



João Pedro Dionísio dos Santos

Licenciado em Ciências da Engenharia Eletrotécnica e de Computadores

Sistema automático de estimação do potencial de produção eólica para Portugal Continental

Dissertação para obtenção do Grau de Mestre em
Engenharia Eletrotécnica e de Computadores

Orientador: Prof. Doutor Paulo Jorge da Costa Santos, Prof. Adjunto, Instituto Politécnico de Setúbal

Co-orientador: Prof. Doutor Mário Ventim Neves, Prof. Auxiliar, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa

Júri:

Presidente: Prof^a Doutora Helena Fino, DEE - FCT/UNL

Arguente: Prof. Doutor Pedro Pereira, DEE - FCT/UNL



FACULDADE DE
CIÊNCIAS E TECNOLOGIA
UNIVERSIDADE NOVA DE LISBOA

Setembro, 2016

Sistema automático de estimação do potencial de produção eólica para Portugal Continental

Copyright © João Pedro Dionísio dos Santos, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa.

A Faculdade de Ciências e Tecnologia e a Universidade Nova de Lisboa têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objetivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

“Trabalha rapaz, trabalha que para ti é”

Agradecimentos

Gostaria de agradecer a todas as pessoas que contribuíram direta ou indiretamente para a realização desta tese de mestrado.

Em primeiro lugar, gostaria de agradecer ao orientador e co-orientador desta dissertação, respetivamente o Professor Doutor Paulo Jorge da Costa Santos, Prof. Auxiliar, Instituto Politécnico de Setúbal e ao Professor Doutor Mário Ventim Neves, Prof. Auxiliar, Faculdade de Ciências e Tecnologia, Universidade Nova de Lisboa. Agradeço a colaboração, os conhecimentos transmitidos, a dedicação e a disponibilidade tanto no acompanhamento desta dissertação, como no meu percurso universitário.

Em segundo lugar, gostaria de mostrar o meu profundo agradecimento ao Eng. Fernando Matos, chefe do ELGS - Sistemas e Desenvolvimento na REN, que me possibilitou realizar esta dissertação em colaboração com aquela empresa. Foi muito importante a abertura, disponibilidade, colaboração e ajuda. Adicionalmente agradeço a todos os membros da REN que sempre se mostraram disponíveis para discutir ideias no âmbito da minha dissertação e assim contribuir para um melhor resultado.

Agradeço o apoio incondicional dos meus pais, irmão e restantes familiares que sempre investiram na minha educação e formação. Sem eles não sou o que seria hoje.

Agradeço à minha namorada e amigos pelo apoio, companheirismo e amizade que mostraram ao longo de todo o curso e essencialmente no período da dissertação. Desejo-vos todo o sucesso pessoal e profissional.

A todos eles, deixo o meu sincero agradecimento.

Resumo

A escassez de recursos não renováveis e a necessidade de manter um ambiente “limpo”, têm contribuído de forma decisiva para o grande crescimento da energia eólica na Europa e no Mundo.

A previsão da produção eólica surge como um auxiliar significativo na gestão da rede elétrica de um país. Em Portugal Continental este tipo de recurso representa cerca de 30% da potência total instalada. Esta contribuição eólica coloca algumas dúvidas nomeadamente para a estabilidade e segurança do sistema, o que não sendo devidamente “controlado” pode acarretar prejuízos significativos, em virtude de se alocarem recursos produtivos não renováveis, não necessários. Por outro lado, a imprevisibilidade do recurso traz consigo insegurança ao sistema, assim a previsão é uma importante “ferramenta” para o operador.

Este tipo de abordagens metodológicas contribui para a sustentabilidade da rede elétrica nacional permitindo gerir da melhor forma o mercado diário e intra diário, gerir a congestão nas linhas de transporte de energia e evitar o esgotamento, comercializar a exportação e importação de energia e conseguir um custo de operação baixo.

O método utilizado nesta dissertação de mestrado consiste em utilizar apenas os dados que a REN tem disponíveis e com base nos mesmos, criar um modelo computacional para conseguir prever tanto a velocidade média do vento que se irá fazer sentir num determinado parque eólico como a potência elétrica que o mesmo irá produzir. Para isso são tidos em conta dados históricos como a velocidade e direção médias do vento, número de aerogeradores ativos em cada momento e potência gerada pelo parque eólico ao longo do tempo.

O trabalho descrito nesta dissertação de mestrado é dividida em três grandes etapas: recolha e tratamento de dados, construção e teste do modelo de previsão da velocidade do vento e construção e teste do modelo de transformação de velocidade do vento em potência elétrica do parque.

Os dados de vento são utilizados como *input* numa rede neuronal que aprende o seu comportamento ao longo do tempo, sendo posteriormente capaz de prever o vento futuro. Com base no vento previsto pela rede neuronal, e através do modelo da turbina eólica característica do parque em análise, é possível fazer uma conversão de vento previsto no parque para potência elétrica prevista no parque. Posto isto, após a conceção do modelo, verifica-se que este pode ser generalizado para outros parques e apresenta-se o desempenho do mesmo. Obtêm-se um modelo capaz de fazer a previsão da potência elétrica de um parque eólico com um erro de 17,83%, com uma janela temporal de 1 hora.

Palavras-chave: previsão do vento, previsão da potência elétrica, rede neuronal feedforward

Abstract

The shortage of non-renewable resources such as oil and coal, and the increasing need to maintain a sustainable environment, have decisively contributed to the growth of wind power in Europe and around the world.

The wind power forecasting for the next hours or, at least, a day have become crucial for the electric power network management in a country. At this moment, in Portugal, the wind power represents 30% of the total installed power. This massive influence has brought new challenges related to the stability and security of the electric system, which can arise some problems if it is not properly controlled. This methodology's approach may be very important to the sustainability of the national power network because it allows: management of the daily market and the intra market, management of the power flow in power transmission lines, management of the export and import energy market and achieve a low operating cost.

In this thesis, a method in which only the REN data were considered was used. Its usage have consisted in creating a computer model for the wind velocity forecast and power forecast in a wind park. In order to do this data such as wind velocity and its direction, the number of active wind turbines on the park and the power generated by the wind farm over time was considered.

The work supporting this dissertation is divided into three main stages: the collection and the data processing, the development and test of the wind velocity forecast model and development and test of the wind velocity transformation model in to electric power.

The wind data was used as an input in a neural network which learn his behaviour over time. Later this model will be able to predict the future wind on site. Based on the wind provided by the neural network, and through the power curve of the wind turbines of the park, it will be possible to make a conversion from the forecasted wind in the park to electric power in the park. Once the model is developed, it is analysed if it can be generalized to other wind parks. From this work, resulted a model capable of predict the future electric power of a wind site with an error of 17,83%, with a time window of 1 hour.

Keywords: Wind forecast, electric power forecast, feedforward neural network

Índice Geral

AGRADECIMENTOS.....	VII
RESUMO.....	IX
ABSTRACT	XI
ÍNDICE GERAL	XIII
ÍNDICE DE TABELAS.....	XV
LISTA DE FIGURAS.....	XVII
LISTA DE ACRÓNIMOS.....	XIX
1 INTRODUÇÃO.....	1
1.1 MOTIVAÇÃO.....	1
1.2 ENQUADRAMENTO E OBJETIVOS	4
1.3 ESTRUTURA DA DISSERTAÇÃO.....	6
2 ESTADO DA ARTE.....	9
2.1 HORIZONTES DE PREVISÃO	9
2.2 METODOLOGIAS DE PREVISÃO.....	10
2.2.1 Métodos “físicos”	11
2.2.2 Métodos estatísticos.....	12
2.2.3 Métodos híbridos.....	15
2.3 COMPARAÇÃO.....	16
3 ESTUDO DE CASO.....	17
3.1 ESCOLHA DOS PARQUES EÓLICOS.....	17
3.2 RECOLHA DE DADOS DO SCADA DA REN.....	19
3.2.1 Análise dos dados	21
3.2.2 Pré tratamento dos dados	27
3.3 METODOLOGIA DA REDE NEURONAL.....	32
3.3.1 Definição de <i>entrada e saída</i>	32
3.3.2 Apresentação das redes neuronais <i>time series</i>	34
3.3.3 Rede neuronal Feedforward.....	40
3.3.4 Comparação das redes	43
3.3.5 Tentativas de diminuição do erro de previsão	45

3.4	MODELO DO PARQUE EÓLICO	51
3.4.1	Modelo com a expressão geral	51
3.4.2	Modelo com a curva característica do aerogerador	54
3.4.3	Modelo com dados SCADA dividido por estações do ano	56
3.4.4	Modelo com dados SCADA divididos por mês e hora	59
3.4.5	Comparação dos vários modelos	60
3.5	MODELO FINAL.....	61
3.6	GENERALIZAÇÃO DO MODELO PARA OUTROS PARQUES.....	63
4	DISCUSSÃO DOS RESULTADOS.....	65
5	CONCLUSÕES	67
5.1	SÍNTESE DO RELATÓRIO	67
5.2	PERSPETIVAS DE TRABALHO FUTURO.....	67
	REFERÊNCIAS	69
	ANEXOS.....	71
	ANEXO A	72
	ANEXO B	73
	ANEXO C	80
	ANEXO D	85

Índice de Tabelas

TABELA 2-1 HORIZONTE DE PREVISÃO PARA A ESTIMAÇÃO DA PRODUÇÃO EÓLICA E AS VANTAGENS DE CADA PERÍODO	9
TABELA 2-2 RESULTADOS DO RMSE APLICADO AO MÉTODO <i>PREDIKTOR</i>	12
TABELA 2-3 REPRESENTAÇÃO DO RMSE PARA PREVISÕES.....	16
TABELA 3-1 LISTA DOS PARQUES SELECIONADOS E RESPECTIVAS CARACTERÍSTICAS.....	19
TABELA 3-2 LEGENDA RELATIVA ÀS ABREVIATURAS USADAS NA COLUNA DOS ‘ELEMENTOS’ DA FIGURA 3-2	20
TABELA 3-3 MÉDIAS DAS VARIÁVEIS CONSOANTE O MÊS	25
TABELA 3-4 CRITÉRIOS PARA ELIMINAÇÃO DE VALORES RETIRADOS DA BASE DE DADOS DA REN	29
TABELA 3-5 ERROS DOS DADOS SEM TRATAMENTO E COM TRATAMENTO EM RELAÇÃO À CURVA CARACTERÍSTICA DA TURBINA ENERCON E-82.....	31
TABELA 3-6 EXEMPLO DE UMA SEQUÊNCIA DE VELOCIDADES DE DADOS HISTÓRICOS DE 2015.....	33
TABELA 3-7 EXEMPLO DA DEFINIÇÃO DOS <i>INPUTS</i> E <i>TARGET</i> PARA UMA REDE QUE USA AS ÚLTIMAS TRÊS VELOCIDADES REGISTRADAS COMO <i>INPUTS</i>	33
TABELA 3-8 COEFICIENTE DE CORRELAÇÃO ENTRE VÁRIOS REGISTOS DE VELOCIDADE DE VENTO E ENTRE A VELOCIDADE E OUTRAS VARIÁVEIS.....	34
TABELA 3-9 CARATERÍSTICAS GERAIS DE TREINO DAS REDES NEURONAIS DO TIPO SÉRIE TEMPORAL.....	36
TABELA 3-10 PERFORMANCE DA REDE NEURONAL NAR	38
TABELA 3-11 PERFORMANCE DA REDE NEURONAL NARX.....	39
TABELA 3-12 PERFORMANCE DA REDE NEURONAL IO	40
TABELA 3-13 CARATERÍSTICAS DE TREINO DE UMA REDE NEURONAL FF	41
TABELA 3-14 PERFORMANCE DA REDE NEURONAL FEEDFORWARD	43
TABELA 3-15 COMPARAÇÃO DOS RMSE DE TESTES DE TODAS AS REDES NEURONAIS PARA INTERVALOS TEMPORAIS DE 15 MINUTOS.....	43
TABELA 3-16 PERFORMANCE DA REDE NEURONAL FEEDFORWARD COM A INCORPORAÇÃO DE UM ATRASO TEMPORAL NA PREVISÃO DO VENTO	44
TABELA 3-17 VALORES BASE DO TESTE DE UMA FF NEURAL NETWORK, COM <i>INPUTS</i> DE VELOCIDADE PARA INTERVALOS TEMPORAIS DE 1 HORA.....	45
TABELA 3-18 PERFORMANCE DO TESTE DE UMA FF NEURAL NETWORK, COM <i>INPUTS</i> DE VELOCIDADE E DIREÇÃO DO VENTO PARA INTERVALOS TEMPORAIS DE 1 HORA	45
TABELA 3-19 PERFORMANCE DO TESTE DE UMA FF NEURAL NETWORK, COM <i>INPUTS</i> DE VELOCIDADE E TENDÊNCIA DO SINAL PARA INTERVALOS TEMPORAIS DE 1 HORA	46
TABELA 3-20 PERFORMANCE DE 3 MOVING AVERAGES DIFERENTES A SUAVIZAR O COMPORTAMENTO DA VELOCIDADE DO VENTO	47
TABELA 3-21 PERFORMANCE DO TESTE DE UMA FF NEURAL NETWORK, COM <i>INPUTS</i> DE VELOCIDADE E EMA DO SINAL PARA INTERVALOS TEMPORAIS DE 1 HORA	47
TABELA 3-22 TABELA COM CONSIDERAÇÕES INICIAS PARA O MODELO COM A EXPRESSÃO GERAL	51
TABELA 3-23 AVALIAÇÃO DO ERRO DO MODELO COM BASE NA EXPRESSÃO GERAL.....	53
TABELA 3-24 AVALIAÇÃO DO ERRO DO MODELO COM BASE NA CURVA CARACTERÍSTICA DO AEROGERADOR.....	55
TABELA 3-25 AVALIAÇÃO DO ERRO DO MODELO COM BASE NOS DADOS SCADA DIVIDIDOS POR ESTAÇÃO DO ANO ..	58
TABELA 3-26 AVALIAÇÃO DO ERRO DO MODELO COM BASE NOS DADOS SCADA DIVIDIDOS POR ESTAÇÃO DO ANO ..	60

TABELA 3-27 COMPARAÇÃO DOS MODELOS CRIADOS PARA TRANSFORMAR VELOCIDADE EM POTÊNCIA	61
TABELA 3-28 PERFORMANCE DO MODELO FF COM A TRANSFORMAÇÃO DO MODELO COM DADOS SCADA DIVIDIDOS POR MÊS E HORA NA PREVISÃO DA POTÊNCIA ELÉTRICA DO PARQUE EÓLICO DE ARGANIL	63
TABELA 3-29 GENERALIZAÇÃO DO MODELO FF COM A TRANSFORMAÇÃO DO MODELO COM DADOS SCADA DIVIDIDOS POR MÊS E HORA NA PREVISÃO DA VELOCIDADE DO VENTO E POTÊNCIA ELÉTRICA DE VÁRIOS PARQUES EÓLICOS COM INTERVALOS TEMPORAIS DE 1 HORA	63
TABELA 5-1 LISTA DOS LOCAIS DE VENTO A PREVER.....	73
TABELA 5-2 LISTA DOS PARQUES EÓLICOS LIGADOS À REN PARA PREVER POTÊNCIA	80

Lista de Figuras

FIGURA 1-1 DISTRIBUIÇÃO MUNDIAL DOS DEZ PAÍSES COM MAIS RECURSOS EÓLICOS, CAPACIDADE INSTALADA E PRODUÇÃO EM 2008.....	2
FIGURA 1-2 EVOLUÇÃO DA SATISFAÇÃO DO CONSUMO PELAS VÁRIAS FONTES DE ENERGIA EM PORTUGAL	3
FIGURA 1-3 GRÁFICO DE IMPORTAÇÃO/EXPORTAÇÃO FOTOGRAFADO DIRETAMENTE DO DESPACHO DA REN NUM DIA FORTEMENTE EXPORTADOR.....	4
FIGURA 1-4 ESPETRO DE VENTO PARA O PARQUE EÓLICO DE BROOKHAVEN (NOVA IORQUE) A 100 METROS DE ALTURA.....	5
FIGURA 2-1 EXEMPLO COM UMA POTÊNCIA PREVISTA (VERMELHO) E COM POTÊNCIA MEDIDA (PRETO)	16
FIGURA 3-1 CURVA CARACTERÍSTICA DA POTÊNCIA E DO CP PARA O AEROGERADOR ENERCON E-82.....	18
FIGURA 3-2 QUERY PARA ACEDER A TODA INFORMAÇÃO RELATIVA AO PARQUE EÓLICO DO POUICINHO 2	20
FIGURA 3-3 QUERY PARA ACEDER À POTÊNCIA ATIVA RELATIVA AO PARQUE EÓLICO DO POUICINHO 2	21
FIGURA 3-4 RESTITUIÇÃO DOS VALORES DE MINUTO A MINUTO E MÉDIAS DE 15 MINUTOS PARA A DIREÇÃO DO VENTO	22
FIGURA 3-5 EVOLUÇÃO TEMPORAL DA VELOCIDADE DO VENTO COM VALORES DE HORA EM HORA	23
FIGURA 3-6 EVOLUÇÃO TEMPORAL DA DIREÇÃO DO VENTO COM VALORES DE HORA EM HORA.....	23
FIGURA 3-7 EVOLUÇÃO TEMPORAL NÚMERO DE AEROGERADORES COM VALORES DE HORA EM HORA	24
FIGURA 3-8 EVOLUÇÃO POTÊNCIA AO LONGO DO TEMPO COM VALORES DE HORA EM HORA.....	24
FIGURA 3-9 EVOLUÇÃO DA VELOCIDADE MÉDIA DO VENTO CONSOANTE O MÊS DO ANO.....	25
FIGURA 3-10 EVOLUÇÃO DA DIREÇÃO MÉDIA DO VENTO CONSOANTE O MÊS DO ANO	26
FIGURA 3-11 EVOLUÇÃO DO NÚMERO DE GERADORES CONSOANTE O MÊS DO ANO.....	26
FIGURA 3-12 EVOLUÇÃO DA POTÊNCIA GERADA CONSOANTE O MÊS DO ANO	27
FIGURA 3-13 DADOS DO SCADA SEM TRATAMENTO	28
FIGURA 3-14 DADOS DO SCADA COM TRATAMENTO.....	30
FIGURA 3-15 COMPARAÇÃO DA CURVA CARACTERÍSTICA DO FABRICANTE COM OS DADOS DO SCADA SEM E COM TRATAMENTO	30
FIGURA 3-16 ERRO ENTRE OS DADOS SEM E COM TRATAMENTO COM A CURVA CARACTERÍSTICA DO FABRICANTE....	31
FIGURA 3-17 NEURAL NETWORK START.....	35
FIGURA 3-18 DINÂMICA DE UMA REDE NEURONAL NAR.....	36
FIGURA 3-19 TREINO DA REDE NEURONAL.....	37
FIGURA 3-20 ESQUEMA REDE NEURONAL NAR.....	37
FIGURA 3-21 DINÂMICA DE UMA REDE NEURONAL NARX	38
FIGURA 3-22 ESQUEMA REDE NEURONAL NARX.....	38
FIGURA 3-23 COMPARAÇÃO DA VELOCIDADE PREVISTA PELO MODELO NARX COM A VELOCIDADE REAL.....	39
FIGURA 3-24 DINÂMICA DE UMA REDE NEURONAL IO.....	40
FIGURA 3-25 ESQUEMA REDE NEURONAL IO	40
FIGURA 3-26 ESQUEMA REDE NEURONAL FEEDFORWARD	41
FIGURA 3-27 RMSE DE CADA REDE, VARIANDO O NÚMERO DE NEURÓNIOS NA CAMADA INTERNA	42
FIGURA 3-28 COMPARAÇÃO DA VELOCIDADE PREVISTA PELO MODELO FF COM A VELOCIDADE REAL.EPS	42
FIGURA 3-29 COMPARAÇÃO DA VELOCIDADE PREVISTA PELO MODELO FEEDFORWARD COM A VELOCIDADE REAL COM A INCORPORAÇÃO UM ATRASO TEMPORAL NA PREVISÃO DO VENTO	44

FIGURA 3-30 DESEMPENHO DE TRÊS DIFERENTES <i>MOVING AVERAGES</i> A SUAVIZAR O COMPORTAMENTO DA SÉRIE TEMPORAL DA VELOCIDADE DO VENTO.....	47
FIGURA 3-31 VELOCIDADES DO VENTO EM ABRIL DE 2015 E 2016 E DEZEMBRO DE 2016.....	48
FIGURA 3-32 COMPONENTES C1-C5 DA VELOCIDADE DO VENTO DE ABRIL DE 2015 E 2016.....	49
FIGURA 3-33 COMPONENTES C6-C8 COM R DA VELOCIDADE DO VENTO DE ABRIL DE 2015 E 2016.....	49
FIGURA 3-34 COMPONENTES C1-C5 DA VELOCIDADE DO VENTO DE ABRIL E DEZEMBRO DE 2015.....	50
FIGURA 3-35 COMPONENTES C6-C8 COM R DA VELOCIDADE DO VENTO DE ABRIL E DEZEMBRO DE 2015.....	50
FIGURA 3-36 COMPARAÇÃO DO MODELO COM BASE NA EXPRESSÃO GERAL DA POTÊNCIA COM O VALOR REAL.....	52
FIGURA 3-37 ERRO DO MODELO COM BASE NA EXPRESSÃO GERAL DA POTÊNCIA EM RELAÇÃO AO VALOR REAL.....	53
FIGURA 3-38 COMPARAÇÃO DO MODELO COM BASE NA CURVA CARACTERÍSTICA DO AEROGERADOR COM O VALOR REAL.....	54
FIGURA 3-39 ERRO DO MODELO COM BASE NA CURVA CARACTERÍSTICA DO AEROGERADOR EM RELAÇÃO AO VALOR REAL.....	55
FIGURA 3-40 MODELO DO AEROGERADOR DE INVERNO E VERÃO.....	57
FIGURA 3-41 COMPARAÇÃO DO MODELO COM BASE NOS DADOS SCADA DIVIDIDOS POR ESTAÇÃO DO ANO.....	57
FIGURA 3-42 ERRO DO MODELO COM BASE NOS DADOS SCADA DIVIDIDOS POR ESTAÇÃO DO ANO.....	58
FIGURA 3-43 COMPARAÇÃO DO MODELO COM BASE NOS DADOS SCADA DIVIDIDOS POR MÊS E HORA.....	59
FIGURA 3-44 ERRO DO MODELO COM BASE NOS DADOS SCADA DIVIDIDOS POR MÊS.....	60
FIGURA 3-45 COMPARAÇÃO DO MODELO FINAL DE PREVISÃO DE POTÊNCIA COM A POTÊNCIA MEDIDA.....	62
FIGURA 3-46 ERRO ENTRE A POTÊNCIA MEDIDA E A PREVISTA.....	62
FIGURA 5-1 GRÁFICO DA POTÊNCIA EÓLICA TELEMEDIA (VERDE), DA POTÊNCIA EÓLICA PREVISTA (AMARELO) E DA POTÊNCIA TOTAL ESTIMADA (AZUL) FOTOGRAFADO DIRETAMENTE DO DESPACHO DA REN NUM DIA FORTEMENTE EXPORTADOR.....	72
FIGURA 5-2 GRÁFICOS DIÁRIO DO CONSUMO TOTAL (VERDE CLARO) E DA PRODUÇÃO RENOVÁVEL (VERDE ESCURO) FOTOGRAFADO DIRETAMENTE DO DESPACHO DA REN NUM DIA FORTEMENTE EXPORTADOR.....	72
FIGURA 5-3 CÓDIGO DE TREINO DA REDE NEURONAL.....	85
FIGURA 5-4 CÓDIGO DA CONSTRUÇÃO DO MODELO DO PARQUE EÓLICO.....	85
FIGURA 5-5 CÓDIGO DA CONSTRUÇÃO DO HHT.....	86

Lista de Acrónimos

REN Redes Energéticas Nacionais

EDP Energias de Portugal

MAPE *Mean Absolute Percent Error*

MAE *Mean Absolute Error*

MSE *Mean Square Error*

RMSE *Root Mean Square Error*

MOS *Model Output Statistics*

NWP *Numerical Weather Prediction*

WasP *Wind Atlas Analysis and Application Program*

ARMA *Auto-Regressive Moving Average*

ARIMA *Auto Regressive Integrated Moving Average*

ARMAX *ARMA com Exogenous Input*

FL *Fuzzy logic*

WTM *Wind Turbine Model*

BP *Back-Propagation*

RMSE *Root Mean Square Error*

SCADA *Supervisory Control and Data Acquisition*

ANN *Artificial Neural Network*

HHT *Hilbert-Huang Transformation*

IMF *Intrinsic Mode Functions*

1 Introdução

Neste capítulo introdutório contextualiza-se o tema da dissertação na atualidade, referindo a sua evolução, relevância, evolução e os problemas adjacentes para este tipo de abordagem metodológica.

No presente capítulo, é apresentado um breve resumo da situação atual da energia eólica em Portugal e no Mundo, referindo-se a grande evolução que esta teve ao longo dos anos.

A previsão da produção eólica para a hora ou dia seguinte revela-se crucial na gestão da rede elétrica de um país, dado que atualmente, o operador do sistema é de certa forma “pressionado” a despachar em termos económicos a produção, dando preferência ao recurso eólico. Uma vez que a energia produzida por fontes eólicas é responsável por cerca de 30% da energia consumida em Portugal continental, colocam-se algumas dúvidas nomeadamente para a estabilidade e segurança do sistema, o que não sendo devidamente controlado pode trazer malefícios, como descrito mais à frente. Como se verificará de seguida, este tipo de abordagens metodológicas contribui para a sustentabilidade da rede elétrica nacional.

É descrita a estrutura da tese.

1.1 Motivação

Em meados da década de 70, a Europa e a América, viram-se envolvidos numa profunda crise petrolífera. No entanto, as suas necessidades energéticas tinham de ser asseguradas, e para tal era necessário obter energia a partir de uma outra fonte. Este fato aliado à grande degradação ambiental produzida pelas fontes não renováveis e ao movimento crescente para reduzir os gases de efeito de estufa, fizeram despoletar interesse pelas energias renováveis e nomeadamente pela energia eólica (Castro, 2005). Atualmente, a crise económica que se vive na Europa contribui para uma maior aceitação deste recurso.

Esta energia consiste no aproveitamento e extração da energia cinética contida no vento em energia mecânica, provocando a rotação das pás de uma turbina eólica. Este movimento é consequentemente transformado em energia elétrica através de um gerador elétrico, como descreve, por exemplo, (ENEOP, 2009).

