



Centro de Competência das Ciências Exatas e da Engenharia da Universidade da Madeira

---

## **Previsão de produção de energia elétrica a partir do vento**

---

**José Dário Pereira Fernandes**

(Licenciado)

*Tese Submetida à Universidade da Madeira para a  
Obtenção do Grau de Mestre em Engenharia Informática*



**Orientador:**

Professor Doutor Fernando Morgado Dias

*Professor Auxiliar do Centro de Competência das Ciências Exatas e da Engenharia da Universidade da Madeira*

**Constituição do júri:****Presidente:**

*Doutor João Dionísio Simões Barros*

*Professor Auxiliar do Centro de Competência das Ciências Exatas e da Engenharia da Universidade da Madeira*

**Vogais:**

*Doutor Fernando Manuel Rosmaninho Morgado Ferrão Dias*

*Professor Auxiliar do Centro de Competência das Ciências Exatas e da Engenharia da Universidade da Madeira*

*Doutor José Carlos Magro Esteves*

*Investigador Auxiliar do Laboratório Regional de Engenharia Civil*



---

# ABSTRACT

---

The capacity to predict accurately the energy production in a wind park is extremely relevant both from an economical point of view and to control the stability of the energy network. Many different models have been used for this purpose, such as physical, statistical, neuro-fuzzy and artificial neural networks. The data available from wind parks is usually noisy and has measurements that are unexpected regarding the available inputs. Dealing with this data and determine system characteristics is not an easy task but, in this work, Artificial Neural Networks are used to predict power generation based on in site wind measurements. The results show that Artificial Neural Networks are a tool that should be considered under these difficult conditions, since they provide a reasonable precision in the predictions. When compared with the results presented in the literature the obtained results are in the same order of values, although the data used seems to have a large amount of outliers.



---

## KEYWORDS

---

Modeling, Artificial Intelligence, Neural Networks, Wind Turbine, Wind Park, Wind Power



---

# RESUMO

---

A capacidade de prever a produção de energia eólica com precisão num parque eólico é de extrema relevância tanto do ponto de vista económico bem como de controlo e estabilidade da rede elétrica. Vários e diferentes métodos têm sido utilizados para este propósito, como os físicos, estatísticos, lógica difusa e redes neuronais artificiais. Os dados disponíveis dos parques eólicos contêm ruído e leituras inesperadas em relação às entradas disponíveis. Lidar com estes dados não é uma tarefa simples mas, neste trabalho, as Redes Neuronais Artificiais são usadas para prever a potência gerada baseada em medições locais do vento. Os resultados mostram que as Redes Neuronais Artificiais são uma ferramenta que deve ser considerada nestas difíceis condições, uma vez que elas proporcionam uma precisão razoável nas suas previsões.



---

# PALAVRAS-CHAVE

---

Modelação, Inteligência Artificial, Redes Neurais, Aerogerador, Parque eólico, Energia do Vento



---

# AGRADECIMENTOS

---

Ao meu orientador, o Professor Doutor Fernando Morgado Dias pela sua amizade, orientação e disponibilidade que sempre demonstrou.

A Empresa de Eletricidade da Madeira pela disponibilidade que demonstraram em fornecer dados e informações dos seus parque eólicos e ao Engenheiro Hélder Andrade pela sua disponibilidade no fornecimento dos dados do parque eólico de Cabo Verde e informações do mesmo.

Um grande agradecimento à minha família, em especial aos meus pais e aos meus irmãos, pelo apoio incondicional que sempre me prestaram ao longo da minha vida pessoal e académica e não menos obstante nesta última fase do mestrado. Sem o apoio deles, jamais conseguiria atingir esta etapa.

À minha namorada, pelo seu companheirismo, dedicação, por todo o apoio incondicional e por ter estado sempre presente e a meu lado nesta fase.

Aos meus amigos, pela sua amizade e companheirismo, que nestes últimos tempos aceitaram e compreenderam a minha ausência, e que muito me apoiaram e encorajaram.

A todos aqueles que direta ou indiretamente estiveram comigo e sempre me ofereceram o seu apoio.



---

# ÍNDICE

---

I. Introdução	1
I.2. Contextualização e motivação .....	2
I.3. Organização.....	3
II. Estado da arte	5
II.1. Introdução.....	6
II.2. Relação entre a potência e a velocidade do vento.....	7
II.2.1. Redes Neurais.....	10
II.2.1.1. Topologia da rede neuronal .....	12
II.2.1.2. Modos de treino .....	13
II.2.1.3. Algoritmos de treino .....	14
II.2.1.4. Vantagens e desvantagens das redes neurais .....	15
II.2.2. Sistemas existentes para a monitorização de aerogeradores .....	16
II.3. Trabalhos relacionados .....	18
II.4. Conclusão.....	20
III. Identificação de sistemas com redes neurais	21
III.1. Introdução.....	22
III.2. Recolha de dados .....	26
III.3. Preparação dos dados .....	27
III.3.1. Escalar os dados .....	27
III.3.1.1. Pré-processamento dos dados .....	28
III.3.1.2. Divisão dos dados em diversos conjuntos.....	28
III.3.1.3. Ordem do sistema .....	29
III.3.1.4. Paragem de treino antecipada .....	29
III.4. Conclusão.....	31
IV. Descrição e tratamento dos dados dos parques eólicos	33
IV.1. Introdução.....	34
IV.2. Descrição dos parques eólicos.....	35
IV.2.1.1. Conjunto de dados .....	38

IV.2.1.2. Pré- processamento dos dados .....	43
IV.2.1.3. O Processo de filtragem dos dados.....	43
IV.3. Conclusão.....	53
V. Teste e avaliação dos modelos de previsão eólica	55
<hr/>	
V.1. Introdução.....	56
V.2. Processo de construção dos modelos .....	57
V.2.1. Escolha do ambiente MATLAB.....	57
V.2.2. Análise da correlação.....	58
V.2.3. Seleção dos dados a utilizar para construir os modelos .....	59
V.2.4. Modelos baseados em redes neuronais.....	64
V.3. Resultados .....	66
V.3.1. Resultados parque eólico do Loiral no ano de 2009.....	66
V.3.2. Resultados no parque eólico do Loiral no ano de 2011.....	71
V.3.3. Resultados parque eólico Cabo Verde.....	75
V.4. Conclusão.....	81
VI. Conclusões	83
VII. Referências	85
Anexos	89
<hr/>	
Anexo A.....	90

---

# LISTA DE FIGURAS

---

Figura 1 – Esquema de um aerogerador [3].....	7
Figura 2 – Curva de potência para o aerogerador VESTAS-V52 com potência nominal de 850 KW [4] .....	8
Figura 3 - Estrutura de cada unidade numa rede neuronal [8].....	10
Figura 4 - Rede neuronal com as unidades organizadas em camadas [8].....	12
Figura 5 - Processo de construção de um modelo .....	23
Figura 6 – Processo de construção de um conjunto de dados.....	25
Figura 7 - Aplicação do fator escala.....	27
Figura 8 – Erro de treino vs. Teste.....	30
Figura 9 - Curva de potência do aerogerador Nordtank para densidade do ar igual a 1,225 kg/m <sup>3</sup> .....	35
Figura 10 - Localização do parque eólico de Cabo Verde [23] .....	36
Figura 11 - Curva de potência do aerogerador Vestas-V52 para densidade do ar igual a 1,225 kg/m <sup>3</sup> .....	36
Figura 12 – Localização parque eólico do Loiral [30] .....	37
Figura 13 - Localização parque eólico das Pedras [31].....	37
Figura 14 - Limitações de potência introduzidas pela central de controlo.....	44
Figura 15 - Fluxograma filtro 1 .....	45
Figura 16 - Dados iniciais .....	46
Figura 17 - Filtro 1 .....	46
Figura 18 - Fluxograma filtro 2.....	47
Figura 19 - Processo de filtragem para o filtro 2 .....	48
Figura 20 – Resultados do filtro 2.....	48
Figura 21 - Exemplo dos dados do parque eólico de Cabo Verde.....	50
Figura 22 – Fluxograma do filtro de Cabo Verde.....	51
Figura 23 - Sequência de dados após a filtragem.....	52
Figura 24 - Curva de potência do aerogerador de Cabo Verde no ano de 1995 .....	60
Figura 25 - Curva de potência do aerogerador do Loiral no ano de 2009 .....	61
Figura 26 - Curva de potência do aerogerador das Pedras no ano de 2009 .....	61
Figura 27 – Modelo NNARX.....	65
Figura 28 - Resultados da melhor simulação para o parque eólico do Loiral no ano de 2009.....	70
Figura 29 - Resultados melhor simulação no parque eólico do Loiral no ano de 2011.....	74
Figura 30 - Resultados melhor simulação parque eólico Cabo Verde.....	79



---

## LISTA DE TABELAS

---

Tabela 1 - Funções de ativação usadas na implementação de Redes Neurais.....	11
Tabela 2 - Dados em falta no parque de Cabo Verde no de ano de 1995.....	38
Tabela 3 - Dados em falta no parque de Cabo Verde no ano de 1996 .....	39
Tabela 4 - Dados em falta parque Cabo Verde ano 1997.....	39
Tabela 5 - Dados em falta no parque de Cabo Verde no ano de 1998 .....	40
Tabela 6 – Dados em falta medidos na <i>nacelle</i> dos aerogeradores do parque do Loiral no ano de 2011 .....	40
Tabela 7 - Dados em falta na estação meteorológica do parque do Loiral ano de 2011 .....	41
Tabela 8 – Dados em falta medidos na <i>nacelle</i> dos aerogeradores no parque das Pedras no ano de 2011.....	41
Tabela 9 - Dados em falta na estação meteorológica do parque das Pedras ano de 2011 .....	42
Tabela 10 - Correlação entre todas as variáveis para o mês de Janeiro parque eólico de Cabo Verde .....	59
Tabela 11 – Dados de treino do parque do Loiral no ano de 2009.....	62
Tabela 12 - Dados de teste do parque do Loiral no ano de 2009.....	62
Tabela 13- Dados de treino do parque de Cabo Verde .....	63
Tabela 14 - Dados de teste do parque de Cabo Verde.....	63
Tabela 15 - Dados de treino do parque do Loiral no ano de 2011 .....	63
Tabela 16- Dados de teste do parque do Loiral no ano 2011 .....	63
Tabela 17 - Resultados do parque eólico do Loiral no ano de 2009 pesos fixos.....	66
Tabela 18 - Resultados parque eólico do Loiral no ano de 2009 pesos aleatórios.....	68
Tabela 19 - Resultados no parque eólico do Loiral no ano 2011 pesos fixos .....	71
Tabela 20 - Resultados parque eólico Loiral ano 2011 pesos aleatórios.....	73
Tabela 21 - Resultados para o parque eólico de Cabo Verde pesos fixos .....	75
Tabela 22 - Resultados para o parque eólico de Cabo Verde pesos aleatórios .....	77



---

# ACRÓNIMOS

---

RAM - Região Autónoma da Madeira

EQM - Erro Quadrático Médio

EQ- Erro Quadrático

SCADA - *Supervisory Control and Data Acquisition*

HIRLAM - *High-Resolution Limited Area Model*

WASP - *Wind Atlas Application and Analysis Program*

CPRNN - *Complex-valued Pipelined Recurrent Neural Network*



---

# I. INTRODUÇÃO

---

---

## **I.2. CONTEXTUALIZAÇÃO E MOTIVAÇÃO**

---

Atualmente existe uma enorme dependência de energia e o seu consumo é cada vez maior. Grande parte desta energia é proveniente do petróleo que apesar de ser uma energia renovável a muito longo prazo, faz com que para o ser humano seja não renovável a curto prazo. Porém este recurso está a esgotar-se muito rapidamente e é uma fonte de energia muito poluente, por estes factos surge a necessidade de recorrer a outros tipos de energia renováveis e não poluentes.

