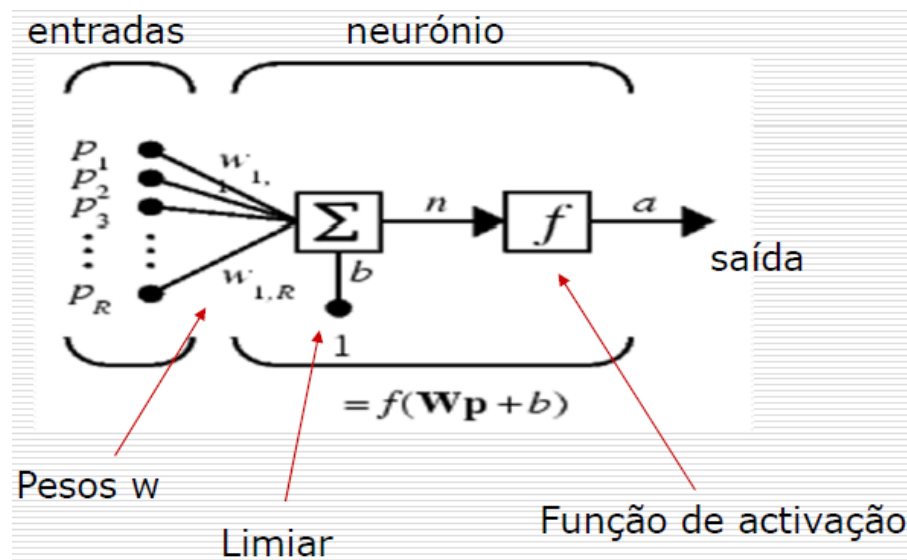


Figura 3.3: Estrutura de um neurónio

O bias pode ser visto como um peso que tem entrada constante igual a um que permite introduzir pequenas transformações nos dados de entrada. Como se pode verificar na Figura 3.3, o neurónio da rede neuronal pode ser decomposto na equação 3.1.

$$Y_i = F_i \left(\sum_k^n X_{ik} \times W_{jk} \right) \quad (3.1)$$

Com $\sum_{k=1}^n X_{ik} \times W_{jk} \geq O_i$

Onde:

- $X_{i1}, X_{i1}, \dots, X_{in}$ são as entradas (inputs);
- $W_{j1}, W_{j2}, \dots, W_{jn}$ são os pesos associados às respetivas entradas;

- F_i função de ativação;
- Y_i saída do neurónio i ;

As funções de ativação normalmente usadas para as unidades das camadas escondidas, são as funções não lineares do tipo sigmóide, no entanto para as unidades da camada de saída é costume usar-se uma função linear pura ($y=x$). A função sigmóide faz a transformação de uma grandeza com um domínio de valores no intervalo $(-\infty, +\infty)$ para um domínio de valores num intervalo finito, como é o caso da tangente hiperbólica, colocando estes valores no intervalo $[-1,+1]$. A função sigmóide é representada pela equação 3.2 [33].

$$f(x) = \frac{2}{(1 + e^{-2x})} - 1 \quad (3.2)$$

3.1.3.2 Tipos de redes neuronais

Há dois tipos de redes neuronais, as unidirecionais (*feedforward*) e as recorrentes (*feedback*), sendo o tipo *feedforward* mais utilizado, funcionando de uma forma progressiva sem informação adicional acerca dos processos a jusante, isto é, sem realimentação. As redes com realimentação (*feedback*), possuem conexões entre neurónios no sentido contrário. Dentro do tipo *feedforward* existe a rede neuronal do tipo Perceptrão Multicamada (denominada de *Multiplayer Perceptrons* – MLP).

3.1.3.3 Treino da rede neuronal

O treino de cada rede neuronal torna-se crucial para o bom funcionamento de uma rede, permitindo assim definir de forma automática os pesos das conexões da rede utilizando um dos vários algoritmos de treino existentes. Os vários tipos de treino são apresentados de seguida [34]:

- **Aprendizagem supervisionada** – aprende com exemplos de sinais de entrada e saída;
- **Aprendizagem não supervisionada** – baseada apenas no sinal de entrada e em esquemas que especifiquem a saída correspondente;
- **Aprendizagem forçada** – No treino forçado são fornecidas as saídas correspondentes às entradas, mas são atribuídos prémios ou penalizações consoante o desempenho do resultado obtido na saída.
- **Aprendizagem por retropropagação (*backpropagation*)** – este é o método de aprendizagem supervisionada mais utilizada
- **Aprendizagem pelo método do Perceptrão** - Este método implementa uma aprendizagem do tipo 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.

- **O método do gradiente** - algoritmo iterativo capaz de resolver sistemas de equações diferenciáveis. O método do gradiente caracteriza-se pelo facto de se escolher em cada iteração a direção que corresponde à descida mais íngreme da função erro.
- **Aprendizagem pelo método de Hebb** - O método de *Hebb* insere-se na classe dos algoritmos de aprendizagem forçada. O princípio deste método consiste no reforço da sinapse quando os dois neurónios dessa ligação estão ativos simultaneamente.
- **Aprendizagem competitiva** - Este método, de aprendizagem não supervisionada, caracteriza-se pelo seu bom comportamento em sistemas de classificação dado que, na rede neuronal, perante um conjunto de entrada, todas as unidades de processamento vão concorrer entre si pelo direito de resposta. A aprendizagem tem capacidade de detetar características nos conjuntos de entrada.
- **Aprendizagem pelo método de Kohonen** - Este método também se pode designar por redes auto-ajustáveis e insere-se na classe dos algoritmos de aprendizagem não supervisionadas.

O método de aprendizagem utilizado foi a *backpropagation*, que consiste num algoritmo que geralmente aplica o método dos mínimos quadrados para minimizar o erro da rede neuronal. Implementa um sistema de cálculo sucessivo das derivadas parciais numa direção contrária á da normal propagação da informação através da rede [35].

Na aprendizagem por retropropagação a rede aprende um conjunto predefinido de pares de exemplos de entrada e saída em ciclos de propagação/adaptação. Para um padrão de entrada o estímulo é propagado até à saída, sendo o padrão de saída comparado com a saída desejada e um sinal de erro é calculado para cada elemento de saída. O sinal de erro é retropropagado ao longo das várias camadas. Cada elemento da camada intermediária recebe apenas uma porção do sinal de erro total, proporcional apenas à contribuição relativa de cada elemento na formação da saída original. Por fim os pesos das conexões são então atualizados para cada neurónio [34].

3.1.3.4 Construção de uma rede neuronal

Para a construção de uma rede neuronal devem ser seguidos os seguintes passos:

1. Definir o problema, identificando as variáveis que pretendemos prever e as variáveis independentes com significância (uma análise prévia da serie temporal pode ser muito útil);
2. Filtrar, separar e processar a informação para treino e teste da rede;
3. Treinar a rede com um conjunto de treino representativo;
4. Testar a rede com um conjunto de teste diferente do conjunto de treino;
5. Escolha da estrutura e topologia da rede (múltiplas tentativas de treino e teste);
6. Implementar o sistema de previsão: o pré-processamento das entradas processamento na RNA e apresentação das previsões;

3.1.4 Comparação entre técnicas de previsão

Neste trabalho optou-se por usar as redes neuronais como ferramenta de previsão da carga natural das subestações em detrimento dos modelos referidos anteriormente.

Apesar da implementação dos outros métodos ser relativamente simples e a sua eficácia ser satisfatória em situações onde se conhece as regras, quando há um desconhecimento dessas regras ou a sua implementação é difícil, o seu desempenho tende a baixar bastante. Assim surgem as redes neuronais artificiais, que se baseiam num modelo apoiado na experiência adquirida de um conjunto de dados históricos e consequentemente não contêm regras.

Estas redes apoiam-se na sua habilidade de adaptação e aprendizagem, uma vez que estas conseguem lidar com dados imprecisos e situações que não estão completamente definidas, isto é, conseguem adaptar-se à evolução do conjunto de dados, tornado possível treinar em qualquer instante de forma a reduzir o erro. A sua característica mais importante reside no facto de conseguirem aproximar qualquer função continua não linear a um grau de correção satisfatório.

Devido à necessidade de um grande conjunto de dados históricos, o processo de treino da rede requiere um grande esforço computacional, no entanto devido aos avanços tecnológicos, estes inconvenientes poderão num futuro próximo desaparecer.

3.2 Previsão da Produção Eólica

A previsão da produção de energia eólica hoje em dia é fundamental para o controlo e operação dos sistemas de energia, uma vez que despachar uma rede sem se conhecer atempadamente a produção eólica futura poderá resultar num desperdício de energia, desta forma é importante o seu consumo imediato devido aos valores impraticáveis para o seu armazenamento sendo também necessário cumprir os despachos das centrais convencionais.

A produção de energia eólica acarreta algumas dificuldades na gestão da produção, pois este tipo de energia é totalmente dependente das condições meteorológicas, tornando-a volátil, desta forma o GS da REN criou diversos mecanismos que fornecem uma previsão da produção de energia eólica, fundamental para se perceber o trânsito presente nas diversas subestações [36].

A crescente produção da energia eólica aumenta também as dificuldades em prevê-la com exatidão, no entanto o GS com o intuito de alcançar previsões mais fiáveis possui uma aplicação de previsão de energia eólica que recorre a entidades externas para a obtenção de dados como a velocidade do vento para diferentes altitudes. Estas previsões do vento são fornecidas pelo IST, UA, Meteorologica e mais recentemente pela *Smartwatt*. Esta previsão da potência eólica é feita apenas em parques com telemedida para o SCADA, tornando possível aplicar medidas de correção à previsão em tempo real. Como apenas 2680 MW possuem telemedida para a REN num total de 4194 MW de potência eólica, existe ainda um longo caminho a percorrer para que toda a esta energia seja prevista atempadamente.

As características necessárias para este tipo de previsão dividem-se em três grupos, elétricas, geográficas e operacionais, sendo que estes dados devem ser fornecidos pelo promotor de cada

parque. Este processo de previsão eólica consiste em converter valores previstos de intensidade do vento em valores de potência produzida, sendo feita esta conversão através de uma aproximação por um polinómio de 5ª ordem à curva mecânica do aerogerador em questão. A previsão da intensidade do vento e a conversão por aproximação de vento em potência são processos capazes de cometer erros, o que indica o grau de sensibilidade desta previsão. [37]

Neste trabalho não foi desenvolvido nenhum método que pudesse melhorar o processo utilizado pelo GS na previsão da produção eólica, no entanto, sendo esta uma previsão relevante para este documento sentiu-se a necessidade de fazer uma breve descrição de como é feito este processo na REN.

3.3 Carga Elétrica

O simples gesto de ligar um aparelho elétrico desencadeia um processo que aumenta a procura por carga elétrica, uma propriedade física fundamental que determina as interações eletromagnéticas. Quando a esse pequeno aparelho se juntam outros a procura por energia tenderá a ser maior, e é este o desafio deste trabalho, procurar perceber e determinar esta tendência.

A carga elétrica tem origem em diferentes unidades consumidoras, sejam elas atividades domésticas assim como atividades industriais. Apesar de cada uma destas atividades apresentar uma grande especificidade, é mais fácil prever o consumo no setor industrial, uma vez que este está invariavelmente dependente do seu nível de produção. No entanto é impossível controlar certos imprevistos que possam ocorrer, tais como acidentes ou até mesmo greve dos trabalhadores, eventos que afetam a previsão de consumo.

O consumo a nível doméstico apresenta outras características que não são tão regulares, dado que é influenciado por diversos fatores da sociedade. Este tipo de comportamentos de consumo pode variar consoante a sua localização geográfica, o clima, a época do ano ou até mesmo devido a um evento social (por exemplo um jogo de futebol). De forma a perceber o que pode afetar a previsão de carga é necessário compreender os comportamentos desta, enumerando os seguintes fatores que podem influenciar a previsão [38].

- Fatores climáticos: variáveis como a velocidade do vento, temperatura, humidade relativa, chuva, relâmpagos ou neve. Dentro destes é de realçar a importância da temperatura, que está diretamente relacionada com o uso de ar-condicionado, aquecedores e sistemas de refrigeração que consomem energia elétrica.
- Fatores económicos e demográficos: fatores que surgem a longo prazo e que possuem uma importância fundamental na evolução da previsão de carga, como é o caso da área demográfica onde se inserem, podendo esta ser rural, industrial ou urbana. O crescimento económico destas áreas influencia o diagrama de carga de cada zona.
- Fatores de tempo: estes são cíclicos como é caso de um feriado, de um sábado ou domingo onde há uma diminuição significativa da procura. Este fatores tendem a ser também sazonais, onde há uma variação da carga em determinadas alturas do ano, como é caso do

Algarve na época do verão, onde o consumo de energia sobe em comparação com o resto do ano.

- Fatores esporádicos: embora aconteçam poucas vezes criam perturbações na carga, exemplos destes fatores são os eventos desportivos, paralisação de serviços devido a uma greve, entre outros.

3.3.1 Diagrama de Carga

A energia elétrica não é um produto simples, mensurável através de um único parâmetro. Dentro do consumo de energia, existem características que impõem a modulação da energia consumida no tempo através de uma função, a variação desse consumo ao longo das horas do dia é denominado de diagrama de cargas [39].

O diagrama de carga é conhecido por seguir um modelo, onde apesar de poder estar alocado em locais de diferentes consumos (maioritariamente residencial, industrial ou rural) segue na maior parte dos casos uma linha padronizada ao longo das 24 horas diárias, tal como se pode verificar na figura 3.4, onde os consumos estão representados em MW. Linha esta que representa bem as diferentes fases diárias da carga, tais como as horas de vazio, de cheias e de ponta.

O período noturno tem o consumo de energia associado a certos transportes e indústrias que têm atividade durante a noite, sendo uma parte residual desse consumo é também influenciado pela iluminação noturna e por algum consumo residencial (residual), esta fase denomina-se como horas de vazio. As horas de cheias começam assim que a população em geral inicia os seus trabalhos, provocando normalmente um aumento do consumo a partir 7h30, este incremento está relacionado com início ou aumento da atividade em setores como a indústria, serviços e transportes. O segundo aumento da carga começa verificar-se a partir das 11h30 até as 14h30, que é precisamente o período de almoço, aumentando neste intervalo de tempo o consumo doméstico e o da restauração. Entre as 19h e as 21h30 verifica-se um pico no consumo, que é explicado pelo aumento da atividade residencial quando a população volta para as suas habitações, onde apesar de setores como a indústria, serviços e transportes terem cessado na sua maioria as suas atividades, o consumo residencial aumenta.

De referir que as horas de pico podem mudar consoante a estação do ano, isto é, o pico diário na altura de inverno, caracterizado com dias de temperaturas mais baixas dá-se na hora do jantar e estende-se até as 23 horas. No entanto, no verão o pico de consumo diário dá-se entre as 13 horas e 14 horas, devido ao uso de dispositivos de ventilação de forma a baixar a temperatura no interior dos edifícios.




Figura 3.4: Diagrama de Carga (kW) em 4 de Dezembro de 2012 na subestação de Vermoim

3.4 Fatores que condicionam o diagrama de carga

De seguida irá focar-se o estudo nas variáveis justificativas que podem influenciar o diagrama de carga, permitindo avaliar se existe alguma correlação entre os dados analisados e o valor da carga.

3.4.1 Dados Temporais

Um dos objetivos propostos consiste em elaborar uma previsão de carga natural para um horizonte de uma semana. Sendo que o modelo utilizado para efetuar as previsões necessita de várias entradas como foi visto anteriormente, estas foram identificadas a partir de uma análise às séries de consumo que poderá ser visto de seguida.

Inicialmente o estudo dos dados temporais baseou-se em avaliar a carga na semana exatamente anterior à mesma hora, e posteriormente foi feita uma abordagem de forma a perceber a evolução da carga nas horas anteriores.

Nesta análise foram usados os valores da carga natural disponibilizado pela REN, onde é feita a avaliação para três períodos do ano de carga REN (Março a Fevereiro), considerando o diagrama de consumo total do sistema em MW.

Os três períodos estão definidos da seguinte forma:

- Período A - Semana de 22 a 28 de Março de 2012
- Período B - Semana de 6 a 12 de Outubro de 2012
- Período C - Semana de 21 a 27 de Fevereiro de 2013

A utilização destes 3 períodos distintos prende-se com a necessidade de haver uma maior abrangência na análise, utilizando períodos em estações do ano diferentes assim como em anos de carga diferentes, neste caso em 2012 e 2013.

3.4.1.1 Análise de uma semana antes em cada período

Analisando o consumo à mesma hora na semana anterior a partir da figura 3.8 é possível verificar uma correlação clara, que deve ser tida em conta para uma previsão futura, sendo no entanto de fácil perceção que apesar de haver uma correspondência forte esta varia em cada período.

A existência de um dia “anormal” na figura 3.9b, demonstrando que é notória a influência de um feriado no diagrama, situação que irá ser abordada à posteriori neste documento. A dispersão neste ponto varia um pouco de semana para semana estando sempre dentro de valores aceitáveis para se afirmar que influenciam o diagrama de carga, no entanto é perceptível uma dispersão mais acentuada no caso da semana de Outubro que é explicada pela ocorrência de um feriado na semana anterior, no caso o feriado de 5 de Outubro.