A escassez de recursos não renováveis como o petróleo ou carvão, e a crescente necessidade de manter um ambiente limpo, reduzindo as emissões de CO₂ para a atmosfera, agregados aos vários tratados ambientais e protocolos elaborados, têm contribuído de forma decisiva para o grande crescimento desta energia na Europa e no Mundo. Hoje em dia, verifica-se que a energia eólica está espalhada por todo o Mundo, maioritariamente nos países desenvolvidos ou em desenvolvimento, como Brasil ou Índia.

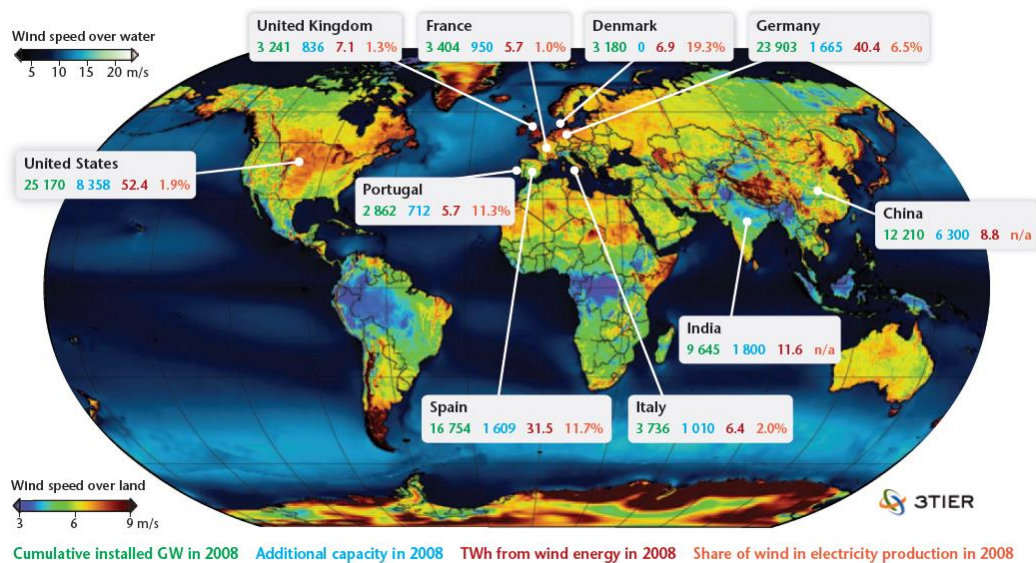


Figura 1-1 Distribuição mundial dos dez países com mais recursos eólicos, capacidade instalada e produção em 2008 (International Energy Agency, 2009)

Na Europa, países como Alemanha, Espanha, Dinamarca e Portugal têm-se destacado na potência instalada, no potencial eólico e na percentagem que a energia eólica representa em relação à totalidade de potência consumida (Monteiro et al., 2009). Descreve-se potencial eólico de uma região como a capacidade de conversão do recurso eólico disponível nessa região em produção de energia através de geradores eólicos. Com base na Figura 1-1, com dados referentes a 2008, observa-se a potência instalada em cada país, a capacidade adicional de potência instalada nesse ano (parques eólicos em construção ou expansão), a quantidade de energia gerada pelas turbinas eólicas (medida em TWh) e a percentagem da energia eólica na totalidade da produção de eletricidade em cada país. Destaca-se o papel da Europa e a grande contribuição dada para o ambiente e para a evolução desta tecnologia (International Energy Agency, 2009).

A Dinamarca é um dos países líder nesta tecnologia. Em 2015 conseguiram estabelecer um novo recorde mundial, em que 42% de toda a eletricidade gerada naquele país foi de origem eólica. Esta marca ultrapassa o antigo recorde, também por eles alcançado no ano anterior, em cerca de 3%. Esta notícia torna cada vez mais real o compromisso feito por este país na conferência do clima em Paris, em que se comprometeu que no ano de 2020, 50% da energia produzida seria de origem eólica. Esta marca torna-se ainda mais impressionante sabendo que duas das maiores turbinas eólicas daquele país estavam desligadas nesse ano (Nørskov & Vittrup, 2016).

Analisando o caso de Portugal, segundo o relatório de dados técnicos da REN, no final do ano de 2014 a produção de energia através de fontes renováveis abasteceu 62% do consumo em Portugal, sendo a percentagem mais elevada desde 1979. A energia eólica produziu 24% da potência consumida no país, superada apenas pela energia hidráulica (31%), sendo a segunda fonte renovável mais importante em Portugal. Esta percentagem é exatamente a mesma do que em 2013, e também nesse ano, a energia eólica conseguiu superar a percentagem de produção de energia produzida através do carvão, principal fonte não renovável de energia (REN (Redes Energéticas Nacionais), 2014).




Figura 1-2 Evolução da satisfação do consumo pelas várias fontes de energia em Portugal (REN (Redes Energéticas Nacionais), 2014)

Em 2013, Portugal possuía 4364 MW de potência instalada. Com a construção de novos parques eólicos, verificou-se um aumento de 176 MW, pelo que no final do ano de 2014, a potência instalada tinha atingido os 4541 MW. Este crescimento foi o mais acentuado em comparação com todas as fontes renováveis e não renováveis de energia (REN (Redes Energéticas Nacionais), 2014).

A título excepcional, e apenas como uma situação pontual, salienta-se ainda a notícia de um registo inédito em que a produção eólica ultrapassou o consumo nacional de eletricidade em Portugal. Durante a madrugada do dia 29 de Dezembro de 2015, o vento forte fez registar uma produção eólica de ponta de 4210 MW, um novo máximo em Portugal, melhorando o registo mais elevado de Janeiro do mesmo ano. Desta forma, e aliado a um consumo baixo, a produção eólica ultrapassou pela primeira vez o consumo nacional. Durante um breve período, as necessidades energéticas do país foram suportadas apenas por energia eólica, como reportado em (Rtp, 2015). Salienta-se também a notícia de um novo recorde estabelecido em Portugal a nível de exportação de eletricidade. No dia 19 de outubro de 2015, a ponta da potência exportada pelo país situou-se nos 3044 MW. A energia total diária exportada atingiu o valor mais elevado de sempre com 47,8 GWh, ou seja, 41% do consumo português (Rocha, 2015).

Tendo em conta que esta dissertação é feita em colaboração com a REN, foi possível recolher imagens diretamente do despacho da empresa num dia fortemente exportador como ilustrado na Figura 1-3, bastante similar ao descrito em cima.

Como se pode observar, neste dia 10 de Janeiro de 2016, o pico de exportação foi 3300 MW, maior do que em (Rocha, 2015), pelo que estamos perante um novo recorde de exportação captado em direto do despacho da REN. No Anexo A, observam-se mais imagens do despacho fotografadas nesse dia.



Figura 1-3 Gráfico de importação/exportação fotografado diretamente do despacho da REN num dia fortemente exportador

Destaca-se o grande crescimento desta fonte de energia renovável e os recordes alcançados, inclusive no ano de 2016. Assim em face do exposto, a energia eólica assume um papel determinante em Portugal e no Mundo.

1.2 Enquadramento e objetivos

O vento é o recurso primário deste tipo de produção. De uma forma muito genérica, os ventos são causados por diferenças de pressão ao longo da superfície terrestre, causadas pela diferença de receção de radiação solar entre as zonas equatoriais e as zonas polares. Os ventos mais fortes e constantes ocorrem a alturas aproximadamente de 10 km de altura. Naturalmente, não é economicamente viável colocar geradores eólicos a esta altura, pelo que a faixa de aproveitamento na atmosfera é de poucas centenas de metros a partir da superfície. No entanto, a esta altura o vento sofre o efeito de atrito e diminuição de velocidade devido à rugosidade do terreno.

A velocidade e direção do vento estão constantemente a variar ao longo do tempo. Para averiguar a sua evolução, é possível analisar na Figura 1-4 o domínio da frequência do vento, ou seja, ter uma medida da energia cinética associada à componente horizontal da velocidade do vento, designando-se densidade espectral de energia. Esta medição é específica para cada sítio medido, mas a forma da sua curva é aproximada para a maioria dos locais.




Figura 1-4 Espectro de vento para o parque eólico de Brookhaven (Nova Iorque) a 100 metros de altura, adaptado de (Van der Hoven, 1957)

Conclui-se que para períodos de alguns dias (100h) existe uma grande quantidade de energia, relacionada com o movimento de grandes massas de ar. Para períodos muito pequenos, na ordem de segundos, a grande variação de energia relaciona-se com as perturbações atmosféricas. As duas variantes podem ser observadas respetivamente nos dois maiores picos da Figura 1-4. No meio destes dois picos existe um vazio espectral, associado a períodos compreendidos entre 10 minutos e 2 horas. Quer isto dizer que o valor médio da velocidade do vento varia pouco neste intervalo. Embora esta variação seja pequena, tem uma influência direta na potência elétrica gerada por uma determinada turbina, pois como se observa na equação (1.1), a potência é influenciada ao cubo pela velocidade do vento (Castro, 2005).

$$P(v) = \frac{1}{2} \cdot C_p \cdot \eta \cdot \rho \cdot A \cdot v^3 \quad (1.1)$$

Constata-se que o valor da potência da turbina em função da velocidade média do vento depende de vários fatores, com uma grande influência da velocidade e direção do vento. Destaca-se que $P(v)$ é a potência elétrica gerada a uma determinada velocidade de vento, C_p é a eficiência do rotor, η é o rendimento da caixa de velocidades e do gerador elétrico, ρ (kg/m³) é a densidade do ar em função da temperatura e pressão atmosférica do ar e que v é a velocidade média do vento (m/s) (Olaofe & Folly, 2012).

Atualmente, toda esta potência das turbinas eólicas é diretamente injetada no Sistema Elétrico Nacional (SEN). No entanto, esta injeção total coloca questões nomeadamente na estabilidade e segurança do sistema, o que constitui um grande desafio. Tendo em conta a imprevisibilidade do vento, a quantidade de potência injetada pelos parques eólicos na rede altera-se em cada segundo. Sabendo que a produção de potência elétrica tem que ser igual ao consumo, de forma a manter a frequência da rede em aproximadamente 50 Hz, esta variação e imprevisibilidade do vento constitui um desafio para o mercado da energia e nomeadamente para os despachantes das Redes Elétricas Nacionais (REN) e Energias de Portugal (EDP). Uma das funções destes trabalhadores é conciliar a produção das várias centrais elétricas com a produção espetável de energia renováveis, salientando-se o grande peso da energia eólica. Assim sendo, é fundamental ter uma ferramenta que consiga prever a potência que será gerada pelos parques

eólicos num período próximo no futuro (horas, dias, semanas). Este horizonte de previsão será discutido no capítulo 2. A previsão do potencial de produção eólica tem impactos positivos nas seguintes áreas:

- O mercado de energia, nomeadamente a compra de energia pelos agentes de mercado (EDP, Endesa, Iberdrola) e venda pelos produtores, funciona pela lei da oferta e da procura. Quanto maior a oferta de energia, menor o preço à qual esta é vendida. A previsão de produção eólica, juntamente com outras previsões, ajuda a calcular a energia disponível nesse dia, e como tal, o preço de cada unidade de energia para os mercados diários e intradiários. Permite também calcular o preço das compensações de energia.

- Melhora a segurança na rede transporte, evitando a potência de esgotamento das linhas. Esta previsão ajuda a planear a quantidade de energia que virá a ser transportada nas várias linhas, de acordo com a localização e produção dos vários parques eólicos. Desta forma, melhora a segurança do SEN, evitando sobrecargas e consequentemente o corte da linha.

- Permite planear a melhor altura para a manutenção das torres e linhas de transporte, uma vez que para este efeito estas têm que ser interrompidas.

- Permite aos despachantes encontrar ao menor custo possível, a energia necessária de entre a geração oferecida naquele momento (nuclear, renováveis ou fósseis), para fazer face ao consumo elétrico necessário.

- Permite determinar e gerir as reservas de operação, para precaver um grande consumo de energia, por exemplo através da bombagem da água nas barragens de jusante para montante. A energia elétrica não é armazenada, devido aos altos preços das baterias, pelo que durante os períodos de baixo consumo (noturno), essa energia pode ser utilizada para complementar a energia hídrica, ou seja, para voltar a colocar a água a montante da barragem para que esta esteja novamente disponível para produzir energia. A quantidade de energia produzida nas turbinas das barragens na segunda passagem da água pode ser inferior aquela que é utilizada para a bombear para montante, mas uma vez armazenada esta água pode ser utilizada para produzir energia que será vendida a um preço bastante superior em relação ao preço da energia utilizada para a elevar (energia de período noturno ou vazio).

- Permite gerir a comercialização de energia, ao nível da exportação e importação com Espanha, analisando a melhor altura para comprar e vender energia.

Tendo em conta todos estes motivos enunciados por (Monteiro et al., 2009) e (Pinson, 2006), uma ferramenta de previsão do potencial de produção eólica tem um papel decisivo, na medida que permite poupar e gerir de forma inteligente e informada os recursos energéticos disponíveis.

1.3 Estrutura da dissertação

Nesta seção é descrita a estrutura básica da tese. Esta divide-se em 5 capítulos, com vários sub capítulos.

No primeiro capítulo contextualiza-se o tema da dissertação na atualidade, apresenta-se um breve resumo da situação atual da energia eólica em Portugal e no Mundo. Salienta-se a grande

importância que a estimação do potencial de produção eólica para a hora/dia seguinte, pode ter na gestão da rede elétrica de um país.

No segundo capítulo é feito um breve resumo de alguns métodos existentes para prever a produção eólica. São analisadas técnicas para avaliar a capacidade de previsão de um determinado método. Os horizontes de previsão são classificados e avaliados consoante a sua utilização. Descrevem-se as técnicas e os resultados obtidos em cada método.

No terceiro capítulo apresenta-se o caso de estudo. Explica-se a razão da escolha do parque eólico alvo nesta dissertação, descreve-se o processo de recolha dos dados provenientes do SCADA da REN e analisa-se o tratamento desses mesmos dados recolhidos. Apresentam-se, de seguida, as diversas tentativas de construção da rede neuronal, capaz de prever a velocidade do vento num período futuro de uma hora. Explicam-se as razões das várias escolhas realizadas ao longo de cada etapa, os objetivos e as limitações. Mostra-se, detalhadamente, as tentativas de melhoria dos resultados inicialmente apresentados. Apresentam-se também todas as etapas para a construção de um modelo capaz de transformar a velocidade do vento presente num parque, na potência que esse parque gera. Por fim, generaliza-se o modelo construído para outros parques eólicos.

No quarto capítulo apresentam-se as diversas conclusões e discutem-se os resultados obtidos no capítulo anterior. Analisa-se o desempenho de cada um dos modelos desenvolvidos para cada uma das fases desta dissertação de mestrado.

No quinto capítulo apresenta-se uma síntese do relatório e as perspetivas de trabalho futuro, nomeadamente de continuação desta dissertação. Apresenta-se uma conclusão sobre o trabalho e os próximos passos para melhorar o modelo desenvolvido.

2 Estado da arte

Neste capítulo apresenta-se um breve resumo das abordagens metodológicas mais utilizadas, que envolvem diversos horizontes de previsão e em particular para o horizonte de curto prazo.

Os métodos apresentados são descritos em função das diferentes abordagens metodológicas. De uma forma geral, os diferentes desempenhos são avaliados através de diferentes parâmetros de medição dos erros.

2.1 Horizontes de previsão

Define-se horizonte de previsão como o período de tempo do futuro até ao qual se pretende obter uma determinada previsão. Entre os autores desta área, não existe um consenso absoluto quanto à definição deste horizonte de previsão, pelo que se considera nesta dissertação os apresentados na Tabela 2-1.

Tabela 2-1 Horizonte de previsão para a estimação da produção eólica e as vantagens de cada período, adaptado de (Monteiro et al., 2009) e (Soman, Zareipour, Malik, & Mandal, 2010).

Horizonte de previsão	Período	Aplicação
Muito Curto	Poucos segundos a 30 minutos	Regulação do sistema elétrico Decisões no despacho da REN e EDP
Curto	30 minutos a 72 horas	Mercado diário e intra diário Gerir a congestão nas linhas e evitar o esgotamento Exportação e importação Conseguir um custo de operação baixo
Médio	72 horas a semanas	Planear a congestão nas linhas Planear as reservas de energia Planeamento da geração de energia convencional
Longo	1 mês	Operações de manutenção e interrupção das linhas elétricas

As metodologias de previsão eólica enunciadas no capítulo 1.2, distribuem-se tendo em conta os quatro horizontes de previsão considerados.

2.2 Metodologias de previsão

Existem diversas abordagens para prever a produção eólica. O método mais simples é o persistente. Este tipo de algoritmo assume que a velocidade do vento para um determinado período (horas) é constante, deste modo, a potência elétrica prevista produzida pelos geradores tem por base o vento médio e a potência nominal dos aerogeradores, através da sua curva característica. Este método pode ser considerado um estimador elementar, e pode ser uma base de comparação para os restantes. Deste modo, qualquer método proposto terá que superar a previsão deste estimador.

Na literatura consultada, os métodos mais utilizados para prever a produção eólica de um parque classificam-se em três tipos: os físicos, os estatísticos e os híbridos. Estas metodologias serão analisadas nos próximos sub capítulos. Usualmente este tipo de abordagens utilizam duas aproximações. A primeira prevê os dados da velocidade média do vento e converte-os para potência elétrica através da curva de potência teórica do gerador. A segunda não efetua um tratamento prévio aos dados das características do vento e prevê diretamente a potência elétrica, convertendo diretamente vento em potência. Esta potência é posteriormente ajustada.

Para avaliar a performance de um método de previsão, existem diversos parâmetros estatísticos. A “qualidade” da metodologia de previsão varia de acordo com o horizonte temporal. Consequentemente, para que um método seja bem avaliado deve ser testado com um horizonte de previsão curto, médio e longo. Segundo (Lydia & Kumar, 2010), os indicadores mais utilizados na literatura para avaliar os métodos de previsão de vento e potência são o *Mean Absolute Percent Error* (MAPE), o *Mean Absolute Error* (MAE), o *Mean Square Error* (MSE) e o *Root Mean Square Error* (RMSE).

O MAPE é uma medida da qualidade do método de previsão, representado pelo tamanho do erro em termos de percentagem. Como mostrado na equação (1.2), calcula-se através da média do valor absoluto do quociente entre a diferença entre o valor medido com a previsão, e o próprio valor medido. Multiplicando este valor por 100, obtêm-se a percentagem do erro esperada.

$$MAPE = \left(\frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \right) * 100 \quad (1.2)$$

Na equação relativa ao MAPE, a variável n representa o número total de amostras do conjunto analisado, A_t representa o valor medido do parâmetro que se está a analisar e F_t representa a previsão desse parâmetro.

O MAPE é regularmente utilizado para avaliar a precisão da previsão, uma vez que a apresentação do erro em termos de percentagens facilita a interpretação do desvio da previsão. No entanto, este apresenta a desvantagem de ser sensível relativamente ao valor em análise. A

título de exemplo, se A_t for nulo, o MAPE será indefinido, uma vez que não se pode dividir por 0.

O MAE é uma quantidade usada para representar a proximidade entre uma previsão e o valor real que se quer medir. Representada na equação (2.2), f_i representa o parâmetro estimado, y_i representa o valor real (medido) desse parâmetro e n representa o número total de dados analisados.

$$MAE = \frac{1}{n} \sum_{i=1}^n |f_i - y_i| \quad (2.2)$$

O MSE do preditor, expresso na equação (2.3), é outra das formas de avaliar a diferença entre um preditor e o verdadeiro valor da quantidade estimada, calculando a média do quadrado do erro.

$$MSE(\theta') = \frac{\sum_{i=1}^n (\theta'_i - \theta_i)^2}{n} \quad (2.3)$$

O RMSE representa-se pela raiz quadrada do MSE. Segundo (Khatib, 2011), calcula-se pela equação (2.4). Representa o desvio de um valor estimado para um medido. A soma dos vários desvios ao longo de um tempo é útil na medida em que classifica a qualidade e validade do modelo para prever determinado parâmetro. Neste caso, o θ' representa o parâmetro estimado, θ representa o valor real desse parâmetro e n representa o número total de dados medidos.

$$RMSE = \sqrt{MSE(\theta')} = \sqrt{\frac{\sum_{i=1}^n (\theta'_i - \theta_i)^2}{n}} \quad (2.4)$$

2.2.1 Métodos “físicos”

Os métodos “físicos” têm em consideração modelos matemáticos capazes de prever as condições meteorológicas de uma região, designados na literatura como *Numerical Weather Prediction* (NWP). Estes métodos são capazes de converter o vento previsto de uma região para um determinado local, tendo em conta as características físicas do terreno como a rugosidade, a orografia e os obstáculos, tentando assim prever a sua influência no vento que se sentirá no local. Sabendo uma aproximação das características do vento para um determinado local, e extrapolando esse valor para as alturas dos rotores das turbinas, estes são capazes de calcular a potência elétrica gerada pelo parque. Este método é suportado por vários sub modelos, uma vez que em parques eólicos de grandes dimensões, as características do terreno podem ser diferentes e assim ter diferentes influências (Monteiro et al., 2009) e (Giebel, Brownsword, Kariniotakis, Denhard, & Draxl, 2011).

Prediktor

Dos vários métodos “físicos”, destaca-se o *Prediktor*. Este é um método de previsão de vento e foi desenvolvido no laboratório Ris0, na Dinamarca.

O *WasP* (*Wind Atlas Analysis and Application Program*) é um *software* que permite simular o comportamento do vento num determinado local, tendo em conta a rugosidade do terreno, através de um coeficiente de rugosidade e da influência dos obstáculos (montes, vegetação). Através desta ferramenta, este método é capaz de transformar o vento previsto por um NWP de uma determinada região numa aproximação do vento real no parque à altura dos rotores dos geradores. Numa fase seguinte, com a velocidade do vento previsto à altura do rotor, é calculada a potência elétrica usando a curva de potência teórica do gerador. No modelo é ainda tido em conta o efeito de esteira, ou seja, a perturbação do vento à saída de um gerador. A potência calculada é ainda refinada com base num *Model Output Statistics* (MOS), o que contribui para reduzir os erros provenientes de NWP ou do modelo feito da superfície terrestre do parque (Pinson, 2006). Consequentemente, o erro associado consegue-se reduzir bastante. Para medir este erro recorre-se ao RMSE. O teste apresentado em (Giebel et al., 2011), mostra o *Prediktor* aplicado a uma turbina dinamarquesa nos anos 90. Este mostra o erro de previsão, ilustrado na Tabela 2-2, com um RMSE médio de 16% ao longo do horizonte de previsão de 36 horas, com uma ligeira subida do erro à medida que o horizonte temporal aumenta.

Tabela 2-2 Resultados do RMSE aplicado ao método *Prediktor*, adaptado de (Giebel et al., 2011)

Horizonte de previsão	RMSE (%)
3	14
9	16
24	17
36	19

Por norma, os dados históricos de potência dos parques eólicos não são tornados públicos pelas empresas, o que confere uma vantagem deste modelo, uma vez que não necessita desse tipo de dados para ser construído.

2.2.2 Métodos estatísticos

Os métodos estatísticos tentam simular a relação entre as previsões meteorológicas, os dados históricos, a potência gerada pelos geradores eólicos, os erros associados a cada previsão para obter um modelo capaz de aprender e extrapolar esta relação para um período futuro próximo. Estes usualmente, não têm em consideração direta as características físicas do terreno. Também para este método é necessário extrapolar os dados de previsão meteorológica de uma região para o local e altura dos rotores. Estes modelos são usados com o objetivo de prever horizontes curtos, uma vez que quanto maior o horizonte pretendido, maior é o erro associado do NWP e consequentemente, maior o erro do modelo de predição. (Monteiro et al., 2009) e (Giebel et al., 2011).

ARMA

Este tipo de abordagem metodológica baseia-se em análises de séries temporais de dados, registados com um intervalo constante. Uma característica interessante deste género de dados é a sua análise e modelação, uma vez que os registos contíguos são dependentes, ou seja, os registos com um tempo similar são semelhantes aos de horizontes mais alargados. Contudo este tipo de abordagem tem como desvantagem o aumento da complexidade dos modelos, em termos da análise dos coeficientes regressivos.

Os modelos baseados em *Auto-Regressive Moving Average* (ARMA) são exemplos típicos de serie temporal cujo objetivo é prever futuros valores dessa mesma série com um horizonte de previsão curto. Este modelo antes de ser aplicado à previsão de potência eólica já estava inserido noutros setores como finanças ou controlo, uma vez que é relativamente fácil de desenvolver.

No ARMA, os dados de entrada são alvo de um pré processamento e posteriormente são definidos como uma função linear entre os últimos valores conhecidos de velocidade ou direção do vento e os últimos erros de previsão. Através de um método iterativo otimizado de *Box-Jenkins*, que encontra o valor que mais se enquadra numa serie temporal consoante os valores passados dessa mesma série, o ARMA pode apresentar resultados 57,6% melhores do que o método persistente para um horizonte de previsão de 120 minutos e valores de velocidade de vento de 10 em 10 minutos. (Giebel et al., 2011).

Uma vez que a velocidade do vento tem uma boa sucessão e aleatoriedade, o uso de modelos ARMA de série temporal são bastante apropriados para prevê-la. No entanto, não sendo tão assertivos na previsão da direção do vento, efetuando algumas variações deste modelo, é possível fazer um compromisso entre a qualidade de previsão da velocidade e direção do vento (Chang, 2014).

Como o método se baseia simplesmente em dados históricos, não consegue ter um bom desempenho para longos horizontes de previsão. No entanto, aplicando vários modelos ARMA consoante a estação do ano, ou mesmo consoante o mês, o desempenho dos modelos melhora substancialmente (Pinson, 2006).

Existem variações deste modelo como o *Auto Regressive Integrated Moving Average* (ARIMA) ou o modelo ARMA com *Exogenous Input* (ARMAX ou ARX). Existem ainda a possibilidade de combinar o ARMA com outros modelos.

Modelos baseados em Redes Neurais

Um método alternativo aos apresentados em cima são as Redes Neurais Artificiais (ANN), que estabelecem a relação entre qualquer entrada na rede neuronal e a potência elétrica produzida pelos geradores. As redes neurais são modelos desenvolvidos por computadores que se baseiam no complexo cérebro humano. A aprendizagem dos “neurónios” da rede neuronal é capazes de ensinar a uma máquina o comportamento de determinados dados assim como a possibilidade de reconhecimento de padrões.