Uma das alternativas existentes e que será abordada nesta tese é a energia eólica, que apesar de ser uma tecnologia recente, segundo dados de 2011 existiam cerca de 4300 MW instalados em Portugal [1]. Para ser mais específico e como grande parte dos dados utilizados nesta tese são de parques eólicos localizados na Região Autónoma da Madeira (RAM), a capacidade de energia eólica instalada e em funcionamento nesta região é de cerca de 43,4 MW [1].

A energia eólica consiste em aproveitar a energia cinética do vento para produzir energia mecânica através da rotação das pás do aerogerador que depois é transformada em energia elétrica através de um gerador.

Os maiores inconvenientes deste tipo de energia é a sua intermitência, pois o vento não sopra sempre à mesma velocidade o que faz com que a energia produzida também seja intermitente o que irá causar dificuldades de fornecimento de energia que necessita ser feito de uma forma estável.

Para resolver este problema normalmente recorre-se a outras alternativas de fontes de energia, como as centrais hidroelétricas.

Outro problema que existe com a energia eólica é o facto de não sabermos antecipadamente a quantidade de energia que um determinado parque irá produzir devido à natureza incerta do vento. Por este facto neste trabalho, e como fase inicial de um projeto mais amplo que seria utilizar os modelos aqui construídos e com base em previsões meteorológicas efetuar previsões a longo prazo. Nesta fase pretende-se desenvolver modelos baseados em redes neuronais capazes de prever a energia gerada por um aerogerador.

Com base nos modelos desenvolvidos neste trabalho e através de boas previsões meteorológicas seria possível prever a capacidade de energia produzida antecipadamente para um determinado intervalo de tempo. Por este facto, é de extrema importância a construção destes modelos uma vez que podem resolver o problema de não se saber antecipadamente a energia que irá ser produzida num determinado parque eólico.

---

## I.3. ORGANIZAÇÃO

---

Esta dissertação encontra-se dividida em cinco capítulos diferentes.

O primeiro capítulo apresenta uma introdução ao trabalho, como está organizada a tese e qual a motivação para o mesmo.

O segundo capítulo, designado por Estado de Arte, oferece uma visão geral de como funciona um aerogerador e o processo de conversão de energia do vento em energia elétrica e como estas estão relacionadas. Também aborda o conceito das redes neuronais, como é o seu funcionamento quais as suas vantagens e desvantagens uma vez que será esta a ferramenta utilizada nesta tese para resolver o problema de previsão de energia eólica. Por fim é feito um pequeno resumo de trabalhos relacionados com o problema da previsão de energia eólica.

Para compreender e perceber melhor como é o processo de identificação de sistemas com redes neuronais o terceiro capítulo será dedicado a este tema explicando como funciona este processo e como se deve seguir este processo de forma a levar a que os resultados obtidos sejam o mais satisfatórios possível.

O quarto capítulo descreve os parques eólicos alvo de estudo referindo as suas localizações, análise dos dados que são registados em cada um dos parques e por fim as técnicas de filtragem utilizadas para remover *outliers* existentes nos dados.

O quinto capítulo apresenta os resultados obtidos, os dados utilizados na construção dos modelos e os resultados de simulação para os melhores modelos para cada um dos parques eólicos.

No encerramento do trabalho, o capítulo seis apresenta as conclusões do trabalho desenvolvido.



---

## II. ESTADO DA ARTE

---

## **II.1. INTRODUÇÃO**

---

Este capítulo aborda a relação entre o vento e a potência elétrica produzida num aerogerador, também aborda as técnicas atuais para modelar este comportamento, os sistemas de monitorização e os trabalhos existentes na área de previsão de produção de energia eólica.

Na parte inicial é descrito como funciona o processo de conversão de energia proveniente do vento em energia eólica, bem como a relação entre estes dois fatores.

Percebendo-se como é que funciona este processo de conversão de energia surge a necessidade de modelar este comportamento. Uma das técnicas que tem vindo a ser bastante utilizada para esse efeito são as redes neuronais que são técnicas computacionais baseadas em modelos matemáticos e inspiradas em sistemas biológicos, como o caso dos neurónios de um humano que adquirem conhecimento através da experimentação.

Por fim um aspeto a ter em consideração é a monitorização do estado dos aerogeradores e para isso existem sistemas de recolha de dados, onde é registado uma grande quantidade de parâmetros. Utilizando os modelos de previsão baseados em redes neuronais em conjunto com estes sistemas é possível detetar possíveis anomalias de funcionamento nos aerogeradores.

## II.2. RELAÇÃO ENTRE A POTÊNCIA E A VELOCIDADE DO VENTO

O sistema de conversão de energia eólica é constituído por três partes: rotor, cabine (*nacelle*) e torre, Figura 1. Um aerogerador capta a energia cinética do vento com um rotor constituído por duas ou mais pás acoplado a um gerador elétrico.

O rotor, em relação à superfície de ataque do vento incidente nas pás, pode ser colocado a montante ou a jusante da torre. A opção *upwind*, em que o vento ataca as pás pelo lado da frente, generalizou-se devido ao facto de o vento incidente não ser perturbado pela torre. Na cabine estão alojados, entre outros equipamentos, o veio principal, o travão de disco, a caixa de velocidades (quando existe), o gerador e o mecanismo de orientação direcional. A torre suporta a *nacelle* e eleva o rotor até uma cota em que a velocidade do vento é maior e menos perturbada do que junto ao solo [2].




Figura 1 - Esquema de um aerogerador [3]

O processo de conversão de energia num aerogerador pode ser descrito pela sua curva de potência como ilustra a Figura 2.

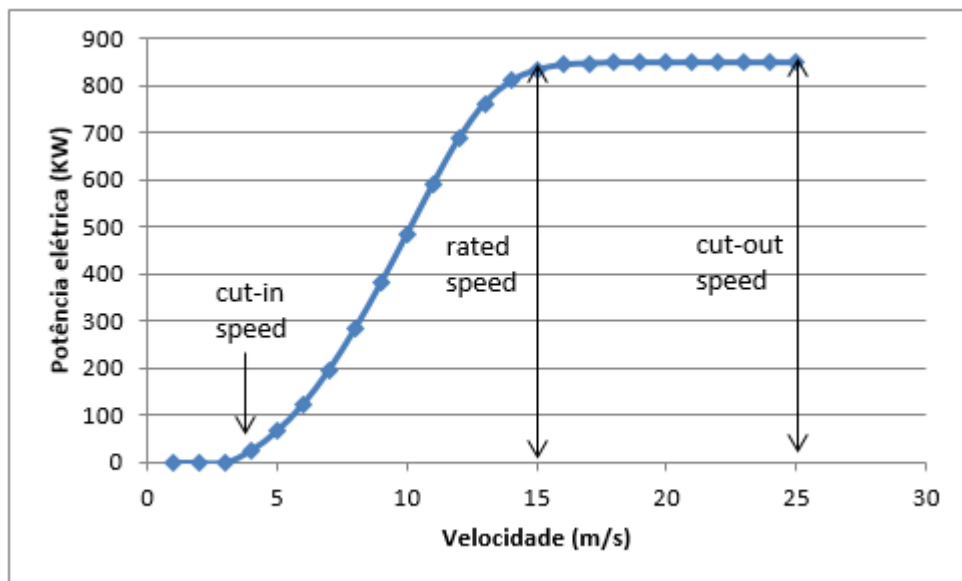


Figura 2 - Curva de potência para o aerogerador VESTAS-V52 com potência nominal de 850 KW [4]

Esta curva característica é muito semelhante, em termos de forma, para todos os aerogeradores, mesmo de diferentes fabricantes. Através da Figura 2 observa-se que não existe produção de energia para velocidades de vento inferiores a *cut-in speed*, a produção aumenta rapidamente entre as velocidades de *cut-in* e *rated speed*, sendo que a potência nominal é atingida para valores próximos da *rated speed*. A produção é quase constante entre a *rated speed* e *cut-out speed*, para velocidades superiores a *cut-out speed* a turbina pára por razões de segurança.

A produção de potência é teoricamente determinada pela seguinte equação:

$$P = \frac{1}{2} \rho A C_p(\lambda, \theta) v^3 \quad (1)$$

onde  $\rho$  é a densidade do ar,  $A$  é a área varrida pelas pás do aerogerador em  $m^2$ ,  $C_p$  é o coeficiente de potência (razão entre potência gerada pelo aerogerador e a potência disponível no vento) e  $v$  é a velocidade do fluxo de ar incidente no aerogerador. Através da equação visualiza-se que a potência gerada é função do cubo da velocidade do vento o que explica a subida abrupta da curva de potência entre *cut-in speed* e *rated speed*. A potência é ainda proporcional à densidade:

$$\rho = \frac{p}{RT} \quad (2)$$

onde  $p$  é a pressão atmosférica,  $R$  é a constante dos gases para ar atmosférico seco (287J/K KG) e  $T$  é a temperatura do ar medida em kelvin (K). Isto implica que a densidade varia de acordo com as condições atmosféricas locais e tem efeito na potência gerada por um aerogerador.

$$C_p(\lambda, \theta) = 0,22 \left( \frac{116}{\lambda_i} - 0,40\theta - 5 \right) e^{-\frac{12,5}{\lambda_i}} \quad (3)$$

$$\lambda_i = \frac{1}{\frac{1}{\lambda + 0,08\theta} - \frac{0,035}{\theta^3 + 1}} \quad (4)$$

O valor de  $C_p(\lambda, \theta)$  varia com a velocidade do vento o que implica que a curva de potência não é apenas função do cubo da velocidade do vento. O coeficiente de potência é também dependente do parâmetro  $\lambda$  denominado razão de velocidade de ponta, que é a razão entre a velocidade tangencial na ponta das pás e a velocidade do vento (ambas em m/s) e  $\theta$  é o ângulo de passo das pás do rotor em graus [5].

O valor máximo de  $C_p$  é usualmente cerca de 0,45. Para velocidade de vento altas, de 18 m/s o coeficiente é de aproximadamente 0,1 para estas velocidades o aerogerador está a extrair aproximadamente a potência máxima e é regulado para não extrair mais por razões de segurança.

### II.2.1. Redes Neurais

Atualmente, é cada vez maior o número de processos onde o controlo é automático, quer seja para necessidades da indústria ou para um maior conforto para os humanos. Tal facto está presente no nosso dia-a-dia, podendo-se verificar isto em sistemas inteligentes como o piloto automático de um avião e a colocação de máquinas em ambientes inóspitos onde o operador humano é substituído pela máquina.

O controlo automático tem assumido diversas formas em função da sua evolução, desde sistemas elementares como é o caso de um simples autoclismo aos sistemas inteligentes como os presentes no controlo de um avião moderno.

Para os sistemas mais complexos é necessário estudar o seu comportamento de forma a desenvolver um modelo que os represente e um controlador para que, sem intervenção humana, o conjunto controlador e sistema desempenhe a função pretendida.

Quando o controlo não é realizado de forma automática é utilizado um operador humano que possui a capacidade de memorizar o seu funcionamento, estabelecendo mentalmente um modelo. Este tipo de informação é guardado no cérebro, cujas unidades de processamento são os neurónios. Se um operador humano é capaz de estabelecer modelos com alguma facilidade, memorizando pontos de funcionamento dos sistemas através do cérebro, é lógico tentar perceber como os neurónios armazenam essa informação e tentar imitar esse comportamento. Este deverá ter sido o pensamento dos primeiros investigadores que se dedicaram à área das redes neuronais [6].

As redes neuronais fazem parte de um campo de estudo da Inteligência artificial, que é uma área que desenvolve técnicas que permitem incorporar num ambiente computacional, mesmo que de forma limitada, algumas funcionalidades dos sistemas biológicos no que se refere aos seus aspetos de inteligência.

As unidades de processamento (neurónios) constituem os principais elementos de uma rede neuronal. A organização das unidades de processamento define a arquitetura ou topologia de uma rede neuronal [7].