Figura 3.5: Período C




Figura 3.6: Período B






Figura 3.7: Período A


Figura 3.8: Gráfico de dispersão entre valores do diagrama de carga da hora alvo e uma semana antes para diferentes períodos



(a) Período A



(b) Período B



(c) Período C

Figura 3.9: Diagrama de carga comparando a carga da hora alvo com a carga à mesma hora na semana anterior em diferentes períodos

3.4.1.2 Análise de duas semanas antes em cada período

Estudo idêntico ao anterior, no entanto o espaço de análise é maior uma semana, sendo comparado neste ponto o consumo na hora alvo com o consumo à mesma hora duas semanas antes. Aqui verifica-se uma diferença maior tendo em conta o estudo anterior, no entanto continua-se a verificar uma correlação entre as duas medidas, tal como se pode ver na figura 3.13. estando a semana de Fevereiro de 2013 influenciada por um feriado, em 12 de Fevereiro, que afetará tanto o diagrama de carga no dia em questão assim como a dispersão em geral da semana.

Na figura 3.14c é possível verificar que a semana de Fevereiro de 2013 é também influenciada por um feriado, em 12 de Fevereiro, que afetará tanto o diagrama de carga no dia em questão assim como a dispersão em geral da semana. Nos restantes dias a carga segue um padrão semelhantes nos dois casos.




Figura 3.10: Período C




Figura 3.11: Período B






Figura 3.12: Período A


Figura 3.13: Gráfico de dispersão entre valores do diagrama de carga da hora alvo e duas semanas antes para diferentes períodos



(a) Período A



(b) Período B



(c) Período C

Figura 3.14: Diagrama de carga comparando a carga da hora alvo com a carga à mesma hora duas semanas antes em diferentes períodos

3.4.1.3 Análise de três semanas antes em cada período

Neste caso, optou-se por focar o estudo na mesma hora no entanto três semanas antes, comparando estes dois valores vê-se que apesar de se sentir uma certa correlação, para o período A a dispersão já é sentida com mais intensidade como se pode comprovar na figura 3.17. Contudo, para as restantes semanas os valores das duas variáveis são próximos, apresentando diferenças pequenas tendo em conta a distância temporal.

Os diagramas da figura 3.19 mostram uma boa correspondência nos diferentes períodos apesar de no caso da figura 3.19a não ser tão evidente esta correlação, pode-se afirmar que tendo em conta as amostras analisadas, a carga três semanas antes é bastante semelhante.

Neste ponto já é notório que quanto maior for o espaço temporal, menor será o seu contributo para a carga alvo.




Figura 3.15: Período C




Figura 3.16: Período B






Figura 3.17: Período A


Figura 3.18: Gráfico de dispersão entre valores do diagrama de carga da hora alvo e três semanas antes para diferentes períodos



(a) Período A



(b) Período B



(c) Período C

Figura 3.19: Diagrama de carga comparando a carga da hora alvo com a carga à mesma hora três semanas antes em diferentes períodos

3.4.1.4 Conclusão de dados temporais

Torna-se claro quais serão as variáveis que mais poderão contribuir para uma fiável previsão de consumo de energia, isto é, quais serão as variáveis temporais que deverão ser tidas em conta na estimação da carga, tendo em conta a correlação das variáveis em relação à sua distância temporal.




Figura 3.20: Correlação dos diagramas de carga nas séries temporais analisadas

A figura 3.20 mostra a correlação entre as diversas variáveis temporais, e de uma forma geral é notório que existe uma forte correlação, sendo que quanto mais próximo do valor 1 maior será a relação linear entre as variáveis. De salientar que é visível a influência dos feriados nestes diagramas, no caso dos períodos A e C onde os feriados de 5 de Outubro de 2012 (Implantação da República) e 12 de Fevereiro de 2013 (Entrudo) afetam consideravelmente a análise em 1 semana antes e 2 semanas antes respetivamente. Como já seria de esperar os valores da correlação para uma semana antes e duas semanas antes são de uma forma global mais altos que as demais em cada semana, no entanto para as restantes variáveis os valores são bastantes aceitáveis havendo até valores bastante próximos do máximo para a semana de Fevereiro. O período que apresenta uma correlação mais baixa é a semana de 22 a 28 de Março tendo no entanto apresentado valores admissíveis. Será importante manter estas variáveis numa futura previsão do diagrama de carga,

Tabela 3.1: Comparações entre os diversos momentos temporais analisados

	1 semana antes	2 semanas antes	3 semanas antes	
Diferença percentual	3.43%	3.20%	7.76%	Período A
Correlação	0.959	0.967	0.959	
Diferença percentual	3.63%	2.79%	4.33%	Período B
Correlação	0.935	0.984	0.982	
Diferença percentual	2.28%	4.39%	1.61%	Período C
Correlação	0.988	0.935	0.995	

uma vez que tendo em conta a diferença em relação à hora de previsão ela indica na maior parte dos casos uma conformidade em relação horas de vazio, cheias e pico.

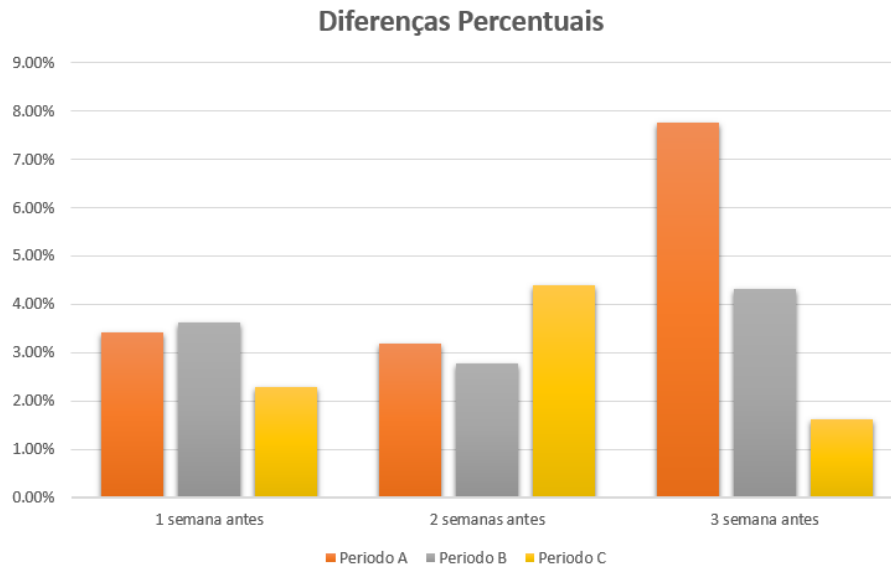


Figura 3.21: Diferenças percentuais dos diagramas de carga nas diversas séries temporais

A figura 3.21 exemplifica em termos numéricos a variação média das diferentes variáveis analisadas, e é possível verificar que na maioria dos casos, quanto mais longe o *target* da previsão estiver maior será o seu erro.

3.4.2 Temperatura e humidade

Será a temperatura ou a humidade uma variável que condicionará o consumo de energia? É a procura pela resposta a esta pergunta que se centrará o próximo estudo, onde foi analisado ao pormenor os dados meteorológicos da temperatura e da humidade a nível nacional e a um nível mais local de forma a conseguir perceber a sua tendência e depois relacioná-la com o diagrama de carga.


Os dados foram obtidos através de [6] [7], que possui um histórico de temperaturas em diversos locais.

Uma vez que não existe forma de obter uma temperatura e humidade relativa de Portugal continental de forma direta, usaram-se diversos valores médios diários de diferentes locais e fez-se uma média que se designou de média de temperatura nacional e humidade relativa nacional. Os locais usados para determinar este valor foram:


- Alverca
- Beja
- Sintra

- Monte Real (Leiria)
- Lisboa
- Faro
- Montijo
- Ovar
- Portalegre
- Porto

O processo repetiu-se para a obtenção dos mesmos dados relativamente a um ponto de localização mais restrito, a cidade do Porto.



(a) Em Portugal continental




(b) Na cidade do Porto

Figura 3.22: Temperatura média diária em (graus *Celsius*) e humidade relativa em percentagem de Março de 2012 até Fevereiro de 2013


Como tal obteve-se o valor médio diário da temperatura e humidade a nível nacional, nas figuras 3.22a e 3.22b estão presentes as temperaturas e a humidade ao longo de um ano, desta forma é

possível perceber como é a variação destas variáveis ao longo do ano, em Portugal Continental e na cidade do Porto.

Analisando os gráficos anteriores obtém-se o que já seria de esperar, que na altura do verão as temperaturas seriam mais altas em contraponto com o inverno, onde a temperatura é mais baixa.



(a) Correlação da temperatura



(b) Correlação da humidade relativa

Figura 3.23: Gráficos de correlação em Portugal e na cidade do Porto

De forma a compreender qual a importância destas duas variáveis no diagrama de carga realizou-se dois estudos da correlação entre o diagrama de carga do SEN e a temperatura média anual em Portugal continental, fazendo o mesmo estudo mas tendo em conta a humidade relativa anual do país. A análise seguinte focou-se em perceber a correlação destas variáveis a um nível mais local, como é o caso da cidade do Porto, fazendo a correlação entre o diagrama de carga natural da subestação de Vermoim (Maia) e a temperatura média anual e humidade relativa média anual no distrito do Porto.

Comparando os resultados, torna-se claro que há uma maior correlação quanto menor for a área de estudo, como se pode comprovar pela figura 3.23, o que o permite afirmar que caso se use a variável da temperatura para uma previsão, esta terá de ser o mais local possível de forma a tornar a previsão mais eficaz. A correlação apresentada para os dois casos é negativa, isto é,

a relação entre as variáveis é inversamente proporcional, quando uma aumenta a outra baixa de valor. Apesar dos valores apresentados estarem longe do ideal, pode-se afirmar que é notório que existe uma relação entre a temperatura e o diagrama de carga. Através da figura 3.28 é possível verificar que há um consumo maior quando a temperatura tende para valores tanto altos como baixos, isto é, quando a os valores da temperatura vão para extremos o consumo tende a ser maior.

No caso da humidade a disparidade entre valores obtidos para as duas zonas é enorme, na casa dos 120% de diferença ao invés da temperatura que situa-se nos 3% de diferença.




Figura 3.24: Em Portugal continental

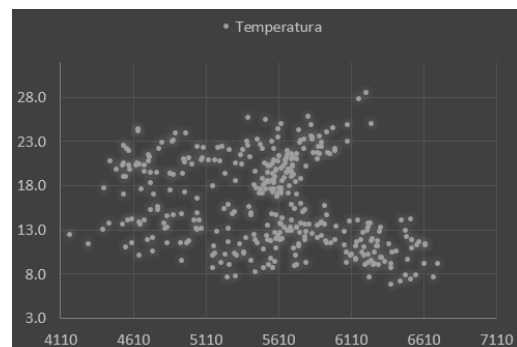


Figura 3.25: Em Portugal continental




Figura 3.26: Na subestação de Vermoim




Figura 3.27: Na subestação de Vermoim

Figura 3.28: Gráfico de dispersão entre valores de temperatura e humidade relativa com o valor de carga em diferentes locais

Fica claro que a humidade é uma variável que pouco afeta o diagrama de carga tal como indica o valor da sua correlação nos dois casos, na figura 3.23b. A diferença de valores entre o caso nacional e o mais local indica claramente a componente mais instável da correlação destas variáveis, podendo ser prejudicial para uma previsão futura.

3.4.3 Feriados

Em Portugal, o número de feriados tem vindo a diminuir devido à atual crise económica, no entanto ainda se pode contar com diversos feriados, sejam estes nacionais ou municipais. Em 2014 o número de feriados nacionais serão 9, podendo ser acrescentado a estes os feriados municipais que irão variar consoante a localidade.

Neste ponto irá analisar-se e comprovar-se como referido anteriormente a influência dos feriados nos diagramas de carga e assim avaliar se estes serão fatores que podem afetar uma boa previsão dos consumos. Como tal definiu-se dois momentos de estudo, um onde se avalia a diferença de consumo na semana de feriado comparando-a com a semana seguinte ou anterior tendo em conta que o feriado se enquadre num dia útil, num outro momento o estudo centrou-se nos mesmos parâmetros, no entanto tendo em conta que o feriado seja a um Domingo (dia habitual de menor consumo de carga).

1. Feriado a um dia útil

A análise seguinte irá focar-se em três intervalos de tempos ao longo do ano de 2012, tendo em conta o consumo e carga na subestação de Vermoim, localizado na cidade da Maia, no distrito do Porto.

A primeira análise centra o seu estudo à volta do feriado de 25 de Abril, Dia da Liberdade, onde se pode observar as diferenças entre a semana 22 a 28 de Abril e a semana de 15 a 21 de Abril. De referir que este feriado ocorreu a uma quarta-feira tal como se indica na figura 3.29.




Figura 3.29: Comparação do consumo de carga na semana de 22 a 28 de Abril e a semana de 15 a 21 de Abril de 2012

Pode-se afirmar que o consumo no dia do feriado foi manifestamente mais baixo tendo em conta o mesmo momento da semana anterior, onde se pode verificar com bastante facilidade os picos de consumo em momentos como a hora de almoço e jantar.




Figura 3.30: Comparação do consumo de carga na semana de 29 de Setembro a 6 de Outubro e a semana de 7 a 13 de Outubro de 2012

De forma a este estudo ganhar maior fiabilidade, analisou-se outra semana que contou com um feriado nacional que celebra a implantação da República, o 5 de Outubro, comparando-a com a semana seguinte tal como está implícito na figura 3.30, onde se verifica que na sexta-feira dia 5 de Outubro, o consumo que foi consideravelmente menor que a semana seguinte, podendo até ter afetado consumos de dia 6 de Outubro.

2. Feriado a um Domingo

De forma a avaliar a influência de um feriado num dia não útil, isto é, saber qual a relação do consumo de um feriado num domingo com o consumo de um outro domingo que não seja feriado, propôs-se realizar um estudo semelhante ao anterior. Numa primeira análise, centrou-se atenções no feriado de 10 de Junho, Dia de Portugal, que em 2012 ocorreu a um domingo. Como tal comparou-se o consumo dessa semana com a seguinte e verificou-se que a diferença de consumos é residual, em comparação com o estudo feito anteriormente, isto provavelmente porque os domingos já serão dias onde a carga será tendencialmente baixa, tal como se pode comprovar pela figura 3.31.




Figura 3.31: Comparação do consumo de carga na semana de 10 a 16 de Junho e a semana de 17 a 23 de Junho de 2012

3. Conclusão acerca das influências dos feriados nos consumos

De forma a concluir o estudo do impacto dos feriados nos diagramas de consumo, comparou-se uma semana que teve dois feriados, um a uma sexta-feira e outro a um domingo, que são os casos da Sexta-feira Santa (6 de Abril) e da Páscoa (8 de Abril) respetivamente. Neste caso pode-se verificar de forma clara o impacto dos feriados num dia útil ou num domingo, como se pode confirmar pela figura 3.32, onde a presença do feriado ao domingo é pouco notada no diagrama de carga ao invés que o feriado de sexta-feira, dia 6 de Abril, é fortemente notado.

Como ficou provado, os feriados quando aparecem em dias úteis criam uma diminuição brusca no diagrama de carga em comparação com o nível normal sentido ao longo do ano, sendo que quando estes ocorrem em dias não úteis, esta diminuição já não é sentida da

Tabela 3.2: Diferenças percentuais e a sua correlação no diagrama de carga entre os diversos dias em 2012

	Entre dias úteis	Entre feriados e dia útil	Entre feriados e domingo
Semana	26 e 19 Abril	25 e 18 Abril	10 e 17 de Junho
Diferença Percentual	4.35%	13.41%	4.13%
Semana	4 e 11 de Outubro	5 e 12 de Outubro	1 e 8 de Abril
Diferença Percentual	2.49%	12.68%	6.83%
Semana	26 e 19 Abril	25 e 18 Abril	10 e 17 de Junho
Correlação	0.9973	0.8410	0.9821
Semana	4 e 11 de Outubro	5 e 12 de Outubro	1 e 8 de Abril
Correlação	0.9955	0.7766	0.9204




Figura 3.32: Comparação do consumo de carga na semana de 1 a 7 de Abril e a semana de 8 a 14 de Abril de 2012

mesma forma, uma vez que nestes dias o consumo de carga habitual é baixo. Assim é possível dizer que em termos de perfil no diagrama de carga, os feriados comportam-se como um domingo.

A tabela 3.2 indica claramente que quando um feriado ocorre a um domingo, o comportamento do seu diagrama de carga é pouco desviado em comparação com domingo sem feriado, ao contrário do que acontece quando o feriado ocorre num dia útil, onde a correlação baixa nitidamente.

Capítulo 4

Treino e validação das estruturas de previsão

Serve o presente capítulo para elucidação da metodologia utilizada, permitindo esta obter as redes com melhor desempenho, isto é, as redes que permitem prever melhor a carga natural de cada subestação

Com a análise de vários critérios de qualidade de erro, escolheu-se as redes que obtiveram melhor desempenho.

Fundamentando-se naquilo que foi revisto no capítulo 3, optou-se por escolher 13 subestações que melhor serviam os interesses da REN no que à previsão de carga diz respeito.

Inicialmente é feita uma descrição relativa aos dados, ao seu tratamento e à forma como foram usados tendo em vista o cumprimento de uma metodologia encontrando desta forma a rede neuronal que melhor interpreta os padrões do perfil de carga de cada subestação.

4.1 Escolha das subestações

Tal como foi referido anteriormente, cada subestação tem características únicas, assim ao nível da operação da rede, estes equipamentos possuem necessidades diferentes da previsão da carga, seja por haver uma forte componente do consumo sobre a produção ou até mesmo o nível de reserva n-1 ser baixo, o que pode aumentar o risco de colapso dos equipamentos e conseqüente interrupção de serviço.