Neste trabalho, as ANN são treinadas com algoritmos que utilizam um conjunto de dados históricos de produção eólica e dados característicos de vento. Desta forma, estes modelos são

capazes de fazer uma boa previsão de vento ou potência para um horizonte curto, mas não para horizontes longos (Pinson, 2006).

Geralmente, as empresas gestoras dos parques eólicos não disponibilizam os dados de velocidade e direção de vento do próprio parque de forma gratuita. Associado a este fato, estas empresas não têm acesso a medições de pressão e humidade do ar no parque, visto que não possuem uma estação meteorológica, devido aos custos de construção e manutenção. Nestas circunstâncias, para se implementar uma metodologia com ANN, pode ser necessário obter essa informação de outra forma. Destaca-se o trabalho de (Li, 2001), cujo objetivo foi prever a potência de uma única turbina, com base na curva de potência teórica dessa turbina e em dados de velocidade e direção de vento medidos em dois postos meteorológicos próximos do parque. A rede neuronal treinada possuía quatro parâmetros de entrada e não apenas um. Este trabalho apresentou resultados melhores do que o método persistente e demonstrou a habilidade das ANN para extrapolar o vento de uma determinada altura e região próxima do parque para a altura dos geradores no próprio parque.

Segundo (Yun, Jianyuan, Mingli, & Liang, 2011), os fatores que mais influenciam a previsão da potência de um parque são a velocidade e direção do vento. No entanto, as restantes características do vento como a humidade, a pressão e a temperatura do ar, também têm influência nesta previsão. Desta forma, utiliza-se uma *Artificial Neural Network* (ANN) para adaptar e melhorar as características do vento provenientes de uma previsão meteorológica para o local do parque. Nesta fase é utilizada uma rede neuronal com 3 camadas (camadas de input, escondida e de saída), cujo treino é efetuado com o algoritmo de *back propagation* (BP). Nesta fase, os dados meteorológicos são comparados com os dados históricos, e os pesos da rede são calculados. À saída da primeira ANN, apresenta-se um vento melhorado e adaptado ao parque. É aplicada agora uma segunda ANN, cujo objetivo é converter a previsão do vento, numa previsão da potência.

Este artigo só faz a experiência para uma turbina e não para um parque completo. Apresenta uma tabela com os erros de previsão e medição para as cinco características do vento. Em conclusão, apresenta um MAE máximo de 11,43% na previsão da potência. Observa-se que trabalhando os dados do NWP e reduzindo o erro associado à previsão do vento, consegue-se obter um resultado mais assertivo na previsão de potência.

Em geral, as redes neuronais são bastante atrativas, uma vez que são capazes de modelar séries temporais não lineares, devido à sua flexibilidade e a facilidade com que se consegue mudar o método de aprendizagem e a estrutura da própria rede neuronal. No entanto, estas devem ser construídas com cuidado e o método utilizado deve ser aplicado tendo em conta o objetivo que se pretende alcançar. Estas têm a desvantagem de que os resultados mais precisos apenas são possíveis com regimes de vento específicos. Adicionalmente, constata-se que se a previsão de vento utilizada na construção do modelo neuronal for específica do parque estudado através de dados de uma estação meteorológica instalada no próprio parque, para o modelo poder ser utilizado noutros parques, estes têm necessariamente que fazer a instalação e manutenção de uma estação meteorológica, o que implica custos financeiros (Pinson, 2006). Para que estes custos sejam evitados, opta-se por comprar previsões meteorológicas a empresas especializadas e utilizar esses dados. Desta forma, o modelo criado para um parque pode ser extrapolado para outros.

Modelos baseados em Fuzzy Logic

A *Fuzzy logic* (FL) é uma área de pesquisa baseada nos princípios da aproximação razoável e de inteligência computacional. Este conceito pode ter dois sentidos: no sentido estrito é um sistema lógico, que é uma extensão da lógica de vários valores. Num sentido mais lato, o FL é quase sinônimo da teoria dos conjuntos *fuzzy*, uma vez que esta relaciona a classe de um objeto com um determinado grupo através de uma função de pertinência (MathWorks, 2015).

As redes neurais baseadas nesta técnica são apropriadas para prever a produção de potência de uma turbina eólica num horizonte de previsão curto a médio. Estes recebem como entrada dados *online* do SCADA e dados do NWP, ou seja, dados de produção elétrica e velocidade e direção do vento (Giebel et al., 2011). Segundo (Lydia & Kumar, 2010), que destaca um modelo usando *fuzzy logic* conseguiu prever a velocidade do vento com um horizonte de previsão de 30 min a 2 horas, apresentando melhores resultados do que o método persistente. Este explora a correlação espacial existente entre os dados da série temporal da velocidade do vento de várias estações de medição localizadas nas zonas circundantes ao parque.

Estes modelos não são tão precisos como os já descritos, mas reduzem a complexidade computacional do mesmo e conseqüentemente o tempo que este demora a calcular a previsão. Visto que o FL é bastante intuitivos e que possui um grande número de aplicações, pode facilmente ser agregado a outros métodos e formar um método híbrido, como se verá de seguida.

2.2.3 Métodos híbridos

Os métodos híbridos são os mais utilizados nas aplicações comerciais, visto que agrupando alguns dos métodos já descritos, aproveitam as vantagens de cada um e reduzem o erro associado à previsão. Estas previsões são feitas atribuindo pesos a diversos métodos de horizonte curto e médio para obter um melhor desempenho em todo o horizonte de previsão (Giebel et al., 2011).

Em (Xia, Zhao, & Dai, 2010) é apresentada uma metodologia híbrida que junta *Neural Networks* e *Fuzzy Logic* para prever a potência elétrica. Este modelo utiliza uma combinação de dados de vento previstos por um NWP que fornece as variáveis meteorológicas para o sítio de interesse do parque e dados de potência gerada medidos do SCADA (em cada turbina). Estes são introduzidos numa rede neuronal que utiliza um algoritmo de treino com *back-propagation*, relacionando os dados meteorológicos da região do parque e os dados de potência efetivamente produzidos.

A previsão do vento dada pelo NWP para a região do parque é dada para um ponto específico dentro da área do parque e depois extrapolada para a altura do rotor de cada turbina, simulando o vento efetivamente sentido pelo rotor. Cada turbina tem um Wind Turbine Model (WTM) que representa a relação entre as variáveis do vento à entrada da turbina e a potência elétrica que esta gera. Esta função de transferência é modelada com uma rede neuro-fuzzy. Desta forma, à entrada da rede é introduzido um vetor com cinco posições (velocidade, direção, humidade, pressão e temperatura), em que cada uma destas representa os valores de cada variável ao longo do tempo. Depois de treinada e otimizada, esta é capaz de modelar o comportamento da turbina para um determinado vento, apresentando a potência estimada.

Estas redes são modelos adaptativos nos quais podemos afinar parâmetros online, como a disponibilidade ou não de uma turbina eólica, ou seja, se esta a produzir ou esta parada. Este modelo fornece um horizonte de previsão de 36 horas, com intervalos de 30 minutos.

Apresenta-se uma tabela de resultados com a avaliação do desempenho do modelo com base no RMSE de quatro previsões.

Tabela 2-3 Representação do RMSE para previsões, adaptado de (Xia et al., 2010)

Dia	RMSE (%)
1º	13,35
2º	11,26
3º	11,09

Apresenta-se também na Figura 2-1, um exemplo de previsão com a respetiva potência medida.

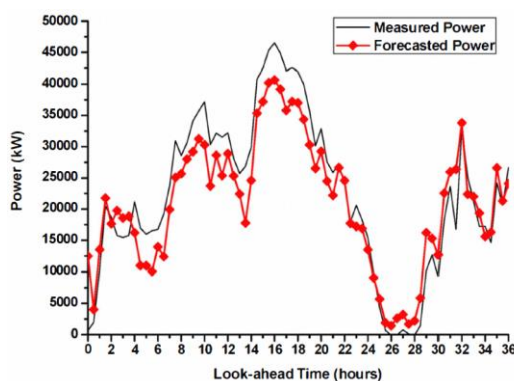


Figura 2-1 Exemplo com uma potência prevista (vermelho) e com potência medida (preto), (Xia et al., 2010)

2.3 Comparação

Segundo (Foley, Leahy, & McKeogh, 2010), nos EUA foram desenvolvidos modelos capazes de apresentar um MAE de 10 a 15% da capacidade nominal do parque eólico para um horizonte de previsão de 24 horas. No entanto, se o modelo for executado novamente algumas horas mais tarde dentro do mesmo horizonte, o MAE apresenta valores típicos de 5% da capacidade nominal do parque. Os modelos não lineares apresentam um RMSE típico de cerca de 10% da capacidade nominal instalada, apresentando melhores resultados do que os modelos lineares (Giebel et al., 2011).

3 Estudo de caso

O método utilizado nesta dissertação de mestrado consiste em utilizar apenas os dados que a REN tem disponíveis e com base neles, criar um modelo para conseguir prever tanto a velocidade do vento que se irá fazer sentir num determinado parque eólico como a potência que o mesmo irá produzir. Para tal são tidos em conta dados disponíveis na REN tais como: velocidade média do vento, direção média do vento, número de aerogeradores ativos em cada momento e potência gerada pelo parque eólico ao longo do tempo.

A velocidade média do vento será utilizada como *input* na rede neuronal que em certo modo “aprende” o seu comportamento, sendo posteriormente capaz de prever o valor da velocidade média do vento esperada. São analisados vários mecanismos de redes neuronais, com diferentes *inputs* e metodologias.

Com base no vento previsto pela rede neuronal, e através do modelo da turbina eólica característica do parque em análise, é possível fazer uma conversão de vento previsto para potência prevista do parque. Depois de construído o modelo, o objetivo é averiguar se este pode ser generalizado para outros parques, ou seja, se consegue prever a velocidade do vento e potência para outros parques eólicos.

Os dados recolhidos correspondem a um horizonte temporal entre as datas 13 de Abril de 2015 e 10 de Maio de 2016 e foram retirados do *Supervisory Control and Data Acquisition* (SCADA) da REN.

3.1 Escolha dos parques eólicos

Segundo o documento de especificação técnica para a previsão de vento e potência elaborado pela REN para os prestadores do serviço de previsão eólica, no ano de 2015 existiam 193 locais de previsão de vento e 116 locais de previsão de potência. Os vários locais suscetíveis de previsão podem ser analisados nos Anexo B e Anexo C, nomeadamente na Tabela 5-1 e Tabela 5-2.

Uma vez que os dados disponíveis na internet relativos às características dos geradores eólicos são limitados, a escolha dos parques eólicos é uma tarefa essencial para o sucesso da metodologia de previsão da potência elétrica. Optou-se, nesta fase da dissertação, por não prever a totalidade dos parques no país em face do tempo disponível e o âmbito de se tratar de uma dissertação de mestrado. Desta modo, foram tidos em conta os seguintes critérios para seleção de parques:

- Parques com apenas um tipo de turbina eólica.
- Parques com turbina eólica do tipo ENERCON E-82.
- Parques de zonas geográficas distintas de Portugal Continental.
- Parques com número variado de geradores eólicos.

- Parques com um número variado de potência nominal

Nem todos os fabricantes de geradores eólicos disponibilizam as informações relativas as turbinas eólicas de uma forma gratuita, pelo que foi necessário fazer uma pré seleção dos parques ligados diretamente à REN. Foram selecionados parques eólicos com apenas um tipo de turbina, pois os dados recolhidos em relação ao número de aerogeradores ativos no parque, apenas indicam quantos aerogeradores estavam ativos em cada momento, e não permitem diferenciar que tipo de aerogeradores estão ativos. Caso exista um parque com dois tipos de aerogeradores cujas potências nominais são diferentes entre eles, seria impossível calcular com exatidão a potência gerada pelo parque.

Assim sendo, elegeu-se a turbina Enercon E-82, visto que a empresa que a fabrica disponibiliza bastante informação relativa às suas turbinas. A Figura 3-1 mostra a relação da velocidade do vento com a potência produzida numa turbina eólica (gráfico a cinzento) e a relação da velocidade do vento com o C_p do aerogerador (gráfico a vermelho).




Figura 3-1 Curva característica da potência e do CP para o aerogerador Enercon E-82, (ENERCON GmbH, 2015)

Escolheram-se parques eólicos de várias zonas geográficas do país para que o vento característico de uma determinada zona não ditasse o mau funcionamento do modelo. Escolheram-se parques eólicos com um número de aerogeradores variado (pequeno, médio e grande) para averiguar a resposta do modelo a esta variação, assim como a uma variação da potência nominal produzida pelo parque.

De seguida apresenta-se na Tabela 3-1, a lista dos vários parques eólicos selecionados a partir da Tabela 5-2, com base nas condições enunciadas em cima. Desta forma, destacam-se as características de cada parque como: número de aerogeradores, potência nominal, marca e modelo das turbinas eólicas e o distrito em que se situa.

Tabela 3-1 Lista dos parques selecionados e respetivas características

Nome do parque	Número de aerogeradores	Potência nominal (MW)	Marca e modelo	Distrito
Alto do Arganil	18	36,9	Enercon E-82	Coimbra
Montalegre	29	60	Enercon E-82	Vila Real
Lourinhã	9	17,7	Enercon E-82	Lisboa
Mougueiras	4	7	Enercon E-82	Castelo Branco
Fanhões	9	17,8	Enercon E-82	Lisboa

Foram selecionadas vários parques para garantir que o modelo construído para um parque, poderia mais tarde ser generalizado para outros, e desta forma, prever a potência total relativamente à contribuição da energia eólica para Portugal Continental.

3.2 Recolha de dados do SCADA da REN

O SCADA da REN, é o sistema de controlo responsável por recolher e armazenar dados relativamente aos constituintes da rede elétrica, como linhas de transporte de energia, transformadores, postos de transformação, entre outros. Desta forma, de modo a permitir o acesso aos dados armazenados pelo SCADA, foi necessário aceder à base de dados da REN. Com base na ferramenta MySQL, foi possível fazer *queries* à base de dados para recolher a informação desejada, neste caso relativa a parques eólicos. Nesta base de dados, cada parque eólico é identificado com uma sigla característica, e assim, acedendo a esse campo, é possível recolher informação relativa a esse parque. Na Figura 3-2 é exemplificada uma simples *querie* para recolher informação de um parque eólico específico, o parque eólico do Poucinho 2.

The screenshot shows a SQL query: `select * from TA_OBJECTS where bloco1='POU2';` The result grid contains the following data:

id	versao	bloco1	bloco2	bloco3	elemento	data_inicio
25901	1	POU2	60 kV		P	2015-12-31 00:00:00
25902	1	POU2	60 kV		Q	2015-12-31 00:00:00
25903	1	POU2	60 kV		S	2015-12-31 00:00:00
25904	1	POU2	60 kV		U	2015-12-31 00:00:00
25905	1	POU2	60 kV		Wm Temp	2015-12-31 00:00:00
25906	1	POU2	SETPOINT		P	2015-12-31 00:00:00
25907	1	POU2	SETPOINT		num_1	2015-12-31 00:00:00
25908	1	POU2	VENTO		num_1	2015-12-31 00:00:00
25909	1	POU2	VENTO		num_2	2015-12-31 00:00:00
25910	1	POU2	VENTO		num_grp	2015-12-31 00:00:00
32638	1	POU2	SETPOINT		P2	2015-12-31 00:00:00
32639	1	POU2	SETPOINT		P3	2015-12-31 00:00:00
32640	1	POU2	SETPOINT		num_2	2015-12-31 00:00:00
32641	1	POU2	SETPOINT		num_3	2015-12-31 00:00:00
32642	1	POU2	SETPOINT		num_4	2015-12-31 00:00:00

Figura 3-2 Query para aceder a toda informação relativa ao parque eólico do Poucinho 2

Na tabela seguinte, apresenta-se a legenda relativa às abreviaturas usadas na coluna dos 'elementos' da Figura 3-2.

Tabela 3-2 Legenda relativa às abreviaturas usadas na coluna dos 'elementos' da Figura 3-2

Elemento	Significado
P	Potência ativa gerada
Q	Potência reativa gerada
S	Potência aparente gerada
Wm Temp	Temperatura ambiente na sub estação mais próxima do parque
Num_1	Velocidade do vento
Num_2	Direção do vento
Num_grp	Número de aerogeradores ativos no parque

Para este parque eólico apenas existe a informação apresentada na Tabela 3-2. Salienta-se, no entanto, que nem todos os parques têm toda a informação apresentada, tomando como exemplo a informação relativa à temperatura ambiente na sub estação mais próxima.

Por forma a conseguir recolher estes dados, foi necessário aceder a um campo específico deste parque eólico. Para isso, apresenta-se na Figura 3-3 uma nova *query*, para aceder à informação relativa à potência ativa nesse parque. Variando o valor de 'id', é possível aceder e recolher dados de todos os campos desta base de dados.

valor	flag	data
5.27	3	2015-04-13 00:01:56
5.22	3	2015-04-13 00:02:55
5.41	3	2015-04-13 00:03:56
5.77	3	2015-04-13 00:04:56
5.34	3	2015-04-13 00:05:55
5.35	3	2015-04-13 00:06:56
6.34	3	2015-04-13 00:07:56
6.35	3	2015-04-13 00:08:56
6.91	3	2015-04-13 00:09:56

Figura 3-3 Query para aceder à potência ativa relativa ao parque eólico do Poucinho 2

Esta informação é apresentada, não para demonstrar a complexidade do processo de recolha de dados, mas sim para demonstrar como está organizada a base de dados da REN.

3.2.1 Análise dos dados

Por definição, os valores registados pelo SCADA são guardados minuto a minuto na base de dados. No entanto, por questões de limitação de memória e processamento nos servidores da REN, se o valor medido no instante t for exatamente igual ao valor registado em $t - 1$, este é omissivo. Consequentemente, quando os dados são retirados da base de dados não estão contíguos no tempo, sendo necessário restituir todos os valores em falta. Para isso, é utilizado um programa desenvolvido em *VBA* no Excel. Escolheu-se esta ferramenta pela facilidade de observação e manuseamento dos dados.

De forma a poder trabalhar com um número razoável de dados, foi necessário transformar os dados com uma resolução de 1 minuto para uma resolução de 15 minutos, através de médias ponderadas. Sabe-se que o registo dos valores na base de dados realiza-se a todos os minutos, mas em segundos diferentes. De forma a poder minimizar o erro da aproximação, é tido em conta o peso de cada valor registado, ou seja, são contabilizados os segundos a que cada valor foi guardado na base de dados. Através da equação (3.1), e sabendo que a data é do formato hh/mm/ss dd/mm/aaaa, calcula-se a diferença entre duas datas contíguas.

$$Peso_{data\ t} = data_t - data_{t-1} \quad (3.1)$$

Para conseguir, realizar as médias de 15 minutos, aplica-se a equação (3.2):

$$Média_{data\ t_{15min}} = \frac{\sum_{i=1}^{15} Valor(i) * Peso_{data\ t}(i)}{\sum_{i=1}^{15} Peso_{data\ t}(i)} \quad (3.2)$$

Na Figura 3-4 é apresentado o output da restituição dos valores de minuto a minuto e as médias de 15 minutos para a direção do vento.

	A	B	C	D	E	F	G	H
1	Valor	Data 1min	Peso	Média			Data 15 min	Médias
2	99.6	13/04/2015 00:00		98.571			13/04/2015 00:00	98.571
3	99.6	13/04/2015 00:01	0.0007				13/04/2015 00:15	98.148
4	99.6	13/04/2015 00:02	0.0007				13/04/2015 00:30	98.854
5	98.26	13/04/2015 00:03	0.0008				13/04/2015 00:45	101.27
6	98.26	13/04/2015 00:04	0.0007				13/04/2015 01:00	101.84
7	98.26	13/04/2015 00:05	0.0007				13/04/2015 01:15	102.18
8	98.74	13/04/2015 00:06	0.0007				13/04/2015 01:30	102.99
9	98.74	13/04/2015 00:07	0.0007				13/04/2015 01:45	102.88
10	98.74	13/04/2015 00:08	0.0007				13/04/2015 02:00	102.47
11	98.07	13/04/2015 00:09	0.0007				13/04/2015 02:15	101.72
12	98.07	13/04/2015 00:10	0.0007				13/04/2015 02:30	101.82
13	98.07	13/04/2015 00:11	0.0007				13/04/2015 02:45	100.66
14	98.54	13/04/2015 00:12	0.0007				13/04/2015 03:00	100.93
15	98.54	13/04/2015 00:13	0.0007				13/04/2015 03:15	102.07
16	98.54	13/04/2015 00:14	0.0007				13/04/2015 03:30	103.2
17	98.16	13/04/2015 00:15	0.0007	98.148			13/04/2015 03:45	105.07
18	98.16	13/04/2015 00:16	0.0007				13/04/2015 04:00	104.48
19	98.16	13/04/2015 00:17	0.0007				13/04/2015 04:15	104.06
20	98.08	13/04/2015 00:18	0.0007				13/04/2015 04:30	104.88
21	98.08	13/04/2015 00:19	0.0007				13/04/2015 04:45	105.52
22	98.08	13/04/2015 00:20	0.0007				13/04/2015 05:00	106.45
23	98.08	13/04/2015 00:21	0.0007				13/04/2015 05:15	109.64
24	98.08	13/04/2015 00:22	0.0007				13/04/2015 05:30	108.04
25	98.08	13/04/2015 00:23	0.0007				13/04/2015 05:45	107.46
26	97.85	13/04/2015 00:24	0.0007				13/04/2015 06:00	105.96
27	97.85	13/04/2015 00:25	0.0007				13/04/2015 06:15	104.88
28	97.85	13/04/2015 00:26	0.0007				13/04/2015 06:30	106.34
29	98.57	13/04/2015 00:27	0.0007				13/04/2015 06:45	105.78
30	98.57	13/04/2015 00:28	0.0007				13/04/2015 07:00	103.41
31	98.57	13/04/2015 00:29	0.0007				13/04/2015 07:15	102.55
32	98.5	13/04/2015 00:30	0.0007	98.854			13/04/2015 07:30	102.59

Figura 3-4 Restituição dos valores de minuto a minuto e médias de 15 minutos para a direção do vento

Apresentam-se de seguida, nas Figura 3-5, Figura 3-6, Figura 3-7 e Figura 3-8, a evolução temporal dos sinais da velocidade e direção do vento, número de aerogeradores e potência gerada, respetivamente. São apresentadas apenas as primeiras 800 horas de cada variável, para que no *output* seja perceptível a evolução de cada um. Note-se que 800 horas correspondem aproximadamente a um mês de dados. Estes dados são relativos ao parque eólico do Alto do Arganil, em Coimbra, localizado na região centro do país.




Figura 3-5 Evolução temporal da velocidade do vento com valores de hora em hora

Como se pode observar o sinal temporal da velocidade média do vento é bastante irregular e não linear. Dificilmente se consegue encontrar na Figura 3-5 um período do sinal, o que indica que se trata de um sinal próximo do aleatório.

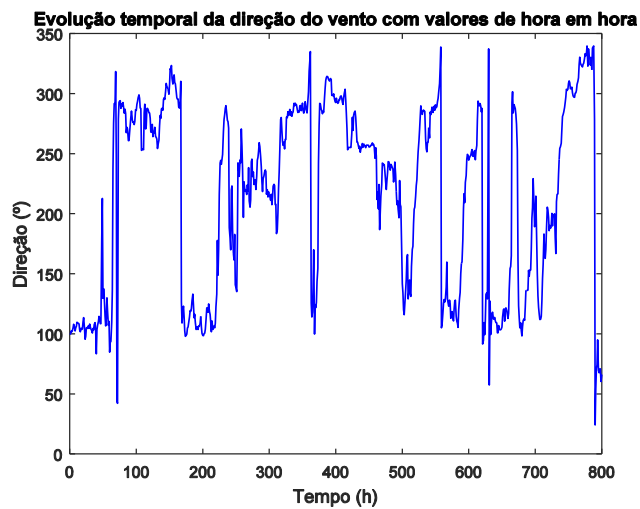


Figura 3-6 Evolução temporal da direção do vento com valores de hora em hora

Como se pode observar o sinal temporal da direção média do vento é também bastante irregular. No entanto, estes dados não serão fundamentais no modelo de previsão e são simplesmente analisados, como será mostrado mais à frente.

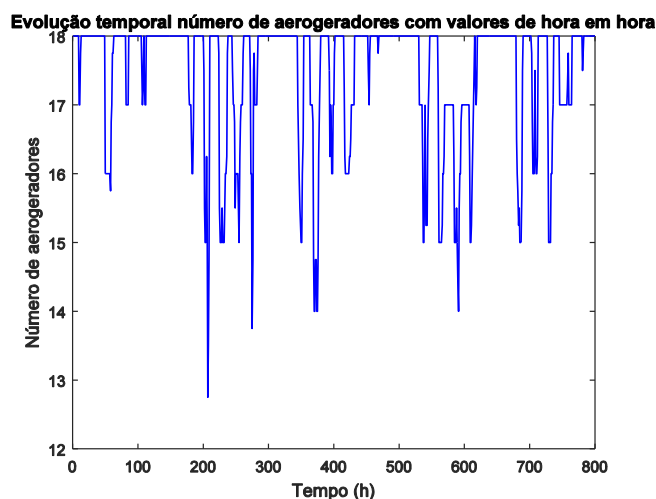


Figura 3-7 Evolução temporal número de aerogeradores com valores de hora em hora

O número de aerogeradores em funcionamento simultâneo é praticamente a totalidade de aerogeradores no parque eólico. Os vários mínimos relativos que se observam devem-se à necessidade de manutenção dos aerogeradores.




Figura 3-8 Evolução potência ao longo do tempo com valores de hora em hora

Como se pode observar o sinal temporal da potência ao longo do tempo no parque é também bastante irregular, uma vez que esta depende maioritariamente do sinal de velocidade média do vento.

Para continuar a analisar os dados provenientes da REN, apresenta-se na Tabela 3-3 as médias das variáveis medidas dadas pelos 12 meses do ano, para facilitar a sua análise. Note-se que os dados apresentados são relativos ao ano de 2015, pelo que poderá ter sido um ano específico de vento.