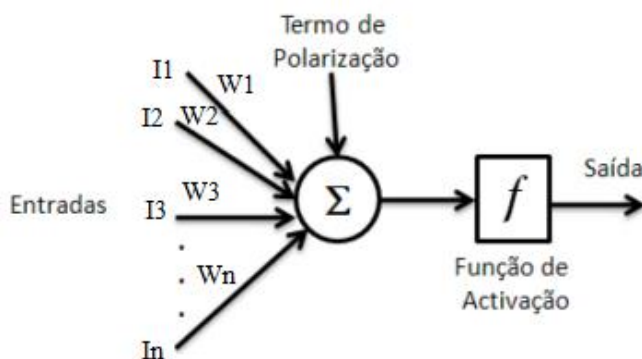


Figura 3 - Estrutura de cada unidade numa rede neuronal [8]

A unidade constituinte e central de uma rede neuronal como ilustrado na Figura 3 é o neurónio. Este é constituído pelas sinapses, que são responsáveis pela atualização dos pesos, e pela aprendizagem, por um somador e uma função de ativação.

A entrada de dados no neurónio é diretamente ligada ao número de sinapses que este possui. Cada sinapse é ligada a um dado de entrada. Quando o neurónio recebe esse conjunto de dados, transfere-os para o somador, multiplicados pelo respetivo peso associado a cada neurónio. Desta maneira o que ocorre é uma soma ponderada de todos os dados pela respetiva importância de cada sinapse.

As funções de ativação presentes na Tabela 1 têm como função modelar a amplitude de saída de cada neurónio.

Tabela 1 - Funções de ativação usadas na implementação de Redes Neurais

Nome	Função
<i>Heaviside</i>	$x < 0 \rightarrow y = 0$ $x \geq 0 \rightarrow y = 1$
<i>Heaviside simétrico</i>	$x < 0 \rightarrow y = -1$ $x \geq 0 \rightarrow y = 1$
Linear	$y = x$
Linear com saturação	$x < 0 \rightarrow y = 0$ $0 < x < 1 \rightarrow y = x$ $x > 1 \rightarrow y = 1$
Linear simétrico com saturação	$x < -1 \rightarrow y = 0$ $-1 < x < 1 \rightarrow y = x$ $x > 1 \rightarrow y = 1$
Log-sigmoide	$y = \frac{1}{1 + e^{-x}}$
Tangente hiperbólica	$y = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Um neurónio genérico implementa a função:

$$y = f\left(\sum_{i=1}^n I_i W_i\right) \quad (4)$$

onde  $I_i$  representa a  $i$ -ésima entrada e  $W_i$  o respetivo peso e  $f$  representa a função de ativação que deve ser diferenciável ou não diferenciável apenas num conjunto infinito de pontos [6].

A escolha de uma rede para uma determinada aplicação consiste em duas etapas: primeiro é necessário escolher a topologia da rede, que é a forma como os neurónios se organizam na rede, e o respetivo número de neurónios. Após a seleção da topologia é necessário escolher o algoritmo de treino, a forma de como os dados são apresentados à rede e ao equacionamento de ajuste das sinapses [7].

### II.2.1.1. Topologia da rede neuronal

A seleção da topologia da rede neuronal é uma decisão muito importante e complexa. Infelizmente não existe qualquer método ou procedimento sistemático e determinado para a configuração e especificação dos parâmetros envolvidos numa rede neuronal [8].

Tudo começa pela escolha adequada da representação dos dados a serem usados na caracterização do problema e no treino da rede. A capacidade de resolução do problema, o desempenho do treino e a fidelidade dos resultados estão intimamente ligados à qualidade da representação adotada.

A Figura 4 apresenta uma rede neuronal com duas camadas intermédias e com duas entradas, tendo a camada de saída apenas uma unidade [8].

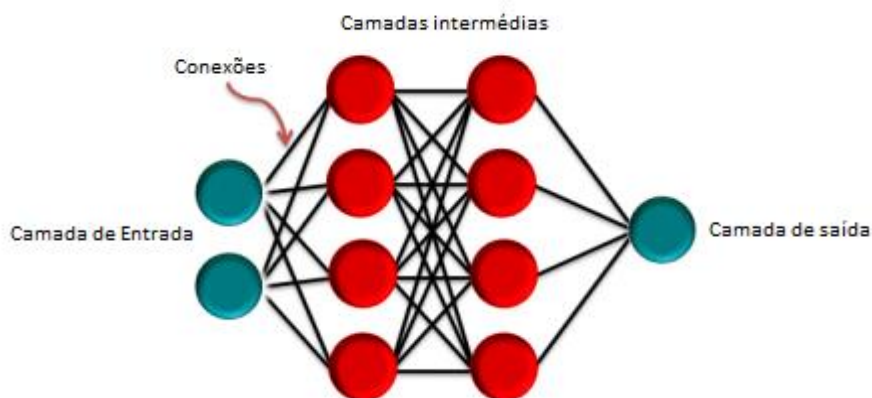


Figura 4 - Rede neuronal com as unidades organizadas em camadas [8]

A rede é organizada geralmente em camadas e o padrão de conexão mais utilizado é o de conexão completa inter-camadas (*full connected*), apenas na direção entrada-saída (*feedforward*), e nenhuma conexão intra-camada. Isto é, um neurónio situado numa determinada camada tem a sua saída conectada a todos os neurónios da camada seguinte (a sua direita) e a nenhum outro neurónio de qualquer outra camada, seja ela anterior ou a sua própria.

Como referido anteriormente a escolha da topologia é uma decisão muito importante, uma topologia demasiado simples pode resultar na incapacidade de reproduzir corretamente os dados, por outro lado, uma topologia demasiado flexível pode originar uma má capacidade de generalização, em consequência da suscetibilidade de ajustamento ao ruído e a outras peculiaridades dos dados.

Assim, a seleção da topologia da rede deve ser norteada de acordo com um compromisso entre a simplicidade e a flexibilidade, visando a obtenção de redes com capacidade de generalização aceitável.

### II.2.1.2. Modos de treino

O método de treino mais utilizado é o algoritmo de retro propagação (*backpropagation*) do erro. Este algoritmo tem como base matemática o método da descida mais íngreme (*steepest descent*). Trata-se de um método de pesquisa local, logo o treino das redes neuronais sofre dos mesmos problemas dos métodos gradientes locais. Estes métodos são muito suscetíveis a ficar aprisionados em mínimos locais, precisamente porque, nas vizinhanças de um mínimo local, o gradiente aponta sempre na "direção errada" e não permite que a solução corrente evolua no sentido de um mínimo global.

O treino da rede neuronal com o algoritmo de retro propagação do erro é realizado de forma supervisionada, onde são apresentados um a um exemplos de um conjunto de treino. Durante a fase de treino, uma passagem completa pelo conjunto de treino é designado por época. Uma prática comum é realizar o ajuste dos pesos e *bias* da rede durante várias épocas até que um determinado critério de convergência seja atingido. Este procedimento deve ser executado com extremo cuidado para evitar um sobre ajustamento da rede neuronal aos dados de treino, sendo necessário garantir a capacidade de generalização da rede neuronal.

A maioria das técnicas existentes para evitar o sobre ajustamento consegue-se com a paragem antecipada do treino (ver capítulo 3.1.4) da rede neuronal. Um método muito comum consiste em dividir os dados em treino e validação, este último conjunto é utilizado para aferir a qualidade do treino e a capacidade de generalização da rede (estimação do erro de generalização); durante a fase de treino, em cada época é calculado o erro no conjunto de validação parando-se quando ao fim de um número definido de iterações o erro aumentar sucessivamente, sendo a melhor solução aquela que dá o erro menor no processo de teste.

## II. Estado da Arte

O treino de retro propagação (*backpropagation*) do erro pode ser realizado de três formas distintas:

**Modo Batch ou offline:** os parâmetros são ajustados somente ao final de cada época (processamento de todo o conjunto de observações), ou seja, os parâmetros da rede são ajustados somente ao final de cada ciclo. Nesta dinâmica, o treino é menos influenciado pela ordem de apresentação dos padrões, é menos suscetível a oscilações, porém a velocidade de aprendizagem (convergência) geralmente é mais baixa. Esta solução é a mais adequada quando os dados estão afetados por ruído.

**Modo Sequencial ou estocástico:** os parâmetros são ajustados ao final do processamento de cada observação (padrão), ou seja os pesos da rede são ajustados no final do processamento de cada observação. Nesta dinâmica, a ordem da apresentação dos padrões é importante para a velocidade de aprendizagem da rede e, em alguns casos, deve-se reorganizar esta ordem, de forma a acelerar o treino.

**Modo Online:** cada novo exemplo de treino disponível é propagado desde a entrada da rede até à saída, sendo depois o erro à saída retro propagado apenas uma vez, atualizando de imediato os pesos da rede. Poderá ser conveniente previamente realizar um treino *offline* com os dados disponíveis (se existirem), para determinar os pesos iniciais do treino online.

### II.2.1.3. Algoritmos de treino

Uma rede neuronal é um aproximador universal [9,10 e 11], para efetuar essa aproximação é necessário executar o ajuste dos parâmetros que permitem essa aproximação, sendo esse processo chamado de treino. Ao efetuar o treino de uma rede neuronal é necessário recorrer a um algoritmo de treino que será o responsável por atualizar os pesos associados a cada ligação entre as entradas e neurónios e entre as saídas e neurónios. O treino é um processo iterativo que após cada alteração do conjunto dos pesos avalia o desempenho do novo conjunto e procura uma solução nova caso a atual não seja satisfatória.

Muitos destes algoritmos já se encontram desenvolvidos, alguns deles foram desenvolvidos especificamente para as redes neuronais e outros foram adaptados e já foram abundantemente estudados pelo que são algoritmos que proporcionam bons resultados e a ideia de funcionamento para todos os algoritmos de treino é semelhante o que varia é a forma como são atualizados os pesos da rede neuronal e a forma como são calculados os critérios de convergência.

Dois dos algoritmos mais utilizados para a resolução de problemas não lineares são o algoritmo Levenberg-Marquart [12,13] e o algoritmo de Gauss-Newton [19], estes algoritmos são variações do método de Newton, que foi criado para minimizar funções que são somas de quadrados de outras funções lineares.

Para avaliar o desempenho do processo de treino existe a necessidade de avaliar a qualidade da solução encontrada, mesmo durante o treino ou posteriormente ao treino. Uma das soluções para avaliar o desempenho e a mais utilizada, é baseada no erro quadrático (EQ) ou no erro quadrático médio (EQM) [6]. Para efetuar esse cálculo são utilizadas as seguintes expressões:

$$EQ = \sum_{i=1}^N (o - y)^2 \quad (5)$$

$$EQM = \frac{1}{N} \cdot \sum_{i=1}^N (o - y)^2 \quad (6)$$

onde  $o$  é a saída pretendida,  $y$  é a saída obtida após o treino e da rede neuronal e  $N$  é o número de pontos utilizados.

#### II.2.1.4. Vantagens e desvantagens das redes neurais

Vantagens	Desvantagens
Qualidade superior comparada com outras técnicas estatísticas.	Resultados desconcertantes, as redes podem permitir chegar a conclusões que contrariam a teoria.
Competitividade, como é uma tecnologia recente empresas que possuem redes mais elaboradas ficam em vantagem em relação às outras.	Treino demorado, o treino da rede em função da aplicação pode demorar horas ou até dias.
Autoaprendizagem, não precisam de conhecimento de especialistas, apenas baseiam-se em dados históricos.	Caixa-cinzenta, embora seja possível saber porque uma rede chegou a determinada conclusão, os critérios que levam a rede a tomar uma decisão são de difícil interpretação.
Custo de implementação, a sua implementação é rápida quando comparado com um sistema equivalente o que torna os custos menores.	Grande volume de dados, para uma rede aprender corretamente poderá precisar de centenas de dados históricos.
Capacidade de generalização, mesmo com lacunas nos dados ou dados incompletos as	Preparações dos dados, estes necessitam de tratamento prévio, por exemplo serem

redes podem preencher essas lacunas sem degradação	normalizados. Dados de má qualidade podem levar a maus resultados.
Adaptabilidade, quando bem construída uma rede eficiente numa determinada aplicação, esta pode ser utilizada em aplicações em tempo real sem que seja necessário alterar a sua arquitetura a cada utilização.	Tentativa e erro, não existe uma regra para determinar o volume de dados para treino, quantos neurónios colocar na camada escondida, percentagem de dados usados para treino e para teste, etc.