Assim sendo foi feita a seleção das subestações que apresentam maior necessidade de previsão de carga, recaindo esta escolha nas seguintes subestações:

- Falagueira
- Rio Maior
- Tunes
- Sines

- Ferreira do Alentejo
- Valdigem
- Carvoeira
- Chafariz
- Estoi
- Pereiros
- Carregado
- Mourisca
- Évora

Um dos estudos prévios baseou-se na possibilidade de criar apenas uma rede que pudesse fazer a previsão da carga deste conjunto de subestações tornando assim mais simples a implementação deste sistema de previsão. De facto, tal como era expectável o desempenho destes testes não foi satisfatório uma vez que cada subestação tem características únicas.

O perfil de carga de cada subestação é influenciado por diversos fatores, como o tipo de consumo, que pode ser industrial, rural ou residencial dependendo muito da sua situação geográfica ou devido ao facto de uma subestação possuir mais geração agregada a si, alterando assim os perfis do trânsito de carga.

Assim sendo, como cada rede neuronal se adapta a um certo comportamento, caso se verifique uma generalização da forma como se prevê a carga a eficácia da previsão irá ser fortemente afetada, como tal optou-se por criar uma rede neuronal para prever a carga em cada subestação de forma a melhorar o desempenho da previsão.

4.2 Procedimentos

Os procedimentos adotados ao longo do trabalho irão ser descritos de seguida, de referir a importância destas linhas condutoras no decurso do trabalho, uma vez que serviram de guião para uma experiência mais precisa, onde um pormenor poderia influenciar o resultado final.

4.2.1 Metodologia de trabalho

Optou-se por adotar um processo que fosse simples e capaz de realizar os pressupostos pretendidos, assim sendo foi criada a metodologia de trabalho descrita na figura 4.1.

Este processo ilustrado está dividido em cinco fases, cada uma com determinadas funções para que no final se possa encontrar uma rede neuronal que apresente um bom desempenho na previsão da carga natural das subestações.

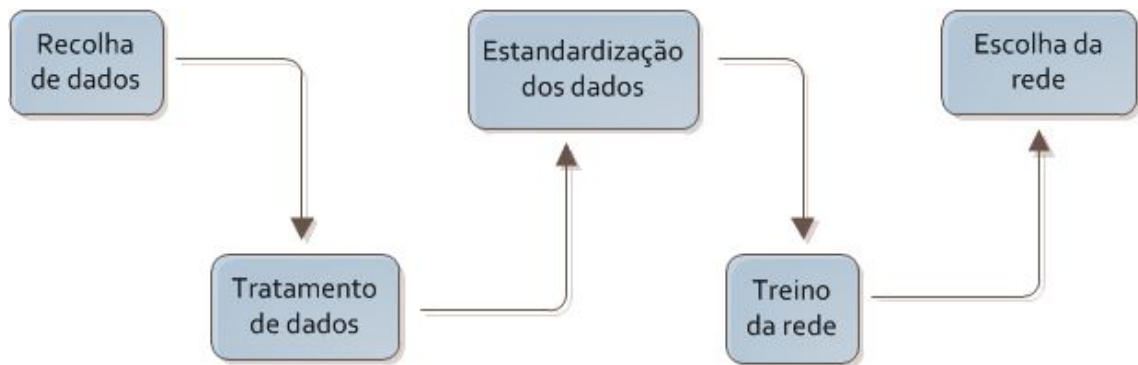


Figura 4.1: Diagrama da metodologia adotada

4.2.2 Recolha de dados

Os valores de potência ativa nos transformadores, da produção distribuída, e o respetivo cálculo de carga natural que serviu de base a este trabalho estão disponíveis em base de dados específica mantida pela REN. Contudo, para cálculo da Carga Natural, utilizam-se os valores do trânsito de potência ativa nos transformadores da REN e ainda os valores de potência ativa da produção distribuída ligada à subestação objeto de estudo, obtidos pelos sistemas de telecontagem. Dado que estes registam os valores de energia em períodos de integração de 15 minutos, é calculada a potência ativa média associada a esse período de tempo, quer para os transformadores quer para a produção distribuída. A recolha dos dados de temperatura foi feita diretamente do SCADA, em subestações dotadas de sensor de temperatura, datada em períodos de 15 minutos. No entanto em algumas subestações onde não havia estes sensores, os valores foram obtidos através dos sítios da [7] (dados históricos) e [6] (previsão de temperatura nos próximos 7 dias).

De seguida decompôs-se estes dados, criando diversas variáveis candidatas a serem a entrada da rede neuronal assim como a variável de saída a prever, onde:

- DDS – Dia da semana (1 = domingo; 2 = segunda-feira; ...; 7= sábado);
- H – hora de previsão (0, 1, ..., 23);
- fer – Feriados, se sim a variável será 1, caso não se verifique o seu valor será zero;
- s1 – Carga na semana anterior, à mesma hora que a previsão;
- s1h1 - Carga na semana anterior, uma hora antes da hora de previsão;
- s1h2 - Carga na semana anterior, duas horas antes da hora de previsão;
- s2 - Carga duas semanas antes, à mesma hora que a previsão;
- s2h1 - Carga duas semanas antes, uma hora antes da hora de previsão;
- s2h2 - Carga duas semanas antes, duas horas antes da hora de previsão;

- tmax – Temperatura diária máxima;
- tmin – Temperatura diária mínima;
- tmed – Temperatura diária média;

Os valores obtidos a partir do SCADA e da telecontagem são dados em graus Celsius no caso da temperatura, já a carga é registada em MW.

Foram extraídos dados referentes a um ano de carga de cada subestação, de referir que o ano de carga na REN inicia-se em Março até Fevereiro, assim sendo os dados usados utilizados para treino, validação e teste da rede neuronal são relativos ao espaço temporal de 15 de Março de 2012 até 28 de Fevereiro de 2013, perfazendo um total de 35040 amostras, estando divididas 60% das amostras para o treino, 20% para a validação e 20% para os testes, o que se traduziu em:

- 21024 como dados de treino;
 - o Perfazendo um total próximo de 31 semanas, 219 dias num ano.
- 7008 como dados de validação;
 - o Perfazendo um total aproximado de 10 semanas, 73 dias num ano.
- 7008 como dados de teste;
 - o Perfazendo um total aproximado de 10 semanas, 73 dias num ano.

A utilização de um número elevado de dados deve-se à necessidade de um histórico de exemplos que simule todas as variações ao longo do ano.

Tabela 4.1: Excerto de tabela com possíveis candidatas a entradas da rede neuronal

DATA	fer	DDS	H	cosDDS	senDDS	cosH	senH	tmed
15/03/2012 02:00	0	5	2	-0.223	-0.975	0.866	0.5	12.715
15/03/2012 02:15	0	5	2	-0.223	-0.975	0.866	0.5	12.715
15/03/2012 02:30	0	5	2	-0.223	-0.975	0.866	0.5	12.715
15/03/2012 02:45	0	5	2	-0.223	-0.975	0.866	0.5	12.715
tmax	tmin	output	s1	s1h1	s1h2	s2	s2h1	s2h2
20.227	3.77	30.933	33.73	35.583	37.035	34.147	35.076	36.594
20.227	3.77	31.172	33.583	35.463	36.286	33.812	35.461	36.234
20.227	3.77	31.054	32.469	35.019	36.106	34.123	35.116	35.772
20.227	3.77	31.029	30.32	34.526	35.668	34.29	34.784	35.404

Na tabela 4.1 estão expostas as variáveis que serão usadas como entradas da rede neuronal, serão feitas várias combinações de forma a descobrir qual a melhor conjugação de dados que dará a previsão mais eficaz.

4.2.3 Tratamento de dados

O tratamento de dados consiste em reformular os valores obtidos, antes de serem fornecidos à rede, para que esta os possa tratar de uma forma eficiente e rápida. Estes procedimentos tornam-se cruciais para o sucesso da rede neuronal [40], das quais se destaca:

- Validação dos dados – Consiste na validação dos dados para verificar a existência de possíveis erros;
 - A importação dos valores de carga das diferentes subestações a partir do SCADA tem em atenção a mudança para o horário de Verão ou Inverno, como a inclusão de uma hora a mais ou a menos em dois dias afetaria o treino da rede, procedeu-se a uma modificação destes dados para estes ficassem com 24h nos seus dias, assim quando é feita a mudança de hora para o horário de Verão são criados quatro dados de entrada baseados na média da hora anterior e posterior, sendo estes armazenados nos quatro momentos referentes à segunda hora desse dia. No caso em que é feita a mudança para o horário de Inverno são eliminados os quatro momentos referentes à segunda hora do dia.
- Representação dos dados – baseia-se na conversão dos dados, como na codificação dos dados não numéricos, a data por exemplo, na definição das variáveis que podem representar dados agrupados, ou por outro lado, quando se pretende que uma variável seja representada por um ou mais neurónios.
 - Um exemplo deste processo consistiu em garantir que o dado referente à carga natural na hora X do dia Y do mês Z fosse o mesmo para a temperatura ocorrida à mesma hora, dia e mês.
 - É criado um valor para cada dia do ano podendo ser 0 ou 1, sendo 1 um dia em que se verifique um feriado e 0 um dia onde não se verifique um feriado.
- Estandarização dos dados – É um processo de ajuste de escalas que permite melhorar a eficiência do treino da rede
 - Para a estandarização foi utilizado o método Min-Máx.
- Filtragem dos dados – consiste na aplicação de técnicas de filtragem aos dados para a eliminação de ruído e consequente suavização da função de aprendizagem.
 - Como exemplo, os valores de temperatura provenientes da telecontagem das subestações em determinados intervalos de 15 minutos aumentavam cerca de 20 graus, algo que não correspondia à realidade e que teve de ser corrigido.

Estes processos revelaram ser extremamente delicados e morosos, exigindo uma grande atenção por parte do utilizador devido ao grande número de exemplos existentes.

4.2.4 Estandarização de dados

A estandarização dos dados foi feita tendo em conta o método Min-Max, onde se supõe que min_a e max_a são o mínimo e o máximo do conjunto de entrada a , a estandarização Min-Max mapeia o valor v de a , na escala $[min_a, max_a]$, em v' de A , na escala $[min_A, max_A]$ [34].

$$v' = \frac{(v - min_a)}{max_a - min_a} \times (max_A - min_A) + min_A \quad (4.1)$$

O processo inverso, que transforma a escala das variáveis estandarizadas na escala real é designado por destandardização, sendo expresso pela equação 4.2.

$$v = \frac{(v' - min_A)}{max_A - min_A} \times (max_a - min_a) + min_a \quad (4.2)$$

Este processo de estandarização é aplicado as variáveis tmed, tmax, tmin, s1, s1h1, s1h2, s2, s2h1, s2h2, estando exposto na tabela 4.2 as possíveis candidatas a variáveis de entrada depois deste procedimento.

Tabela 4.2: Excerto de tabela com possíveis candidatas a variáveis de entradas depois da estandarização

DATA	fer	DDS	H	cosDDS	senDDS	cosH	senH	tmed
15/03/2012 02:00	0	5	2	-0.223	-0.975	0.866	0.5	-0.202
15/03/2012 02:15	0	5	2	-0.223	-0.975	0.866	0.5	-0.202
15/03/2012 02:30	0	5	2	-0.223	-0.975	0.866	0.5	-0.202
15/03/2012 02:45	0	5	2	-0.223	-0.975	0.866	0.5	-0.202
tmax	tmin	output	s1	s1h1	s1h2	s2	s2h1	s2h2
-0.231	-0.274	30.933	-0.539	-0.492	-0.455	-0.528	-0.505	-0.466
-0.231	-0.274	31.172	-0.542	-0.495	-0.474	-0.536	-0.495	-0.475
-0.231	-0.274	31.054	-0.57	-0.506	-0.479	-0.529	-0.504	-0.487
-0.231	-0.274	31.029	-0.624	-0.519	-0.49	-0.524	-0.512	-0.496

4.2.5 Treino da rede neuronal

Após o tratamento de dados passou-se ao treino da rede neuronal em ambiente *Matlab (matlabR2012b)* [41].

Para cada subestação foram ensaiadas 3 estruturas diferentes de conjuntos de entrada, em cada estrutura foram testados redes com diferentes neurónios na camada escondida, iniciando-se os testes com 25 neurónios passando para 30 e finalizando os testes nos 35 neurónios, sendo este o limite máximo até começar a ocorrer o sobre treino da rede. Finalmente foram realizados 6 testes por cada conjunto, fazendo um total de 54(3x3x6) testes, fornecendo cada um uma rede neuronal que foi devidamente avaliada.

A figura 4.2 mostra o diagrama da metodologia associada aos testes para a obtenção das redes neuronais.

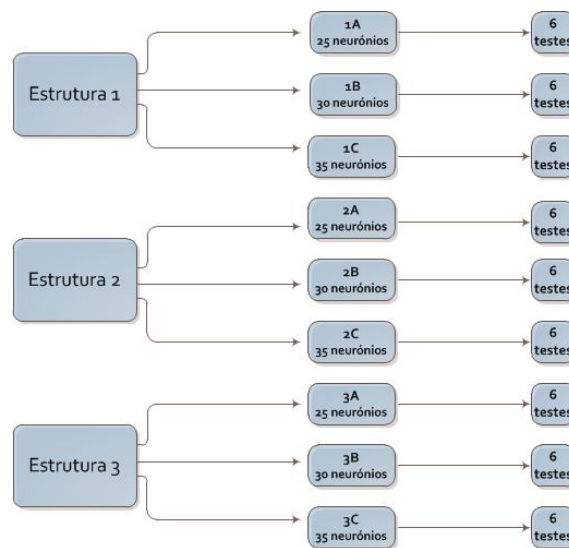


Figura 4.2: Metodologia de teste da rede neuronal

Depois de estabelecido o procedimento a adotar, passou-se para a criação de comando de código de forma a obter a rede neuronal desejada. De seguida está exposto o código necessário para a realização de um teste, neste caso para a subestação da Falagueira.

Inicialmente são importados os dados em formato *EXCEL* como seguinte código:

1. `Data=xlsread('Entradas - Falagueira.xls',1,'A1:A35041');`

Este comando importa todo o conjunto de dados presentes na matriz de A1 até R25041, folha 1 do ficheiro “Entradas – Falagueira.xls”.

2. `Entradas=[s1,s2,s1h1,s1h2,s2h1,s2h2,tmed,cosDDS,cosH,senDDS,senH,fer];`

3. `saidas=(output);`

4. `inputs = Entradas';`

5. `targets = saidas';`

No ponto 2 cria-se uma matriz denominada de “Entradas”, no ponto 3 cria-se a matriz “saídas”, no ponto 4 e 5 define-se estas com sendo os *inputs* e *targets* da rede, respetivamente.

6. `hiddenLayerSize = 25;`

7. `net = fitnet(hiddenLayerSize);`

Nos dois últimos comandos, é criada uma rede que se adapta as entradas tendo em conta o tamanho da camada escondida (número de neurónios), que neste caso é igual a 25. A rede criada é tipo direto (*feedforward*), funcionando de uma forma progressiva, isto é, sem

realimentação, onde não há informação adicional acerca do que se passa a jusante ou a montante. Sendo o tipo de rede que é mais utilizado em previsão.

8. `net.divideFcn = 'dividerand';`
9. `net.divideMode = 'sample';`
10. `net.divideParam.trainRatio = 60/100;`
11. `net.divideParam.valRatio = 20/100;`
12. `net.divideParam.testRatio = 20/100;`

Nos comandos 8 até ao 12, é feita a divisão dos dados importados para treino, validação e teste. Divide-se assim os dados de forma aleatória em 60% para o treino, 20% para a validação e 20% para o teste.

13. `net.trainFcn = 'trainlm';`
14. `net.performFcn = 'mse';`

O comando 13 declara que o treino da rede neuronal terá por base o algoritmo de *Levenberg-Marquardt*, este método corresponde a uma variante do método de Newton, sendo cerca de 10 a 100 vezes mais rápido que o método do gradiente [42]. O índice de avaliação do treino é definido no comando 14, sendo o MSE (*mean square error*) o índice adotado, representando a média da diferença entre o valor de saída da rede e o valor real, ao quadrado. Quanto menor for o seu valor, maior será a performance da rede. É importante referir que se o MSE do conjunto de validação se mantiver inalterado ao fim de 6 iterações, é dada ordem para o treino termine. Sendo 6 o valor por omissão do *matlab*.

15. `(net,tr) = train(net,inputs,targets);`

Este último comando realiza o treino da rede tendo em conta as variáveis “*net*”, “*inputs*” e “*targets*”, sendo estas a estrutura que irá ser treinada, a matriz de valores que servirá de entrada da rede e o vetor de valores será alvo das respetivas entradas.

16. `outputs = net(inputs);`

Neste ponto é criado o vetor “*outputs*” que contém os valores previstos da saída, tendo em conta os valores de entrada do conjunto “*inputs*”.

17. `outputs=transpose(outputs);`

O comando 17 faz a transposição do vetor “*outputs*”, de forma a garantir uma coluna de valores em vez de uma linha.

18. `xlswrite('results - falagueira - 1A.xls',hiddenLayerSize,1,'C4');`

Neste último comando, é escrito na folha *EXCEL* referente aos resultados da previsão na subestação da Falagueira a previsão da rede treinada.

Assim criou-se uma rede *feedforward* de duas camadas, usando a função de ativação sigmóide para os neurónios escondidos e a linear para os neurónios de saída. Dando assim dados consistentes e neurónios suficientes para a camada escondida. A rede foi treinada com o algoritmo de *backpropagation* de *Levenberg-Marquardt* (trainlm).

4.2.6 Análise de desempenho da rede

Os valores futuros das variáveis neste estudo tornam-se difíceis de prever dada a complexidade da grande maioria dessas variáveis, tendo assim uma importância extrema a qualidade da previsão, isto é, a precisão da previsão.