Tabela 3-3 Médias das variáveis consoante o mês

Mês	Velocidade média (m/s)	Direção média (°)	Número de Aerogeradores médio	Potência gerada média (MW)
Janeiro	8,39	222,86	17,8	16,42
Fevereiro	10,2	236,40	17,5	20,09
Março	6,98	304,07	17,6	12,43
Abril	6,80	218,94	17,4	11,46
Maio	6,72	197,74	17,5	10,69
Junho	5,26	204,03	17,5	5,64
Julho	6,77	265,22	17,6	11,10
Agosto	5,80	255,51	17,7	8,28
Setembro	5,92	217,23	17,7	8,55
Outubro	7,08	167,57	17,8	12,94
Novembro	6,32	188,34	17,6	9,93
Dezembro	5,89	154,39	17,8	8,73

Apresentam-se nas Figura 3-9, Figura 3-10, Figura 3-11 e Figura 3-12 os gráficos relativos à Tabela 3-3. Apresentam-se os gráficos contínuos, e não discretos, para facilitar a evolução de cada gráfico.

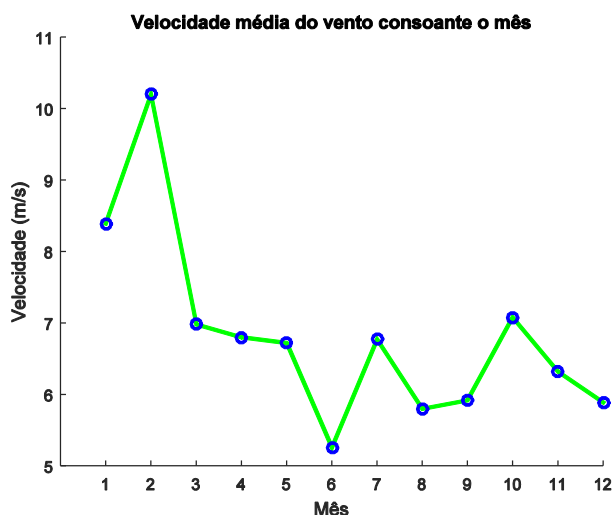


Figura 3-9 Evolução da velocidade média do vento consoante o mês do ano

Pela simples análise do gráfico constata-se que os meses cuja velocidade média do vento é maior são Janeiro, Fevereiro e Outubro. Observa-se também que a velocidade média do vento é mais elevada no Inverno do que no Verão, como seria de esperar. O mês com menor velocidade média do vento foi Junho.

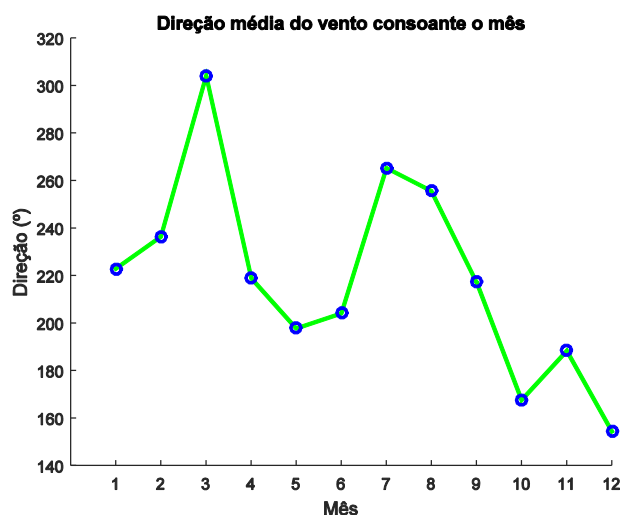


Figura 3-10 Evolução da direção média do vento consoante o mês do ano

Em relação à direção média do vento, observa-se que a variação é oscilante e vai diminuindo de amplitude no decorrer do ano. Constata-se que a direção média com maior valor por mês foi de 304° e a mínima foi de 154°, correspondendo aos meses de Março e Dezembro respetivamente.

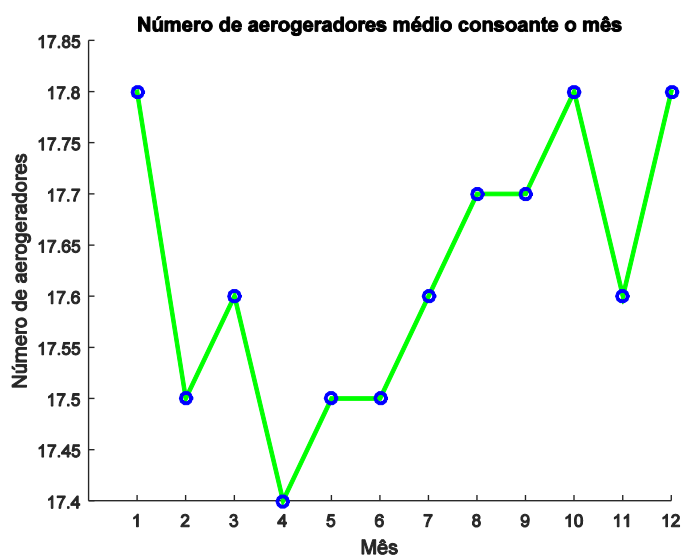


Figura 3-11 Evolução do número de geradores consoante o mês do ano

Analisando o número de aerogeradores médio no parque, constata-se que é sempre maior do que 17.4. No entanto, durante o período de verão a média baixa um pouco, possivelmente devido à manutenção que se realiza. É escolhido o período de verão visto que a velocidade média do vento é mais baixa, e desta forma minimiza-se a falta de produção. A produção das centrais solares no verão, também facilitam essa decisão. Este fato pode também resultar de outros fatores.




Figura 3-12 Evolução da potência gerada consoante o mês do ano

Tal como explicado no Estado da arte, mais especificamente no capítulo 1.2, a potência depende da velocidade do vento elevado ao cubo. Desta forma, compreende-se porque é que a Figura 3-9 e a Figura 3-12 são tão similares. A maior potência está intimamente ligada ao maior valor de velocidade média do vento e a menor potência à menor velocidade. Consequentemente, a maior produção aconteceu em Fevereiro e a menor em Agosto.

Os dados guardados no SCADA são dados genéricos do parque, ou seja, são recolhidos apenas por um aerogerador no centro do parque. Desta forma, os dados recolhidos não representam com exatidão o vento sentido em cada aerogerador, mas sim o vento geral no parque. Visto que existem parques com uma área muito vasta, esta generalização pode introduzir um erro significativo na previsão da potência gerada.

3.2.2 Pré tratamento dos dados

Uma vez recolhidos os dados do SCADA, as séries temporais foram analisadas e expurgadas de incorreções, nomeadamente por falha de registos, que se prendem por alterações na recolha ou interrupções na comunicação. Apresenta-se na Figura 3-13 a relação da velocidade do vento com a potência gerada por cada aerogerador no parque. Apresenta-se a vermelho, a linha de tendência com bases nos valores inicialmente guardados. Sabendo que existem muitos dados dispersos para uma grande gama de potências, não é possível verificar se a curva de tendência se aproxima à curva característica desta turbina eólica (Enercon E-82).

Visto que os dados disponíveis apenas davam conhecimento da potência total produzida pelo parque e do número de geradores ativos, aplicou-se a equação (3.3) para determinar a potência produzida por cada aerogerador, dividindo a potência total do parque pelo número de aerogeradores ativos.

$$P_{gerador} = \frac{P_{parque}}{Nr^o \text{ geradores ativos}} \quad (3.3)$$

Como se pode observar, na Figura 3-13, existem aerogeradores, na ordem dos 20 m/s, que apresentam uma potência instalada de cerca de 10 MW. Lembra-se que a potência instalada dos aerogeradores é de 2.1 MW, logo os valores em excesso têm necessariamente de ser excluídos.




Figura 3-13 Dados do SCADA sem tratamento

Na tentativa de trabalhar o mais próximo possível com a característica do aerogerador, tentando reduzi o erro, procedeu-se a um pré tratamento dos dados recolhidos pelo SCADA. Tentou-se eliminar todas as variáveis cuja relação com os outros valores não correspondesse ao esperado, ou seja, cujos valores tenham sido mal recolhidos no terreno. As relações são estabelecidas entre a velocidade do vento, o número de aerogeradores ativos e a potência gerada pelo parque e por cada aerogerador. Desta forma, foram tidos em conta os seguintes critérios, sumarizados na Tabela 3-4, para a eliminação de valores:

- Eliminação dos elementos cuja potência por aerogerador fosse maior do que aproximadamente 2,1 MW. Sabendo que os geradores têm uma potência instalada de 2,1 MW, sempre que o resultado da equação (3.3) excedesse esse valor, o elemento era eliminado. Teve-se em consideração que o valor teórico do catálogo poderia por vezes ser ligeiramente excedido (0.1 MW).

- Eliminação de todos os elementos cuja velocidade fosse maior do que zero e o número de aerogeradores igual a zero. Se o número de aerogeradores ativos fosse igual a 0, não se poderia aplicar a equação (3.3), visto que dividir por 0 é uma impossibilidade matemática. Adicionalmente, se o número de aerogeradores for 0, a potência gerada terá de ser obrigatoriamente 0. Consequentemente, estes valores não têm interesse para o treino da rede neuronal.

- Eliminação de todos os elementos cuja velocidade fosse maior do que 15 m/s, e a potência por aerogerador fosse menor do que 1.65 MW. Com base na Figura 3-1, a curva característica do aerogerador deste parque, para velocidades de vento maiores do que 15 m/s, a potência produzida por um aerogerador será geralmente a potência nominal (2.1 MW).

- Eliminação de todos os elementos cuja velocidade fosse maior do que 3 m/s, e a potência total do parque fosse igual a 0 MW. Novamente, segundo a Figura 3-1, quando a velocidade do vento é maior do que 2 m/s, os aerogeradores deveriam estar a produzir eletricidade.

Tabela 3-4 Critérios para eliminação de valores retirados da base de dados da REN

	Velocidade (m/s)	Número de Aerogeradores	Potência total parque (MW)	Potência por aerogerador (MW)
Condições	-	-	-	> 2,10
	≥ 0	0	-	-
	> 15	-	-	< 1,65
	> 3	-	0	-

Apresenta-se na Figura 3-14, os dados anteriores depois do tratamento enunciado em cima. Aqui já é possível ver que a linha de tendência, desenhada a vermelho, se aproxima bastante da curva característica de uma turbina eólica. Note-se que os dados apresentados são de 15 em 15 minutos.

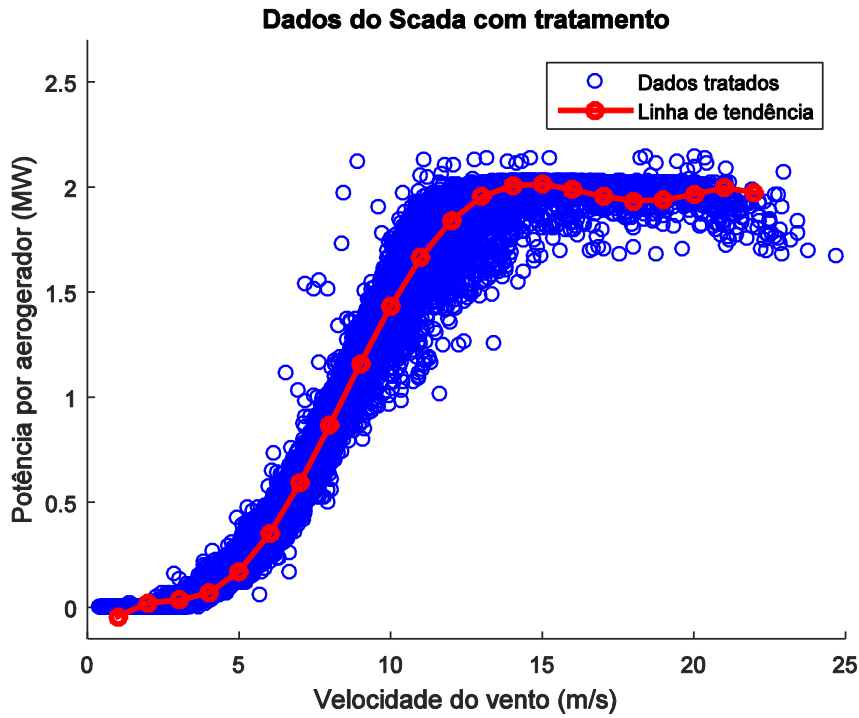


Figura 3-14 Dados do SCADA com tratamento

De forma a perceber se os resultados obtidos são consistentes com os valores reais apresentados pelo fornecedor da turbina eólica, apresenta-se na Figura 3-15, a comparação das linhas de tendência dos dados sem e com tratamento em comparação com a curva real do aerogerador.

Comparação da curva característica do fabricante com os dados do Scada sem e com tratamento




Figura 3-15 Comparação da curva característica do fabricante com os dados do Scada sem e com tratamento

Na Figura 3-16 apresenta-se a diferença das linhas de tendência dos dados sem e com tratamento em relação à curva de tendência teórica do fabricante. Como se pode observar, até à velocidade de 10 m/s, ambas as curvas seguem bastante bem a curva real. Curiosamente, a partir da velocidade de 16 m/s, a curva dos dados sem tratamento consegue acompanhar melhor a curva real. De seguida apresenta-se o desvio (erro) das duas curvas em relação à curva característica.

Erro entre os dados sem e com tratamento com a curva característica do fabricante

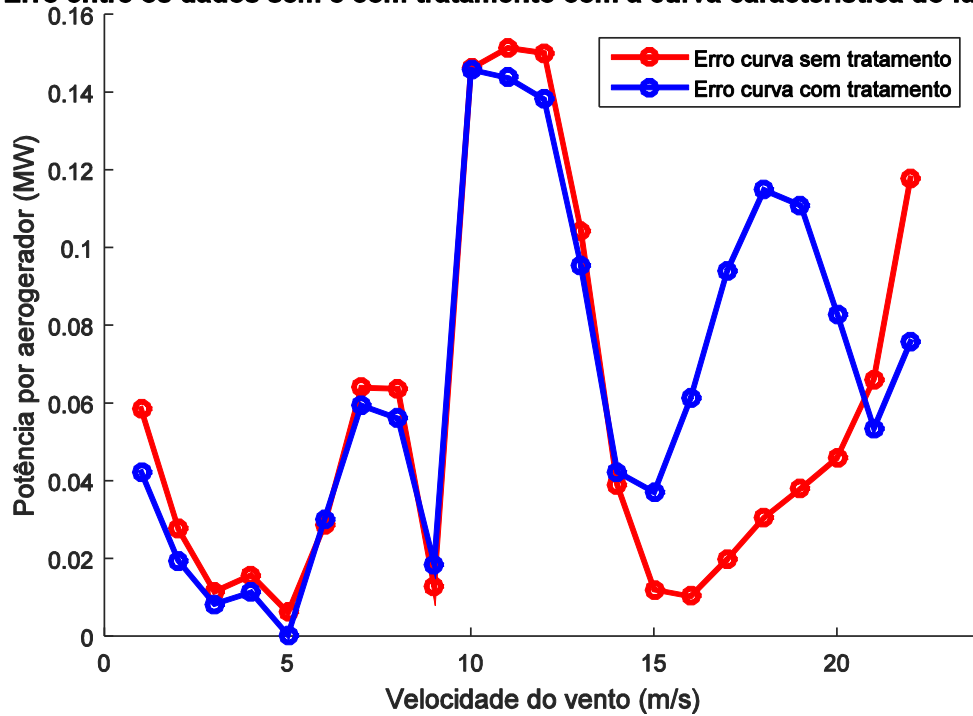


Figura 3-16 Erro entre os dados sem e com tratamento com a curva característica do fabricante

Naturalmente, conclui-se que o erro da curva com tratamento de dados apresenta um erro maior do que a curva sem tratamento. A diferença entre a curva real e as curvas sem e com tratamento são exibidas na Figura 3-16. Na Tabela 3-5 é mostrado o RMSE de cada curva.

Tabela 3-5 Erros dos dados sem tratamento e com tratamento em relação à curva característica da turbina Enercon E-82

Erro	Dados sem tratamento	Dados com tratamento
RMSE (MW)	0,3360	0,3679

Estes resultados contraditórios podem dever-se ao fato de que a curva real (teórica do fabricante) é construída para uma densidade do ar de $p = 1.225 \text{ Kg/m}^3$, e essa pode não ser a verdadeira densidade do ar sentida em Portugal, ou especificamente no Parque eólico do Alto

do Arganil (ENERCON GmbH, 2015). Com base nesta informação, embora a curva característica sem tratamento dos dados se aproxime melhor da curva do fabricante, usa-se a curva com tratamento dos dados. Embora o erro seja um pouco maior, foram eliminados valores que não correspondiam à verdade. É fundamental utilizar dados fidedignos e sem erros, uma vez que estes constituem a base de qualquer modelo de previsão.

3.3 Metodologia da rede neuronal

De forma a prever a potência gerada num parque eólico, é necessário prever a velocidade do vento que se irá fazer sentir no mesmo. Desta forma, nesta dissertação de mestrado é escolhida uma técnica de *machine learning*, as redes neuronais, para tentar realizar essa previsão.

Tal como observado no capítulo 2, as redes neurais artificiais (RNAs) são modelos computacionais inspirados pelo sistema nervoso central, o cérebro, que são capazes de aprender a relação entre os *entrada* e *targets*, assim como o reconhecimento de padrões. Depois de devidamente treinados, estes modelos aprendem a extrapolar esta informação, ou seja, quando são novamente apresentados dados de *entrada*, o modelo consegue, com base na aprendizagem que realizou, prever o valor de *saída* futuro. As redes neuronais são muito poderosas e podem ter um papel muito importante num futuro próximo, uma vez que, podem trabalhar com todo o tipo de dados, sendo por isso utilizadas em áreas como a banca, seguros, marketing, entre outros (Giebel et al., 2011).

3.3.1 Definição de *entrada* e *saída*

A escolha das *entradas* e *saídas* está diretamente relacionada com a escolha da rede neuronal. No entanto, tendo em conta o objetivo deste trabalho, o elemento fundamental de *entrada* são os dados históricos de velocidade do vento. Adicionalmente, como se irá observar nos próximos capítulos, é testado o acoplamento de outro tipo de dados aos de *entrada*, para averiguar a sua influência na diminuição do erro de previsão. Em relação à *saída*, é considerado sempre o registo de velocidade seguinte à última velocidade de vento que é introduzida nas entradas, visto que o objetivo da rede neuronal é prever a próxima velocidade. Desta forma, a rede neuronal pode aprender os padrões de velocidade que se registaram entre o passado e o futuro. Chama-se a este processo o treino da rede neuronal. Este treino, e nomeadamente as entradas necessárias, variam consoante a rede que é utilizada. O estudo dessas variações será observada neste capítulo.

Apresentam-se nas Tabela 3-6 e Tabela 3-7 um exemplo prático de definição das entradas e saídas se forem utilizados três registos de velocidades passadas para prever uma velocidade futura. Este exemplo é apresentado para facilitar a compreensão dos passos seguintes.

Tabela 3-6 Exemplo de uma sequência de velocidades de dados históricos de 2015

Velocidades do vento	10,7	10,2	9,5	8,4	8,9	9,1
-----------------------------	------	------	-----	-----	-----	-----

Tabela 3-7 Exemplo da definição dos *inputs* e *target* para uma rede que usa as últimas três velocidades registadas como inputs

Inputs			Target
t+3	t+2	t+1	t
10,7	10,2	9,5	8,4
10,2	9,5	8,4	8,9
9,5	8,4	8,9	9,1

O *target*, tal como indica o próprio nome, representa o resultado que se quer prever. Tendo em conta, que o treino da rede neuronal é feito com base em dados históricos, as velocidades “futuras”, ou seja o tempo t , estão sempre acessíveis nos dados recolhidos.

Depois da rede neuronal ser treinada, ou seja, depois de aprender a relação entre as velocidades passadas e as presentes, obtêm-se um modelo neuronal. Para se usar este modelo no futuro, basta introduzir à sua entrada um conjunto de *inputs*, e este calcula o *output*. Naturalmente, numa perspetiva empresarial, estes modelos são utilizados com dados presentes de vento, para prever o vento futuro.

A escolha do número de amostras anteriores para usar com *inputs* da rede neuronal não é uma escolha aleatória, visto que foi alvo de um estudo. Para isso, foi utilizada a função `corrcoef()` do Matlab®. O objetivo do estudo é averiguar o coeficiente de correlação entre os vários valores registados de velocidade e entre a velocidade do vento e as outras variáveis, como a direção do vento, o número de geradores ativos no parque e a potência gerada em cada aerogerador.

Apresenta-se na Tabela 3-8, o resultado dessa comparação. Note-se que esta função pode apresentar os seguintes resultados:

- Valores próximos de 1, indicando que existe uma relação linear positiva entre as variáveis, ou seja quando uma aumenta a outra também aumenta.
- Valores próximos de -1, indicando que existe uma relação linear negativa entre as variáveis, ou seja quando uma aumenta a outra diminui.
- Valores próximos de 0, indicando que não existe uma relação linear entre as variáveis.

Tabela 3-8 Coeficiente de correlação entre vários registos de velocidade de vento e entre a velocidade e outras variáveis

Variável 1	Variável 2	Correlação (15 min)	Correlação (1 hora)
Velocidade (t)	Velocidade (t+1)	0,983	0,955
	Velocidade (t+2)	0,965	0,896
	Velocidade (t+3)	0,948	0,843
	Velocidade (t+4)	0,933	0,792
	Velocidade (t+5)	0,918	0,743
	Direção (t)	0,238	0,2435
	Número Aeroogeradores (t)	0,047	0,049
	Potência por Aeroogerador	0,906	0,915

Pela observação da tabela 3.8, percebe-se que existe uma relação linear positiva entre os vários registos de velocidade. No entanto, na correlação de dados com 15 minutos de intervalo, observa-se uma correlação linear positiva muito forte, sempre acima de 0,9. Como seria de esperar, nos dados com intervalo de 1 hora, percebe-se que essa correlação, embora também seja linear positiva, não é tão forte, acima dos 0.75. Desta forma conclui-se que quando se quer prever uma velocidade com dados de intervalos curtos (15 minutos), pode-se usar vários registos anteriores. Todavia, se o objetivo é prever uma velocidade com base em registos mais alargado (1 hora), será mais aconselhado usar poucos registos anteriores. Em face do horizonte da hora seguinte e da característica do sinal a variável de *input* é apenas o vento registado nos instantes anteriores, enquanto para outros horizontes será necessário recorrer a outro tipo de informação exógena. Observando a tabela 3.8, conclui-se que a correlação de linearidade entre a velocidade e a direção do vento existe, mas é muito fraca, cerca de 0.25, em ambos os dados. Observando a relação entre a velocidade média do vento e o número de aerogeradores, conclui-se que não existe, cerca de 0, como seria expectável. A relação entre a velocidade do vento e a potência de cada aerogerador apresenta, naturalmente, uma relação linear positiva muito forte, cerca de 0.9, para ambos os tipos de dados.

Tendo em conta que o objetivo desta dissertação é prever a velocidade do vento na hora seguinte, justifica-se o uso de apenas 3 registos anteriores de velocidade do vento para o treino da rede neuronal, apresentado como exemplo na Tabela 3-7.

3.3.2 Apresentação das redes neuronais *time series*

Existem vários tipos de redes neuronais, com diferentes *inputs*, mecanismos e funções. Escolhem-se algumas das metodologias existentes e testam-se as mesmas para ver qual delas se adequava melhor ao propósito exigido. A rede neuronal escolhida tem que ser capaz de

conseguir prever o instante ou instantes de velocidade futura do vento, com base no treino realizado com valores históricos.

Tal como descrito nos capítulos anteriores, todas as redes neuronais terão pelo menos duas camadas (camada interna e de saída). Cada camada tem um número variável de neurónios. A primeira, terá um número de neurónios proporcional ao número de *inputs*, sendo que uma análise mais pormenorizada é realizada mais à frente. A segunda terá apenas um neurónio, visto que se quer apenas prever a velocidade futura do vento (uma variável).

Uma ferramenta útil para avaliar e testar as várias redes neuronais do Matlab é a *nnstart*, ilustrada na Figura 3-17. Esta ferramenta apresenta exemplos, testes e explicações sobre cada tipo de rede neuronal.

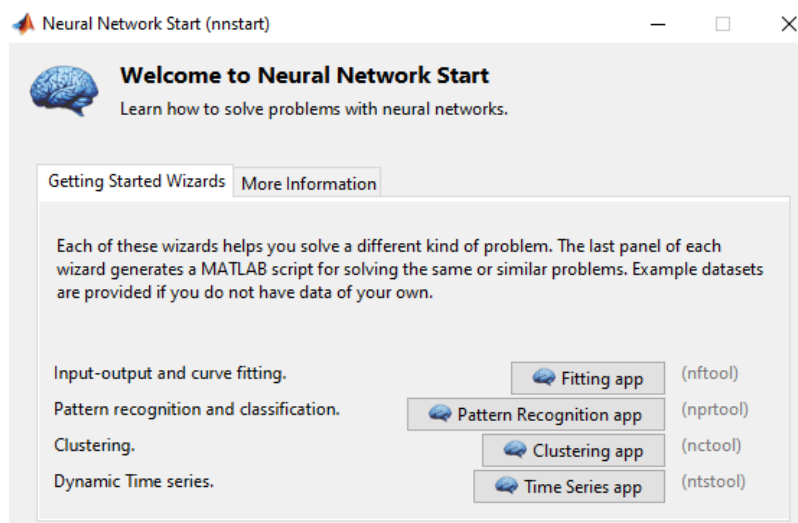


Figura 3-17 Neural Network Start (nnstart)

Inicialmente, foram utilizadas as redes neuronais do tipo série temporal. Foram construídas várias redes neuronais para analisar o desempenho de cada uma delas e conseguir escolher a que melhor se adaptava aos dados apresentados. Foram testadas e apresentadas as redes neuronais do tipo serie temporal: NAR, NARX e IO.

3.3.2.1 Rede neuronal NAR

Segundo a função *help* do Matlab, uma rede neural NAR é uma *Nonlinear AutoRegressive neural network*. Estes modelos podem ser treinados para prever uma série temporal futura $y(t)$, a partir de d valores históricos dessa mesma série temporal de $y(t)$. Esta dinâmica pode-se observar na Figura 3-18. Considera-se que o quadrado azul representa a rede neuronal, enquanto o quadrado verde representa o *output* dessa rede neuronal depois de treinada. Se existisse um quadrado verde representado antes da rede neuronal, esse representaria os *inputs* da rede, como se verá de seguida.