## II.2.2. Sistemas existentes para a monitorização de aerogeradores

Atualmente existem no mercado diversos sistemas de monitorização do funcionamento dos aerogeradores. Grande parte desses sistemas é baseada em análises de vibração e usam essas vibrações como um indicador da condição do aerogerador tal como o sistema SKF's *WindCon* [14].

O principal componente a ter em consideração é a transmissão: a caixa de velocidades que é composta por rolamentos e engrenagens, o eixo principal, o rolamento principal e o gerador. [15]

Outras técnicas que podem ser utilizadas para monitorizar a condição dos aerogeradores são a análise do óleo, a termografia, a condição física dos materiais, a medição de tensão, a medição acústica, os efeitos elétricos, os parâmetros do processo, as inspeções visuais e monitorização da performance.

Estas técnicas permitem uma manutenção básica que pode ser aplicada aos aerogeradores. Esta estratégia implica que a manutenção seja conduzida antes que ocorra uma falha devendo ser também capaz de prever falhas iminentes.

Uma vez que a tendência é para instalar torres cada vez maiores e em lugares de acesso remoto os custos de manutenção estão a aumentar. A estratégia mais eficiente para manutenção difere para os distintos componentes do aerogerador.

Foi provado que a manutenção baseada em condição é eficiente em relação aos custos para componentes como engrenagens e rolamentos [16]. Esta investigação mostra que esta estratégia pode otimizar a manutenção para um parque eólico e os custos de manutenção são reduzidos significativamente [17].

Outras estratégias que podem ser aplicadas são baseadas no tempo, implicando que a manutenção seja efetuada num tempo predeterminado. Estas estratégias podem ser mais eficientes em termos de custos para alguns componentes do aerogerador, por exemplo nos casos em que é difícil prever uma falha iminente.

Para monitorização da performance dos aerogeradores é utilizado, frequentemente, um sistema SCADA (*Supervisory Control And Data Acquisition*). Estes são usados como complemento dos

sistemas de monitorização de condição, que apenas disponibiliza informações acerca da condição dos componentes do aerogerador e não da performance do aerogerador.

Os sistemas SCADA têm sido, durante um longo período, uma parte vital do sistema de controlo do aerogerador. Esses sistemas têm sido desenvolvidos recentemente para colher, monitorizar e guardar grandes quantidades de dados, fazendo com que os sistemas de monitorização melhorassem significativamente.

Todas as torres que estão a ser instaladas hoje em dia têm sensores que são utilizados para obter grandes quantidades de dados SCADA. Este sistema visa controlar e monitorizar todo o processo e o número de medições distintas é usualmente superior à 50 para cada aerogerador. Parâmetros de interesse particular, para além da velocidade do vento e a potência ativa, são as temperaturas da engrenagem de velocidades, temperatura do óleo da engrenagem e a temperatura dos rolamentos do gerador. A frequência das medições é geralmente de 1 Hz, mas a maior parte dos sistemas SCADA apenas guardam informação da média de intervalos de 10 minutos. Os dados utilizados para este trabalho são recolhidos através de um sistema deste tipo para o parque eólico que se está a trabalhar.

As redes neuronais podem ainda ser utilizadas de forma a detetar anomalias nos aerogeradores em conjunto com os sistemas SCADA. Uma rede neuronal é um sistema de mapeamento não linear para identificar padrões em grandes quantidades de dados. Foi verificado em [18] que este é um dos melhores métodos para descobrir anomalias nos aerogeradores, bem como para a previsão de potência sob determinadas condições.

---

## II.3. TRABALHOS RELACIONADOS

---

A previsão da energia eólica é de elevada importância e poderá ter várias aplicações, nomeadamente na otimização da gestão da rede elétrica, no comércio da energia eólica no mercado de energia e no planeamento da manutenção dos parques eólicos e linhas de transporte.

Contudo a previsão da produção de energia eólica é um problema complexo, devido ao comportamento aleatório do vento e às não linearidades introduzidas pela curva de potência dos aerogeradores. Assim, a investigação incide no estudo e desenvolvimento de ferramentas computacionais com o intuito de prever a potência eólica com precisão.

Os métodos considerados como métodos de referência são normalmente métodos mais simples, como o método da persistência, em que se considera que o valor previsto é igual ao apresentado no presente. Embora este método seja um método muito simples, apenas se torna fiável para previsões em horizontes temporais a muito curto prazo. No entanto este método continua a apresentar resultados a curto prazo melhores do que muitos outros métodos mais complexos [2].

De um modo geral, podem distinguir-se três métodos de previsão: métodos físicos, métodos estatísticos e métodos combinados. Os métodos físicos tentam utilizar apenas considerações físicas para alcançar as melhores estimativas da velocidade do vento.

Os métodos estatísticos procuram encontrar relações entre as variáveis explicativas e o valor da variável a prever, utilizando normalmente técnicas recursivas, sendo neste caso necessário determinar analiticamente uma expressão que traduza a relação entre os valores de entrada e saída. Contudo, métodos estatísticos mais sofisticados, como as redes neuronais artificiais conseguem encontrar essa relação entre os valores de entrada e saída, e deste modo gerar melhores previsões que os métodos clássicos de regressão linear [8].

Ao longo das últimas décadas foram realizados vários estudos acerca da capacidade de prever a produção de energia eólica. Sendo através desses estudos, encontradas várias soluções, onde algumas das quais já foram implementadas. Cameron e Michael combinaram abordagens através de sistemas difusos (*fuzzy systems*) e redes neuronais num sistema de inferência adaptativo de neurónios difusos (*neuro-fuzzy*), para a previsão de séries temporais de vento [20].

Landberg [21] construiu um modelo para prever a potência produzida por um sistema eólico usando os dados a partir do de previsão do tempo *High-Resolution Limited Area Model* (HIRLAM) e o modelo de previsão do tempo local *Wind Atlas Application and Analysis Program* (WASP).

Li et al. [22] compararam modelos de regressão e redes neuronais, a fim de estimar a curva de um aerogerador. Constataram que o modelo de redes neuronais superou o modelo de regressão. Goh et al. [23] sugeriam uma arquitetura de uma rede neuronal *Complex-valued Pipelined Recurrent Neural Network* (CPRNN), utilizando um valor complexo (combinação da velocidade do vento e direção num valor complexo) como entrada da rede neuronal, para prever a saída do aerogerador.

Lange e Focken [24] apresentaram vários modelos para prever a energia do vento a curto prazo, incluindo os modelos físicos, conjuntos difusos e redes neuronais difusas.

Barbounis et al. [25] construíram um modelo de rede neural recorrente local para a previsão a longo prazo da velocidade do vento e a potência produzida com base em dados meteorológicos. Previsões de hora em hora, até às 72 horas seguintes, foram produzidas para um parque eólico.

Neste contexto é primordial a utilização de ferramentas que permitam prever a potência associada à geração eólica para efeitos de despacho do sistema electroprodutor conseguindo-se desta forma uma melhor gestão da produção e do mercado da eletricidade.

Para resolver tal facto pretende-se, com este trabalho, desenvolver um modelo/ferramenta baseado em redes neuronais, utilizando conceitos/abordagens já existentes nesta área e adaptando-os a um parque eólico existente na RAM e outro em Cabo Verde.

---

## II.4. CONCLUSÃO

---

As redes neuronais têm sido uma ferramenta cada vez mais utilizada na modelação de sistemas, nomeadamente em sistemas que se pretende, no ambiente de simulação, prever o seu comportamento ou até mesmo efetuar previsões de produção de energia num parque eólico que é muito útil para controlo da energia que estará a ser produzida num determinado instante.

Possuindo-se uma maior noção de como as redes neuronais funcionam, da sua utilidade, simplicidade de utilização, capacidade de generalização e adaptabilidade. Como verificado em trabalhos já realizados, este é um bom método de previsão em problemas de energia eólica e é prudente recorrer a esta técnica que é de utilização simples e obtém bons resultados.

---

### **III. IDENTIFICAÇÃO DE SISTEMAS COM REDES NEURONAIS**

---

## III.1. INTRODUÇÃO

---

A identificação de sistemas é uma área científica relativa à construção ou seleção de modelos de sistemas dinâmicos para servirem determinados propósitos [26].

O processo de identificação de sistemas baseados em redes neurais aplica diretamente a maioria dos resultados já conhecidos da teoria dos sistemas lineares, mas com um ligeiro aumento da complexidade [27].

Este processo de identificação de sistemas baseados em redes neurais, consiste numa sequência de etapas, começando pela aquisição dos dados, seguindo-se a determinação do número de regressores ou ordem do sistema, pré processamento dos dados, escolha da classe de modelos a utilizar e por fim a utilização de uma estrutura de treino e validação da qualidade do modelo. Na figura 5 está representado de forma simplificada o processo que leva à identificação de um sistema e à consequente criação de um modelo.

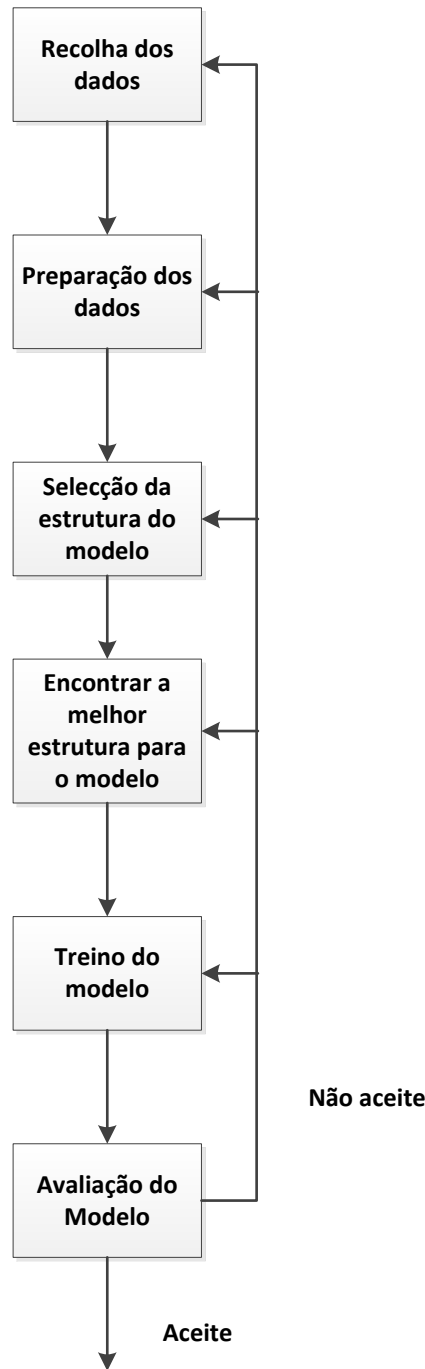


Figura 5 - Processo de construção de um modelo

Das quatro etapas presentes no modelo a mais difícil de executar é a seleção da estrutura do modelo, pois existem vários modelos há escolha e não é possível prever antecipadamente que tipos de resultados serão obtidos [6]. Daí este processo não ser de sentido único, por vezes é necessário voltar atrás após a avaliação do modelo, quer seja para escolher uma nova estrutura para o modelo ou ter de efetuar um novo treino ou até em último caso ter de fazer uma nova recolha de dados. Em relação ao treino e avaliação ou validação do modelo será abordado mais à frente a forma como estas operações foram realizadas.

### III. Identificação de Sistemas com Redes Neurais

No processo de avaliação do modelo geralmente são utilizados outros dados que não foram utilizados na construção do modelo por forma a verificar se o modelo escolhido possui capacidade de generalização.

Este processo é simples de se realizar, mas o seu funcionamento é uma espécie de tentativa e erro o que o torna um pouco exaustivo, contudo há uma grande variedade de soluções já existentes em que se consegue obter bons resultados, daí a maior dificuldade é a de selecionar a estrutura para o modelo que proporciona os melhores resultados possíveis.