Com o objetivo de obter uma melhor percepção sobre o quão precisa pode ser a previsão, torna-se fulcral incluir informação sobre a forma como a previsão pode desviar-se do valor real da variável. Na gestão deste processo é necessário medir e monitorizar as previsões procurando reduzir os desvios e trazer maior fiabilidade ao sistema.

A diferença entre o valor real e a previsão dá origem ao erro de previsão:

$$e_t = A_t - P_t \quad (4.3)$$

Onde:

e_t - Erro no período t

A_t - Valor real no período t

P_t - Previsão para o período t

Assim sendo irá ser feita a avaliação da previsão tendo em conta os seguintes indicadores:

MAD – Mean Absolute Deviation

O MAD (desvio médio absoluto) é a média dos desvios absolutos individuais gerados em cada período, não leva em conta se um erro foi sobrestimado ou subestimado, caracteriza-se por ser a média dos erros cometidos pelo modelo de previsão durante uma série de períodos de tempo.

A equação seguinte mostra o cálculo do MAD como fração entre o somatório dos desvios absolutos e o número n de períodos analisados.

$$\frac{\sum_{i=1}^t |e_t|}{t} \quad (4.4)$$

MSE – Mean squared error

O MSE (erro quadrático médio) é também uma das ferramentas que se utiliza para avaliar a qualidade da previsão, sendo determinado através da soma dos erros de previsão ao quadrado e dividido pelo número de erros usados no cálculo, sendo expresso pela seguinte equação:

$$\frac{\sum_{i=1}^t e_t^2}{t} \quad (4.5)$$

MAPE – Mean absolute percentage of error

O MAPE (erro médio percentual absoluto) identifica a percentagem média em que a previsão desviou a procura ocorrida em determinada serie histórica, assim o MAPE é a média da diferença absoluta entre os valores previstos e atuais, expressa e percentagem. Sendo a expressão que determina o MAPE ilustrada na equação 4.6:

$$\frac{\sum_{i=1}^t \frac{|e_i|}{A_i}}{t} \times 100 \quad (4.6)$$

FA – Forecast accuracy

O FA (precisão da previsão) é um dos indicadores mais importantes para o acompanhamento da previsão, que indica o quanto esta é assertiva em relação ao seu valor real. Para o cálculo deste indicador numa dada série histórica, o resultado deve ser obtido em função do MAPE, uma vez que este utiliza a média dos desvios na sua equação 4.6 e com isto são considerados todos os períodos individuais analisados. Assim sendo o FA será obtido a partir da seguinte equação:

$$FA\% = 100\% - MAPE \quad (4.7)$$

Quanto maior for a medição da precisão melhor será a tomada de decisão por parte do operador de sistema.

RMSE – Relative Mean squared error

O RMSE corresponde a um erro de previsão relativo, com um valor máximo de 1, significa que um erro de regressão com um valor inferior a 1 indica que o modelo fornece previsões mais precisas que a simples utilização de valor médio da saída:

$$RMSE(f) = \frac{MSE(f)}{MSE(\bar{A})} = \frac{\frac{1}{t} \sum_{i=1}^t (A_t - P_t(f))^2}{\frac{1}{t} \sum_{i=1}^t (A_t - \bar{A})^2} \quad (4.8)$$

Capítulo 5

Resultados obtidos para cada teste

Neste capítulo apresenta-se os resultados obtidos para cada teste realizado, tendo em conta a metodologia proposta no capítulo 4.

Inicialmente enumera-se as diferentes estruturas utilizadas e apresenta-se os seus resultados para a subestação da Falagueira. São selecionadas e demonstradas as redes que melhores resultados obtiveram para cada subestação. Finalmente é feita uma comparação com um método de previsão atual em [5] para as mesmas datas.

5.1 Falagueira

O processo de treino da rede consistiu num treino de 6 redes neuronais para cada uma das diferentes estruturas, sendo definidas como Rede Neuronal (RN). No final, depois de revistos os melhores resultados de cada estrutura, é escolhida a que apresenta a performance mais satisfatória, que irá servir como modelo de previsão, tendo em conta os diversos parâmetros vistos anteriormente. Para cada conjunto foi calculado o desvio médio absoluto (MAD), o erro quadrático médio MSE, o erro médio percentual absoluto (MAPE), a precisão da previsão (FA) e o erro quadrático médio relativo (RMSE).

As variáveis de entradas que irão ser representadas de seguida nas diferentes estruturas da rede neuronal têm o seguinte significado:

- D – Dia da semana (1 = domingo; 2 = segunda-feira; ... ; 7= sábado);
- H – hora de previsão (0, 1, ..., 23);
- Fer – Feriados, se sim a variável será 1, caso não se verifique o seu valor será zero;
- C(s1) – Carga na semana anterior, à mesma hora que a previsão;
- C(s1h1) - Carga na semana anterior, uma hora antes da hora de previsão;
- C(s1h2) - Carga na semana anterior, duas horas antes da hora de previsão;
- C(s2) - Carga duas semanas antes, à mesma hora que a previsão;

- $C(s2h1)$ - Carga duas semanas antes, uma hora antes da hora de previsão;
- $C(s2h2)$ - Carga duas semanas antes, duas horas antes da hora de previsão;
- t_{max} – Temperatura diária máxima;
- t_{min} – Temperatura diária mínima;
- t_{med} – Temperatura diária média;

Sendo importante referir que os dados usados utilizados para treino, validação e teste da rede neuronal são relativos ao espaço temporal de 15 de Março de 2012 até 28 de Fevereiro de 2013.

1. Estrutura de rede - 1

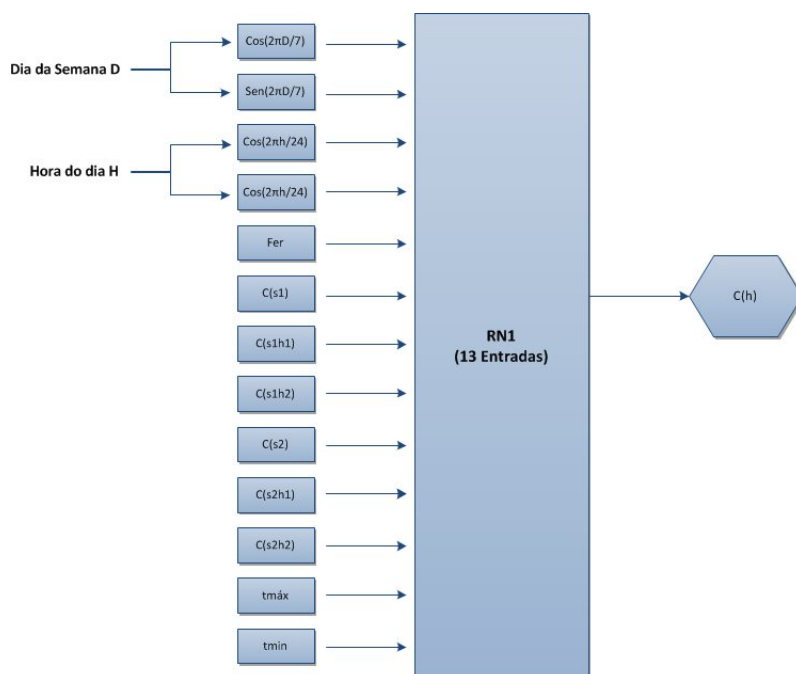


Figura 5.1: Estrutura da rede 1

Sendo esta a estrutura relativa aos valores de entrada e saída, é necessário analisar o desempenho da estrutura usando diferentes valores na primeira camada escondida da rede neuronal.

O número de unidades nas diversas camadas é especificado pela sequência 13-X-1-1, indicando que esta rede tem 13 entradas, X unidades na primeira camada escondida, uma unidade na segunda camada escondida e uma saída.

(a) Estrutura 1A

Com 25 Unidades na primeira camada escondida.

Na tabela 5.1 estão dispostos os resultados obtidos para os 6 testes.




Figura 5.2: Esquema da RN 1A

Tabela 5.1: Resultados do desempenho para cada RN do teste 1A

RN	MAD	MSE	MAPE	FA	RMSE
1	3.86395691	26.4108859	9.8891%	90.1109%	0.451900
2	3.73699302	25.5028352	9.5205%	90.4795%	0.436362
3	3.87924741	27.0524107	9.9283%	90.0717%	0.462876
4	3.6895449	24.5269536	9.4148%	90.5852%	0.419654
5	3.95377447	28.2814117	10.1215%	89.8785%	0.483891
6	3.94189781	28.1521339	10.0775%	89.9225%	0.481693

(b) Estrutura 1B

Com 30 Unidades na primeira camada escondida.




Figura 5.3: Esquema da RN 1B

Na tabela 5.2 estão dispostos os resultados obtidos para os 6 testes.

Tabela 5.2: Resultados do desempenho para cada RN do teste 1B

RN	MAD	MSE	MAPE	FA	RMSE
1	3.91691408	27.0480508	9.9739%	90.0261%	0.462798
2	3.69016195	24.3877622	9.4203%	90.5797%	0.417283
3	3.63536017	22.8711509	9.2872%	90.7128%	0.391332
4	3.81803857	26.3375655	9.7463%	90.2537%	0.450644
5	3.68248756	24.0702577	9.4103%	90.5897%	0.411848
6	3.98634276	28.5530936	10.2102%	89.7898%	0.488550

(c) Estrutura 1C

Com 35 Unidades na primeira camada escondida.

Na tabela 5.3 estão dispostos os resultados obtidos para os 6 testes.




Figura 5.4: Esquema da RN 1C

2. Estrutura de rede - 2

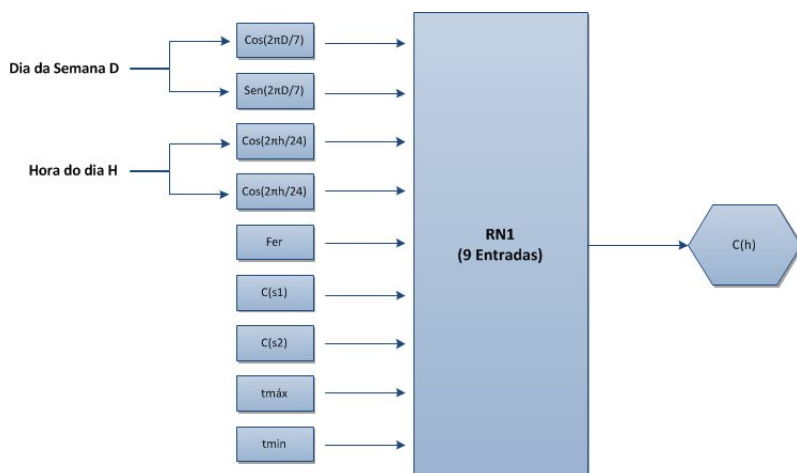


Figura 5.5: Estrutura da rede 2

Apresenta-se assim a estrutura relativa aos valores de entrada que se diferencia da estrutura A como sendo mais simples, isto é, possuindo menos valores de entrada. De seguida analisou-se o desempenho desta estrutura usando diferentes unidades na primeira camada escondida da rede neuronal e verifica-se se o uso de uma estrutura mais simples como esta, traduz em melhores resultados na previsão da carga.

O número de unidade nas diversas camadas é especificado pela sequência 9-X-1-1, indicando que esta rede tem 9 entradas, X unidades na primeira camada escondida, uma unidade na segunda camada escondida e uma saída.

Tabela 5.3: Resultados do desempenho para cada RN do teste 1C

RN	MAD	MSE	MAPE	FA	RMSE
1	3.6836417	23.9156927	9.3990%	90.6010%	0.409206
2	3.5401045	22.6030912	9.0842%	90.9158%	0.386745
3	3.72879696	24.1443445	9.5048%	90.4952%	0.413112
4	3.90654548	26.9764746	9.9901%	90.0099%	0.461577
5	3.37168283	20.4975811	8.5279%	91.4721%	0.350721
6	3.60329353	22.7915115	9.1757%	90.8243%	0.389969

(a) Estrutura 2A

Com 25 Unidades na primeira camada escondida.




Figura 5.6: Esquema da RN 2A

Na tabela 5.4 estão dispostos os resultados obtidos para os 6 testes.

Tabela 5.4: Resultados do desempenho para cada RN do teste 2A

RN	MAD	MSE	MAPE	FA	RMSE
1	3.71611118	24.5800727	9.4196%	90.5804%	0.420574
2	3.82442114	25.9981991	9.7656%	90.2344%	0.444839
3	3.93412398	27.3220369	10.0425%	89.9575%	0.467475
4	3.58202545	22.7519821	9.1289%	90.8711%	0.389294
5	3.5728321	22.9989388	9.0551%	90.9449%	0.393519
6	3.76210749	25.519236	9.6362%	90.3638%	0.436643

(b) Estrutura 2B

Com 30 Unidades na primeira camada escondida.




Figura 5.7: Esquema da RN 2B

Na tabela 5.5 estão dispostos os resultados obtidos para os 6 testes.

Tabela 5.5: Resultados do desempenho para cada RN do teste 2B

RN	MAD	MSE	MAPE	FA	RMSE
1	3.39430571	21.0646436	8.6465%	91.3535%	0.360423
2	3.43319283	21.3857969	8.7117%	91.2883%	0.365919
3	3.81394842	26.1154017	9.7524%	90.2476%	0.446843
4	3.52786701	22.194313	8.9913%	91.0087%	0.379753
5	3.33550351	19.8849189	8.4410%	91.5590%	0.340238
6	3.50987638	22.2811734	8.9476%	91.0524%	0.381239

(c) Estrutura 2C

Com 35 Unidades na primeira camada escondida.




Figura 5.8: Esquema da RN 2C

Na tabela 5.6 estão dispostos os resultados obtidos para os 6 testes.

Tabela 5.6: Resultados do desempenho para cada RN do teste 2C

RN	MAD	MSE	MAPE	FA	RMSE
1	3.56620703	22.7767575	9.0600%	90.9400%	0.389718
2	3.45336246	21.1726369	8.8064%	91.1936%	0.362271
3	3.73312396	25.1782883	9.5804%	90.4196%	0.430810
4	3.69559259	24.0732927	9.4499%	90.5501%	0.411903
5	3.57724451	22.5377343	9.1406%	90.8594%	0.385628
6	3.31580665	19.6414046	8.4128%	91.5872%	0.336070

3. Estrutura de rede - 3

Neste caso, a estrutura 3 apresenta valores de entrada semelhantes à 1, no entanto os valores da temperatura introduzidos são a média diária, ao contrário do que acontece na estrutura 1, em que a entrada dos valores da temperatura diária é efetuada através dos seus valores máximos e mínimos.

De seguida analisou-se o desempenho desta estrutura usando diferentes unidades na primeira camada escondida da rede neuronal e verificando se o uso desta estrutura se traduz em melhores resultados na previsão da carga.

Nos próximos testes o número de unidade nas diversas camadas é especificado pela sequência 12-X-1-1, indicando que esta rede tem 12 entradas, X unidades na primeira camada escondida, uma unidade na segunda camada escondida e uma saída.

(a) Estrutura 3A

Com 25 Unidades na primeira camada escondida.

Na tabela 5.7 estão dispostos os resultados obtidos para os 6 testes.




Figura 5.9: Estrutura da rede 3

(b) Estrutura 3B

Com 30 Unidades na primeira camada escondida.

Na tabela 5.8 estão dispostos os resultados obtidos para os 6 testes.

Tabela 5.8: Resultados do desempenho para cada RN do teste 3B

RN	MAD	MSE	MAPE	FA	RMSE
1	3.9641749	27.9611915	10.1285%	89.8715%	0.478417
2	4.0710235	29.4167172	10.4300%	89.5700%	0.503330
3	4.0136042	28.827392	10.2380%	89.7620%	0.493235
4	4.111299	30.4464692	10.5492%	89.4508%	0.520950
5	3.9690786	28.5749079	10.1309%	89.8691%	0.488927
6	4.0485101	29.759815	10.3474%	89.6526%	0.509201

(c) Estrutura 3C




Figura 5.10: Esquema da RN 3A

Tabela 5.7: Resultados do desempenho para cada RN do teste 3A

RN	MAD	MSE	MAPE	FA	RMSE
1	3.90660847	27.8199974	9.9859%	90.0141%	0.476005
2	3.99384763	28.7325941	10.1977%	89.8023%	0.491615
3	4.08592894	30.18129415	10.4536%	89.5464%	0.516407
4	4.19672571	31.74576465	10.7767%	89.2233%	0.543162
5	4.12893562	30.77080215	10.5733%	89.4267%	0.526488
6	4.20128224	32.05865142	10.7658%	89.2342%	0.548535

Com 35 Unidades na primeira camada escondida.

Na tabela 5.9 estão dispostos os resultados obtidos para os 6 testes.