Figura 3-18 Dinâmica de uma rede neuronal NAR

Apresentam-se na Tabela 3-9, as características de treino das várias redes neuronais apresentadas nesta dissertação. Visto que as características de treino são similares para as outras redes neuronais do tipo série temporal, esta informação não é repetida na apresentação das seguintes redes.

Tabela 3-9 Características gerais de treino das redes neuronais do tipo série temporal

Variável	Valor
Número de <i>inputs da rede</i>	3
Número de neurónios da camada interna	3 - 30
Número de neurónios da camada de saída	1
Função de ativação da camada interna	purelin
Função de ativação da camada de saída	purelin
Função de treino	trainbr

Estas características de treino foram obtidas depois de um processo bastante moroso de tentativa e erro. Foi analisada exaustivamente a variação de cada parâmetro e o impacto que teria sobre o output da rede neuronal, tendo-se concluído que estas foram as melhores condições encontradas. Salienta-se que os resultados da rede neuronal com uma função de treino *trainbr* ou *trainlm* apresenta resultados similares, mas com melhor desempenho ao usar a *trainbr*.

O treino de cada rede acontece pela seguinte plataforma, como demonstra a Figura 3-19.

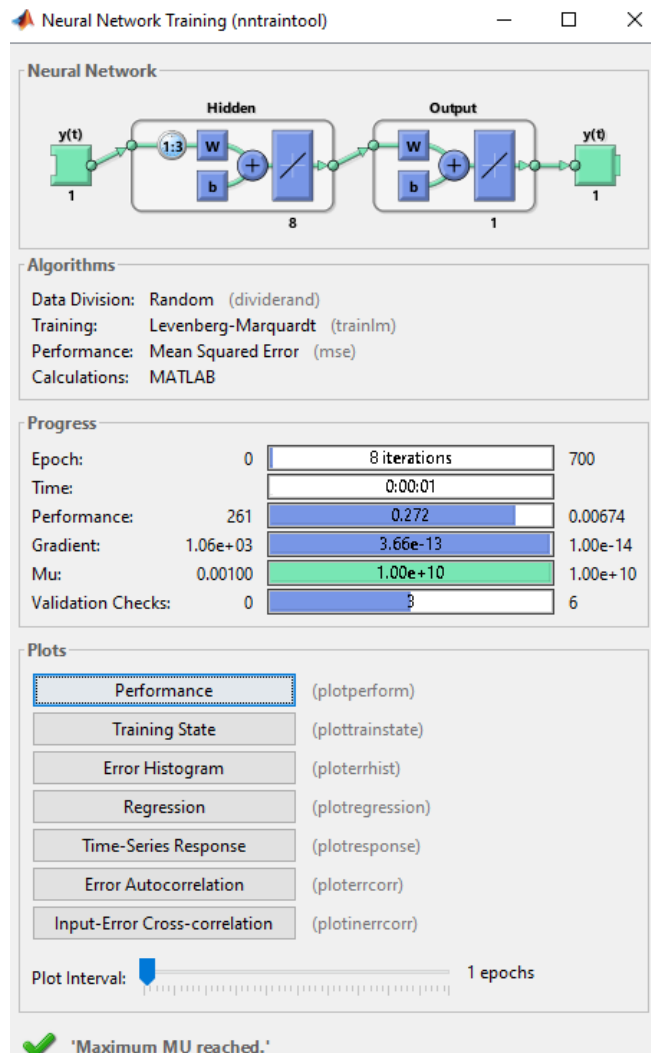


Figura 3-19 Treino da rede neuronal

Aqui encontram-se as principais características da rede neuronal, é possível observar gráficos correspondentes ao treino da rede, de forma a avaliar o seu desempenho.

O aspeto geral da rede neuronal NAR é o que se encontra na Figura 3-20.

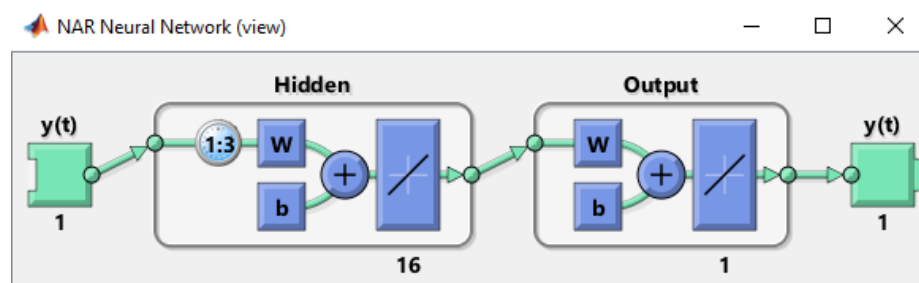


Figura 3-20 Esquema rede neuronal NAR

O treino da rede é efetuado nestas condições. Para ser testada, esta rede tem a particularidade de se ter que fechar o ciclo. Para isso, usa-se a função *closeloop*, que substitui o *feedback de entrada*, $y(t)$, por uma ligação direta entre a saída e a entrada. Pode-se observar o ciclo fechado na Figura 3-18. O desempenho da NAR Neural Network é apresentada na Tabela 3-10.

Tabela 3-10 Performance da rede neuronal NAR

Diferença temporal dos registos	15 minutos
RMSE teste (m/s)	0,69

Não é apresentada a resposta temporal do teste da rede neuronal, comparando o output da rede com o target esperado, uma vez que o graficamente, o resultado obtido nesta rede neuronal é bastante similar à Figura 3-23 (resposta temporal de uma NARX), que se irá apresentar de seguida por ser a rede neuronal do tipo time series mais complexa. Salienta-se no entanto, que existe um ligeiro *shift* entre o *output* da rede neuronal e o *target* que se queria obter.

3.3.2.2 Rede neuronal NARX

Segundo a função *help* do Matlab, uma rede neuronal NARX é uma *Nonlinear Autoregressive with External (Exogenous) Input neural network*. Estes modelos podem ser treinados para prever uma série temporal futura $y(t)$, a partir de d valores históricos dessa mesma série temporal de $y(t)$ e outra série de *inputs* $x(t)$. Esta dinâmica pode-se observar na Figura 3-21.




Figura 3-21 Dinâmica de uma rede neuronal NARX

O aspeto geral desta rede neuronal é o que se encontra na Figura 3-22. Esta rede apresenta-se mais complexa do que a anteriormente analisada.




Figura 3-22 Esquema rede neuronal NARX

Na Figura 3-23 encontra-se a comparação da velocidade prevista pelo modelo NARX com a velocidade real. Como se pode observar, o *shift* registado no modelo anterior mantêm-se, pelo que esta rede neuronal não resolveu esse problema. Tendo em conta que esta rede é da família das redes *time series*, não se esperava que o problema fosse resolvido, mas sim atenuado.

Comparação da velocidade prevista pelo modelo NARX com a velocidade real

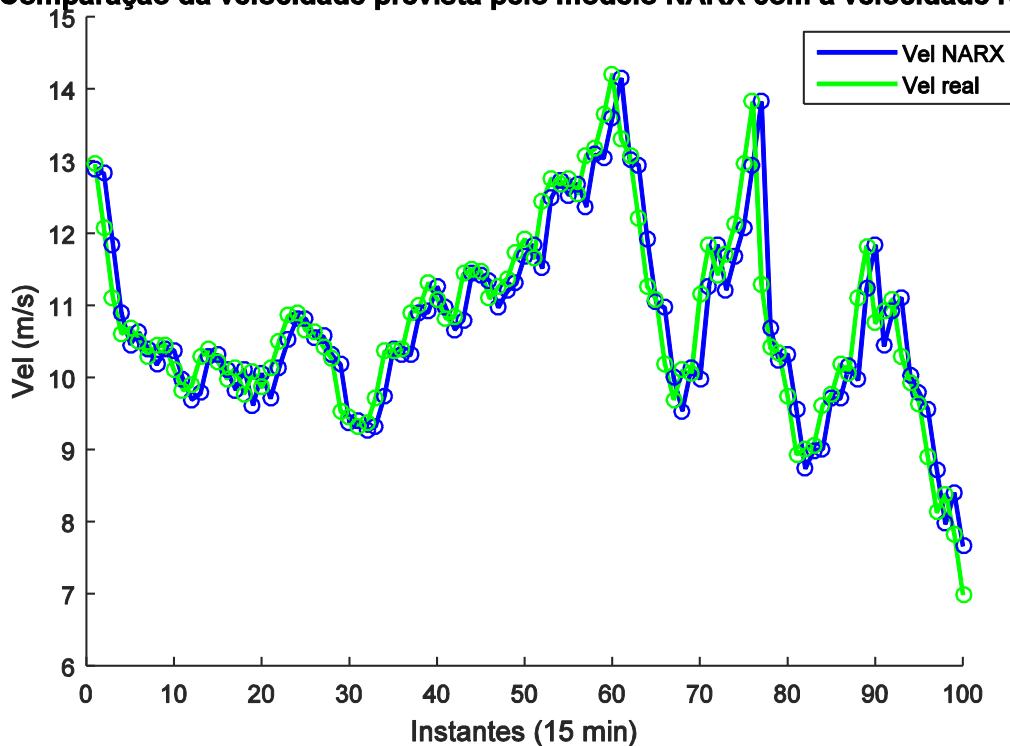


Figura 3-23 Comparação da velocidade prevista pelo modelo NARX com a velocidade real

De forma a concluir se o erro foi ou não atenuado, analisa-se o valor de erro calculado na Tabela 3-11. As conclusões finais, analisando os erros de todas as redes são comparados no capítulo 3.3.4.

Tabela 3-11 Performance da rede neuronal NARX

Diferença temporal dos registos	15 minutos
RMSE teste (m/s)	0,52

3.3.2.3 Rede neuronal IO

Segundo a função *help* do Matlab, uma rede neural IO é uma *Nonlinear Input-Output network*. Estes modelos podem ser treinados para prever uma série temporal futura $y(t)$, a partir de d valores históricos de outra série temporal de *inputs* $x(t)$. Esta dinâmica pode-se observar na Figura 3-24.




Figura 3-24 Dinâmica de uma rede neuronal IO

O aspeto geral desta rede neuronal é o que se encontra na Figura 3-25:




Figura 3-25 Esquema rede neuronal IO

O desempenho da rede é apresentada na Tabela 3-12.

Tabela 3-12 Performance da rede neuronal IO

Diferença temporal dos registos	15 minutos
RMSE teste (m/s)	0,51

Não é apresentada novamente a resposta temporal do teste da rede neuronal, comparando o *output* da rede com o *target* esperado, visto que graficamente, o resultado obtido seria similar à Figura 3-23 (resposta temporal de uma NARX). Salienta-se que o *shift* entre o *output* da rede neuronal e o *target* não foi removido com a utilização desta rede neuronal.

3.3.3 Rede neuronal Feedforward

Uma rede Feedforward (FF network) é bastante simples. Esta caracteriza-se por não existir um ciclo fechado entre os *inputs* e o *target*, ou seja, tal como indica o nome, a informação desloca-se numa só direção, dos nós de inputs, passando pelos nós da camada interna, até aos nós de target.

A principal diferença desta rede para as anteriores, é que aqui a introdução do vetor de regressão tem que ser produzida, não estando incorporada na função. No entanto, o controlo que se tem sobre o que está a acontecer é maior e desta forma, é mais fácil descobrir possíveis erros de construção da rede.

O aspeto geral desta rede neuronal é o que se encontra na Figura 3-26:

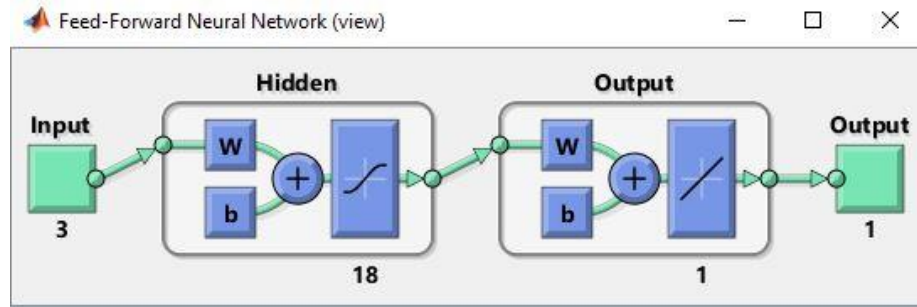


Figura 3-26 Esquema rede neuronal Feedforward

Ao observar a imagem, conclui-se que a rede neuronal tem 3 *inputs*, 18 neurónios na camada interna (a escolha do número de neurónios na camada interna faz-se a partir da Figura 3-27) e 1 neurónio da camada de saída.

Na Tabela 3-13 encontram-se as características utilizadas na rede para o treino da mesma.

Tabela 3-13 Características de treino de uma rede neuronal FF

Variável	Valor
Número de <i>inputs</i>	3
Número de neurónios da camada interna	10 - 30
Número de neurónios da camada de saída	1
Função de ativação da camada interna	tansig
Função de ativação da camada de saída	purelin
Função de treino	trainbr

Para descobrir o melhor desempenho da rede neuronal, varia-se o número de neurónios da camada interna, e escolhe-se o número de neurónios que conduzir a um RMSE menor. Apresenta-se na Figura 3-27, a análise do RMSE de treino para cada rede neuronal, variando apenas o número de neurónios da camada interna. Esta informação é apresentada num gráfico de barras para uma compreensão facilitada.

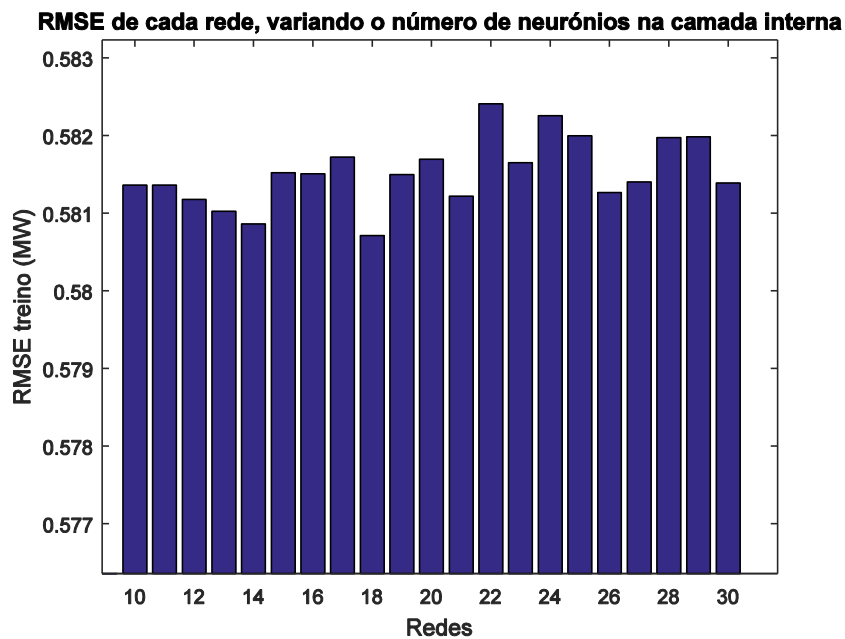


Figura 3-27 RMSE de cada rede, variando o número de neurónios na camada interna

Naturalmente, escolhe-se a rede com menor RMSE, a rede com 18 neurónios. Na Figura 3-28 apresenta-se a resposta da rede neuronal depois de treinada.

Comparação da velocidade prevista pelo modelo FF com a velocidade real

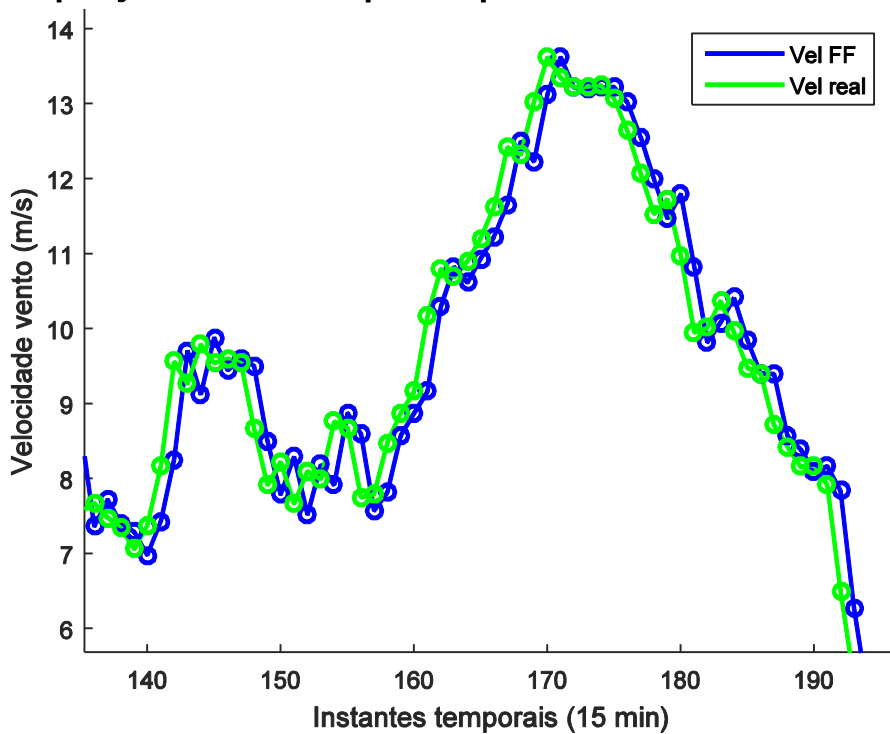


Figura 3-28 Comparação da velocidade prevista pelo modelo FF com a velocidade real.eps

Observa-se novamente que o *shift* não foi corrigido. No entanto, constata-se pela Tabela 3-14 que o RMSE diminuiu.

Tabela 3-14 Performance da rede neuronal FeedForward

Diferença temporal dos registos	15 minutos
RMSE teste (m/s)	0,49

3.3.4 Comparação das redes

Nesta seção comparam-se os erros de previsão de cada rede. O RMSE calculado é referente a registos de velocidade com 15 minutos de intervalo entre eles. Embora não seja este o horizonte de previsão que se quer testar nesta tese de mestrado, esta comparação constitui uma base para avaliar todas as redes, uma vez que todos os RMSE apresentados nos capítulos 3.3.2 e 3.3.3 são referentes a intervalos de 15 minutos. Ao analisar cuidadosamente todos os gráficos, observa-se que existe um *shift* entre os valores previstos e os valores medidos, ou seja, os valores previstos estão sempre atrasados em relação aos valores reais. Repara-se, no entanto, que o formato do gráfico é bastante bom, uma vez que a previsão acompanha as subidas e descidas da velocidade do vento. Este *shift* não é propositado, e resultante disso, os valores de RMSE acabam por ser maiores do que o esperado. O valor de erro agrava-se quando os registos de velocidade prevista sobem ou diminuem drasticamente. O valor do erro também aumenta quanto maior for o intervalo de previsão de velocidade. Através da Tabela 3-15, observa-se a comparação dos RMSE das redes neuronais construídas.

Tabela 3-15 Comparação dos RMSE de testes de todas as redes neuronais para intervalos temporais de 15 minutos

Rede neuronal	RMSE de teste (m/s)
NAR	0,69
NARX	0,52
IO	0,51
FEEDFORWARD	0,49

Naturalmente, escolhe-se o modelo de rede que apresenta o menor erro. A escolha final é a rede *feedforward* devido ao menor valor de RMSE e à simplicidade de construção. Esta rede neuronal é similar às anteriores apresentadas, mas é necessário construir o vetor de regressão temporal, ou seja, definir os *inputs* e *target*. De certa forma, esta necessidade confere um melhor controlo sobre a rede neuronal.

Apresenta-se de seguida o resultado da previsão da rede neuronal, se não existisse o *shift*, simplesmente para averiguar os resultados. Para isso, incorpora-se um atraso temporal na

previsão do vento. Observa-se que o RMSE associado diminuiu drasticamente, como se observa na Tabela 3-16.

Tabela 3-16 Performance da rede neuronal FeedForward com a incorporação de um atraso temporal na previsão do vento

Diferença temporal dos registos com o <i>shift</i> corrigido	15 minutos
RMSE teste (m/s)	0,12

O RMSE é bastante pequeno devido aos intervalos temporais de teste serem de apenas 15 minutos, e desta forma, a resposta gráfica da velocidade prevista e real serem quase coincidentes. Assim sendo, de forma a facilitar a compreensão gráfica, apresenta-se a previsão da velocidade do vento não com um intervalo de 15 minutos, mas sim de 1 hora. Como se pode observar na Figura 3-29, a previsão da velocidade do vento acompanha bastante bem a velocidade real do vento, divergindo apenas em alguns momentos e sem o *shift* associado.

Comparação da velocidade prevista pelo modelo FF com a velocidade real, retirando o shift manualmente

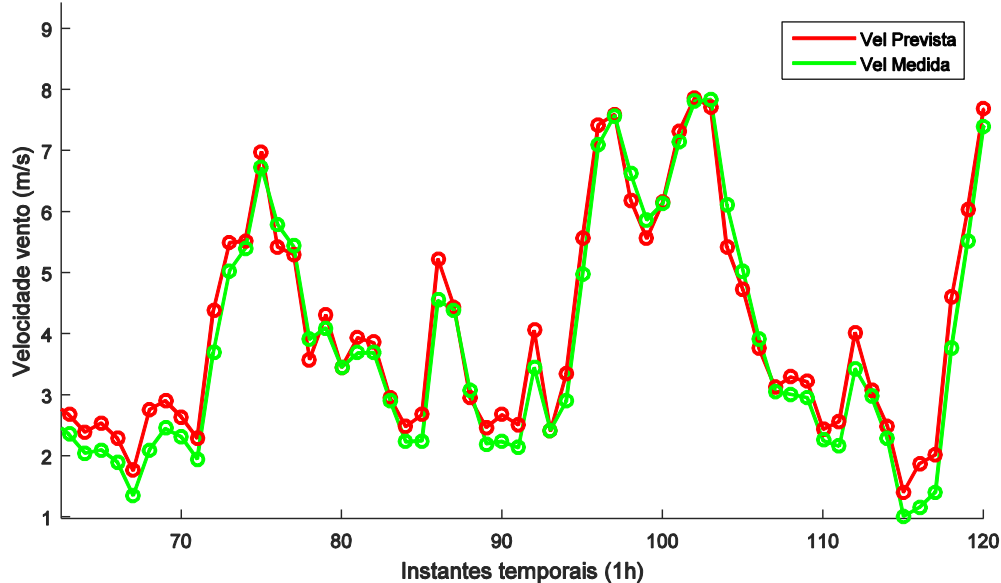


Figura 3-29 Comparação da velocidade prevista pelo modelo FeedForward com a velocidade real com a incorporação um atraso temporal na previsão do vento

Tendo em conta este fato, tenta-se corrigir o *shift*, para obter uma ótima previsão da velocidade do vento. Visto que o resultado do teste da rede neuronal Feedforward acompanha quase perfeitamente o *target* desejado, investiu-se algum tempo a tentar otimizar esta resposta da rede neuronal.

3.3.5 Tentativas de diminuição do erro de previsão

Tendo em conta que a construção anterior apresenta um *shift* bastante problemático na previsão da velocidade do vento, são apresentadas neste subcapítulo várias tentativas para correção desse *shift* observado no subcapítulo anterior. Desta forma, é testado o acoplamento de outro tipo de dados aos *inputs* já existentes, para averiguar a sua influência na diminuição do *shift*, e conseqüentemente, no erro de previsão. Como valores base, são utilizados o MAPE e o RMSE registados para o teste da rede neuronal depois de treinada, ou seja, os valores da Tabela 3-17.

Tabela 3-17 Valores base do teste de uma FF Neural Network, com *inputs* de velocidade para intervalos temporais de 1 hora

Performance Teste	MAPE (%)	RMSE (m/s)
Base	15,78	0,91

3.3.5.1 Introdução da direção do vento

Numa primeira perspetiva, tenta-se introduzir como *input* da rede neuronal os últimos registos de velocidades medidas, como já se fazia anteriormente, juntamente com o último registo da direção do vento.

Tabela 3-18 Performance do teste de uma FF Neural Network, com *inputs* de velocidade e direção do vento para intervalos temporais de 1 hora

Performance	MAPE (%)	RMSE (m/s)
Base	15,78	0,91
Mudança	16,00	0,92

Conclui-se que a adição da direção do vento aos *inputs* da rede neuronal não implica uma diminuição do RMSE. Não se apresenta uma representação gráfica da velocidade prevista, uma vez que seria bastante similar à Figura 3-28. Esta conclusão já seria espetável, uma vez que se esperava que a direção do vento não tivesse uma ação direta na velocidade do mesmo. Salienta-se, no entanto, que a incorporação da direção do vento nos *inputs* da rede neuronal poderia ter um efeito significativo se o *target* da rede fosse a potência produzida pelo parque, e não a velocidade medida no parque.

3.3.5.2 Introdução da tendência do sinal

Numa segunda perspetiva, tentou-se introduzir como *input* da rede neuronal as últimas velocidades medidas, juntamente com a diferença de $v_{t-1} - v_{t-3}$ para tentar mostrar à rede neuronal a tendência do sinal. Desta forma, se o resultado da equação em cima for positivo, o sinal está a crescer, ou seja, a velocidade está a aumentar. Se o resultado for negativo, a velocidade está a diminuir.

Pretende-se que a rede ao saber se a velocidade do vento está a aumentar ou diminuir, pudesse responder mais rapidamente na previsão da próxima amostra temporal e, desta forma, reduzir o *shift*.

Tabela 3-19 Performance do teste de uma FF Neural Network, com inputs de velocidade e tendência do sinal para intervalos temporais de 1 hora

Performance	MAPE (%)	RMSE (m/s)
Base	15,78	0,91
Mudança	16,59	0,92

Novamente, o resultado da mudança tem um impacto pouco significativo ou nulo na diminuição do RMSE, pelo que a solução não foi encontrada.

3.3.5.3 Introdução do Exponential Moving Average

Em estatística, uma média amovível, é um cálculo para ajudar a suavizar uma determinada série temporal, filtrando o ruído causado pelas flutuações nos valores dessa série temporal. Esta média é calculada através de diferentes conjuntos de dados relativamente ao conjunto completo.

Este tipo de aproximação é muito usual nos mercados bolsistas para suavizar os preços de determinados produtos ou ações. Para averiguar qual a média amovível que se adapta melhor aos dados, apresenta-se, na Figura 3-30, a aproximação de um sinal de velocidade de vento no tempo com várias *moving averages*: simple moving average (SMA), exponential moving average (EMA) e triangular moving average (TMA).