Geralmente num processo deste tipo por vezes são armazenados milhares de dados sendo que também podem existir muitas variáveis que são registadas o que torna muito complicada a tarefa de “olhar” para os dados e retirar alguma informação deles, para além de que nestes sistemas é registada informação que não corresponde ao real funcionamento do sistema quer seja por erro humano ou por erros de sensores ou de qualquer outra forma que seja utilizada para registar informação.

Porém existem técnicas existentes que ajudam tanto a detetar *outliers*, como relações entre variáveis, através de auto correlações, co linearidade, testes estatísticos entre outros.

Em [28] é explicado como através de um conjunto de dados históricos é possível construir um conjunto de dados que seja o mais aceitável possível e que melhor descreva o funcionamento de um determinado sistema. Um resumo de como isto pode ser feito é apresentado na figura 6.

Uma outra função que pode ser útil quando se trabalha com redes neuronais é a função de *Lipschitz* que é utilizada como auxiliar na determinação do número de regressores que irão ser utilizados como entrada da rede neuronal (ver anexo A).

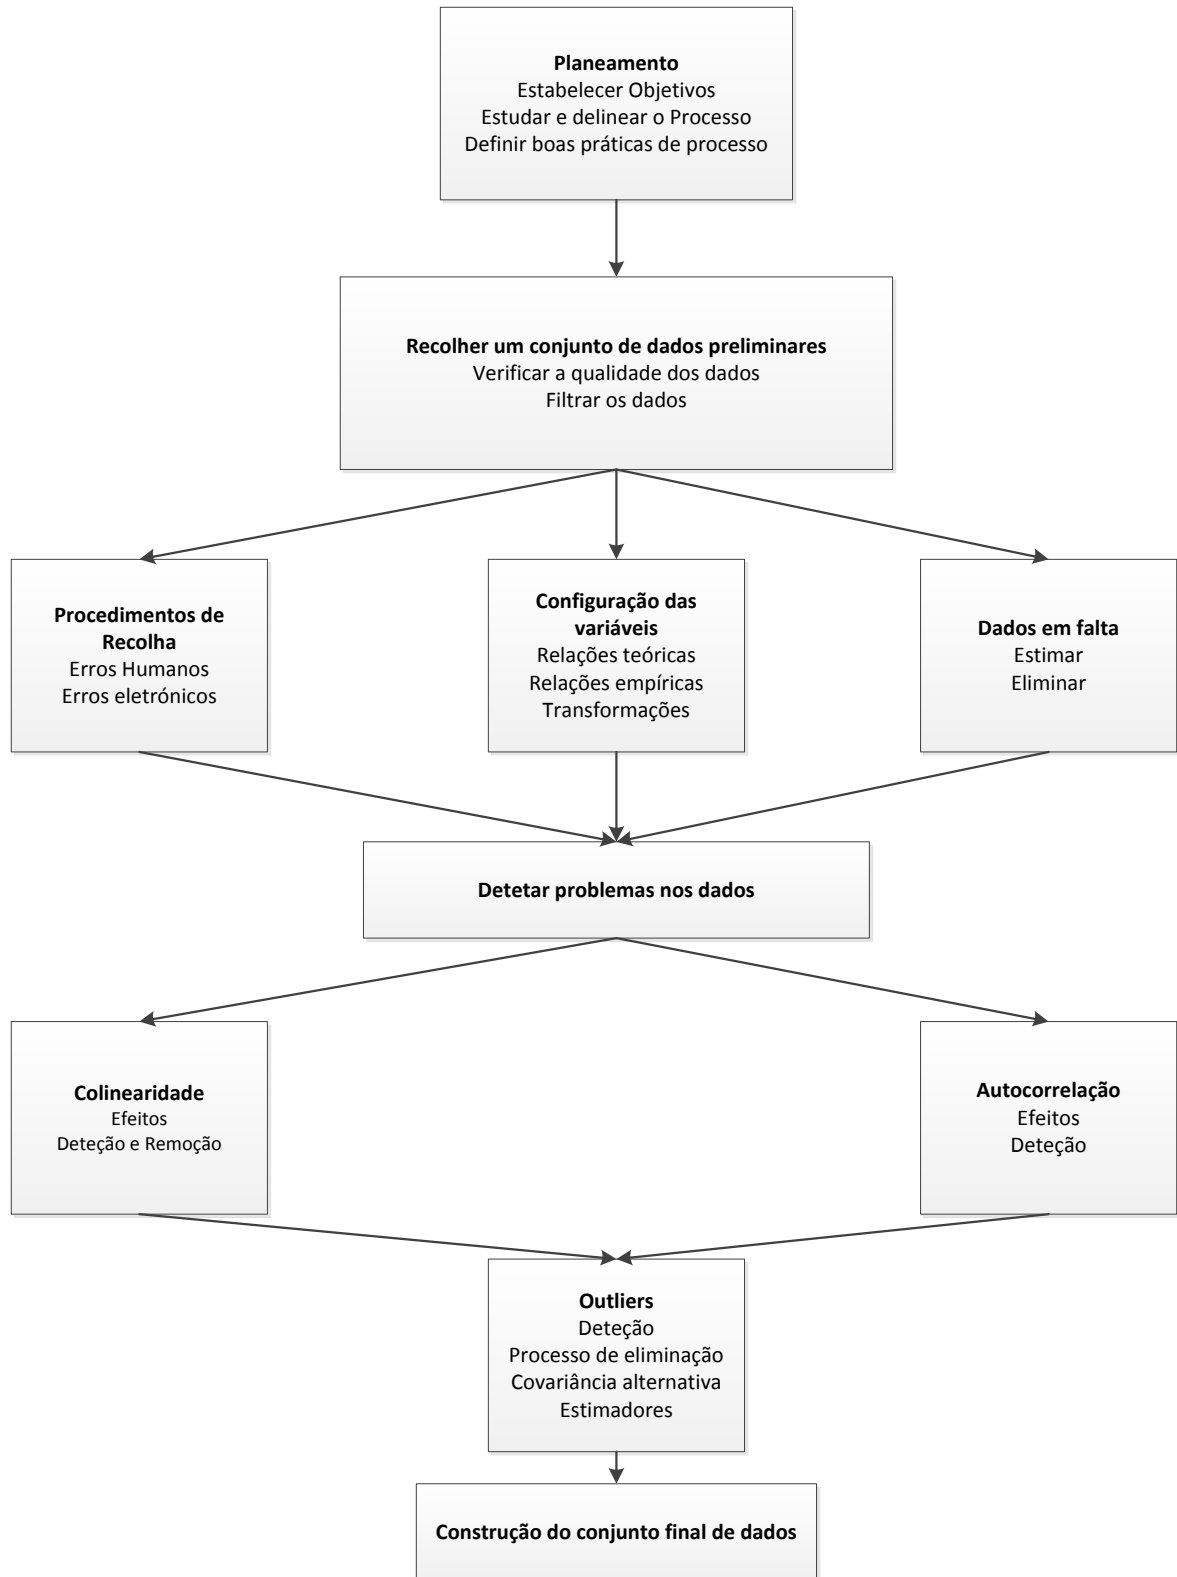


Figura 6 - Processo de construção de um conjunto de dados

## **III.2. RECOLHA DE DADOS**

---

A fase de recolha dos dados, à primeira vista, pode parecer uma operação demasiado simples de construir no processo de identificação de sistemas e à partida pode parecer não constituir uma fase neste processo, contudo é uma fase, uma vez que esta só está concluída quando a identificação do sistema é bem-sucedida.

A recolha de dados não foi realizada neste trabalho uma vez que os dados disponíveis já estavam recolhidos. Mas geralmente nesta fase são escolhidas as condições experimentais, o período de amostragem e o tipo de dados a utilizar.

### III.3. PREPARAÇÃO DOS DADOS

Após a conclusão da fase de recolha dos dados existe a necessidade de os preparar para realizar o treino dos modelos. Para tal é necessário efetuar um pré processamento dos dados através de técnicas de filtragem, separação dos dados em diferentes conjuntos e escalar os dados.

#### III.3.1. Escalar os dados

Em [26] é fortemente recomendado a aplicação de um fator escala aos dados, justificado pelo facto de haver a possibilidade dos sinais serem medidos em unidades físicas diferentes o que fará com que o sinal de maior amplitude domine o modelo. O algoritmo de treino torna-se mais robusto e leva a uma convergência mais rápida, a experiência em [27] mostra que os resultados obtidos pelos modelos são mais precisos.

A aplicação de um fator de escala significa para cada valor das amostras aplicar a seguinte fórmula:

$$X_{novo} = \frac{X - \mu}{\sigma} \quad (8)$$

onde  $X_{novo}$  corresponde ao valor escalado,  $X$  é uma observação,  $\mu$  é a média das observações e  $\sigma$  o respetivo desvio padrão. A aplicação do fator escala está ilustrada na figura 7, onde  $U$  representa o sinal de entrada,  $Y$  o sinal de saída,  $Us$  o sinal de entrada escalado e  $Ys$  o sinal de saída escalado.




Figura 7 - Aplicação do fator escala

Este processo de aplicação do fator escala nem sempre têm de ser realizado desta forma e nem sempre é um processo simples, por exemplo poderá haver modelos em que não é possível saber *a priori* a média e a variância das amostras. O processo para resolver este problema não será aqui demonstrado uma vez que não foi necessário utilizar neste trabalho. A aplicação do fator escala não tem de seguir o processo demonstrado na figura 7. No caso do trabalho aqui presente, todos os sinais foram escalados e só depois da validação do modelo é aplicado o fator escala inverso.

### III.3.1.1. Pré-processamento dos dados

Nesta fase de pré-processamento dos dados, geralmente, é efetuada a remoção de dados redundantes e de *outliers*. A eliminação de dados redundantes consiste em remover dados que representam o mesmo funcionamento de um determinado sistema, ou seja, que não contribuem para uma melhor caracterização do sistema.

Contudo na modelação de certos sistemas, como foi o caso deste trabalho, a eliminação de dados redundantes pode ser complexa de efetuar devido à dependência que a saída tem das amostras anteriores neste tipo de sistemas dinâmicos. Os modelos não poderão ser treinados com dados onde é perdida a sequência das amostras anteriores, a solução encontrada neste trabalho para resolver este problema está descrita no próximo capítulo.

Outro aspeto a ter em atenção é a remoção de *outliers* que consistem em valores cuja saída não corresponde à entrada. Torna-se óbvio com esta afirmação que para os poder identificar é necessário possuir um conhecimento alargado do sistema que se está a modelar. A remoção destes *outliers* pode ser através de substituição de amostras que possuam um comportamento semelhante ou por substituição dos valores estimados. Nenhuma destas técnicas será utilizada neste trabalho porque podem ser introduzidos valores que não correspondam ao funcionamento normal de um aerogerador.

### III.3.1.2. Divisão dos dados em diversos conjuntos

Quando se está a construir modelos baseados em redes neurais habitualmente os dados são divididos em conjuntos que vão ser utilizados para diferentes funções. Usualmente estes dados são divididos em dois conjuntos, um conjunto maior de dados para treino do modelo e outro mais pequeno para validação do modelo. Geralmente, esta técnica é utilizada devido à necessidade de resolver o problema de *overtraining*. Este problema surge dado que a rede neuronal pode aprender a informação específica do conjunto de dados quer seja o ruído ou as características desnecessárias do sinal, perdendo desta forma capacidade de generalização.

Portanto, para resolver este problema é utilizada a sequência de treino para a aprendizagem da rede neuronal e é usada a sequência de teste após o treino da rede neuronal para verificar a capacidade de generalização da rede neuronal e resolver o problema do *overtraining*.

### III.3.1.3. Ordem do sistema

“Na identificação de sistemas “clássicos” para se construir um modelo do sistema é essencial determinar a sua ordem, ou seja, determinar qual a ordem das equações necessária para caracterizar o sistema com determinado grau de exatidão ou encontrar um ponto de equilíbrio entre a facilidade de estabelecer o modelo e a sua exatidão” [6].