Tabela 5.9: Resultados do desempenho para cada RN do teste 3C

RN	MAD	MSE	MAPE	FA	RMSE
1	3.94188006	27.68428853	10.0905%	89.9095%	0.473688
2	4.20195402	31.9710546	10.7461%	89.2539%	0.547031
3	3.97140595	28.48263107	10.1979%	89.8021%	0.487341
4	3.96329549	28.30823486	10.1734%	89.8266%	0.484359
5	4.12288142	29.90617526	10.5407%	89.4593%	0.511687
6	3.92932801	27.54418311	10.0657%	89.9343%	0.471291

5.1.1 Escolha da rede

Depois de analisadas todas as estruturas, é necessário escolher a rede que melhores resultados apresente, isto é, a rede mais fiável. Como tal de seguida irá selecionar-se a melhor RN de cada teste e assim avaliar qual delas será escolhida como sendo a melhor estrutura de rede neuronal que permite obter uma previsão de carga natural para uma semana

Tabela 5.10: Comparação de desempenhos para a melhor rede de cada estrutura utilizada

Teste	RN	Rede	MAD	MSE	MAPE	FA	RMSE
1A	4	1	3.6895	24.52695	9.4148%	90.5852%	0.419654
1B	3	2	3.6354	22.87115	9.2872%	90.7128%	0.391332
1C	5	3	3.3717	20.49758	8.5279%	91.4721%	0.350721
2A	5	4	3.5728	22.99894	9.0551%	90.9449%	0.393519
2B	5	5	3.3355	19.88492	8.4410%	91.5590%	0.340238
2C	6	6	3.3158	19.6414	8.4128%	91.5872%	0.336070
3A	1	7	3.9066	27.82	9.9859%	90.0141%	0.476005
3B	1	8	3.9642	27.96119	10.1285%	89.8715%	0.478417
3C	6	9	3.9293	27.54418	10.0657%	89.9343%	0.471291

Na tabela 5.10 estão presentes as redes que apresentaram melhores previsões, mostrando a qual das estruturas dizem respeito assim como os seus valores de erro e precisão. Esta tabela mostra claramente que a rede 6, referente à RN 6 da estrutura **2C** é a que apresenta os resultados




Figura 5.11: Esquema da RN 3B

mais satisfatórios. De salientar a tendência presente na figura 5.13, onde a previsão torna-se cada vez mais eficaz quanto mais unidades na primeira camada escondida houver, no entanto e tal como se viu anteriormente quanto maior for o número de unidades na primeira camada escondida maior será o risco da rede ficar sobre-treinada.




Figura 5.12: Esquema da RN 3C

5.1.2 Análise da rede escolhida

Após ter sido validada a estrutura que irá ser utilizada na ferramenta de previsão, foram geradas várias previsões semanais com dados de entrada real de forma a compreender como varia a previsão gerada. Em comparação com as restantes subestações escolhidas, a da Falagueira obteve um erro maior, isso deve-se em parte a dois fatores, às diversas transferências de carga realizadas neste transformador e à contribuição da produção distribuída neste equipamento. Tendo em conta estas condições, é possível afirmar que o erro médio obtido de 8.42% é satisfatório.

Foram analisadas duas semanas distintas, uma no verão de 30 de julho até dia 5 de agosto de 2012 e a outra no outono, de dia 29 de Outubro até dia 4 de Novembro de 2012, sendo que o foco desta semana foi avaliar como se comportaria a previsão num intervalo de dados onde existe um diagrama de carga um pouco atípico em comparação com o restante ano, resultante de várias transferências de carga assim como da ocorrência de um feriado, como se pode constatar na figura 5.15, no dia 1 de Novembro (quinta-feira) o diagrama da carga natural foi claramente previsto pela rede.

5.2 Resultados para outras subestações

Depois deste estudo, foi aplicado o mesmo método nas restantes subestações e os resultados obtidos estão presentes na tabela 5.11.

De referir que estes valores de erro, têm como previsão o ano de carga de 2012, isto é, o erro é obtido tendo em conta o valor real e o estimado para o intervalo de 15 de Março de 2012 até 28 de Fevereiro de 2013.

Na figura 5.16 estão presentes alguns dos diagramas de carga obtidos com a previsão para a semana de 1 de Outubro até dia 7 de Outubro de 2012, sendo esclarecedor que apesar de cada subestação ter a sua especificidade a previsão é eficaz na maior parte dos casos mesmo tendo em atenção que está a ser vista uma semana que tem presente um feriado nacional (implantação da República), neste caso o 5 de Outubro (sexta-feira).

5.3 Análise de resultados

A definição de uma metodologia eficaz foi fundamental neste estudo, permitindo ao utilizador ser capaz de realizar variadíssimos testes de uma forma precisa e célere. Foi notório que quanto




Figura 5.13: Gráfico referente aos desempenhos da melhor rede de cada estrutura utilizada

mais simples forem as variáveis de entrada da rede neuronal melhor será o desempenho desta. Depois de analisar as previsões da carga natural das diferentes subestações, é claramente perceptível que em termos gerais as previsões anteciparam com boa eficácia a carga natural em diferentes épocas do ano, percebendo com precisão o comportamento da carga tanto em dias úteis como em feriados, como é caso do dia 5 de Outubro de 2012. As variações na eficácia das previsões que se verificam nas subestações são explicadas pelo diferente perfil que cada subestação apresenta, sendo que quanto mais volátil for o seu perfil de carga natural menor será a eficácia da sua previsão. Como se pode verificar na figura 5.16, a subestação de Tunes apresenta o melhor desempenho neste estudo, que se justifica em grande parte pela pouca volatilidade da sua carga, que apresenta poucos picos de consumo ao longo do ano, possibilitando uma antecipação da carga extremamente eficaz.

5.4 Comparação de resultados com o método de previsão atual

Nesta secção analisa-se as diferenças em termos de resultados entre o método desenvolvido neste documento e o método de previsão de carga natural presente no COR atualmente, estando este descrito em [5].

Foram definidos dois períodos de estudo, estando estes definidos como:

- Período 1 - de dia 30 de Julho até dia 5 de Agosto de 2012
- Período 2 - de dia 1 até dia 7 de Outubro de 2012

Através da tabela 5.12 é possível verificar que em termos gerais o método desenvolvido neste documento apresenta resultados bastante mais satisfatórios, chamando a atenção para o período 1 na subestação de Valdigem, onde apesar de o MAPE apresentar melhor desempenho pelo método de previsão atual, a nível de MSE isso já não se verifica, o que poderá indicar que o método atual poderá ter variação de valores percentuais de erros maiores, enfatizando assim os dados




Figura 5.14: Comparação da carga natural real e prevista entre 30 de Julho de 2012 e 5 de Agosto de 2012







Figura 5.15: Comparação da carga natural real e prevista entre 29 de Outubro e 4 de Novembro de 2012




(a) Na subestação de Ferreira do Alentejo




(b) Na subestação de Rio Maior



(c) Na subestação de Sines



(d) Na subestação de Tunes



(e) Na subestação da Valdigem

Figura 5.16: Comparação da carga natural real e prevista entre 1 e 7 de Outubro de 2012

Tabela 5.11: Amostra dos resultados da rede para cada subestação


Subestação	RN	MAD	MSE	MAPE	FA	RMSE
Carregado	2	6.072	63.669	5.570%	94.43%	0.1148
Carvoeira	1	5.456	54.514	12.730%	87.27%	0.3118
Chafariz	2	1.486	3.837	4.044%	95.96%	0.0541
Estoi	1	4.247	31.523	3.477%	96.52%	0.0475
Évora	1	1.994	7.598	3.839%	96.16%	0.0649
Falagueira	6	3.316	19.641	8.413%	91.59%	0.3361
Fer. Alentejo	2	2.491	10.842	4.589%	95.41%	0.1251
Mourisca	2	5.448	55.389	4.119%	95.88%	0.0487
Pereiros	1	7.622	101.156	5.630%	94.37%	0.1554
Rio Maior	4	4.217	31.615	4.420%	95.58%	0.0896
Sines	1	3.609	22.237	5.538%	94.46%	0.0891
Tunes	6	2.790	14.220	3.226%	96.77%	0.0301
Valdigem	2	4.910	47.563	6.097%	93.90%	0.1014

discrepantes de maneira inconsistente com a mediana dos dados de amostra. É possível verificar uma tendência na tabela 5.12, onde na maioria das subestações em análise, do período 1 para o 2 há um aumento do MAPE em ambos os métodos devido à inclusão do feriado (5 de Outubro). Contudo este aumento é bem maior com a implementação do método de previsão atual, o que revela que o método de previsão proposto não só apresenta resultados mais satisfatórios a nível global como também minimiza o erro na ocorrência de um feriado.


Tabela 5.12: Comparação de desempenho dos dois métodos em dois períodos distintos

Período	Método Previsão Atual		Método Previsão Proposto		Subestações
	1	2	1	2	
MAPE	5.854%	13.667%	3.360%	3.203%	Rio Maior
MSE	46.937	207.261	18.400	13.231	
MAPE	9.800%	12.850%	5.502%	6.740%	Falagueira
MSE	20.520	46.421	7.349	12.985	
MAPE	6.825%	13.778%	2.254%	2.548%	Tunes
MSE	146.168	156.152	10.129	8.437	
MAPE	13.257%	7.064%	5.387%	3.579%	Sines
MSE	122.152	47.203	22.435	15.373	
MAPE	9.768%	14.262%	2.918%	3.716%	Ferr. Alentejo
MSE	49.619	71.367	4.668	5.888	
MAPE	4.941%	12.001%	6.381%	7.134%	Valdigem
MSE	33.632	178.446	22.764	43.820	

A figura 5.17 é demonstrativa das diferenças de previsão do diagrama de carga natural entre os dois métodos, nesta figura é comparado o diagrama de carga natural previsto em duas subestações, os restantes diagramas encontram-se em anexo B.



(a) Na subestação da Valdigem



(b) Na subestação de Sines

Figura 5.17: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos entre 1 e 7 de Outubro de 2012

5.5 Erro alcançado

O aumento da qualidade de cada previsão é um dos pressupostos deste trabalho, assim sendo e tendo em conta a secção 5.4 esse objetivo foi amplamente alcançado, no entanto é necessário perceber o erro que foi obtido e quais as suas limitações, para que o utilizador possa interpretar melhor os resultados.

5.5.1 Limitações

Existem vários fatores que podem afetar a qualidade da previsão alcançada neste documento, sendo estes:

- A volatilidade dos diagramas de carga natural que estão dependentes de inúmeras variáveis, como a produção que provem de produtores ligados à Distribuição, das transferências de carga que existem entre subestações REN e ainda quando surge uma situação de malha fechada entre subestações REN.
- Mudanças de diagrama de carga bruscas numa determinada subestação REN, como a rede de cada subestação foi treinada com uma determinada carga, ajustando os seus pesos de forma a prever melhor a carga, se este diagrama tiver uma mudança bastante notória poderá

aumentar o erro da previsão. Os exemplos mais exemplificativos deste tipo de mudança são: o aumento ou abaixamento da carga média anual acima de 20% ou a inclusão de vários produtores em regime especial com forte contribuição em determinada subestação REN.

- Dias que possuam diagrama de carga fora do comum em comparação com o diagrama de um dia útil. No caso da aplicação desenvolvida é provável que o erro aumente 1 a 2 pontos percentuais caso haja um feriado nos dados históricos (s1 e s2).

5.5.2 Medidas de minimização de limitações

Com o intuito de minimizar possíveis limitações do treino desenvolvido, é recomendável a seguinte lista de medidas:

- Criação de uma ferramenta que indique os feriados existentes em dados históricos, utilizados para a previsão de determinada semana que contenha feriados, fornecendo assim mais informação à rede.
- No treino das redes, é necessário ter em atenção as suas particularidades, isto é, caso haja muitas transferências de carga nos dados a treinar o erro de previsão irá aumentar.
- Caso haja a inclusão de previsão de carga natural para uma nova subestação, é aconselhável que haja um treino de rede com dados históricos de pelo menos 3 meses, sendo o ideal um ano de dados históricos para treinar a rede.

Capítulo 6

Conclusões e Desenvolvimentos Futuros

Estão neste capítulo final expressas as principais conclusões a extrair da pesquisa e do estudo elaborados no desenvolvimento deste trabalho, assim como possíveis ideias a introduzir em futuros desenvolvimentos de métodos de previsão de carga natural usando as redes neuronais. A primeira secção apresenta diversas conclusões relativas ao principal objetivo desta dissertação e dos resultados obtidos ao longo da realização da mesma. A segunda secção expõe um conjunto de sugestões de forma a melhorar a previsão do trânsito de potência presente nos transformadores, assim como se propõe várias adições e modificações à aplicação *PrevCarga*, a considerar em desenvolvimentos futuros

6.1 Conclusões Finais

Com o desenvolvimento desta dissertação pretendia-se munir o GS de uma ferramenta que possa facilitar a programação das indisponibilidades dos transformadores, tal objetivo foi concretizado, tomando em consideração os resultados obtidos e comparando-os com o método de previsão usado habitualmente no GS, sendo notório que há um melhoramento. Esta melhoria foi materializada no desenvolvimento da aplicação *PrevCarga*, programada em linguagem *Matlab*, que inclui também uma interface gráfica para facilitar a interação com o utilizador.

De forma a compreender melhor o desafio proposto, realizou-se um estudo acerca do estado do RNT e as suas tendências futuras, tendo em consideração o aumento de produção em regime especial uma vez que esta variável afeta consideravelmente o diagrama de carga sentido nos transformadores de potência das subestações MAT/AT. Devido à volatilidade da produção distribuída, a previsão da potência de transformação torna-se menos precisa podendo induzir em erro o GS na programação das indisponibilidades dos transformadores.

Com o intuito de garantir a segurança e a continuidade de serviço da RNT, o COR, possui um conjunto de regras de análise de indisponibilidades dos transformadores. Estando assim o serviço assegurado no caso de ocorrência de algum imprevisto para cada subestação MAT/AT é definido um valor de reserva que garanta um serviço ininterrupto, denominando-se de reserva n-1.

Foi feita uma caracterização das diversas subestações MAT/AT de forma a perceber a sua especificidade e o risco a que estas estão sujeitas, criando assim uma ferramenta útil e de fácil acesso ao GS, que enumera as particularidades destes equipamentos.

Tornou-se imperativo adicionar neste estudo o termo de carga natural, sendo esta variável obtida através da soma de todos os produtores que se ligam a uma determinada subestação e o trânsito efetivo nos transformadores de potência dessa subestação MAT/AT.

Dada a importância de perceber o valor carga natural para a programação das indisponibilidades, foi proposto criar uma ferramenta de previsão diferente da usada até aqui pelo GS, tendo sido adotada a técnica de aprendizagem automática: Rede Neuronal, uma vez que esta tem sido recorrentemente utilizada com algum sucesso em casos de estudo semelhantes. Após a escolha do método a utilizar para a previsão, foi feita uma análise de forma a compreender quais seriam as variáveis de entrada que melhor se ajustavam neste trabalho, assim fez-se um estudo que incidiu sobre as variáveis justificativas do diagrama de carga e compreendeu-se o peso que cada uma tem neste diagrama. Os resultados foram conclusivos, indicando que o valor da carga à mesma hora semanas antes mostra uma correlação forte com o valor de carga alvo, perdendo força quanto maior for o espaço temporal. A influência dos feriados também é analisada em detalhe, evidenciando significativas alterações no diagrama de carga. Em relação a dados meteorológicos, a análise indicou que apesar das duas variáveis observadas não possuírem uma correlação forte com a carga, a temperatura tem um impacto bem maior no diagrama em comparação com a humidade.

Com a análise de todos estes fatores torna-se claro que a aplicação de uma metodologia bem estruturada é fulcral para o tratamento de dados, tornando-o menos moroso e menos perceptível a erros durante o tratamento.

A rede neuronal unidirecional (*feedforward*) foi o tipo de rede adotada neste dissertação, sendo que o treino usado foi o de aprendizagem por retropropagação (*backpropagation*). No que se refere ao número de camadas escondidas e unidades neuronais nas camadas escondidas, deve ser encontrado um ponto de equilíbrio que permita o melhor desempenho da rede neuronal, sendo que se assumiu que uma única camada escondida será suficiente para qualquer tipo de previsão, prendendo-se a variação única e exclusivamente no número de neurónios da referida camada.

Os resultados obtidos referentes à previsão de carga natural revelaram-se bastante interessantes quando comparados com os valores obtidos pelo método de previsão de carga usado no GS. O valor de erro varia consoante a subestação que se utiliza devido às particularidades destas, no entanto em todas as subestações e independentemente do intervalo de tempo analisado o método de previsão desenvolvido apresenta melhorias claras. Além dos resultados satisfatórios, este método consegue prever com eficácia os diagramas de carga de feriados, ao contrário do que acontece com o método de previsão atual pelo GS.

Em relação à aplicação desenvolvida, denominada de PrevCarga, a sua implementação adveio da necessidade de dotar o GS de uma ferramenta intuitiva e eficaz que possa facilitar a programação das indisponibilidades. A simplicidade desta ferramenta procura que qualquer agente do COR a possa utilizar sem que haja necessidade de compreender os principais fundamentos das

redes neuronais. A simulação e o interface é feita em ambiente *Matlab*, tendo por base os dados existentes em ficheiros EXCEL.

6.2 **Desenvolvimentos Futuros**

Existe ainda um longo caminho no que à previsão de carga diz respeito, no entanto esse caminho já se começou a percorrer e é com esse intuito que de seguida se propõe para desenvolvimentos futuros a implementação de novos métodos que possam fortalecer o GS de uma ferramenta de previsão de carga natural mais eficaz.

A inclusão de redes neuronais como técnica de previsão de carga natural revelou ser bastante eficiente principalmente tendo em conta o método utilizado pela GS, embora esta técnica tenha apresentado bons resultados ainda poderá ser melhorada.

No sentido de melhorar a ferramenta criada neste documento propõe-se o seguinte:

- Treino para todas as subestações - Neste trabalho foram criadas redes que possibilitam a previsão apenas para as subestações que apresentam maior risco de indisponibilidade, perfazendo 13 num total de 64 subestações.
- Criação de uma rede de treino com mais dados históricos, isto é, neste documento foram treinadas redes com um ano de dados históricos, que percorriam as diversas estações do ano. O que se propõe é um aumento do intervalo de dados para 2 ou 3 anos, tendo sempre em atenção as situações "anómalas" como por exemplo as transferências de carga presentes.
- Inclusão de um método que indique à rede neuronal que os dados históricos de consumo das semanas anteriores podem ser afetadas por feriados.
- Inclusão de outros tipos de produtores em regime especial além dos produtores eólicos. Desta forma a previsão do trânsito de potência presentes nos transformadores MAT/AT tornava-se cada mais condizente com a realidade.
- Criação de um método menos moroso para o tratamento de dados que provêm de diferentes origens.