Desempenho de 3 diferentes moving averages a aproximar o comportamento da velocidade do vento

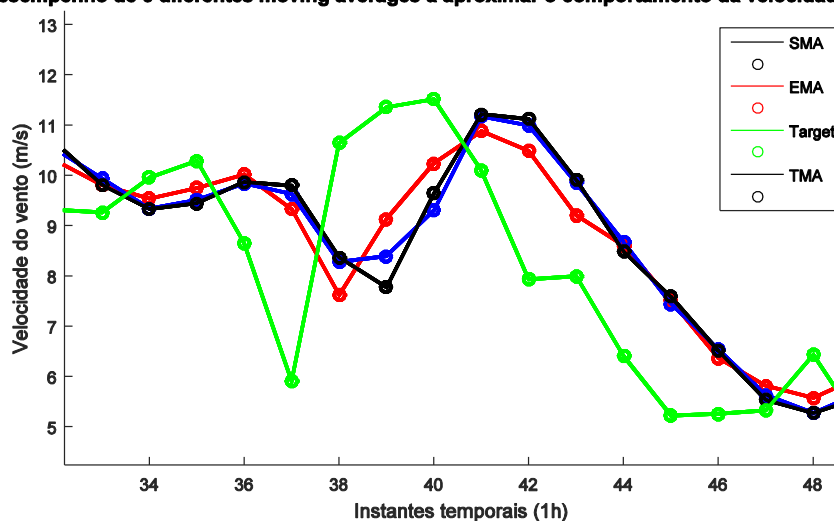


Figura 3-30 Desempenho de três diferentes *moving averages* a suavizar o comportamento da série temporal da velocidade do vento

Facilmente se observa que a curva vermelha (EMA) é a média amovível que se aproxima mais da curva verde (Target), seguida pela SMA e posteriormente pela TMA. Constata-se na Tabela 3-20, através da comparação do RMSE entre a aproximação e o *target*, que a EMA é efetivamente a melhor aproximação.

Tabela 3-20 Performance de 3 moving averages diferentes a suavizar o comportamento da velocidade do vento

Moving Average	RMSE (m/s)
EMA	1,1792
SMA	1,2922
TMA	1,3274

Consequentemente, tentou-se introduzir como *input* da rede neuronal as últimas velocidades medidas, juntamente com a EMA dos últimos registos de velocidade medidos na tentativa de diminuir o erro associado.

Tabela 3-21 Performance do teste de uma FF Neural Network, com *inputs* de velocidade e EMA do sinal para intervalos temporais de 1 hora

Performance	MAPE (%)	RMSE (m/s)
Base	15,78	0,91
Mudança	16,58	0,93

Verifica-se que o RMSE não foi diminuído, e conseqüentemente esta alteração não é satisfatória.

3.3.5.4 Introdução de Hibert Huang Transformation

Em (Shi, Lee, Tx, & Wang, 2011), o método de Hilbert-Huang (HHT) corresponde a uma transformação do sinal temporal não linear e não estacionário, num sinal dividido em várias componentes, mas em frequências mais baixas. Ou seja, alisa-se o sinal original, e produzem-se componentes do sinal cada vez com maior período de onda. Estas componentes contêm informação quanto ao aumento ou diminuição da velocidade do vento, ou seja, a tendência do vento. Cada uma destas componentes chama-se *intrinsic mode functions* (imf) do sinal e foi calculada através de funções em matlab@.

No artigo mencionado, verifica-se exatamente o mesmo *shift* que se pode observar no capítulo 3.3.3.. Conseqüentemente, constata-se que o *shift* pode ser resolvido com a junção aos *inputs* das componentes de HHT. Felizmente, observa-se que os resultados obtidos no artigo antes de realizar a transformação de HHT, são piores do que os observados no capítulo 3.3.3, razão pela qual se acredita que depois de conseguir realizar esta transformação, os resultados obtidos com este modelo serão bastantes satisfatórios e inclusive melhores do que os obtidos por Hilbert e Huang.

Os autores não especificam de que maneira é que as componentes do sinal geradas pelo HHT vão ser usadas para diminuir o *shift*. Considera-se a hipótese de que a velocidade do vento num determinado mês do ano, siga o mesmo padrão no ano seguinte, ou seja, estima-se que o vento nos meses de Abril de 2015 siga o mesmo padrão do que o vento de Abril de 2016. Em contraste, o vento do mês de Dezembro de 2015, terá um padrão diferente dos dois anteriores apresentados. Conseqüentemente, se for conhecido o período do sinal em Abril de 2015, poder-se-á estimar o comportamento da velocidade no mês de Abril de 2016. Desta forma, será possível saber o comportamento futuro do sinal, com base no comportamento num período homólogo do ano transato. Saliencia-se que é considerado o mês de Abril como exemplo, uma vez que é o único mês com dados de 2015 e 2016, e assim sendo, pode ser testada a teoria. Para validar esta teoria apresenta-se o estudo realizado. Inicialmente são comparadas na Figura 3-31 as velocidades de Abril de 2015, Abril de 2016 e Dezembro de 2015. Refere-se que seria benéfico possuir mais anos de dados para verificar estas tendências, contudo estes não se encontram disponíveis.

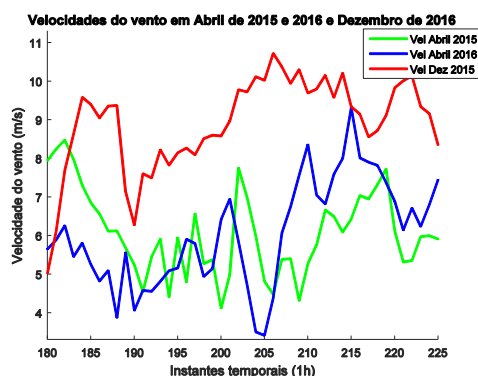


Figura 3-31 Velocidades do vento em Abril de 2015 e 2016 e Dezembro de 2016

Como seria de prever, as velocidades de Abril de 2015 e 2016 são similares, enquanto a velocidade de Dezembro de 2015 é diferente das duas anteriormente referidas. Apresentam-se agora, na Figura 3-32 e Figura 3-33, as componentes imf do sinal para o mês de Abril de 2015 e 2016.

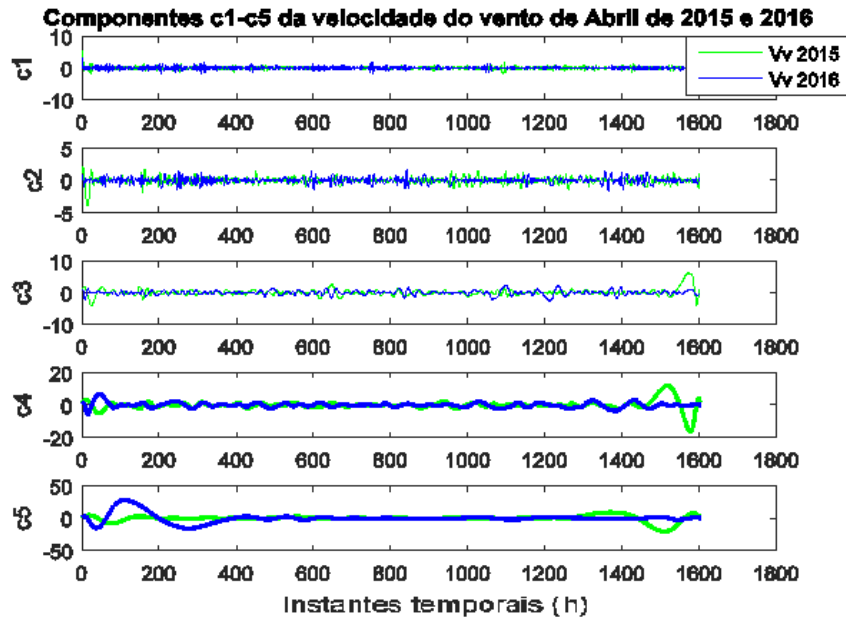


Figura 3-32 Componentes c1-c5 da velocidade do vento de Abril de 2015 e 2016




Figura 3-33 Componentes c6-c8 com r da velocidade do vento de Abril de 2015 e 2016

Apresentam-se agora, na Figura 3-34 e Figura 3-35, as componentes imf do sinal para o mês de Abril e Dezembro de 2015.

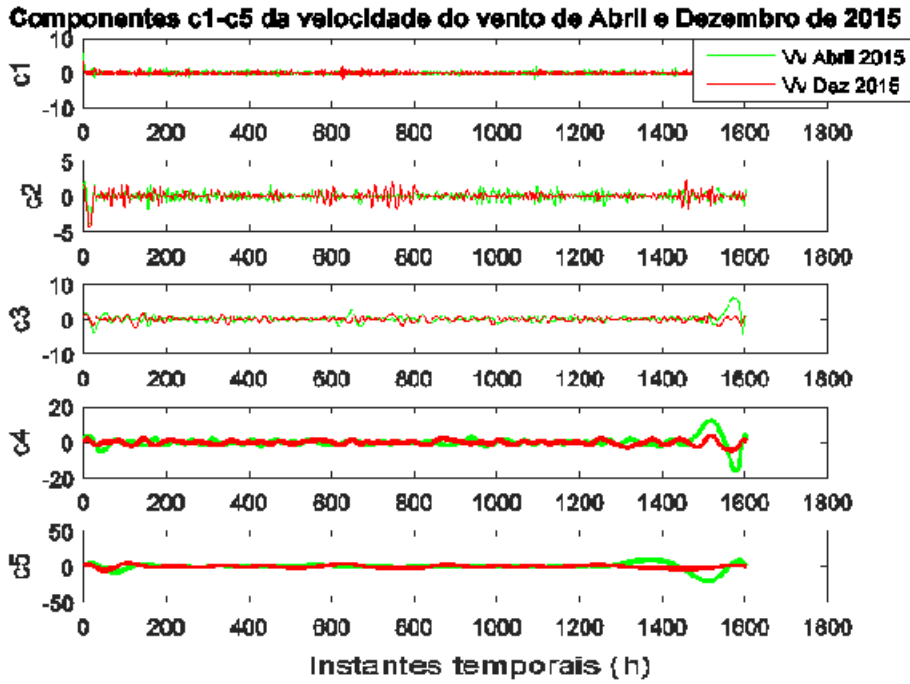


Figura 3-34 Componentes c1-c5 da velocidade do vento de Abril e Dezembro de 2015

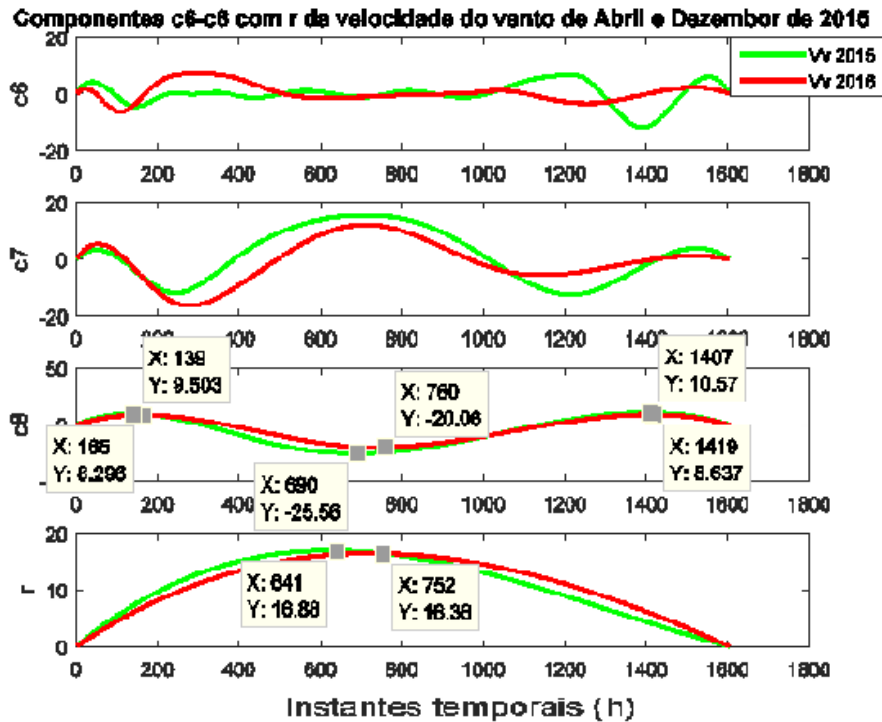


Figura 3-35 Componentes c6-c8 com r da velocidade do vento de Abril e Dezembro de 2015

Através da observação atenta da Figura 3-33 e da Figura 3-35, extrapola-se que as componentes imf do sinal para o mês de Abril de 2015 e 2016 apresentam aproximadamente os mesmos mínimos e máximos relativos. Contrariamente, as componentes imf do sinal para o mês

de Abril e Dezembro de 2015 apresentam mínimos e máximos relativos desfasados e não coincidentes. Recordar-se que os dados apresentados estão em horas, significando isto que um desfasamento de aproximadamente 50, embora pouco perceptível no gráfico, corresponde a uma diferença de dois dias.

Infelizmente, não foi possível testar o acoplamento do HHT com os *inputs* de velocidade do vento já referidos. Esta fase do trabalho é considerado como trabalho futuro e continuação da tese de mestrado. O objetivo é usar o imf de 2016 para prever a tendência do vento de 2017, em períodos homólogos, tendo como base que o imf de Abril de 2015 é parecido com o de 2016. Consequentemente, espera-se que possa também ser similar com o de 2017, de maneira a que se possa prever se o vento terá tendência em subir ou descer nesse período.

3.4 Modelo do parque eólico

O modelo do parque eólico é necessário para converter as velocidades estimadas na rede neuronal em potência elétrica. Para uma avaliação focada somente no comportamento do modelo, não são tidas em conta nesta fase as velocidades previstas na rede neuronal, mas somente a velocidade do vento medida no parque, o número de aerogeradores ativos e a potência efetivamente produzida no parque.

Este passo é fulcral na construção do modelo de previsão de potência, uma vez que uma conversão incorreta de vento em potência pode agravar muito o erro de previsão total.

3.4.1 Modelo com a expressão geral

A primeira tentativa para a construção deste modelo foi utilizada a equação (1.1), visto que se conhecia a velocidade estimada do vento e que se tinha conhecimento dos restantes parâmetros da mesma, uma vez que esses são fornecidos pelo fabricante das turbinas eólicas. Para fazer uma avaliação correta do comportamento do modelo, aplicou-se o algoritmo para cada velocidade prevista numa gama de valores elevada (testaram-se aproximadamente 23000 velocidades previstas, em intervalos de 15 minutos).

Indicam-se na Tabela 3-22 as considerações iniciais dos parâmetros necessários para o cálculo da equação (1.1).

Tabela 3-22 Tabela com considerações iniciais para o modelo com a expressão geral

Considerações iniciais	Valores
Densidade do ar	1,225 kg/m ³
Diâmetro do rotor	82 m
Área de varrimento das pás	5281 m ²

Relativamente ao C_p , coeficiente de potência, sabe-se que é variável consoante a velocidade do vento, como se pode observar na Figura 3-1 (gráfico a vermelho). Recorde-se que

este gráfico é construído para $\rho = 1.225 \text{ Kg/m}^3$. Tendo em conta que a empresa fabricante dos geradores eólicos apenas divulga o C_p , para valores de velocidade do vento na casa das unidades, não se tem acesso ao C_p , exato para uma velocidade com valor decimal. Toma-se como exemplo a velocidade de 8.53 m/s. De forma a ultrapassar este problema, é realizada uma aproximação linear entre os valores de C_p , imediatamente antes e depois da velocidade medida, neste caso 8 e 9 m/s, respetivamente. Uma vez calculada a reta que aproxima a união destes pontos, é utilizada a velocidade do vento como valor de x e o C_p , como o respetivo valor de y, tomando como equação $y = mx + b$.

Relativamente ao ρ , considera-se o valor padrão de 1.225 Kg/m^3 . Sabe-se, no entanto, que este valor é uma variável bastante importante na atmosfera, uma vez que diminui com o aumento da altitude e que também varia com a alteração de temperatura. Tendo em conta que os valores de pressão atmosférica não estão acessíveis nos parques eólicos, esta variável é considerada com o valor constante referenciado em cima.

Tendo calculados todos os valores necessários para calcular a equação (1.1), efetua-se o cálculo da potência prevista. Relembra-se que este valor é correspondente apenas a um aerogerador, no centro do parque. Para se extrapolar esta potência para o parque eólico, multiplica-se a potência de um aerogerador pelo número de aerogeradores ativos no momento em que o valor da velocidade foi medida, como se observa na equação (3.4).

$$Pot_{parque} = Pot_{aerogerador} * Num_{aerogeradores \text{ ativos}} \quad (3.4)$$

Para averiguar visualmente a resposta do modelo, apresenta-se na Figura 3-36 a comparação da potência calculada pelo modelo com a expressão geral e da potência real medida no parque.




Figura 3-36 Comparação do modelo com base na expressão geral da potência com o valor real

Para uma melhor compreensão da performance deste modelo, apresenta-se na Figura 3-37 um gráfico com a evolução da diferença em MW entre a resposta do modelo e a potência real.




Figura 3-37 Erro do modelo com base na expressão geral da potência em relação ao valor real

Na Tabela 3-23 apresentam-se duas formas de medição desse erro. Salienta-se que para efeitos de gráfico são considerados apenas 100 pontos, de forma a tornar perceptível a leitura do mesmo. No cálculo do erro na tabela são usados, naturalmente, todos os valores.

Tabela 3-23 Avaliação do erro do modelo com base na expressão geral

Erro	Valor
MAPE	18,18 %
RMSE	1,54 MW

Concluindo, como o valor de ρ é considerado constante ao longo do tempo, este fato pode provocar um erro significativo, uma vez que este deveria variar consoante a altitude do parque e a estação do ano. Salienta-se ainda que a potência calculada pelo modelo é na maioria do tempo superior à potência real. Isto pode dever-se ao valor elevado de ρ , significando que o seu valor real seria menor, o que estaria de acordo com o enunciado. Também a aproximação linear de C_p pode introduzir um erro bastante grande. Embora a curva teórica do C_p esteja definida para os valores de velocidade unitários, não está definida para os valores decimais. Desta forma, ao calcular uma aproximação de uma reta em zonas da curva do C_p que são curvilíneas, podem ser

introduzidas alterações significativas, quando este valor é multiplicado por valores na ordem dos MW, como se pode verificar.

3.4.2 Modelo com a curva característica do aerogerador

Visto que o modelo anterior apresentava um erro bastante grande de conversão de velocidade do vento em potência, foi necessário criar um novo algoritmo. Tendo em conta que grande parte do erro do modelo anterior estava associado à variação de ρ , cria-se um novo modelo independente de ρ .

Assim sendo, criou-se o modelo com base na curva característica do aerogerador. Observando a Figura 3-1 (gráfico a cinzento), percebe-se que esta relaciona a velocidade do vento com a potência gerada por um aerogerador. Tal como realizado para o modelo anterior, e tendo em conta que a empresa fabricante dos geradores eólicos apenas divulga a potência gerada para valores de velocidade do vento na casa das unidades, não se tem acesso à potência exata para uma velocidade com valor decimal. Toma-se, novamente, como exemplo a velocidade de 8.53 m/s. É realizada uma aproximação linear entre os valores de potência imediatamente antes e depois da velocidade medida, neste caso 8 e 9 m/s, respetivamente. Uma vez calculada a reta que aproxima a união destes pontos, é utilizada a velocidade do vento como valor de x e a potência, como o respetivo valor de y , tomando como equação $y = mx + b$. Quando se calcula a potência gerada pelo modelo para um aerogerador, aplica-se novamente a equação (3.4), para calcular a potência total do parque.

Na Figura 3-38, apresenta-se a comparação do modelo com base na curva característica do aerogerador com o valor real. São novamente apresentados somente os 100 primeiros pontos nas figuras, e são usados todos os valores para o cálculo dos erros.




Figura 3-38 Comparação do modelo com base na curva característica do aerogerador com o valor real

Na Figura 3-39, apresenta-se o erro do modelo com base na curva característica do aerogerador em relação ao valor real.




Figura 3-39 Erro do modelo com base na curva característica do aerogerador em relação ao valor real

Na Tabela 3-24, apresenta-se avaliação do erro do modelo com base na curva característica do aerogerador.

Tabela 3-24 Avaliação do erro do modelo com base na curva característica do aerogerador

Erro	Valor
MAPE	17,32 %
RMSE	1,25 MW

Concluindo, observa-se que a potência estimada pelo modelo com base na curva característica do aerogerador e pelo modelo com base na expressão geral são bastante semelhantes, o que seria de esperar uma vez que o mecanismo para o seu cálculo foi parecido, embora tenham sido calculados com base em informações diferentes. Como a curva característica apresentada na Figura 3-1 é também referente a uma densidade do ar $\rho = 1.225 \text{ Kg/m}^3$, o problema associado ao modelo anterior mantém-se. Novamente, verifica-se que a aproximação linear não é suficiente para representar os valores de velocidades do vento com valor decimal. Embora o erro da resposta do modelo tenha reduzido ligeiramente, verifica-se que o modelo apresentando não é suficiente bom.

3.4.3 Modelo com dados SCADA dividido por estações do ano

Analisando os erros dos dois modelos apresentados anteriormente, verifica-se que esta metodologia não é suficientemente boa para que o resultado seja aceitável. Desta forma, é necessária uma alteração de metodologia para que o erro diminua.

Desta forma, era necessário um método que não estivesse dependente do valor de p . Apresenta-se uma nova metodologia com base nos próprios dados recolhidos das bases de dados da REN. Analisando estes dados, verifica-se que no mesmo instante são registados os valores de velocidades, número de aerogeradores ativos e potência elétrica total gerada no parque. Aplicando a equação (3.3), ou seja, dividindo a potência total gerada no parque pelo número de aerogeradores ativos, obtêm-se a potência gerada em cada aerogerador. Desta forma, pode-se fazer uma relação entre a velocidade do vento registado no parque e a potência gerada por um aerogerador. Esta relação é, conforme foi anteriormente referida, a curva característica do aerogerador. No entanto, a curva característica referida anteriormente é uma curva teórica, fornecida pelo fabricante do gerador eólico, enquanto a curva utilizada neste modelo é obtida através do próprio aerogerador. Consegue-se, desta forma, anular a necessidade de utilização da densidade do ar na construção do modelo.

Assim sendo, quando uma velocidade de vento é introduzida no modelo, este vai procurar todos os registos que tem com a mesma velocidade (exatidão até as centésimas), e faz uma média das respetivas potências para essa velocidade. Se não existir nenhum registo da velocidade que se quer analisar, o modelo procura registos de velocidades com $\pm 0.01 \text{ m/s}$. Uma vez que encontre esses valores, efetua o mesmo mecanismo que anteriormente. Neste modelo são analisados os registos de minuto em minuto, e não as médias de 15 minutos que se efetuaram para a introdução nas redes neuronais, para não reduzir os registos de velocidades usados no modelo.

No entanto, tomando como exemplo a velocidade de 8.53 m/s , verifica-se que este valor pode ocorrer durante um dia de calor ou durante um dia de chuva e que a potência produzida pelo parque apresenta medições de potência bastante divergentes. Consequentemente, o erro relativo a este modelo, pode variar entre muito bom e mau, consoante os registos de velocidades e potências armazenados. De forma a mitigar este erro, apresenta-se o modelo com base nas estações do ano. Com base em análises efetuadas aos dados, apresenta-se a Figura 3-40, como possibilidade de divisão dos dados.




Figura 3-40 Modelo do aerogerador de Inverno e Verão

Assim sendo, existem dois conjuntos de registos divididos em Verão e Primavera (1 Março até 31 Agosto) e Inverno e Outono (1 Setembro até 28 Fevereiro). Verifica-se uma certa semelhança desta análise, pela simples observação de que os valores de Inverno ocupam uma larga maioria das velocidades do vento maiores do que 15 m/s, visto que a velocidade do vento no Inverno é, por norma, maior do que no Verão.




Figura 3-41 Comparação do modelo com base nos dados SCADA divididos por estação do ano

Observa-se, na Figura 3-41, a comparação do modelo com base nos dados SCADA divididos por estação do ano, como indicado em cima. Note-se que os dados para os quais este modelo foi testado são diferentes dos dados de teste para os modelos anteriores, uma vez que para testar cada modelo, foram analisados dois conjuntos de dados, os de Verão e Inverno. O valor de erro apresentado em todos os modelos é uma média dos dois erros obtidos, com os diferentes conjuntos. Nos dois primeiros modelos, foi apresentado o primeiro conjunto de dados, nos modelos com base nos dados do SCADA, é a apresentado o segundo conjunto de dados.

Naturalmente, observa-se que a potência estimada pelo modelo já é uma aproximação bastante razoável à potência real. Verifica-se, no entanto, que para uma potência gerada muito grande (36 MW), o que equivale à capacidade nominal do parque, o modelo não consegue responder muito bem. Isto deve-se aos poucos registos de dados SCADA em situações em que o parque eólico esteja a produzir uma potência igual à sua potência nominal.

Na Figura 3-42, observa-se o erro do modelo com base nos dados SCADA divididos por estação do ano. Embora na sua generalidade, o erro seja bastante reduzido, existem alguns picos, em que a potência prevista pelo modelo é bastante diferente da potência real. Na Tabela 3-25, apresentam-se as métricas do erro.




Figura 3-42 Erro do modelo com base nos dados SCADA divididos por estação do ano

Tabela 3-25 Avaliação do erro do modelo com base nos dados SCADA divididos por estação do ano

Erro	Valor
MAPE	5,36 %
RMSE	1,37 MW

Como se pode observar, o MAPE foi bastante reduzido, querendo indicar que este tipo de modelo é melhor do que o anterior. Embora apresente maiores picos no gráfico do erro, apresenta menos picos do que os modelos passados, querendo indicar que apenas pontualmente não consegue realizar a transformação com exatidão.

3.4.4 Modelo com dados SCADA divididos por mês e hora

Uma vez que o modelo com dados SCADA divididos por estação do ano, apresentava um erro razoavelmente bom, significava que o método adotado era satisfatório. No entanto, para o tentar melhorar, foram testadas outras vertentes.

Uma das vertentes testadas, foi a divisão dos dados SCADA por mês e hora. Através da visualização dos dados, especificamente da Figura 3-5 até à Figura 3-12, observa-se que a forma da velocidade do vento se repete diariamente, variando a intensidade consoante a hora do dia, e mensalmente consoante a estação do ano. No entanto, a divisão dos dados por mês permite fazer uma melhor aproximação, ou seja, para a construção do modelo com dados SCADA divididos por mês e hora, foi utilizada a mesma metodologia do que no modelo anterior, mas com um filtro mais fino, esperando que esta transformação fizesse reduzir o erro associado.