Quando se está a modelar com redes neurais a situação é semelhante uma vez que o aumento do número de regressores leva a um rápido aumento dos parâmetros. Na identificação de sistemas com redes neurais a palavra “ordem” deve ser substituída por número de regressores, pois o termo ordem não se aplica em modelos com redes neurais.

O número de parâmetros (NP) numa rede neuronal é dado pela seguinte expressão:

$$NP = NCE \cdot (NE + 1) + NS \cdot NCE + 1 \quad (9)$$

onde NCE é o número de neurónios na camada escondida, NE número de entradas e NS número de saídas. O que implica que um aumento do número de regressores leve a uma maior dificuldade em efetuar o treino, pois quanto mais elevado for o número de regressores maior será o número de entradas fazendo com que o número de parâmetros seja maior.

### III.3.1.4. Paragem de treino antecipada

A paragem de treino antecipada consiste em limitar o número de iterações de treino de uma rede neuronal. Supondo que a primeira iteração de treino é designada por  $\theta_0$  as primeiras iterações de treino irão inicialmente modificar os parâmetros que têm maior influência no erro de treino e só posteriormente serão efetuados os ajustes “finos”, ou seja, dos parâmetros que possuem menor influência.

Quando o treino é excessivo através destes ajustes “finos” o sistema pode aprender características desnecessárias do sistema, como por exemplo o ruído. Por este motivo é necessário encontrar um equilíbrio entre a aprendizagem dos parâmetros que têm maior influência e os que possuem menor influência.

### III. Identificação de Sistemas com Redes Neurais

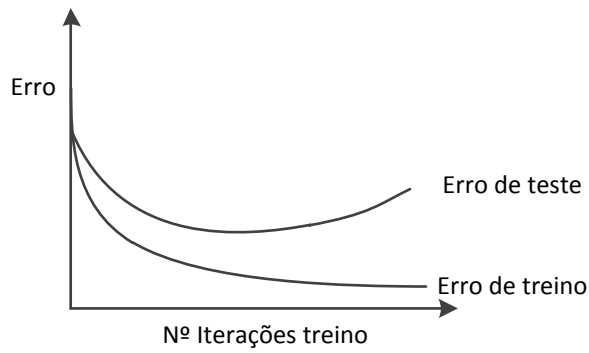


Figura 8 - Erro de treino vs. Teste

Analisando a figura 8 verifica-se que à medida que o número de iterações de treino aumenta o erro de teste ou validação a partir de um determinado ponto começa a aumentar o que é inconveniente quando se está a modelar este tipo de sistemas. Este acontecimento ocorre sempre no treino de redes neurais pelo que é necessário encontrar um ponto de equilíbrio entre número de iterações de treino e do erro de teste. Demasiadas e poucas iterações fazem com que o sistema produza erros elevados, daí surge a necessidade de encontrar a iteração de treino em que o erro de teste é o mínimo, a esta técnica chama-se paragem antecipada do treino.

---

## III.4. CONCLUSÃO

---

Neste capítulo foi apresentando o processo de identificação de sistemas baseado em redes neuronais. Como referido, é um processo sequencial e exaustivo e muitas vezes há a necessidade de voltar atrás entre as etapas para que a qualidade do modelo seja a melhor. Este processo começa pela recolha dos dados, seleção da estrutura do modelo, seleção da melhor estrutura para o modelo treino do modelo e por fim a avaliação do modelo.

Foi abordado de forma muito breve algumas técnicas existentes como o pré processamento dos dados, a divisão dos dados em conjuntos, a determinação da ordem do sistema e paragem do treino antecipada. Estas foram as técnicas utilizadas nesta tese para a construção dos modelos, que em conjunto contribuem para melhores resultados.

Apesar de existirem algumas técnicas, este é um processo que requer muita supervisão por parte do utilizador, por exemplo não existem técnicas para determinar qual o melhor número de neurónios, o número de iterações de treino, como escolher o tempo de amostragem, entre outras, daí a razão pela qual este é um processo de muita tentativa e erro.



---

## **IV. DESCRIÇÃO E TRATAMENTO DOS DADOS DOS PARQUES EÓLICOS**

---

## **IV.1. INTRODUÇÃO**

---

Neste capítulo serão apresentados os parques eólicos em estudo. Estão em análise dados referentes a três parques eólicos, os quais serão descritos brevemente, sendo também efetuada uma análise de quais os dados que são recolhidos para cada um deles.

Geralmente, neste tipo de registo de dados existe a possibilidade de ocorrência de erros nas medições o que leva a registo de dados errados e por vezes também há ausência de alguns registos. Para resolver estes problemas, neste capítulo será apresentada uma descrição mais detalhada dos dados em análise para os três parques eólicos e as soluções encontradas para ultrapassar as falhas existentes nos dados, para que os dados utilizados na construção dos modelos sejam os melhores possíveis.

---

## IV.2. DESCRIÇÃO DOS PARQUES EÓLICOS

---

O parque eólico de Cabo Verde situa-se na ilha de São Vicente e tem uma potência instalada de 900 KW repartidos por 3 aerogeradores *Nordtank*, com uma potência nominal de 300 kW cada. O comportamento destes aerogeradores é descrito pela sua curva de potência característica na Figura 9.

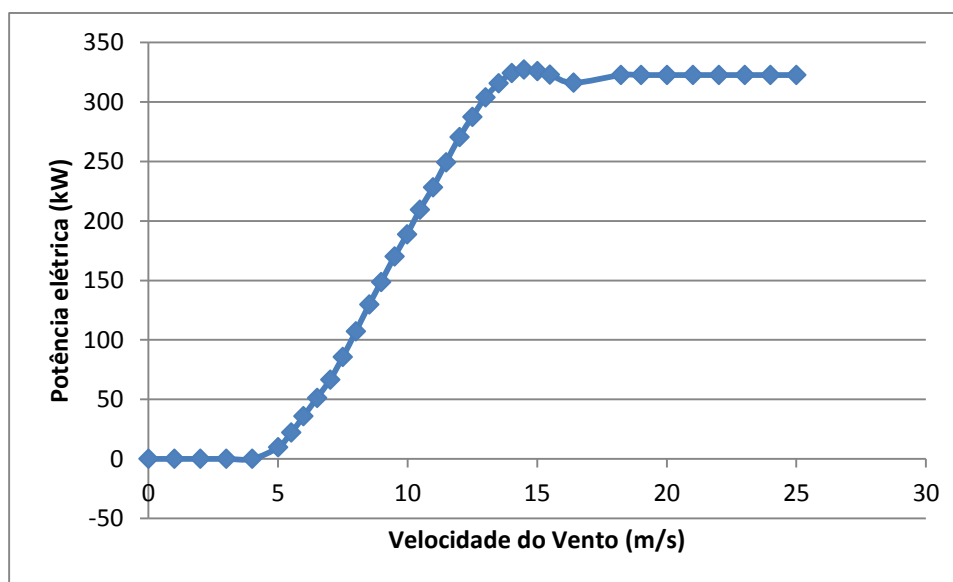


Figura 9 - Curva de potência do aerogerador Nordtank para densidade do ar igual a 1,225 kg/m<sup>3</sup>

O terreno onde os aerogeradores estão instalados, a sua orografia é constituída por pequenos vales e montanhas, Figura 10.

IV. Descrição e Tratamento dos Dados dos Parques Eólicos



Figura 10 - Localização do parque eólico de Cabo Verde [23]

Os restantes parques eólicos estão localizados na Ilha da Madeira, um é denominado parque eólico do Loiral, tem uma potência instalada de 5100 KW repartidos por 6 aerogeradores Vestas V-52 de 850kW e o seu comportamento é descrito pela sua curva de potência característica na Figura 11.




Figura 11 - Curva de potência do aerogerador Vestas-V52 para densidade do ar igual a 1,225 kg/m<sup>3</sup>

O parque está localizado num planalto no topo das montanhas, Figura 12.

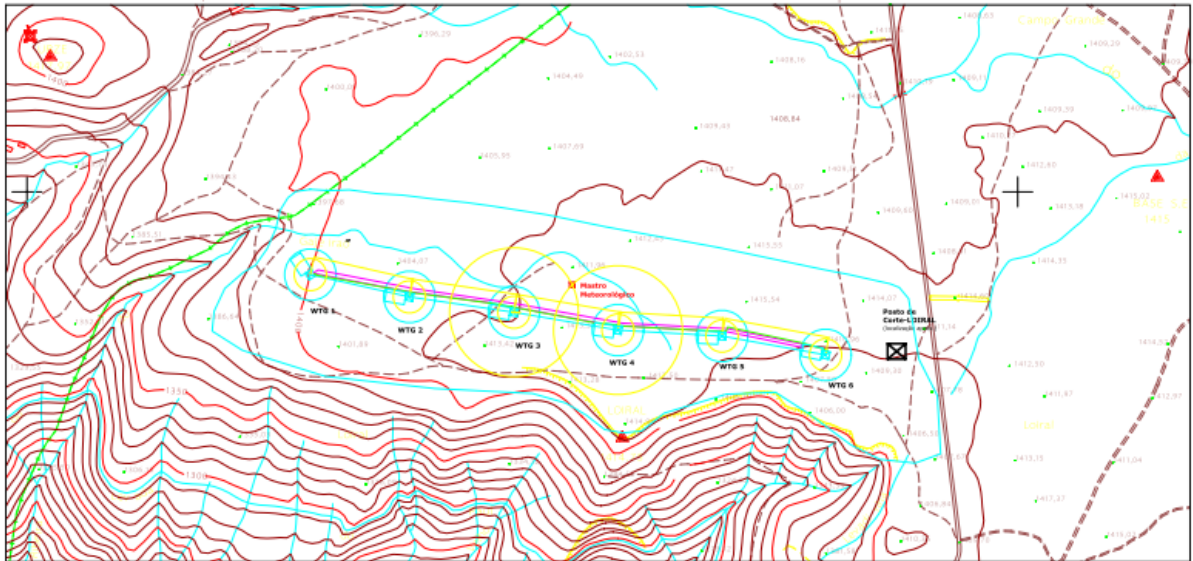


Figura 12 - Localização parque eólico do Loiral [30]

O outro parque encontra-se também localizado na Ilha da Madeira e é denominado parque eólico das Pedras, tem uma potência instalada de 10200 KW repartidos por 12 aerogeradores Vestas V-52 de 850kW. A topologia do terreno é idêntica à do parque do Loiral, Figura 13.




Figura 13 - Localização parque eólico das Pedras [31]

#### IV.2.1.1. Conjunto de dados

Como referido anteriormente os dados disponíveis são referentes a três parques eólicos, o de Cabo Verde, do Loiral e das Pedras. Para o parque eólico de Cabo Verde os dados estão organizados em medições efetuadas desde o início do ano 1995 até 1998. Estes estão organizados mensalmente, através de medições periódicas de dez minutos, sendo registados a velocidade do vento no sensor número 1 e 2 localizados num mastro meteorológico a diferentes alturas, direção do vento, pressão atmosférica e as produções de energia para os três aerogeradores.

Em relação aos dados do parque eólico do Loiral, foram também recolhidos em amostras de medições periódicas de dez minutos com início a 1 de Setembro de 2009 até 31 Agosto de 2010 e ainda outros que foram recolhidos de 1 de Janeiro de 2011 a 31 de Dezembro de 2011.

Os dados registados são os parâmetros da velocidade média do vento, direção do vento medidas na *nacelle* do aerogerador e ainda a potência média. Também é registada a velocidade média do vento, direção do vento, pressão atmosférica e temperatura medidas num mastro meteorológico. Os parâmetros de temperatura e pressão atmosférica não estavam disponíveis para este parque no ano de 2009, já para os dados de 1 de Janeiro de 2011 a 31 de Dezembro de 2011 estes parâmetros encontram-se disponíveis.

Em relação aos dados do parque eólico das Pedras os dados foram recolhidos da mesma forma que os do parque eólico do Loiral para o mesmo período de tempo, sendo as variáveis medidas também as mesmas. Os parâmetros de temperatura e pressão atmosférica também não estão disponíveis para este parque para o primeiro período de recolha.