Referências

- [1] REN Rede Elétrica Nacional. *Estatística Anual 2004 - 2013 Eletricidade*. REN, Janeiro 2014.
- [2] REN Rede Elétrica Nacional. *PDIRT – Plano de desenvolvimento e investimento da rede de transporte de eletricidade 2012-2017(2022)*. REN, Julho 2011.
- [3] E2P. *Parques Eólicos em Portugal*”,. E2P – Energias Endógenas de Portugal, Deembro 2012.
- [4] REN Rede Elétrica Nacional. *O Setor Elétrico*. REN, Outubro 2013.
- [5] João Pinto. *Previsão dos consumos na RNT considerando a produção distribuída*. Faculdade de Engenharia da Universidade do Porto, Julho 2013.
- [6] Instituto Português do Mar e Atmosfera. Dados meteorológicos. <https://www.ipma.pt/pt/>, Janeiro 2014.
- [7] AccurWeather. Dados meteorológicos. <http://www.accuweather.com/en/pt/portugal-weather>, Dezembro 2013.
- [8] ERSE Entidade Reguladora dos Serviços Energéticos. *Eletricidade*. ERSE, 2013.
- [9] REN Rede Elétrica Nacional. *Cadeia de valor da rede de transporte*.
- [10] REN Rede Elétrica Nacional. *Caracterização da rede nacional de transporte para efeito de acesso à rede*. REN, Dezembro 2013.
- [11] ERSE Entidade Reguladora dos Serviços Energéticos. *Rede de Transporte de Eletricidade*. ERSE, Outubro 2013.
- [12] REN Rede Elétrica Nacional. *Dados técnicos de eletricidade 2012*. REN, 2013.
- [13] U.S. Energy Information Administration (2011). *International Energy Outlook 2011*. U.S. Energy Information Administration, 2011.
- [14] REN 21. *RENEWABLES 2012 GLOBAL STATUS REPORT*. Paris, França, 2012.
- [15] REN Rede Elétrica Nacional. História ren. <http://www.ren.pt>, Outubro 2013.
- [16] REN Rede Elétrica Nacional. *“Missão e Funções”, Gestão do Sistema – Operação de Rede*. REN, 2012.
- [17] REN Rede Elétrica Nacional. *“Programação dos trabalhos nas instalações da Rede Nacional de Transporte”, Gestão do Sistema – Operação de Rede*. REN, 2012.

- [18] ERSE. *Parâmetros de Regulação para o período de 2012 a 2014*. ERSE - Entidade Reguladora dos Serviços Energéticos, Dezembro 2011.
- [19] ERSE Entidade Reguladora dos Serviços Energéticos. *Despacho ERSE 2014-2009*. ERSE, 2009.
- [20] REN Rede Elétrica Nacional. *Regras de análise de indisponibilidades. Cargas máximas admissíveis*. Gestor do Sistema, Março 2007.
- [21] Fidalgo C., Monteiro e N. *O Problema da previsão de consumos*. Faculdade de Engenharia da Universidade do Porto, 2012.
- [22] Pedreira C. E. Souza R. C. Hippert, H. S. *Neural Networks For Short-Term Load Forecasting: A Review and Evaluation*. Power Systems, IEEE Transactions on, 2001.
- [23] Rob J. De Gooijer, Jan G. e Hyndman. *25 years of time series forecasting*. *International Journal of Forecasting*. IEEE Transactions, 2006.
- [24] Matteo De Felice. *Short-Term Load Forecasting with neural networks Ensembles a Comparative Study*. ENEA, Italy 2011.
- [25] Machado J. e Neves J. Cortez, P. *An evolutionary Artificial Neural Network Time series Forecasting System*. Braga, Portugal.
- [26] V.H. Kher e S.K. Joshi. *hort-Term Electrical Load Forecasting Using Artificial Neural Network*. Vadodara, India.
- [27] Y. Hayati, M. e Shirvany. *Artificial Neural Network Approach for Short Term Load Forecasting for Illam Region*. Illam, Iran 2007.
- [28] S.O.A. Ogunjuyigbe G.A. Adepoju e K.O. Alawode. *Application of Neural Network to Load Forecasting in Nigerian Electrical Power System*. Nigeria, 2007.
- [29] E. A. Mohamed A. J. Al-Shareef e E. Al-Judaibi. *One Hour Ahead Load Forecasting Using Neural Network for the Western os Saudi Arabia*. Saudi Arabia 2008.
- [30] Mohammad Nazeeruddin Hesham K. Alfares. *Electric load forecasting: Literature survey and classification of methods*. Junho de 2011.
- [31] Genethliou D. Feinberg, E. A. *Applied Mathematics for Restructured Electric Power Systems*. 2005.
- [32] Ricardo Bento Bessa. *Treino On line de Redes Neurais com Critérios de Informação Aplicado à Previsão Eólica*. Faculdade de Engenharia da Universidade do Porto, 2008.
- [33] Maria Helena Vasconcelos. *Avaliação e Controlo de segurança de Redes Interligadas com Grande Penetração Eólica com base em métodos de Aprendizagem Automática*. Faculdade de Engenharia da Universidade do Porto, 2007.
- [34] Cláudio Monteiro. *Redes Neurais*. Faculdade de Engenharia da Universidade do Porto, DOIC, 2007.
- [35] Vladimiro Miranda. *Redes Neurais – Treino por retropropagação*. ropropagação”, Faculdade de Engenharia da Universidade do Porto, 2007.

- [36] Cláudio Monteiro. *Previsão de produção eólica*. Faculdade de Engenharia da Universidade do Porto, 2012.
- [37] Carla Rocha. *Produção Eólica, Perspectiva do Operador da Rede*. Sacavem Maio 2007.
- [38] Wesin Ribeiro Alves. *Modelos para previsão de carga a curto prazo através de redes neuais artificiais com treinamento baseado na teoria da informação*. Universidade federal do Pará, Instituto de Tecnologia, 2011.
- [39] F. Maciel Barbosa. *Gestão do diagrama de cargas*. Gestão de energia, Faculdade de Engenharia da Universidade do porto, 2004.
- [40] Susana Maria Tavares Rodrigues. *Modelação do Desempenho Académico de estudantes Universitários utilizando Redes Neurais*. Faculdade de Ciências e Tecnologia da Universidade Nova de Lisboa, 2011.
- [41] MATLAB Documentation Center. Vectorization. http://www.mathworks.com/help/matlab/matlab_prog/vectorization.html#btimcm2-1, Dezembro 2013.
- [42] V.M.F. Mendes J.P.S. Catalão, N.M.S. Martins. *REDES NEURONAIAS ARTIFICIAIS PARA PREVISÃO DA POTÊNCIA EÓLICA*. Universidade da Beira Interior.
- [43] MathWorks. Creating guis. <http://www.mathworks.com/discovery/matlab-gui.html>, Dezembro 2013.

Anexo A

Manual de utilizador da aplicação PrevCarga

O presente anexo tem como principal intuito a descrição de um manual do utilizador referente à aplicação PrevCarga.

A principal finalidade do PrevCarga é permitir ao utilizador realizar previsões da carga natural presente em cada subestação. O seguinte conjunto de instruções e imagens demonstram as operações possíveis de executar no programa.

A.1 Requisitos

- Sistema operativo: Windows;
- Microsoft Excel, ou semelhante;
- Matlab ou compilador MCR (Matlab Compile Runtime) [43];
- Todos os ficheiros de entrada têm de estar no mesmo diretório que a aplicação PrevCarga, como se demonstra na figura A.1.







Nome	Tipo	Tamanho
 Valdigem.xlsx	Folha de Cálculo do Microsoft Excel	213 KB
 Valdigem.txt	Documento de texto	1 KB
 Valdigem	Microsoft Access Table Shortcut	9 KB
 PrevCarga.m	MATLAB Code	10 KB
 PrevCarga.fig	MATLAB Figure	7 KB
 feriados.txt	Documento de texto	1 KB

Figura A.1: Diretório da aplicação

Dentro do diretório ilustrado na figura A.1 encontram-se os ficheiros de suporte ao programa, que fornecem a seguinte informação:

- feriados.txt - a data dos feriados existentes num ano, este ficheiro deve ser atualizado todos os anos.
- Valdigem.xlsx - Contem as entradas que irão servir de suporte à previsão. Neste ficheiro os dados de históricos da carga natural (s1 e s2) são importados de telecontagem.
- Valdigem.txt - Contem a informação acerca de cada subestação, referente a sua reserva n-1, os seus transformadores e a produção distribuída associada a esta.

Uma vez iniciado o PrevCarga, surge o ambiente de trabalho indicado na figura A.2.

	Tmin	Tmax
Dia 1	0	0
Dia 2	0	0
Dia 3	0	0
Dia 4	0	0
Dia 5	0	0
Dia 6	0	0
Dia 7	0	0

Figura A.2: Interface do PrevCarga

Para se iniciar o processo de previsão da carga natural é necessário seguir os 3 passos seguintes:

1. Carregar Subestação - No botão 'Carregar Subestação', escolhe-se a subestação que se vai prever a carga natural. Ao clicar-se neste botão, é aberta uma janela de pesquisa do ficheiro da subestação como mostra a figura A.3
2. Colocar a temperatura dos próximos 7 dias nas caixas de texto do intervalo temporal que se pretende prever. A figura A.4 mostra a inclusão desses dados por parte do utilizador,

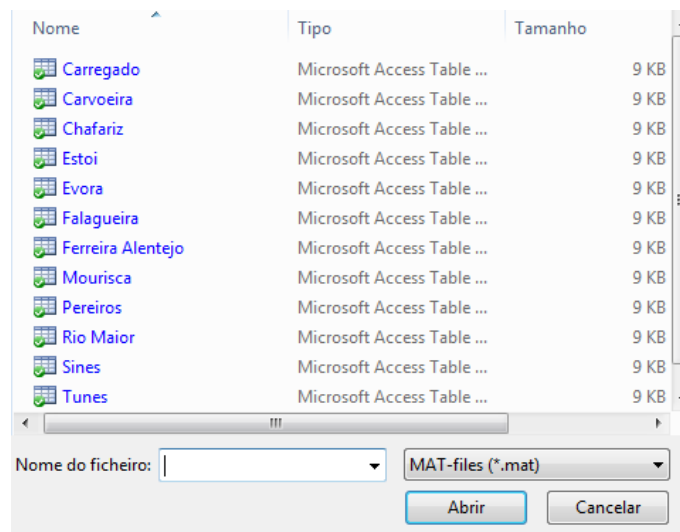


Figura A.3: Importar ficheiro de entrada

que acede a estes dados clicando em 'IPMA' e será dirigido para o site do Instituto do Mar e Atmosfera - IPMA, que contém a previsão das temperaturas máximas e mínimas dos próximos 7 dias.

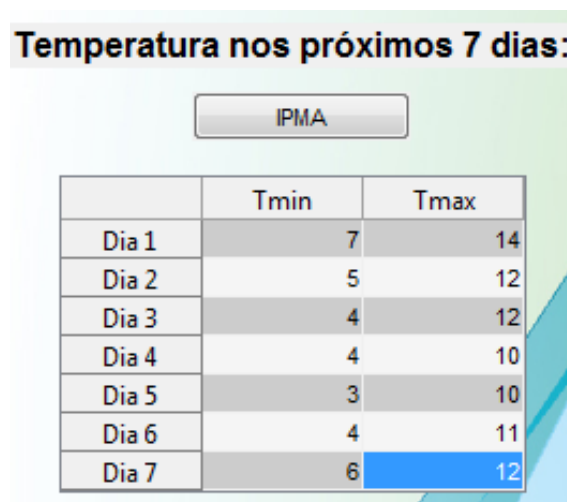


Figura A.4: Dados de temperatura inseridos pelo utilizador

3. O botão 'Realizar Previsão' permite obter a previsão tendo em conta os dados fornecidos anteriormente. É desencadeado um processo que demonstra a nível gráfico o diagrama de carga da semana, como se pode constatar na figura A.5. É escrito na folha EXCEL associada a esta subestação o valor da previsão para os 7 dias, em intervalos de tempo de 15 minutos.

O painel 'Informação' indica a informação relativa à subestação escolhida, como se constata na figura A.6. Este painel indica:




Figura A.5: Gráfico da carga natural prevista com a reserva n-1 associada à subestação.

- A reserva n-1 em MVA associada à subestação;
- A quantidade de transformadores existentes na subestação assim como a sua potência aparente;
- A produção distribuída associada a subestação escolhida;

Figura A.6: Informação relativa à subestação escolhida

O botão 'Reset' coloca apaga toda a informação colocada anteriormente, sendo assim possível recomeçar outra previsão.

A.2 Exemplo de Utilização

Um exemplo de utilização do PrevCarga é mostrado de seguida.

Informação:

- Subestação escolhida: Valdigem
- Semana de previsão: De 10 a 16 de Janeiro de 2014

The screenshot shows the 'PrevCarga' application interface. On the left, under 'Escolha a Subestação:', there is a 'Carregar Subestação' button and a highlighted 'Valdigem.mat' option. Below this is a 'Temperatura nos próximos 7 dias:' section with a 'PMA' button and a table with columns 'Dia', 'Tmin', and 'Tmax'. The table contains seven rows, all with '0' in the 'Tmin' and 'Tmax' columns. On the right, an 'Informação' window is open, displaying 'Reserva n-1 associada à subestação (MVA): 126'. Under 'Escolha o transformador:', the 'Potência de Transformação (MVA): 126' is shown with a dropdown menu set to 'TR2'. Below this is a list of 'Produção distribuída associada:' including 'Parque Eólico de Alvão', 'Parque Eólico de Fonte de Mesa', 'Parque Eólico de Pena Suar', 'Parque Eólico de Vila de Lobos', 'Parque Eólico de Trandeiras', 'Parque Eólico de Teixeira', 'Parque Eólico de S. Cristovão', 'Parque Eólico das Meadas', and 'Parque Eólico de Testos'. At the bottom of the 'Informação' window are 'Realizar Previsão' and 'Reset' buttons.

Figura A.7: Escolha da subestação da Valdigem

O primeiro passo para a previsão da carga natural com esta aplicação é a escolha da subestação, como está ilustrado na figura A.7.

This is a close-up of the 'Informação' window from the previous figure. It shows the 'Reserva n-1 associada à subestação (MVA): 126' at the top. Below that, under 'Escolha o transformador:', the 'Potência de Transformação (MVA): 126' is displayed with a dropdown menu set to 'TR1'. The 'Produção distribuída associada:' list is also visible, showing the same set of wind parks as in Figure A.7.

Figura A.8: Informação relativa à subestação da valdigem

É possível verificar as suas características na figura A.8, tendo em especial atenção o valor da sua reserva, uma vez que este valor não deve ser ultrapassado pela carga natural. Depois de inseridos as temperaturas como se pode constatar na figura A.9, realiza-se a previsão obtendo-se o gráfico que se apresenta na figura A.10.

Temperatura nos próximos 7 dias:

IPMA

	Tmin	Tmax
Dia 1	7	14
Dia 2	6	13
Dia 3	7	14
Dia 4	7	13
Dia 5	8	14
Dia 6	10	14
Dia 7	10	13

Figura A.9: Dados de temperatura inseridos pelo utilizador

Como não havia dados para comparação na altura em que a previsão foi feita, passado uma semana conjugou-se os resultados obtidos com a carga natural real e os resultados mostraram um MAPE de 7.189%. A figura A.11 mostra o diagrama de carga, sendo possível verificar que a PrevCarga previu com eficácia a carga natural apesar de este ser um exemplo onde a aplicação poderia não obter resultado satisfatórios uma vez que no seu histórico de dados(s1 e s2) existem feriados.