Apresenta-se na Figura 3-43, o desempenho do modelo final.




Figura 3-43 Comparação do modelo com base nos dados SCADA divididos por mês e hora

Na Figura 3-44 observa-se o erro do modelo com base nos dados SCADA divididos por mês e hora. Existe apenas um grande pico, e mais uma vez se verifica que ocorre para velocidade do vento muito grandes.




Figura 3-44 Erro do modelo com base nos dados SCADA divididos por mês

Na Tabela 3-26 apresenta-se a avaliação do erro do modelo com base nos dados SCADA divididos por mês e hora. Verifica-se o menor registro de MAPE e RMSE de todos os modelos analisados.

Tabela 3-26 Avaliação do erro do modelo com base nos dados SCADA divididos por estação do ano

Erro	Valor
MAPE	4,70 %
RMSE	1,17 MW

Este é o modelo que transforma a velocidade do vento em potência gerada pelo parque com o menor erro possível. Comparando com o anterior, naturalmente verifica-se que mantêm a mesma forma, mas pontualmente constata-se que faz uma melhor aproximação aos valores reais. Conseqüentemente escolhe-se este modelo para receber a previsão da velocidade do vento e transforma-la em potência.

3.4.5 Comparação dos vários modelos

Apresenta-se, na Tabela 3-27, a comparação dos modelos criados para transformar velocidade do vento no parque em potência elétrica. Observa-se que os novos modelos vão sendo capazes de reduzir o erro de cálculo. Uma vez que todos os erros, ao longo dos vários processos realizados, são cumulativos até ao valor final, é importante reduzir ao máximo cada

um deles. Verifica-se que desde o modelo inicial até ao final, acontece uma redução significativa do erro.

Constata-se que os modelos que utilizam os dados SCADA apresentam resultados mais fiáveis do que outros. Naturalmente, este fato deve-se à falta de informação por parte do fornecedor de turbinas eólicas. A utilização de dados SCADA revelou-se uma solução bastante fidedigna. Elege-se, finalmente, o modelo com base em dados SCADA divididos por mês e hora para ser o modelo utilizado na conversão de velocidade de vento para potência.

Tabela 3-27 Comparação dos modelos criados para transformar velocidade em potência

Modelo	MAPE (%)	RMSE (MW)
Com a expressão geral	18,18	1,54
Com a curva característica do aerogerador	17,32	1,25
Com dados SCADA dividido por estações do ano	5,37	1,37
Com dados SCADA divididos por mês e hora	4,70	1,17

Note-se que para o cálculo do MAPE, visto que requer a divisão pelo valor real, pode ocorrer que este valor real seja muito pequeno, o que traz implicações. Qualquer número dividido por um valor muito pequeno, resulta num valor bastante grande. De forma a não provocar um aumento exacerbado no valor calculado de erro, apenas são tidos em conta valores de potências maiores do que 1 MW. Desta forma, explica-se o decréscimo acentuado desta medida de erro em função das outras, não evitando, no entanto, que este modelo seja o melhor de entre todos os apresentados.

Constata-se que os modelos baseados em dados do SCADA não conseguem fazer uma boa transformação, quando são sujeitos a velocidades muito elevadas e conseqüentemente potências muito elevadas. Este fato verifica-se, uma vez que, não existem muitos registos no ano de dados disponível, referente a potências próximas da potência nominal. Desta forma, é necessário recolher mais dados no ano seguinte. Naturalmente, quanto maior o número de dados registados, maior será a exatidão deste modelo. Tendo em conta que para a realização desta tese de mestrado estavam apenas disponíveis dados de um ano, os modelos deste tipo têm tendência a ficar mais exatos com o aumento do número de registos.

3.5 Modelo final

Neste capítulo apresenta-se o modelo final de previsão da potência elétrica para um determinado parque eólico, ou seja, junta-se a previsão da velocidade do vento, descrita no capítulo 3.3, com a transformação da velocidade do vento previsto para potência, descrito no capítulo 3.4 e obtêm-se os valores finais de previsão de vento e potência. Tendo em conta o processo descrito, conclui-se que a melhor hipótese para realizar esta previsão será utilizando

uma rede neuronal FF e posteriormente transformar essa velocidade prevista através do modelo com dados SCADA divididos por mês e hora, respectivamente o capítulo 3.3.3 e 3.4.4.

Apresenta-se nas Figura 3-45 e Figura 3-46 a comparação do modelo final de previsão de potência com a potência medida e o erro entre a potência medida e a prevista, respectivamente.

Comparação do modelo final de previsão de potência com a potência medida

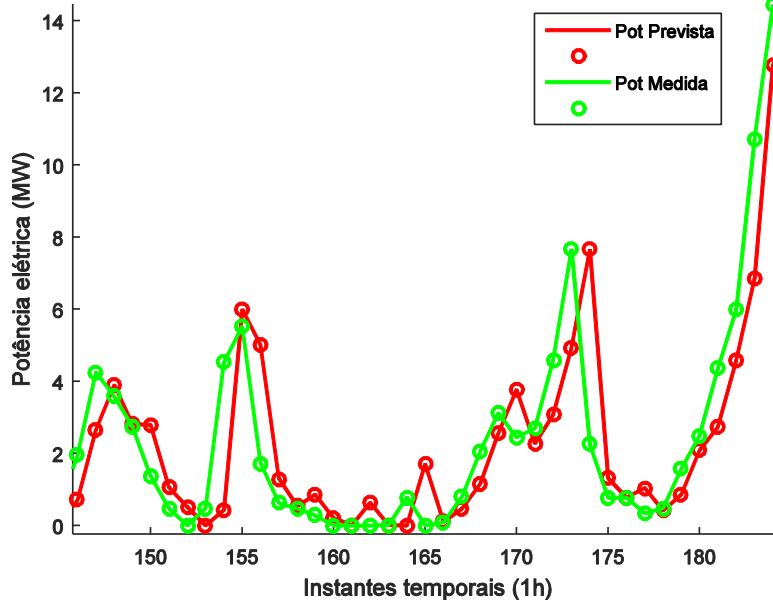


Figura 3-45 Comparação do modelo final de previsão de potência com a potência medida

Erro entre a potência medida e a prevista

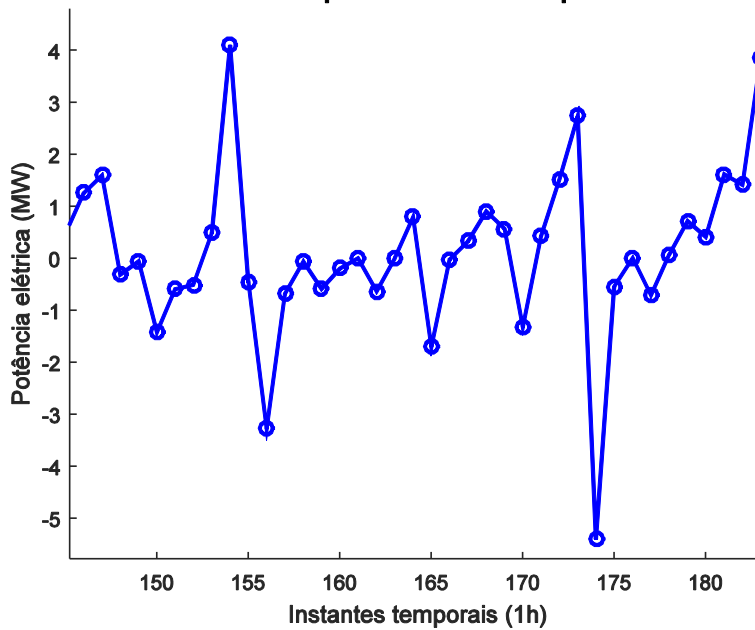


Figura 3-46 Erro entre a potência medida e a prevista

Observa-se que o *shift* se mantém, o que faz com que o RMSE seja elevado. No entanto, este apenas tem um peso significativo no RMSE nas variações repentinas da velocidade, uma vez que nesse momento o acompanhamento da resposta da rede neuronal é lento.

Na Tabela 3-28 apresenta-se a performance deste modelo na previsão de vários intervalos temporais.

Tabela 3-28 Performance do modelo FF com a transformação do modelo com dados SCADA divididos por mês e hora na previsão da potência elétrica do parque eólico de Arganil

Intervalos temporais	MAPE (%)	RMSE (MW)
15 m	10,91	1,77
30 m	13,98	2,13
1 h	17,83	2,94
2 h	26,91	4,12

Conclui-se que a correção do *shift* é essencial para a melhoria do modelo.

3.6 Generalização do modelo para outros parques

Embora o modelo necessite de continuar a ser melhorado para atingir um erro mais reduzido, uma dos objetivos do trabalho era também fazer uma generalização do modelo de previsão e averiguar se este é adaptável a outros parques eólicos.

Para isso foi realizado exatamente o mesmo processo que se descreveu no capítulo 3.2, uma vez que o *script* foi programado já com este objetivo. Os novos parques eólicos escolhidos foram o parque eólico da Lourinhã e de Montalegre, por representarem respetivamente menor e maior potência nominal em relação ao parque eólico de Arganil. As exigências para a escolha do segundo parque são exatamente as mesmas que para o primeiro. Apresenta-se na Tabela 3-29, a performance do modelo em relação aos três parques eólicos apresentados.

Tabela 3-29 Generalização do modelo FF com a transformação do modelo com dados SCADA divididos por mês e hora na previsão da velocidade do vento e potência elétrica de vários parques eólicos com intervalos temporais de 1 hora

Parque eólico	Potencial nominal parque	MAPE_1 (%)	RMSE_1 (m/s)	MAPE_2 (%)	RMSE_2 (MW)
Lourinhã	17,7	12,85	0,90	22,02	2,17
Arganil	36,9	16,41	0,91	17,83	2,94
Montalegre	60	11,04	0,88	24,18	4,97

Nesta tabela, é possível analisar o desempenho do modelo a prever a velocidade do vento em cada parque eólico (número 1), assim como analisar a sua performance a transformar velocidade de vento prevista em potência elétrica prevista (número 2) em diferentes parques eólicos. Como se pode observar a previsão da velocidade do vento (MAPE_1 e RMSE_1), são aproximadamente iguais para todos os parques analisados, verificando-se inclusive uma melhoria para os parques da Lourinhã e Montalegre. A transformação de velocidade de vento para potência prevista também segue valores aproximados aos do parque original do Alto de Arganil, embora sejam um pouco mais elevados.

Concluiu-se que o modelo de previsão de vento e potência pode ser generalizado para outros parques, embora deva ser otimizado uma vez que apresenta valores de erro um pouco mais elevados para parques diferentes aos do parque original.

4 Discussão dos resultados

O trabalho descrito nesta dissertação de mestrado foi dividida em três grandes etapas: recolha e tratamento de dados, construção e teste do modelo de previsão da velocidade do vento e construção e teste do modelo de transformação de velocidade do vento em potência elétrica do parque. Neste capítulo discutem-se os erros obtidos para cada uma das etapas. Uma vez que estes são acumulados ao longo dos vários processos realizados, é importante reduzi-los ao máximo em cada etapa.

A primeira etapa consistiu na recolha de dados, pelo que não foi construído um modelo para essa recolha de dados da REN. O tratamento dos dados foi realizado com base em médias ponderadas. Esta etapa pode ser analisada nos capítulos 3.1 e 3.2.

A segunda etapa consistiu na construção e teste do modelo de previsão da velocidade do vento. Nesta etapa foram construídos quatro modelos de previsão, com base em quatro metodologias diferentes de redes neuronais. Através da Tabela 3-15, observa-se a comparação dos RMSE dos testes das redes neuronais construídas. Observa-se que os resultados são bastante similares entre eles, escolhendo-se evidentemente a rede que apresenta menor erro e maior simplicidade de construção, a rede *feedforward*. No entanto, verifica-se que o resultado da previsão de todas as redes apresenta um *shift* em relação ao *target*. Embora a previsão seja realizada com sucesso, este *shift* induz um erro maior do que seria expetável. O seu efeito ganha expressão, quando existe uma variação repentina de velocidade do vento, pois a previsão da rede não consegue acompanhar essa variação repentina do vento. Testa-se a incorporação de um atraso temporal na previsão do vento e verifica-se que o erro de previsão diminui quatro vezes em relação à previsão inicial, o que apresentaria resultados bastante satisfatórios. Desta forma, tenta-se encontrar uma solução para esta correção. O HHT apresenta-se como a solução mais promissora, uma vez que já foi utilizada num trabalho com um problema semelhante com sucesso. Este método não foi totalmente implementado por falta de tempo, pelo que não foi possível testar esta junção ao modelo já desenvolvido. No entanto, com o modelo atual, é possível realizar previsões com uma janela temporal de 1 hora, com um erro de RMSE de 0,91 m/s, menos do que 1 m/s. Este resultado é bastante aceitável, e tendo em conta que pode vir a ser melhorado apresenta-se como bastante promissor. Esta etapa pode ser analisada nos capítulos 3.3.

A terceira etapa consistiu na construção e teste do modelo de transformação de velocidade do vento em potência elétrica do parque. Para isso foram construídos quatro modelos diferente. Através da Tabela 3-27, pode-se observar a performance de cada um deles. Constata-se que os modelos que utilizam os dados SCADA apresentam resultados mais fiáveis do que os modelos com base nas características do aerogerador ou do modelo da expressão geral, revelando-se uma solução bastante fidedigna, elegendo-se, o modelo com base em dados SCADA divididos por mês e hora. Estes não conseguem fazer uma boa transformação, quando são sujeitos a velocidades muito elevadas, uma vez que não existem muitos registos no ano de dados disponível para esta tese de mestrado, referente a potências próximas da potência nominal. Naturalmente, quanto maior o número de dados registados, maior será a exatidão deste modelo.

O modelo de transformação eleito apresenta um MAPE de 4.70% e um RMSE de 1.17 MW, o que significa que este modelo é bastante útil e dentro das expectativas do operador do sistema, uma vez que tem erros bastante pequenos. Esta etapa pode ser analisada nos capítulos 3.4.

O modelo final da tese de mestrado consiste na junção dos dois modelos anteriormente referidos. Visto que o erro é acumulado ao longo do processo, obtêm-se um RMSE final de previsão de potência elétrica no parque eólico de 2.94 MW e um MAPE de cerca de 17%, para a previsão de uma janela temporal de 1 hora. Estes dados podem ser analisados na Tabela 3-28. Para averiguar a validade do modelo criado apresenta-se a comparação direta da previsão de potência realizada entre o modelo desenvolvido nesta dissertação e o modelo desenvolvido no artigo (Xia et al., 2010), nomeadamente na comparação dos RMSE obtidos através de intervalos de 30 minutos. Comparando a Tabela 3-28, representativa do desempenho desta dissertação, e lendo o artigo mencionado, constata-se que os RMSE apresentados são respetivamente de 13.98% e de 13.35%, concluindo-se que o modelo desenvolvido tem efetivamente um desempenho similar a outros modelos já construídos. É feita a comparação para o RMSE de 30 minutos, uma vez que este artigo apenas apresenta resultados para esta janela temporal.

Na tentativa de comparar o modelo criado com os modelos das empresas que atualmente oferecem serviço à REN, analisou-se o diagrama de produção eólica disponibilizado na *internet* pela empresa, e adicionado no Anexo A. Através da leitura do gráfico, percebe-se que num dia de variação constante da velocidade média do vento, a previsão da potência a nível nacional pode atingir um MAPE de aproximadamente 50%, enquanto num dia de vento constante, pode atingir um MAPE de aproximadamente 20%. Salienta-se que não é possível fazer uma comparação direta entre os dois modelos uma vez que a REN apenas disponibiliza a previsão a nível nacional, e não para cada parque eólico. Destaca-se também que os valores indicados são apenas representativos, uma vez que foram extrapolados de um gráfico, sem acesso aos valores reais. Note-se ainda que é desconhecido o período de previsão usado pela REN para obter estes resultados, embora se acredite que são realizadas 4 previsões por dia, ou seja, com um período de 6 horas entre elas.

Salienta-se que o tempo de treino da rede neuronal nesta dissertação é de 6 minutos. No entanto, apenas é necessário realizar este processo uma vez, visto que posteriormente se pode usar um modelo já treinado da rede neuronal. Para se testar a rede neuronal, simplesmente aplicam-se os dados de *input* ao modelo já criado. O tempo de execução e apresentação da solução é aproximadamente 15 segundos, considerando-se que existe um bom *trade-off* entre a exatidão da previsão e o tempo de execução do processo.

5 Conclusões

A previsão da produção eólica para a hora seguinte revela-se crucial na gestão da rede elétrica, dado que atualmente, o valor atual da potência eólica em Portugal Continental é cerca de 30% da potência total instalada. Esta ação coloca algumas dúvidas nomeadamente para a estabilidade e segurança do sistema, o que não sendo devidamente controlado pode comprometer as mesmas. Este tipo de abordagens metodológicas apresenta-se fundamental para a sustentabilidade da rede elétrica nacional.

5.1 Síntese do Relatório

Como resultado desta dissertação de mestrado é apresentado um modelo computacional, capaz de fazer a previsão da velocidade do vento e essencialmente, a previsão da potência elétrica para vários parques eólicos de Portugal Continental. Através da comparação direta deste modelo com outros modelos apresentados na parte teórica desta dissertação, conclui-se que o modelo desenvolvido apresenta resultados igualmente satisfatórios, concluindo-se assim que o objetivo da tese de mestrado foi cumprido com sucesso. Adicionalmente, verifica-se que o modelo pode ser generalizado para outros parques eólicos o que traz bastantes vantagens.

De forma a validar os resultados com os modelos no mercado, tentou-se realizar uma comparação dos resultados obtidos com os resultados tornados públicos pela REN. No entanto, tendo em conta que a REN apenas reporta a previsão de potência total para Portugal Continental, e não as previsões de potência por parque eólico, é difícil fazer uma comparação justa entre ambos.

Refere-se que, embora os dados tenham sido cedidos gratuitamente e de boa vontade, verificou-se uma ligeira limitação de abundância e diversidade de dados relativos à expectativa inicial, o que de certo modo acabou por condicionar o desenvolvimento e aprofundamento dos trabalhos realizados. Adicionalmente, devido a questões burocráticas e de confidencialidade, a disponibilização dos dados demorou mais tempo do que inicialmente esperado.

5.2 Perspetivas de Trabalho Futuro

Como perspetivas de trabalho futuro, destaca-se a conclusão do método de *Hilbert-Huang Transformation* e a conseqüente junção com as entradas do modelo já existente, de forma a melhorar a previsão efetuada, e claro diminuir o erro apresentado. Perspetiva-se que com a junção do HHT, o modelo desta dissertação se torne bastante fidedigno, uma vez que a análise direta entre o output desta dissertação e a do artigo referido sem a inclusão do método de HHT, revela que os resultados obtidos nesta dissertação são bastante mais aproximados do *target* desejado e desta forma, apresentam um erro bastante menor do que o artigo. Destaca-se que a conclusão do método de HHT teve de ser gerida em função do tempo disponível para o

desenvolvimento desta dissertação, pelo que não foi possível aprofundá-lo. No entanto, analisando os resultados apresentados, é expectável uma melhoria considerável do modelo.

Um erro que pode também ser facilmente minimizado é do modelo do parque eólico. Através da inclusão de mais dados recolhidos dos parques eólicos, é possível calcular com melhor precisão a transformação de velocidade do vento para potência elétrica, essencialmente nas maiores velocidades do vento. Recorda-se que para esta tese de mestrado apenas estava disponível um ano de dados, o que de certa forma limita um pouco a construção do modelo.

Espera-se que o resultado presente nesta dissertação de mestrado possa constituir uma base de motivação para que o próprio e para que outros investigadores consigam desenvolver este tema tão importante, como é a previsão da potência eólica para os parques eólicos de Portugal continental.

Referências

- Castro, R. M. G. (2005). Introdução à energia eólica. *DECC/ Secção de Energia, 2005(2.1)*, 38. http://doi.org/http://inerte.horabsurda.org/wp-content/uploads/Introducao_a_Energia_Fotovoltaica.pdf
- Chang, W. (2014). A Literature Review of Wind Forecasting Methods. *Journal of Power and Energy Engineering*, (April), 161–168.
- ENEOP, E. de P. (2009). O que é a Energia Eólica? Retrieved January 25, 2016, from http://www.eneop.pt/canais.asp?id_canal=110
- ENERCON GmbH. (2015). *ENERCON product overview*. Dreekamp 5 · 26605 Aurich, Germany.
- Foley, a. M., Leahy, P. G., & McKeogh, E. J. (2010). Wind power forecasting & prediction methods. *9th International Conference on Environment and Electrical Engineering*, 353(0), 61–64. <http://doi.org/10.1109/EEEIC.2010.5490016>
- Giebel, G., Brownsword, R., Kariniotakis, G., Denhard, M., & Draxl, C. (2011). The State-Of-The-Art in Short-Term Prediction of Wind Power A Literature Overview. *Technical Report, ANEMOS.plus*, 1–109. Retrieved from <papers://6470de79-5287-45a9-8e4f-b629919aff7a/Paper/p5443>
- International Energy Agency. (2009). *Technology Roadmap*. Retrieved from http://www.iea.org/publications/freepublications/publication/wind_roadmap.pdf
- Khatib, A. a L. (2011). Developing a Wind speed prediction tool using artificial neural networks and designing Wind Park in Syria using WAsP software By Aubai AL Khatib.
- Li, S. (2001). Using neural networks to estimate wind turbine power generation. *Energy Conversion, IEEE Transactions on (Volume:16 , Issue: 3)*, 276 – 282. <http://doi.org/10.1109/60.937208>
- Lydia, M., & Kumar, S. S. (2010). A comprehensive overview on wind power forecasting. *IPEC 2010 Conference Proceedings, Singapore*, 268–273. <http://doi.org/10.1109/IPECON.2010.5697118>
- MathWorks. (2015). What Is Fuzzy Logic? Retrieved January 26, 2016, from <http://www.mathworks.com/help/fuzzy/what-is-fuzzy-logic.html?refresh=true>
- Monteiro, C., Bessa, R., Miranda, V., Botterud, a., Wang, J., & Conzelmann, G. (2009). Wind Power Forecasting: State-of-the-Art 2009 Decision and Information Sciences Division. *Argonne National Laboratory*, (November 6), 1–216. Retrieved from http://www.osti.gov/energycitations/product.biblio.jsp?osti_id=968212
- Nørskov, J., & Vittrup, C. (2016). New record-breaking year for Danish wind power. Retrieved January 25, 2016, from <http://energinet.dk/EN/EI/Nyheder/Sider/Dansk-vindstroem-slaar-igen-rekord-42-procent.aspx>
- Olaofe, Z. O., & Folly, K. A. (2012). Wind Power Estimation Using Recurrent Neural, 1–7.
- Pinson, P. (2006). Estimation of the uncertainty in wind power forecasting. *Centre Energétique et Procédés-Ecole Des Mines de*, 266. Retrieved from <http://www.opengrey.eu/item/display/10068/800613>
- REN (Redes Energéticas Nacionais). (2014). *Dados Técnicos*. Retrieved from <http://www.centrodeinformacao.ren.pt/PT/InformacaoTecnica/DadosTecnicos/2014.pdf>
- Rocha, D. (2015). Portugal bateu recorde de exportação de electricidade no sábado. *PÚBLICO E LUSA*. Retrieved from <https://www.publico.pt/economia/noticia/portugal-bateu-recorde-de-exportacao-de-electricidade-no-sabado-1711671>
- Rtp. (2015). Produção eólica ultrapassa pela 1ª vez esta madrugada o consumo nacional. Retrieved from <http://www.rtp.pt/noticias/economia/producao-eolica-ultrapassa-pela-1-vez->

- Shi, J., Lee, W., Tx, U. S. A., & Wang, P. (2011). Short Term Wind Power Forecasting Using Hilbert- Huang Transform and Artificial Neural Network, *863*(2007), 162–167.
- Soman, S. S., Zareipour, H., Malik, O., & Mandal, P. (2010). A review of wind power and wind speed forecasting methods with different time horizons. In *North {American} {Power} {Symposium} ({NAPS}), 2010* (pp. 1–8). <http://doi.org/10.1109/NAPS.2010.5619586>
- Van der Hoven, I. (1957). Power Spectrum of Horizontal Wind Speed in the Frequency Range From 0.0007 To 900 Cycles Per Hour. *Journal of Meteorology*. [http://doi.org/10.1175/1520-0469\(1957\)014<0160:PSOHWS>2.0.CO;2](http://doi.org/10.1175/1520-0469(1957)014<0160:PSOHWS>2.0.CO;2)
- Xia, J., Zhao, P., & Dai, Y. (2010). Neuro-fuzzy networks for short-term wind power forecasting. *2010 International Conference on Power System Technology*, 1–5. <http://doi.org/10.1109/POWERCON.2010.5666697>
- Yun, T., Jianyuan, X., Mingli, Z., & Liang, W. (2011). Study of wind farm power output predicting model based on nonlinear time series. *2011 International Conference on Electrical Machines and Systems*, 1–4. <http://doi.org/10.1109/ICEMS.2011.6073967>

Anexos

Anexo A

Estas fotografias foram captadas no dia 10 de Janeiro de 2016 no Despacho da REN, num dia fortemente exportador. Estas representam a informação apresentada aos despachantes desta empresa e é segundo este conjunto de dados estes trabalhadores tomam decisões para gerir e assegurar a continuidade do SEN.




Figura 5-1 Gráfico da potência eólica telemidia (verde), da potência eólica prevista (amarelo) e da potência total estimada (azul) fotografado diretamente do despacho da REN num dia fortemente exportador



Figura 5-2 Gráficos diário do consumo total (verde claro) e da produção renovável (verde escuro) fotografado diretamente do despacho da REN num dia fortemente exportador

Anexo B

Neste anexo estão contidos os locais de vento a prever pelos prestadores do serviço. Note-se que o sistema de coordenadas é o WGS84.