De forma a verificar se a recolha destes dados era contínua, ou seja, sem falhas de leitura, foi feita a seguinte análise para os três parques eólicos (ver tabelas 2,3 e 4):

Tabela 2 - Dados em falta no parque de Cabo Verde no de ano de 1995

Parâmetro	Número de leituras em falta	Percentagem
Velocidade Vento Sensor 1	10813	20,57%
Velocidade Vento Sensor 2	10791	20,53%
Direção do Vento	10795	20,54%
Pressão Atmosférica	10791	20,53%
Temperatura	10791	20,53%
Produção Torre 1	10806	20,56%
Produção Torre 2	10803	20,55%
Produção Torre 3	10803	20,55%

Tabela 3 - Dados em falta no parque de Cabo Verde no ano de 1996

<b>Parâmetro</b>	<b>Número de leituras em falta</b>	<b>Percentagem</b>
<b>Velocidade Vento Sensor 1</b>	12449	23,69%
<b>Velocidade Vento Sensor 2</b>	12449	23,69%
<b>Direção do Vento</b>	12457	23,70%
<b>Pressão Atmosférica</b>	12450	23,69%
<b>Temperatura</b>	12450	23,69%
<b>Produção Torre 1</b>	12453	23,69%
<b>Produção Torre 2</b>	12456	23,70%
<b>Produção Torre 3</b>	12456	23,70%

Tabela 4 - Dados em falta parque Cabo Verde ano 1997

<b>Parâmetro</b>	<b>Número de leituras em falta</b>	<b>Percentagem</b>
<b>Velocidade Vento Sensor 1</b>	25516	48,55%
<b>Velocidade Vento Sensor 2</b>	28842	54,87%
<b>Direção do Vento</b>	21895	41,66%
<b>Pressão Atmosférica</b>	21895	41,66%
<b>Temperatura</b>	21895	41,66%
<b>Produção Torre 1</b>	21895	41,66%
<b>Produção Torre 2</b>	21895	41,66%
<b>Produção Torre 3</b>	21895	41,66%

IV. Descrição e Tratamento dos Dados dos Parques Eólicos

Tabela 5 - Dados em falta no parque de Cabo Verde no ano de 1998

Parâmetro	Número de leituras em falta	Percentagem
Velocidade Vento Sensor 1	12641	24,05%
Velocidade Vento Sensor 2	15670	29,81%
Direção do Vento	8375	15,93%
Pressão Atmosférica	8365	15,92%
Temperatura	8363	15,91%
Produção Torre 1	8375	15,93%
Produção Torre 2	8374	15,93%
Produção Torre 3	12671	24,11%

Tabela 6 - Dados em falta medidos na nacelle dos aerogeradores do parque do Loiral no ano de 2011

Parâmetro	Número de leituras em falta	Percentagem
Velocidade Vento Torre 1	607	1,15%
Velocidade Vento Torre 2	161	0,31%
Velocidade Vento Torre 3	210	0,40%
Velocidade Vento Torre 4	365	0,69%
Velocidade Vento Torre 5	212	0,40%
Velocidade Vento Torre 6	231	0,44%
Direção Torre 1	607	1,15%
Direção Torre 2	161	0,31%
Direção Torre 3	210	0,40%
Direção Torre 4	365	0,69%
Direção Torre 5	212	0,40%
Direção Torre 6	231	0,44%
Produção Torre 1	607	1,15%
Produção Torre 2	161	0,31%
Produção Torre 3	210	0,40%
Produção Torre 4	365	0,69%
Produção Torre 5	212	0,40%
Produção Torre 6	231	0,44%

Tabela 7 - Dados em falta na estação meteorológica do parque do Loiral ano de 2011

Parâmetro	Número de leituras em falta	Porcentagem
Velocidade Vento Sensor 1	1832	3,49%
Velocidade Vento Sensor 2	1737	3,30%
Direção Sensor 1	1788	3,40%
Direção Sensor 2	1737	3,30%
Temperatura	1737	3,30%
Pressão Atmosférica	1988	3,78%

Tabela 8 - Dados em falta medidos na nacelle dos aerogeradores no parque das Pedras no ano de 2011

Parâmetro	Número de leituras em falta	Porcentagem
Velocidade Vento Torre 1	3	0,01%
Velocidade Vento Torre 2	137	0,26%
Velocidade Vento Torre 3	9	0,02%
Velocidade Vento Torre 4	3	0,01%
Velocidade Vento Torre 5	135	0,26%
Velocidade Vento Torre 6	217	0,41%
Velocidade Vento Torre 7	2803	5,33%
Velocidade Vento Torre 8	13	0,02%
Velocidade Vento Torre 9	2867	5,45%
Velocidade Vento Torre 10	13	0,02%
Velocidade Vento Torre 11	25	0,05%
Velocidade Vento Torre 12	7	0,01%
Direção Torre 1	3	0,01%
Direção Torre 2	137	0,26%
Direção Torre 3	9	0,02%
Direção Torre 4	3	0,01%
Direção Torre 5	135	0,26%
Direção Torre 6	217	0,41%
Direção Torre 7	2803	5,33%
Direção Torre 8	13	0,02%
Direção Torre 9	2867	5,45%
Direção Torre 10	13	0,02%
Direção Torre 11	25	0,05%
Direção Torre 12	7	0,01%

IV. Descrição e Tratamento dos Dados dos Parques Eólicos

<b>Produção Torre 1</b>	3	0,01%
<b>Produção Torre 2</b>	137	0,26%
<b>Produção Torre 3</b>	9	0,02%
<b>Produção Torre 4</b>	3	0,01%
<b>Produção Torre 5</b>	135	0,26%
<b>Produção Torre 6</b>	217	0,41%
<b>Produção Torre 7</b>	2803	5,33%
<b>Produção Torre 8</b>	13	0,02%
<b>Produção Torre 9</b>	2867	5,45%
<b>Produção Torre 10</b>	13	0,02%
<b>Produção Torre 11</b>	25	0,05%
<b>Produção Torre 12</b>	7	0,01%

Tabela 9 - Dados em falta na estação meteorológica do parque das Pedras ano de 2011

<b>Parâmetro</b>	<b>Número de leituras em falta</b>	<b>Percentagem</b>
<b>Velocidade Vento Sensor 1</b>	2627	5%
<b>Velocidade Vento Sensor 2</b>	2617	5%
<b>Direção Sensor 1</b>	8892	17%
<b>Direção Sensor 2</b>	2519	5%
<b>Temperatura</b>	27579	52%
<b>Pressão Atmosférica</b>	3318	6%

Através da análise das tabelas acima apresentadas pode ver-se a quantidade de dados que não possui registos para os três parques eólicos e a respetiva percentagem. É possível verificar que existem algumas limitações nos dados que podem ser utilizados, visto que alguns dos parâmetros registados possuem percentagens de dados em falta algo elevadas, contudo apesar destas limitações foram utilizadas as melhores e maiores sequências de dados possíveis para a construção dos modelos pretendidos. Em relação aos parques eólicos das Pedras e Loiral no ano 2009 foi também analisada a quantidade de registos não disponíveis, sendo verificado que para o período 1 de Setembro de 2009 a 31 Agosto de 2010 não existem falhas de leitura para os dados recolhidos na *nacelle* dos aerogeradores. Porém para esse mesmo intervalo de tempo não existem registos dos dados da estação meteorológica.

#### IV.2.1.2. Pré- processamento dos dados

Ao efetuar o pré-processamento dos dados foi necessário ter em atenção a remoção de dados que não estejam de acordo com o funcionamento normal dos aerogeradores, bem como resolver erros de leitura. Para isso é possível recorrer a alguns métodos como o da persistência, ou através da média da leitura, antes e depois da falha. Em relação a todos os dados em estudo não foi empregado nenhum destes métodos. Estes métodos foram testados neste trabalho e foram construídos modelos baseados em redes neuronais, mas foi verificado através dos resultados obtidos não foram satisfatórios a razão para este facto é que podem estar a ser introduzidos valores como entrada da rede neuronal que não correspondam ao real funcionamento dos aerogeradores.

Por forma a determinar quais as variáveis que possuem maior relevância para serem incluídas nos modelos efetuados, também se realizou um estudo das correlações entre as variáveis para os parques eólicos que será explicado com mais detalhe no próximo capítulo. Mesmo sem efetuar este estudo é óbvio que o parâmetro da velocidade do vento tem de ser incluído e justificado pela relação cúbica com a potência.

Verifica-se também que a potência depende da densidade do ar, como se pode verificar na equação 1, e podendo também estar dependente da direção do vento devido à disposição dos aerogeradores, uma vez que se o vento incidir de uma determinada direção pode influenciar a velocidade com que o vento atinge os restantes aerogeradores. Todavia este facto não se verifica, pois os aerogeradores estão a uma distância considerável entre eles.

#### IV.2.1.3. O Processo de filtragem dos dados

Após a análise dos dados registados para cada um dos parques eólicos e como geralmente dados deste género possuem uma quantidade relativamente de *outliers* houve a necessidade de efetuar um processo de filtragem. O facto de existir um número elevado de *outliers*, deve-se a erros de medição causados por mau funcionamento dos sensores, ausência de registos e ainda pelas limitações de potência, Figura 14, que são introduzidas pela empresa que gere a rede elétrica por forma a manter a sua estabilidade. Estas limitações são introduzidas na rede elétrica, pois em certos momentos não possui capacidade para consumir toda a energia que é produzida o que faz com que sejam registados dados que não correspondem ao funcionamento normal do aerogerador e desta forma faz com que a quantidade de *outliers* presente nos dados aumente. Esta situação só se verifica nos parques eólicos do Loiral e das Pedras.




Figura 14 - Limitações de potência introduzidas pela central de controlo

Para solucionar este problema das limitações de potência foi necessário recorrer a um processo de filtragem não só para remover estas limitações bem como para a remoção de outros *outliers* existentes nos dados. Para isso foram desenvolvidos dois filtros para que apenas fossem utilizados nos modelos os valores de potência que mais se aproximem da curva teórica, Figura 11, para os aerogeradores do parque eólico do Loiral.

Um dos filtros desenvolvido, denominado filtro 1, possui o funcionamento demonstrado no fluxograma da Figura 15.

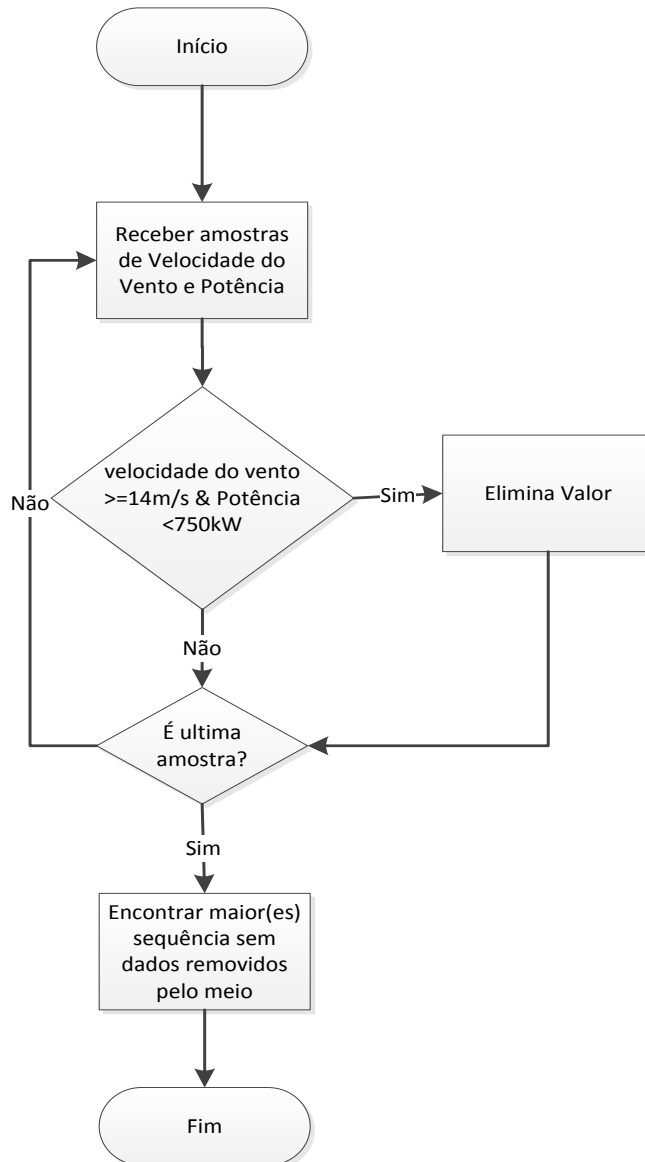


Figura 15 - Fluxograma filtro 1

O processo deste filtro como referido anteriormente proporciona que sejam eliminadas algumas das limitações de potência e posteriormente encontrar a maior ou as maiores sequências sem dados removidos pelo meio. Este processo de encontrar as sequências sem dados removidos pelo meio é de elevada importância, pois nos modelos que se pretende construir é importante manter a ordem do sistema, que consiste em ter o registo das leituras anteriores e posteriores aos dados que estão a ser utilizados e desta forma é garantido que essa ordem se mantém. Nas Figuras 16 e 17 é demonstrado o processo de funcionamento deste filtro através de ilustrações para um dos aerogeradores do parque do Loiral.