Figura A.10: Diagrama de carga natural obtido do PrevCarga

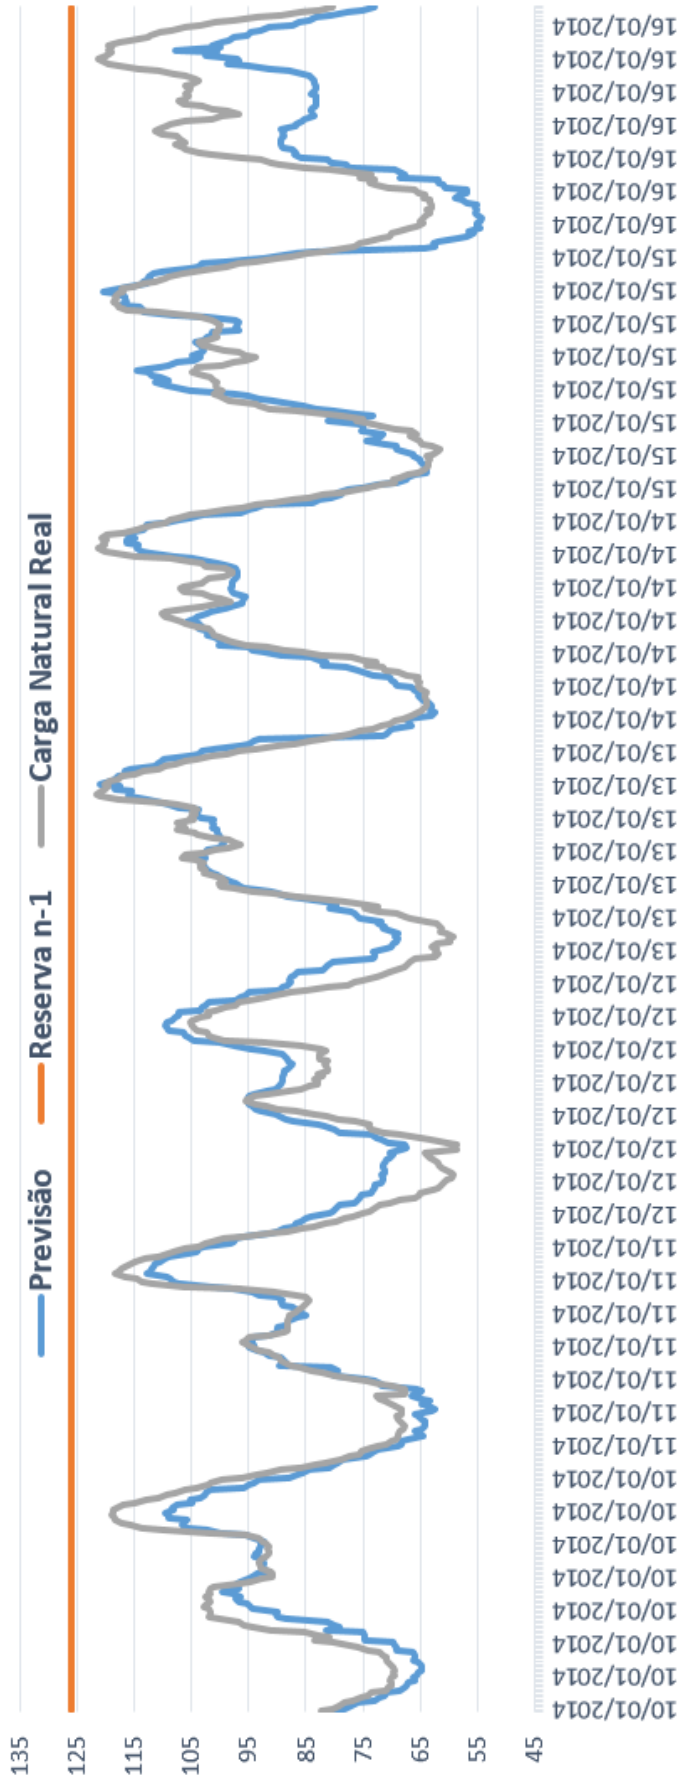



Figura A.1.1: Diagrama de carga comparando o valor de carga natural e o previsto


Anexo B

Comparação entre Métodos

Prosseguindo a análise efetuada em , de seguida estão exposto os diagramas referentes à carga natural real e à prevista com dois métodos analisados.



(a) No período 1



(b) No período 2

Figura B.1: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Rio Maior




Figura B.2: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação da Falagueira




Figura B.3: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Tunes

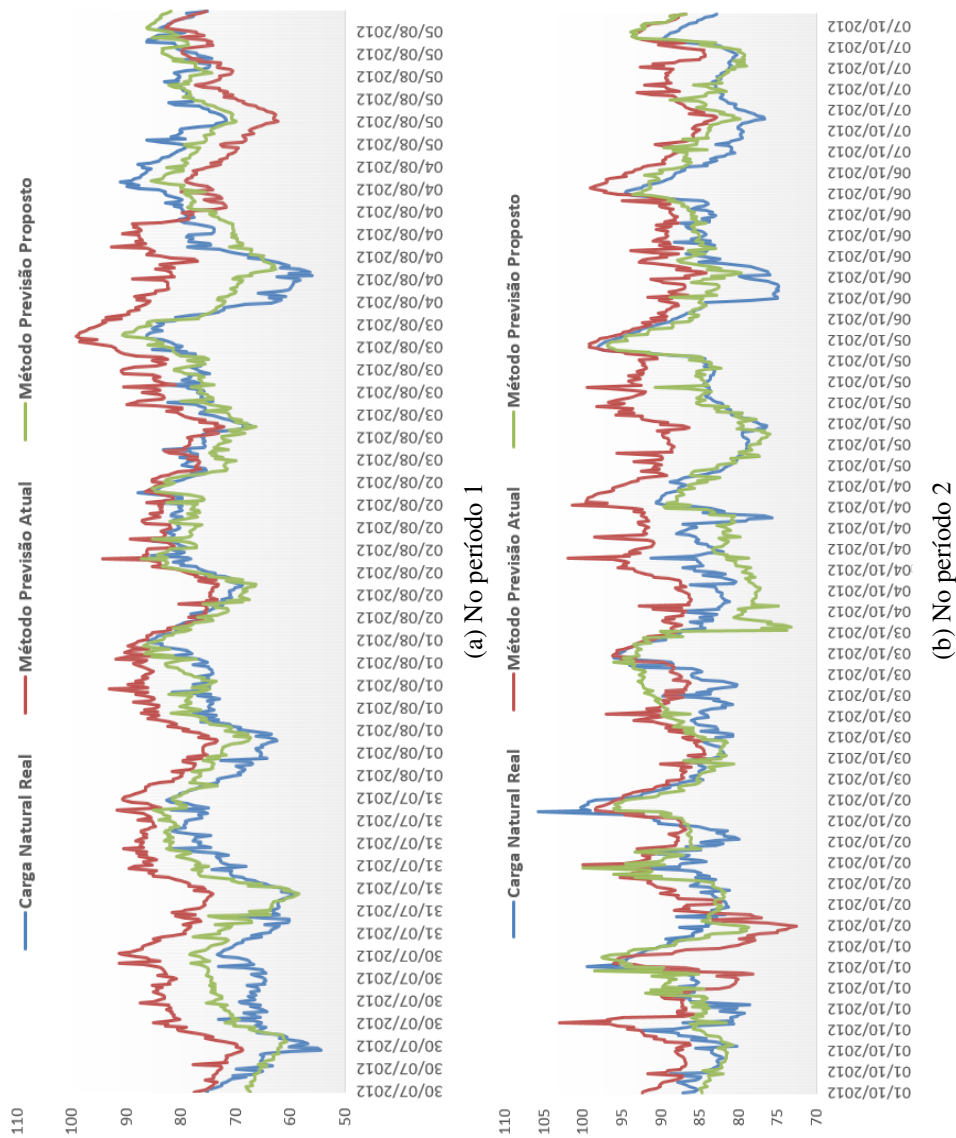


Figura B.4: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Sines

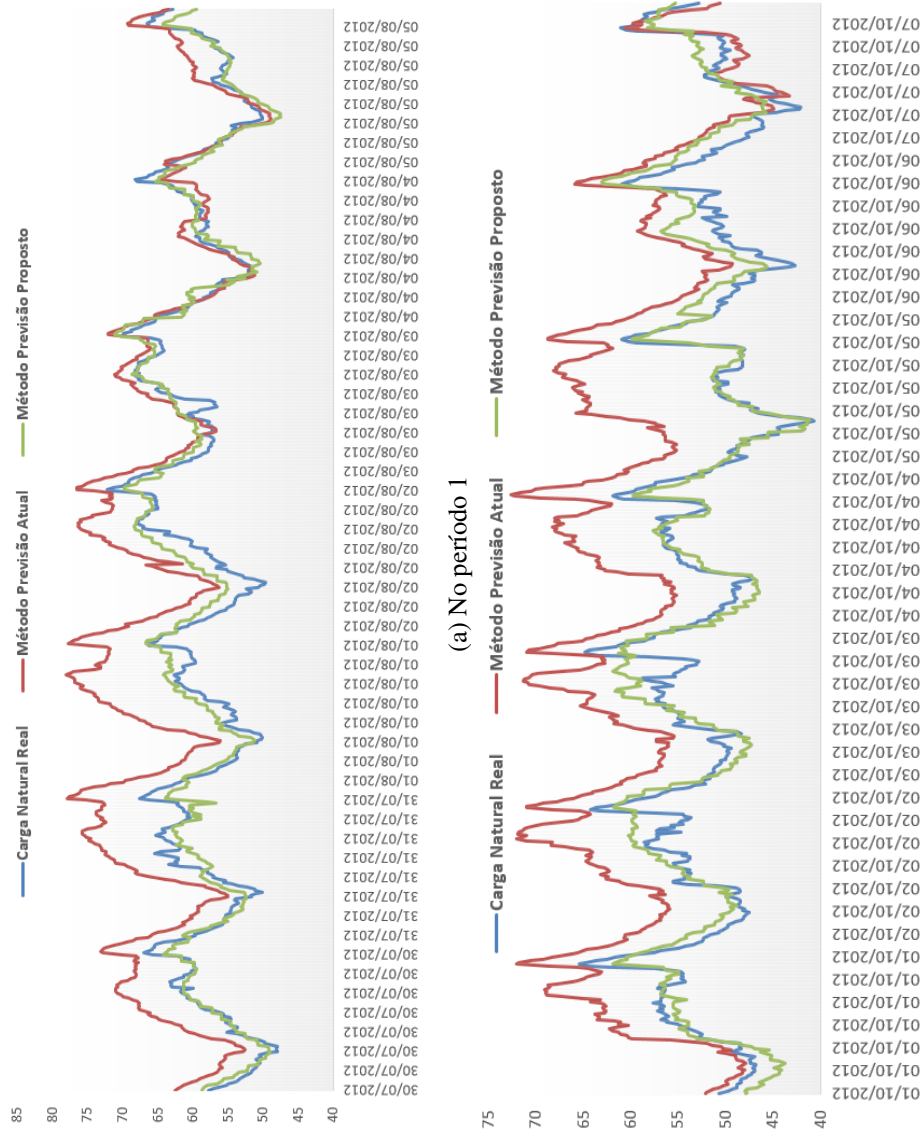


Figura B.5: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação de Ferreira do Alentejo




Figura B.6: Comparação do diagrama de carga natural real e prevista com os dois métodos referidos em dois períodos na subestação da Valdigem

B.1 Caraterização de Subestações REN

Nome Subestação	Sigla	Transformadores												Consumo				Geração					Transferência Carga		Presença do consumo sobre a produção	Necessidade de previsão				
		MVA		MVA		MVA		MVA		MVA		MVA		P(mVA) Ligação	P(mVA) Ligação	Eólica	Hídrica	Tipo	Cogeração Solar	ΣPRE/ Mês	Influência Relativa da PRE	Geração maioritária	Carga Não Transf	Carga Não Transf			Nível de transf			
		TR1	TR2	TR1	TR2	TR1	TR2	TR1	TR2	TR1	TR2	TR1	TR2															TR1	TR2	TR1
ALQUEYA	SAY	TR1 170	TR2 170										170	170	340	50	Alta	60.6	58.7	0%	22%	0%	79%	17%	Baixa	Solar	34	0	Baixa	Média
ALTO MIRA	SAM	TR1 170	TR2 170	TR3 170									170	510	680	245	Alta	291.1	41.2	89%	0%	12%	0%	12%	Baixa	Eólica	194	53	Média	Alta
BATALHA	SBL	TR1 170	TR2 170	TR3 170									170	340	510	245	Médio	283.6	112.7	89%	0%	11%	0%	32%	Média	Eólica	106	115	Média	Alta
BODIOSA	SBA	TR1 170	TR2 170										170	340	340	160	Baixa	111.2	226.3	81%	17%	2%	0%	64%	Alta	Eólica	83	14	Média	Não se verifica
CAMELAS	SCM	TR1 120	TR2 120	TR3 120	TR4 126								126	360	486	285	Médio	405.5	134.3	3%	90%	6%	0%	38%	Média	Hídrica	145	194	Média	Alta
CARRAPATELO	SCL		TR1 170	TR2 170									170	170	340	170	Nula	68.3	202.6	95%	5%	0%	0%	58%	Alta	Eólica	27	0	Baixa	Não se verifica
CARRÉGADO	SCG		TR1 120	TR2 120	TR3 120	TR4 170							120	240	360	180	Médio	186.6	85.3	82%	0%	18%	0%	24%	Baixa	Eólica	146	0	Alta	Alta
CARRICHE	SCH	TR1 170	TR2 120	TR3 120	TR4 170								170	410	580	220	Alta	234.1	6.8	0%	0%	100%	0%	2%	Nula	Cogeração	161	73	Média	Alta
CARVOEIRA	SCVR		TR1 170	TR2 170									170	170	340	140	Baixa	91.9	99.2	94%	0%	6%	0%	28%	Média	Eólica	48	0	Média	Não se verifica
CASTELO BRANCO	SCC			TR5 126	TR4 63								126	63	189	50	Médio	53.3	41.2	89%	0%	11%	0%	12%	Baixa	Eólica	52	0	Alta	Média
CHAFARIZ	SCF		TR1 126	TR2 63	TR3 63								126	126	252	90	Médio	65.6	141.8	54%	46%	0%	0%	40%	Média	Mix	57	0	Média	Não se verifica
CHAVES	SCV				TR1 63								63	0	63	60	Nula	95.9	0				0%	0%	Nula	N/A	30	0	Baixa	Muito Alta
CUSTÓIAS	SCT		TR1 170	TR2 126	TR3 170								170	296	466	230	Médio	262.9	137.3	0%	0%	100%	0%	39%	Média	Cogeração	191	39	Alta	Alta
ERMESINDE	SED		TR1 170	TR2 170	TR3 170								170	340	510	220	Médio	224.7	16.8	0%	27%	73%	0%	5%	Nula	Mix	191	28	Alta	Alta
ESTARREJA	SEJ	TR1 170	TR2 126	TR3 126	TR4 126								170	378	548	325	Baixa	365.5	153.7	51%	7%	41%	0%	44%	Média	Mix	189	144	Média	Alta
ESTREMOZ	SEM		TR2 60										63	60	123	65	Nula	61.7	0	0%	0%	100%	0%	0%	Nula	N/A	62	0	Alta	Alta
ESTÓI	SET	TR2 126	TR3 126										126	252	378	185	Médio	230.4	76.9	98%	0%	2%	0%	22%	Baixa	Eólica	172	24	Alta	Alta
ÉVORA	SER	TR2 63	TR3 63										63	126	189	100	Médio	99.2	0.3	0%	0%	100%	0%	0%	Nula	Solar	85	15	Alta	Alta
FALAGUEIRA	SFR	TR2 63											63	63	126	100	Nula	165.3	165.3	29%	57%	14%	0%	47%	Média	Mix	36	2	Alta	Não se verifica
FANHÕES	SFU	TR1 170	TR2 170	TR3 170									170	340	510	160	Alta	236.5	219.4	48%	0%	49%	3%	62%	Alta	Mix	179	30	Alta	Média

Figura B.7: Exemplo da folha de caracterização das subestações REN

Nome Subestação	Sigla	Transformadores												Consumo			Geração						Transferência Carga			Prevalência do consumo sobre a produção	Necessidade e previsão	
		MVA			MVA			MVA			P(MVA) Ligação	Eólica	Hídrica	Tipo Cogeração Solar	ΣPRE/ Máz	Influência Relativa da PRE	Geração maioritária	Carga M3o Transf	Carga M3o Transf	Carga M3o Transf								
		NE	MVA	TR	NE	MVA	TR	NE	MVA	TR																		
FERNÃO FERRO	SFF	TR3	126	TR4	126			TR2	126	126	252	378	170	Médio	210.8	40.8	0%	0%	100%	0%	12%	Baixa	Cogeração	94	100	Média	Alta	Baixa
FERRERIA DO ALENTEJO	SFA	TR2	63	TR3	126			TR1	50	126	113	239	90	Médio	99.8	58.9	0%	22%	0%	78%	17%	Baixa	Solar	67	15	Alta	Alta	Baixa
FERRERIA DO FERRO	SFE			TR1	126	TR2	126	TR3	63	126	189	315	70	Alta	87.5	137.8	60%	37%	3%	0%	39%	Média	Mix	79	0	Média	Mão se verifica	Média
FRADES	SFRD			TR3	170			TR1	170	170	170	340	155	Baixa	39.5	158.2	100%	0%	0%	0%	45%	Média	Eólica	5	0	Baixa	Mão se verifica	Muito Alta
GUIMARÃES	SGR							TR1	126	126	0	126	75	Nula	99.1	24.4	0%	10%	90%	0%	7%	Baixa	Cogeração	59	0	Baixa	Alta	Muito Alta
LAGOÇA	SLGC									0	0	0	0	#DIV/0!	0.0	0					0%	Nula	N/A	Indefini	Indefini	Alta	#DIV/0!	
LAYOS	SLV	TR2	170	TR3	170					170	170	340	90	Alta	244.8	176.4	4%	0%	96%	0%	50%	Alta	Cogeração	113	18	Alta	Média	Baixa
MACEDO DE CAVALHEIROS	SMC			TR1	126	TR2	126			126	126	252	50	Alta	65.6	95.2	68%	32%	0%	0%	27%	Média	Mix	47	0	Média	Mão se verifica	Média
MOGADOURO	SMG			TR2	63	TR1	63			63	63	126	11	Alta	14.5	4.4	98%	0%	0%	2%	1%	Nula	Eólica	0	14	Baixa	Alta	Baixa
MOURISCA	SMC			TR1	120	TR2	126	TR3	170	170	246	416	165	Médio	232.7	130.8	28%	14%	60%	0%	37%	Média	Mix	131	63	Alta	Alta	Baixa
OLEIROS	SOR	TR2	126	TR3	170			TR1	126	170	252	422	190	Médio	213.4	35.9	0%	30%	70%	0%	10%	Baixa	Mix	143	20	Alta	Alta	Baixa
PALMELA	SPVI									0	0	0	0	#DIV/0!	0.0	0					0%	Nula	N/A	Indefini	Indefini	Alta	#DIV/0!	
PARAMO	SPI	TR4	170	TR6	170					170	170	340	125	Médio	131.0	11.7	73%	0%	27%	0%	3%	Nula	Mix	86	10	Alta	Alta	Baixa
PEDRALVA	SPDV							TR4	140	140	0	140	32	Nula	40.3	29.2	50%	50%	0%	0%	8%	Baixa	Mix	21	0	Baixa	Média	Muito Alta
PENELA	SPPL			TR1	170	TR2	170			170	170	340	160	Baixa	52.2	169.8	100%	0%	0%	0%	48%	Média	Eólica	16	0	Baixa	Mão se verifica	Muito Alta
PEREIROS	SFR			TR1	126	TR2	120	TR3	126	126	246	372	190	Médio	264.6	174.4	64%	21%	16%	0%	50%	Média	Mix	202	46	Alta	Alta	Baixa
POCINHOS	SFN			TR1	90					90	0	90	39	Nula	43.4	18.6	45%	51%	4%	0%	5%	Baixa	Mix	32	0	Baixa	Alta	Muito Alta
POMBAL	SFB			TR1	126					126	0	126	45	Nula	83.6	43.7	49%	0%	51%	0%	12%	Baixa	Mix	60	0	Baixa	Alta	Muito Alta
PORTIMÃO	SPO	TR3	170	TR4	63			TR2	170	170	233	403	105	Alta	120.3	143.2	95%	2%	4%	0%	41%	Média	Eólica	75	0	Média	Mão se verifica	Média
PORTO ALTO	SFA							TR3	63	63	0	63	58	Nula	61.0	2.5	0%	0%	100%	0%	1%	Nula	Cogeração	27	23	Baixa	Alta	Muito Alta