Tabela 5-1 Lista dos locais de vento a prever

Nº	Local	Latitude	Longitude	Altura
1	Pinheiro	40,968494	-7,978978	65,0
2	Trandeiras	41,541300	-7,703800	60,0
3	TerrasAltasFafe	41,489598	-8,075600	67,0
4	ChaoFalcao	39,613547	-8,756023	80,0
5	Pampilhosa da Serra	40,122900	-7,936700	80,0
6	Candeeiros	39,396700	-8,938400	80,0
7	Malhadizes	40,014900	-8,297500	65,0
8	Cabril	40,983300	-8,045300	65,0
9	Alvao1	41,445900	-7,728600	65,0
10	Alvao2	41,475700	-7,775300	65,0
11	Proenca	39,806200	-7,888000	65,0
12	SPedro	40,994100	-8,092300	65,0
13	Videmonte	40,577400	-7,403400	67,0
14	Seladolinho	39,877166	-7,914155	65,0
15	Alvelos	39,940033	-7,971568	80,0
16	Penamacor1	40,207407	-7,245362	78,0
17	Penamacor3A	40,280900	-7,134700	78,0
18	Furnas	39,866291	-7,853333	65,0
19	Fundeiro	39,817764	-7,965358	65,0
20	Nave	40,943447	-7,766585	67,0
21	Mourisca	40,948122	-7,806857	67,0
22	Rendeiro	39,846513	-7,972124	79,0
23	Moradal	39,924081	-7,742652	79,0
24	Penamacor2	40,200578	-7,170875	80,0

25	Penamacor3B	40,299111	-7,094506	80,0
26	Cigarrelho	40,058210	-7,673889	78,0
27	CabecoAlto	40,094611	-7,685184	78,0
28	Maunca	40,098303	-7,649087	78,0
29	Moeda	40,083470	-7,613737	78,0
30	Alvoaca1	40,240004	-7,731470	64,0
31	Alvoaca2	40,263424	-7,701951	64,0
32	SJoao1	40,022309	-8,289168	70,0
33	SJoao2	39,999350	-8,398583	70,0
34	Leomil	40,960511	-7,662639	80,0
35	Picos	42,076512	-8,208319	68,0
36	AltodoCorisco	42,019488	-8,244923	68,0
37	SantoAntonio	42,008421	-8,299251	68,0
38	Mendoiro	41,995627	-8,417860	68,0
39	Bustavade	42,017654	-8,423084	68,0
40	Picoto	41,983475	-8,559315	68,0
41	SaoSilvestre	41,962810	-8,567893	78,0
42	Bezerreira	40,579404	-8,198832	65,0
43	Caselho	40,621259	-8,150424	65,0
44	TerrasAltasFafe2	41,547753	-8,123851	67,0
45	Testos	40,982505	-7,846810	85,0
46	FontedaQuelha	41,011628	-8,100551	64,7
47	AltodoTalefe	40,988146	-7,982728	64,7
48	Zibreiro	40,028491	-7,709643	78,0
49	Mastro	40,072730	-7,568299	78,0
50	Lameira	40,962267	-8,034093	60,0
51	Aveloso	41,014498	-8,082911	78,0
52	Carvalhosa	40,973857	-7,968186	78,0
53	Picao	40,967310	-7,936736	78,0
54	Arada	40,826429	-8,162590	78,0
55	CabecoRainha2a	39,873102	-7,878518	85,0

56	CabecoRainha2b	39,844032	-7,935291	65,0
57	LagoaDJoaoFeirao	41,033353	-7,938681	78,0
58	Ribabelide	41,015064	-7,872699	78,0
59	NegreloGuilhado	41,476436	-7,625293	85,0
60	Lousa2a	40,028272	-8,227597	80,0
61	Lousa2b	40,062962	-8,219911	80,0
62	AroucaSilva	40,157139	-7,833568	80,0
63	ToitaDecabelos	40,088610	-7,949586	80,0
64	Burrela	40,202478	-7,893375	80,0
65	Sabugal	40,320038	-6,908693	80,0
66	ChaoFalcao2	39,651543	-8,753759	80,0
67	ChaoFalcao3	39,556282	-8,674253	80,0
68	SerraAlvao1	41,420161	-7,735721	67,0
69	SerraAlvao2	41,455398	-7,746530	67,0
70	Bornes1	41,473718	-6,945382	80,0
71	Bornes2	41,456096	-6,973571	80,0
72	SerraBarroso2	41,696207	-7,842278	85,0
73	SalgueirosGuilhado	41,490873	-7,599401	85,0
74	Mougueiras	39,908689	-7,835208	85,0
75	Bravo	39,906303	-8,043040	85,0
76	VilaNova2a	40,053132	-8,255477	85,0
77	VilaNova2b	40,033173	-8,302869	85,0
78	BaraoSJoao1	37,149229	-8,812860	80,0
79	BaraoSJoao2	37,140858	-8,793866	80,0
80	AltodoArganil	40,202841	-7,794152	85,0
81	LombadoVale	41,602607	-7,989599	80,0
82	FachoColmeia	41,785818	-7,841598	85,0
83	Montalegre1	41,730134	-7,947316	85,0
84	Montalegre2	41,761632	-7,913712	85,0
85	Contim	41,778288	-7,874601	85,0
86	Armamar1	41,047389	-7,681241	85,0

87	Armamar2	41,046439	-7,655486	85,0
88	Cadafaz2	40,120872	-8,046728	85,0
89	SerraBarroso3	41,683019	-7,850577	85,0
90	AltodaCoutada1	41,526581	-7,592375	98,0
91	AltodaCoutada2	41,543481	-7,557073	85,0
92	AltodaCoutada3	41,557638	-7,533411	85,0
93	AltodaCoutada4	41,572614	-7,512214	85,0
94	AltodaCoutada5	41,551566	-7,518536	85,0
95	AltodaCoutada6	41,525761	-7,517172	85,0
96	SraNecessidades	40,260319	-7,824523	85,0
97	Acor2	40,219318	-7,839147	64,0
98	Balocas	40,248204	-7,759126	85,0
99	SerradeSampaio	41,060320	-7,436815	85,0
100	Ranhados	41,012100	-7,363800	85,0
101	SerradaNave	40,929142	-7,695831	85,0
102	Troviscal	40,317121	-7,204330	85,0
103	SaoCornelio1	40,347189	-7,180920	85,0
104	SaoCornelio2	40,366633	-7,161562	85,0
105	Testos2a	40,981849	-7,835944	85,0
106	Testos2b	41,000754	-7,863731	85,0
107	Bustelo	41,003046	-7,993969	85,0
108	SMacario2	40,994560	-7,969099	80,0
109	PedrasLavradas2	40,235408	-7,742438	85,0
110	Sendim	41,064606	-7,545294	85,0
111	Chavaes	41,079196	-7,580519	85,0
112	Pousafoles1	40,363173	-7,221052	85,0
113	Pousafoles2	40,403342	-7,200273	85,0
114	Benespera	40,420819	-7,261161	85,0
115	Sobrado	40,963409	-8,039222	80,0
116	Cinfaes	41,024209	-8,090079	85,0
117	Falperra	41,421819	-7,646581	85,0

118	ValeGrande	40,187898	-7,915703	80,0
119	PassaFrio	37,324548	-7,784316	85,0
120	CerrodoGato	37,276141	-7,854445	85,0
121	Fanhoes	38,889769	-9,145122	67,0
122	Bairro	39,588479	-8,574850	85,0
123	Maravilha1	39,070667	-9,223519	85,0
124	Maravilha2	39,057671	-9,199542	85,0
125	Milagres	39,035257	-9,140160	85,0
126	SerradoMu	37,372228	-8,092527	85,0
127	ValeGalegos1	39,048241	-9,309263	85,0
128	RomaRomeirao	39,013890	-9,332238	85,0
129	Caldas1	39,295784	-9,013880	78,0
130	CabecoRainha1a	39,849847	-7,922269	46,0
131	CabecoRainha1b	39,856014	-7,911523	65,0
132	CabecoRainha1c	39,846020	-7,873476	85,0
133	Capucha	39,060658	-9,257413	66,0
134	SerradelRei	39,314371	-9,264856	80,0
135	Coentral	40,070113	-8,193870	70,0
136	Safra	40,059794	-8,166294	70,0
137	Bordeira	37,213786	-8,794040	78,0
138	Outeiro2	41,756353	-8,837149	85,0
139	Guerreiros1	37,227161	-8,756358	78,0
140	Mosqueiros2	40,440216	-7,359971	85,0
141	Agucadoura	41,460633	-8,849767	68,0
142	AlentejoMertola1a	37,482826	-7,811565	98,0
143	AlentejoMertola1b	37,485256	-7,861021	98,0
144	AlentejoMertola1c	37,510345	-7,833231	98,0
145	FonteMesa2	41,092193	-7,865703	85,0
146	Lourinha2	39,266842	-9,238166	85,0
147	Gevancas2	41,405487	-7,792641	85,0
148	SraSocorro	39,020611	-9,207006	85,0

149	AltoMarco	41,406620	7,801054	85,0
150	Azinheira	41,426917	-8,057958	85,0
151	Abogalheira	41,194283	-8,042937	80,0
152	Amaral	39,025907	-9,044152	67,0
153	Bolores	38,861576	-9,229190	60,0
154	Cadafaz	40,104080	-8,044114	46,0
155	Madrinha	37,306756	-8,620779	65,0
156	Montijo2	39,021944	-9,139444	65,0
157	Mosteiro	40,308480	-7,149506	60,0
158	Ortiga	40,007690	-8,235011	70,0
159	PenaSuar	41,292819	-7,920050	65,0
160	PicoAlto	37,262398	-8,235919	85,0
161	Po	39,303382	-9,214619	60,0
162	SraCastelo2	41,030278	-8,155000	65,0
163	SerradoSico	39,926004	-8,564730	85,0
164	Videira	39,872778	-8,403056	65,0
165	Passarinho	38,983459	-9,174441	85,0
166	Acor	40,213818	-7,870218	85,0
167	SerraBarroso1	41,686310	-7,868941	68,0
168	AlagoaCima	41,972889	-8,440773	64,7
169	FonteMesa1	41,096549	-7,868057	40,0
170	Outeiro	41,332174	-7,837208	65,0
171	Padrela	41,458294	-7,634561	64,7
172	Arruda1	38,969585	-9,166107	78,0
173	Sobral2	38,971714	-9,176744	78,0
174	Meadas	41,113021	-7,854101	80,0
175	Doninhas	40,668184	-8,352561	65,0
176	Perdigao	39,707575	-7,744901	85,0
177	VilaNova1	40,044628	-8,281347	68,0
178	Arega	39,842907	-8,328769	85,0
179	Alvaiazere1	39,828101	-8,412991	85,0

180	AldeiaNova	40,728813	-7,400351	85,0
181	CabecodeOiro	40,809766	-7,348277	85,0
182	RiodeMelCa	40,835247	-7,384552	85,0
183	Lourinha1	39,296509	-9,265821	85,0
184	Almargem	39,108676	-9,193743	85,0
185	Prados	40,553035	-7,361335	85,0
186	Tocha	40,324044	-8,809153	80,0
187	CarrecoOuteiro1	41,755210	-8,821850	80,0
188	Vergao	39,755255	-7,990127	60,0
189	Chamine	37,866007	-8,751126	80,0
190	Trancoso	40,856750	-7,381265	85,0
191	Mosqueiros1	40,460507	-7,345875	85,0
192	ForneloMonte	40,641347	-8,127821	65,0
193	Silvares	40,629701	-8,140104	65,0

Anexo C

Neste anexo estão os parques eólicos cuja potência deve ser prevista pelos prestadores do serviço. A previsão neste caso é entregue em potência. Associado a cada parque, observa-se o número de aerogeradores que o mesmo contém, a potência nominal, a potência instalada e o limite de potência a que esse parque está sujeito.

Tabela 5-2 Lista dos parques eólicos ligados à Ren para prever potência

Nº	Nome do parque	Número de Aerogeradores	Potência nominal [MW]	Potência instalada [MW]	Limite de potência [MW]
1	Pinheiro	12	21,2	21,6	21,2
2	Cabril	11	20,2	20,3	20,2
3	FontedaQuelha	9	11,4	13,5	11,4
4	AltodoTalefe	9	11,4	13,5	11,4
5	Lameira	8	10	10,4	10
6	SaoPedro	5	10	10,25	10
7	Trandeiras	14	18,2	18,2	999,9
8	Alvao	12	22,1	22,8	22,1
9	TerrasAltasdeFafe	53	106	106	109
10	ChaoFalcao	35	77,9	80,5	77,9
11	PampilhosadaSerra	38	96,6	114	96,6
12	Candeeiros	37	103,3	111	103,3
13	PinhalInterior	63	130	146,2 5	130
14	Mougueiras	4	7	8,2	7
15	Bravo	8	13	16,4	13
16	Videmonte	16	32	32	32
17	Penamacor	60	120	123,8	120
18	Nave	19	38	38	999,9
19	Mourisca	19	38	38	999,9
20	Gardunha	57	116,8 5	116,8 5	121,3

21	SJoao	13	21,7	21,71	21,7
22	VilaNova2	14	24,1	29,3	24,1
23	SAlvoaca	17	34,7	36,6	34,7
24	SLeomil	7	16,1	16,1	16,1
25	CaramuloSBA	24	49,2	49,2	999,9
26	AltoMinhol	120	246	246	258
27	Testos	12	24,6	24,6	24,6
28	AradaMontemuro	56	114,8	114,8	999,9
29	CabecodaRainhall	15	29	31,75	29
30	LagoaDJoaoeFeira o	17	31	34,85	31
31	Ribabelide	7	12,6	14,35	12,6
32	Lousall	20	50	50	52,6
33	Toutico	34	102	102	999,9
34	SerraAlvao	21	42	42	999,9
35	NegreloGuilhado	11	19,4	22,55	19,4
36	Bornes	24	60	60	999,9
37	SerraBarroso2	6	10,7	12,3	10,7
38	SerraBarroso3	11	19,4	23,45	19,4
39	SalgueirosGuilhado	6	10,6	12,9	10,6
40	BaraoSJoao	25	49	50	49
41	AltodoArganil	18	36,9	36,9	999,9
42	TerraFria	52	86,5	106,6	86,5
43	LombadoVale	9	21,1	21,1	21,1
44	AltoDouro	111	215	258,7 5	215
45	Beiras	45	84,8	102,6 5	84,8
46	AltodaCoutada	72	141,6	169,2	141,6
47	Raia	56	109,8	131,6	109,8
48	Bustelo	9	15	18,45	15
49	SMacario2	10	23	23	999,9

50	Sobrado	4	8	8	999,9
51	Cinfaes	4	7	8,2	7
52	ValeGrande	6	12,3	12,3	999,9
53	Malhanito	29	56,7	68,15	56,7
54	Fanhoes	9	17,8	18	17,8
55	Bairro	11	18,5	22,55	18,5
56	Maravilha1	3	5	6,15	5
57	Maravilha2	2	3,5	4,1	3,5
58	Milagres	3	5	6,15	5
59	SerradoMu	15	27,6	31,05	27,6
60	ValedeGalegos	13	23,3	28,45	23,3
61	Caldas1	5	10	10	999,9
62	CabecodaRainha1	23	22,35	22,35	999,9
63	Capucha	5	10	10,25	10
64	SerradelRei	13	20,6	21,71	20,6
65	CoentralSafra	25	39,6	41,75	39,6
66	Bordeira	12	23	24,6	23
67	CarrecoOuteiro2	6	11,8	14,1	11,8
68	Guerreiros	9	18,45	18,45	999,9
69	Mosqueiros2	12	20,6	25,2	20,6
70	Agucadoura	1	2	2	999,9
71	AlentejoMertola	19	37,2	44,65	37,2
72	FonteMesa2	5	9	10,25	9
73	Lourinha2	9	17,7	21,15	17,7
74	Gevancas2	5	10,5	11,75	10,5
75	SraSocorro	4	8,2	8,2	999,9
76	iAltoMarco	6	12,3	12,3	999,9
77	Azinheira	7	14,35	14,35	999,9
78	Abogalheira	2	3,34	3,34	999,9
79	Amaral	5	10	10	999,9
80	Bolores	4	5,2	5,2	999,9

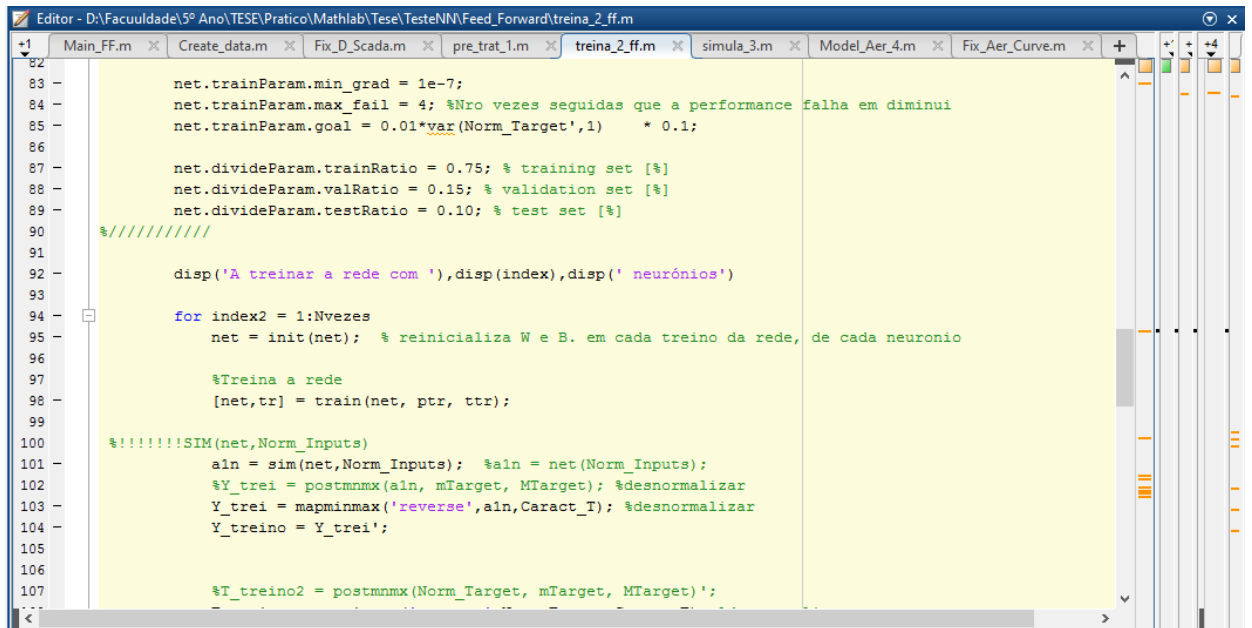
81	Cadafaz	17	10,2	10,2	999,9
82	Madrinha	5	10,25	10,25	999,9
83	Montijo2	1	2,05	2,05	999,9
84	Mosteiro	7	9,1	9,1	999,9
85	Ortiga	8	13,36	13,36	999,9
86	PenaSuar	23	16,6	18,15	16,6
87	PicoAlto	3	6,15	6,15	999,9
88	Po	7	9,1	9,1	999,9
89	SraCastelo2	2	4	4	999,9
90	SerradoSico	10	20,5	20,5	999,9
91	Videira	3	6,15	6,15	999,9
92	Passarinho	6	12,3	12,3	999,9
93	Acor	12	24,6	24,6	999,9
94	SerraBarroso1	9	16	18	16
95	AlagoaCima	9	13,5	13,5	999,9
96	FonteMesa1	17	10,2	10,2	999,9
97	Outeiro	15	28,6	30,75	28,6
98	Padrela	5	7,5	7,5	999,9
99	Arruda1	3	6	6	999,9
100	Sobral2	7	14	14	999,9
101	Meadas	3	7,6	9	7,6
102	Doninhas	1	0,81	0,81	999,9
103	Perdigao	1	2,05	2,05	999,9
104	VilaNova1	15	25,3	30	25,3
105	Alvaiazere	9	18,45	18,45	999,9
106	BeiralInterior	25	49,5	58,75	49,5
107	Lourinha1	9	17,7	21,15	17,7
108	Almargem	3	6,15	6,15	999,9
109	Prados	17	33,8	39,95	33,8
110	Tocha	5	8,5	9	8,5
111	CarrecoOuteiro1	9	18,6	20,7	18,6

112	Vergao	10	10	13	10
113	Chamine	3	5,7	6,9	5,7
114	Trancoso	14	28,7	28,7	999,9
115	Mosqueiros1	4	8,2	8,2	999,9
116	CaramuloEDPD	21	43,05	43,05	999,9

Anexo D

São apresentados alguns excertos de código desenvolvido, para que se perceba a complexidade do trabalho realizado.

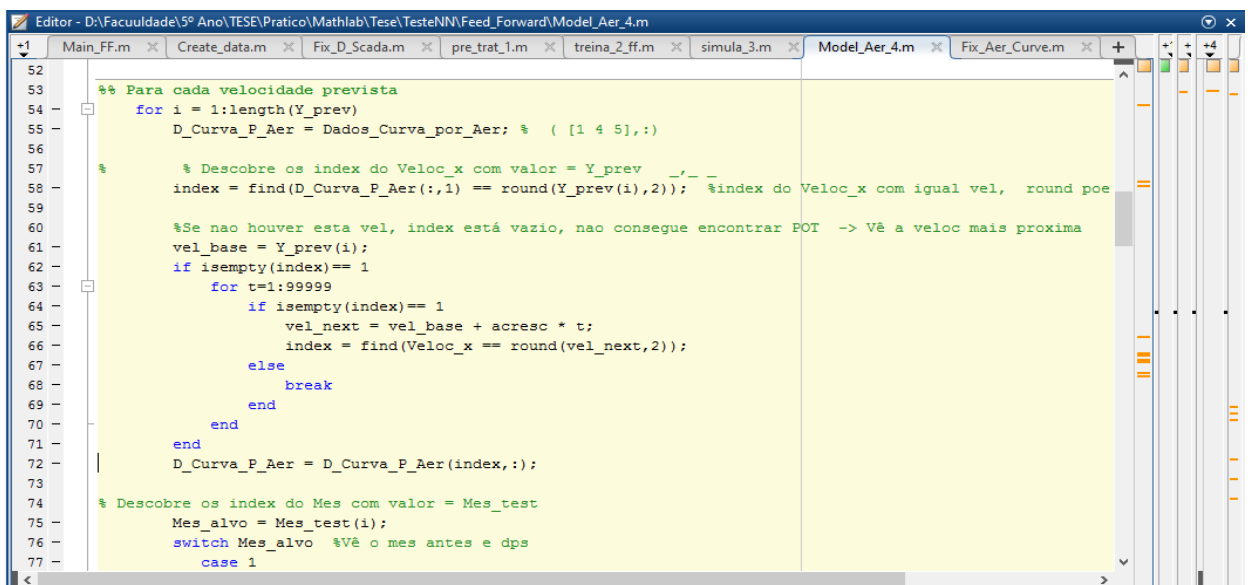
Treino da rede neuronal



```
82
83 net.trainParam.min_grad = 1e-7;
84 net.trainParam.max_fail = 4; %Nro vezes seguidas que a performance falha em diminuir
85 net.trainParam.goal = 0.01*var(Norm_Target',1) * 0.1;
86
87 net.divideParam.trainRatio = 0.75; % training set [%]
88 net.divideParam.valRatio = 0.15; % validation set [%]
89 net.divideParam.testRatio = 0.10; % test set [%]
90
91 %//////////
92 disp('A treinar a rede com '),disp(index),disp(' neurónios')
93
94 for index2 = 1:Nvezes
95     net = init(net); % reinicializa W e B. em cada treino da rede, de cada neuronio
96
97     %Treina a rede
98     [net,tr] = train(net, ptr, ttr);
99
100 %!!!!!!SIM(net, Norm_Inputs)
101 aIn = sim(net, Norm_Inputs); %aIn = net(Norm_Inputs);
102 %Y_trei = postmmx(aIn, mTarget, MTarget); %desnormalizar
103 Y_trei = mapminmax('reverse',aIn,Caract_T); %desnormalizar
104 Y_treino = Y_trei';
105
106
107 %T_treino2 = postmmx(Norm_Target, mTarget, MTarget)';
```

Figura 5-3 Código de treino da rede neuronal

Construção do modelo do parque eólico



```
52
53 %% Para cada velocidade prevista
54 for i = 1:length(Y_prev)
55     D_Curva_P_Aer = Dados_Curva_por_Aer; % ( [ 1 4 5],:)
56
57     % Descobre os index do Veloc_x com valor = Y_prev
58     index = find(D_Curva_P_Aer(:,1) == round(Y_prev(i),2)); %index do Veloc_x com igual vel, round poe
59
60     %Se nao houver esta vel, index está vazio, nao consegue encontrar POT -> Vê a veloc mais proxima
61     vel_base = Y_prev(i);
62     if isempty(index) == 1
63         for t=1:99999
64             if isempty(index) == 1
65                 vel_next = vel_base + acresc * t;
66                 index = find(Veloc_x == round(vel_next,2));
67             else
68                 break
69             end
70         end
71     end
72     D_Curva_P_Aer = D_Curva_P_Aer(index,:);
73
74     % Descobre os index do Mes com valor = Mes_test
75     Mes_alvo = Mes_test(i);
76     switch Mes_alvo %Vê o mes antes e dps
77     case 1
```

Figura 5-4 Código da construção do modelo do parque eólico

Construção do HHT

```
Editor - D:\Faculdade\5º Ano\TESE\Pratico\Mathlab\Tese\TesteNN\Feed_Forward\plot_hht.m
plot_hht.m x emd.m x findpeaks.m x tryNNtrain_with_HHT.m x imf_abril_14_15_ult_tent.m x plot_hht.m x emd.m x findpeaks.m x
22 %% Get HHT.
23 imf = emd(x);
24 for k = 1:length(imf)
25     b(k) = sum(imf{k}.*imf{k});
26     th = angle(hilbert(imf{k}));
27     d(k) = diff(th)/Ts/(2*pi);
28 end
29 [u,v] = sort(-b);
30 b = 1-b/max(b);
31
32 %% Set time-frequency plots.
33 N = length(x);
34 c = linspace(0, (N-2)*Ts, N-1);
35 %Faz a Figure 1 e 2
36 for k = v(1:2)
37     figure,
38     plot(c,d(k), 'k.', 'Color', b([k k]), 'MarkerSize', 3);
39     set(gca, 'FontSize', 8, 'XLim', [0 c(end)], 'YLim', [0 1/2/Ts]);
40     xlabel('Time'), ylabel('Frequency');
41 end
42
43 %% Set IMF plots.
44 M = length(imf);
45 N = length(x);
46 c = linspace(0, (N-1)*Ts, N); %eixo dos x, de 0 até length(data)-1
47 for k1 = 0:4:M-1 %4 subplots por grafico
48     figure
```

Figura 5-5 Código da construção do HHT