Figura B.8: Exemplo da folha de caracterização das subestações REN

Nome Subestação	Sigla	Transformadores												Consumo		Geração				Transferência Carga			Prevalência do consumo sobre a produção	Necessidade e previsão									
		MVA		MVA		MVA		MVA		MVA		P(MVA) Ligação	Eólica	Hídrica	Tipo Cogeração	Solar	ΣPRE/ Máx PRE	Influência Retórica da PRE	Geração matortitória	Carga Transf	Carga Não Transf	Nível de transf											
		TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10														TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19
PRELADA	SPD	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	0	N/A	Mix	108	0	Alta	Alta	Baixa				
RECAREI	SFR	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	TR22	TR23	6.1	0%	2%	72%	0%	2%	Alta	Alta	Média			
RIBA D'AVE	SRA	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	TR22	268.3	23%	23%	54%	0%	76%	Mix	211	125	Média		
RIO MAIOR	SRI	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	TR22	TR23	174.3	100%	0%	0%	0%	50%	Mix	68	90	Alta		
SACAVÉM	SSV	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	20.5	0%	0%	100%	0%	6%	Baixa	Cogeração	88	120	Média	
SANTARÉM	SSR	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	10.1	0%	0%	100%	0%	3%	Nula	Cogeração	92	0	Alta	
SETE RIOS	SSS	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	1.8	0%	1%	100%	0%	1%	Nula	Cogeração	44	183	Baixa	
SETUBAL	SSB	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	107.3	0%	0%	99%	1%	31%	Média	Cogeração	72	179	Baixa	
SINES	SSN	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	TR22	112.8	64%	0%	36%	0%	8%	Baixa	Mix	21	79	Baixa	
TÁBUA	STBÁ	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	40.7	93%	5%	2%	0%	19%	Baixa	Eólica	28	0	Baixa	
TAVIRA	STVR	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	0.6	100%	0%	0%	0%	14%	Baixa	Eólica	indefinido	indefinido		
TORRÃO	STR	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	99.6	102	99%	0%	1%	29%	Média	Eólica	65	5	Alta	
TRAFARIA	STR	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	126.6	11.3	0%	0%	100%	0%	3%	Nula	Cogeração	80	37	Média
TRAJOUCE	STJ	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	348.2	2.5	0%	0%	100%	0%	1%	Nula	Cogeração	186	74	Alta
TUNES	STN	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	188.7	26.6	23%	2%	0%	75%	8%	Baixa	Mix	139	0	Alta
VALDIGEM	SVG	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	217.9	351.2	86%	14%	0%	0%	100%	Baixa	Mix	110	0	Alta
VALPAÇOS	SVPC	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	71.1	73.3	0%	2%	98%	0%	21%	Baixa	Mix	7	0	Baixa
VERMOIM	SVM	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	TR22	TR23	339.1	66.2	1%	49%	52%	0%	20%	Baixa	Cogeração	180	171	Alta
VILA CHÁ	SVC	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	135.6	1%	75%	24%	0%	39%	Média	Mix	89	0	Média	
VILA FRIA	SVF	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	185.2	185.2	48%	20%	33%	0%	53%	Mix	75	89	Média	
VILA POUCA DE AGUIAR	SVPA	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	0	0	0%	0%	0%	0%	Nula	N/A	18	0	Baixa	
ZAMBUAL	SZBJ	TR1	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	208.6	2.9	0%	0%	100%	1%	Nula	Solar	135	49	Alta	
ZÉZERE	SZR	TR2	TR3	TR4	TR5	TR6	TR7	TR8	TR9	TR10	TR11	TR12	TR13	TR14	TR15	TR16	TR17	TR18	TR19	TR20	TR21	231.8	154.8	21%	45%	34%	0%	44%	Mix	210	12	Alta	

Figura B.9: Exemplo da folha de caracterização das subestações REN

B.2 Mapas

Capacidade geradora por Distritos e Regiões Autónomas

Capacity per district and autonomous region

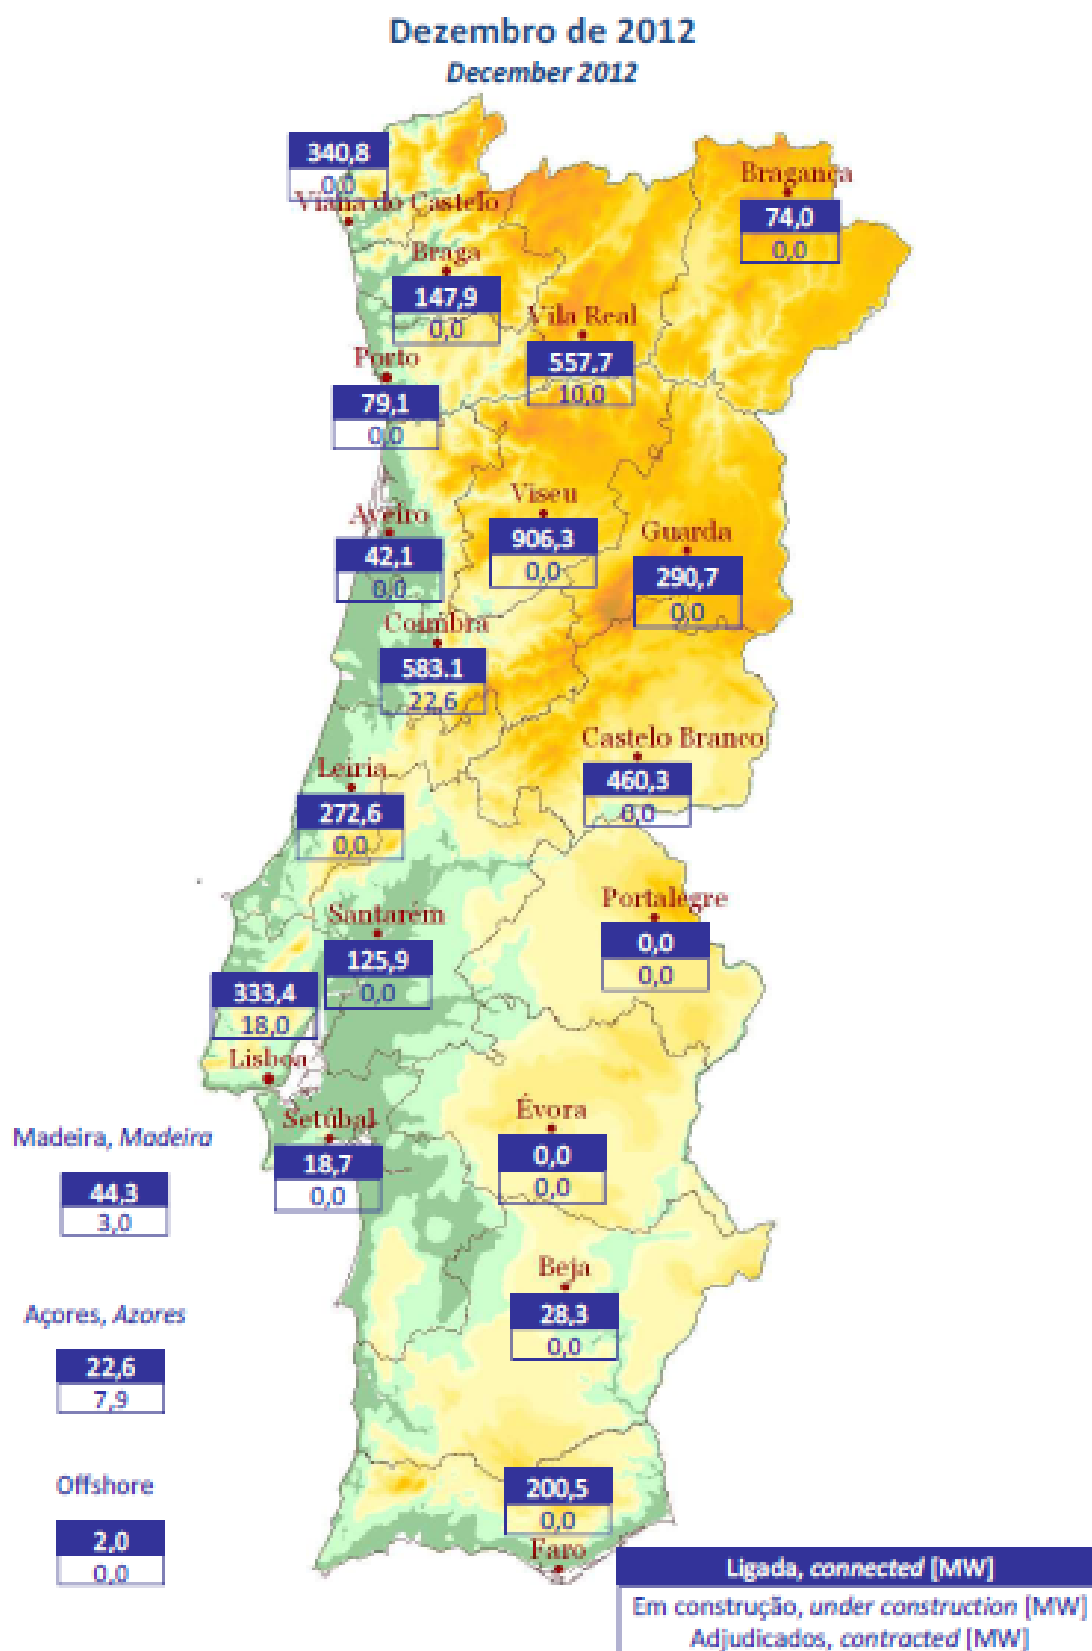


Figura B.10: Mapa com a distribuição da potência eólica gerada por distritos [3].

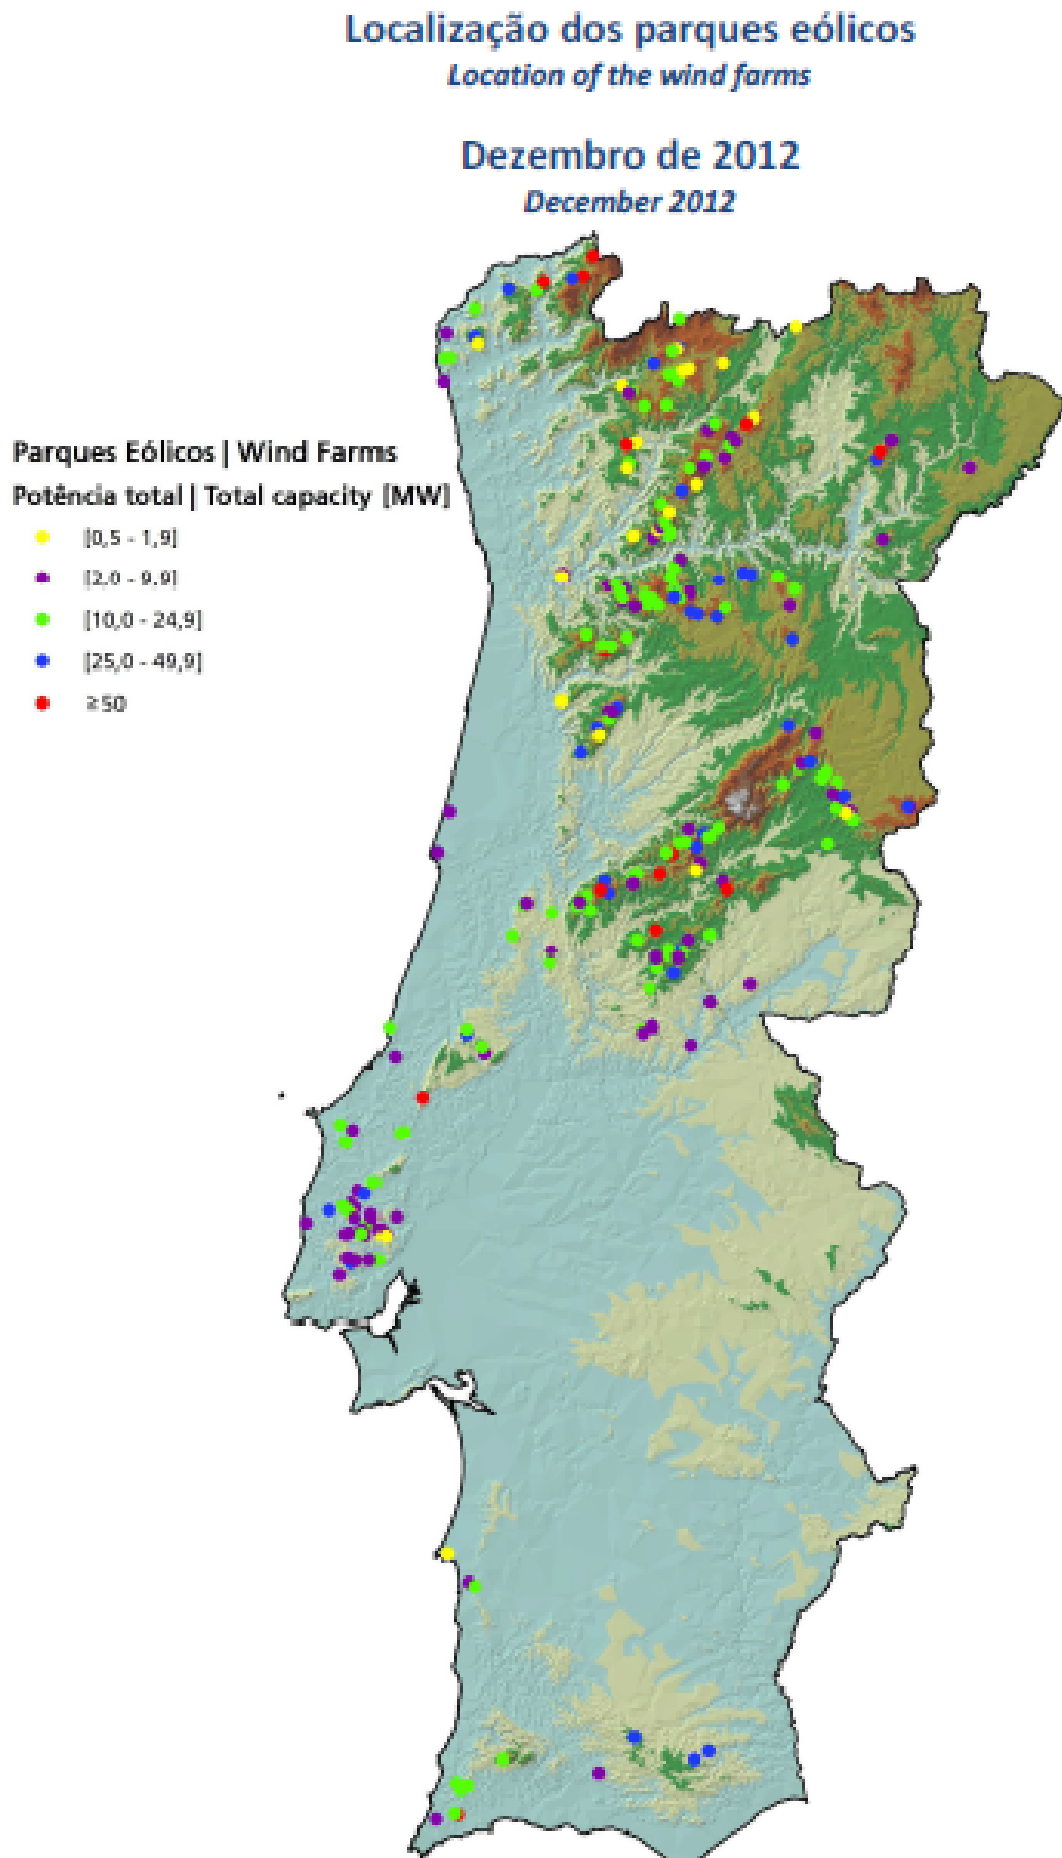


Figura B.11: Mapa da localização dos parques eólicos diferenciados por classes de potência instalada [3].