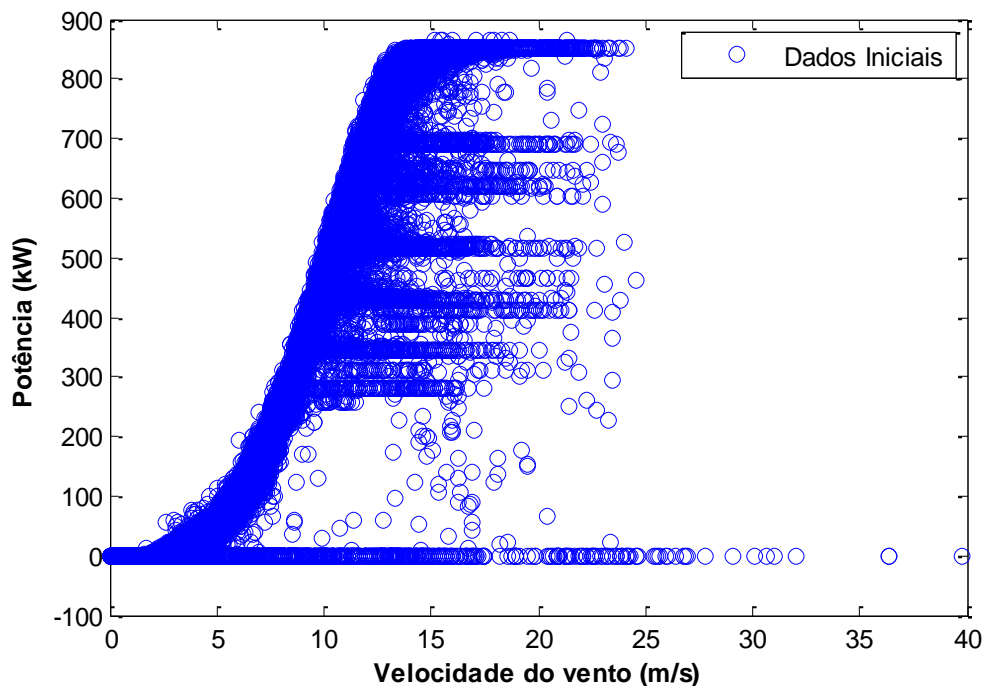


Figura 16 - Dados iniciais




Figura 17 - Filtro 1

Analisando as figuras 16 e 17 verifica-se que grandes partes das limitações de potência foram removidas. Alguns valores de potência que eram iguais a zero para valores de velocidade do vento relativamente elevadas também foram removidos uma vez que correspondem a erros de registo ou devido as turbinas estarem desligadas para manutenção. Todos estes valores não interessam para os modelos que se pretende construir pois correspondem a *outliers*, logo podem ser rejeitados.

Apesar de ter sido removido grande parte dos *outliers* analisando a Figura 17 observa-se que existe ainda uma quantidade relativamente elevada de *outliers* que têm de ser removidos. Por esse facto foi construído um segundo filtro que é aplicado após o primeiro. A ideia deste filtro consiste em remover os dados que se distanciem da curva de potência ideal para este tipo de aerogeradores. Por forma a obter esses resultados foram utilizados polinómios que aproximam as curvas de potência deste tipo de aerogeradores. A ideia de funcionamento deste filtro é demonstrada no fluxograma Figura 18.

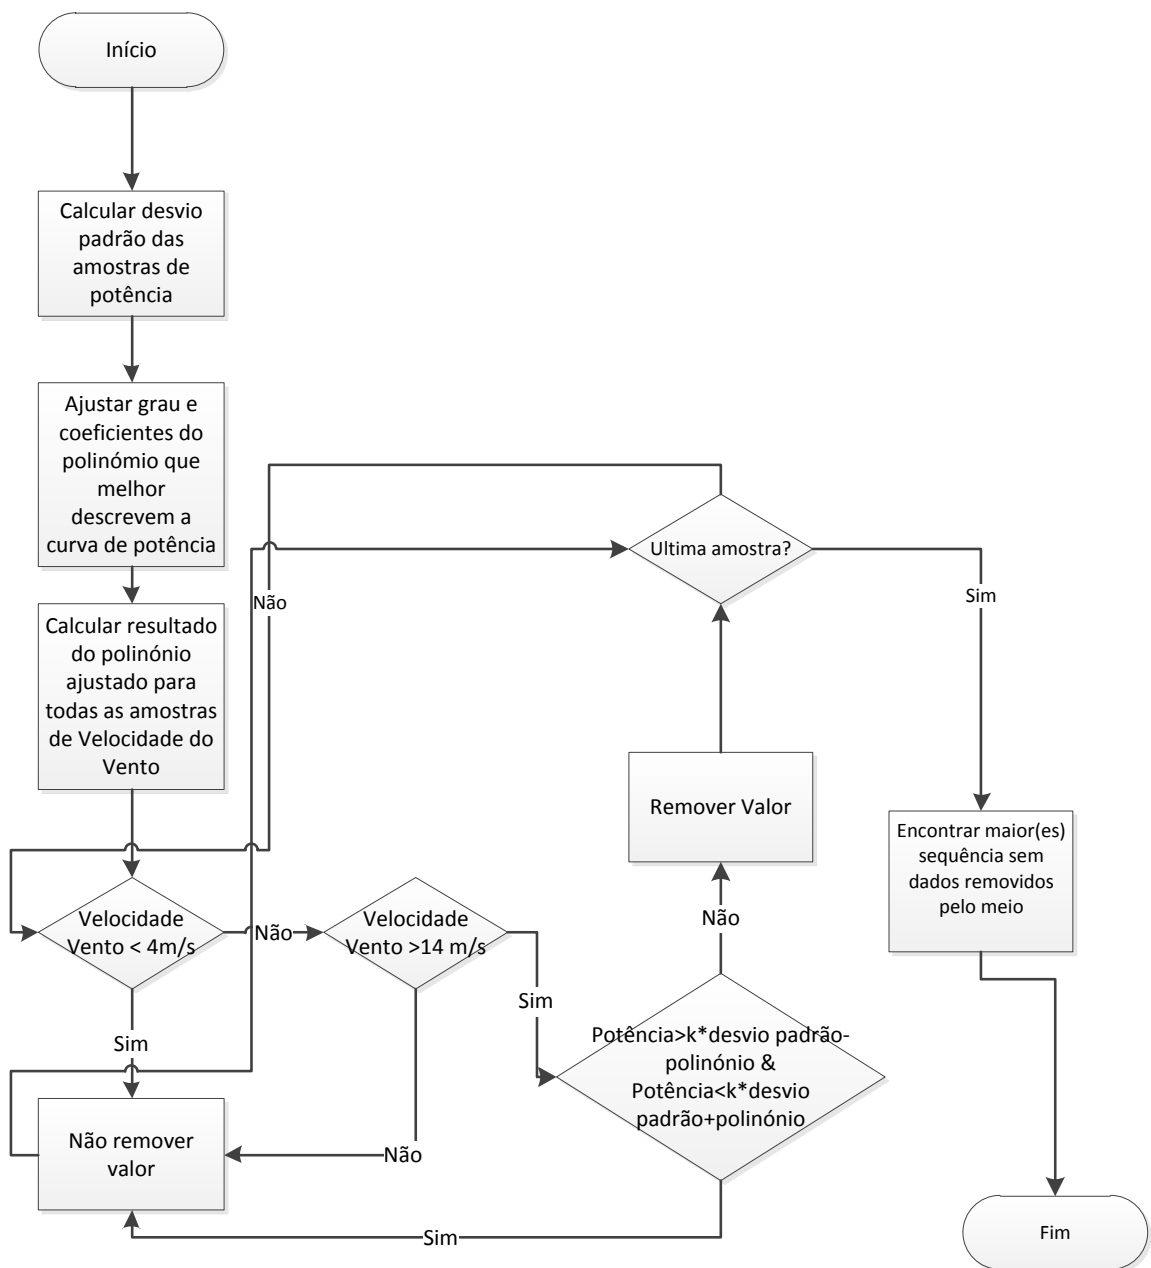


Figura 18 - Fluxograma filtro 2

IV. Descrição e Tratamento dos Dados dos Parques Eólicos

Este filtro como referido anteriormente proporciona uma apresentação apenas dos dados que se encontram mais próximos da curva de potência, na Figura 19 visualiza-se o funcionamento deste filtro.

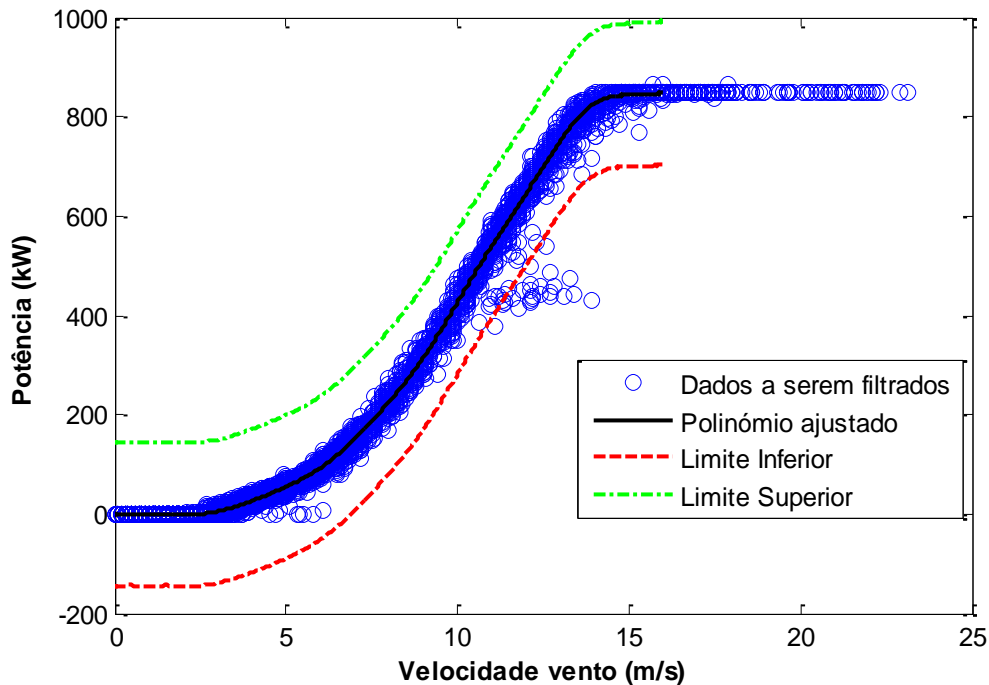


Figura 19 - Processo de filtragem para o filtro 2

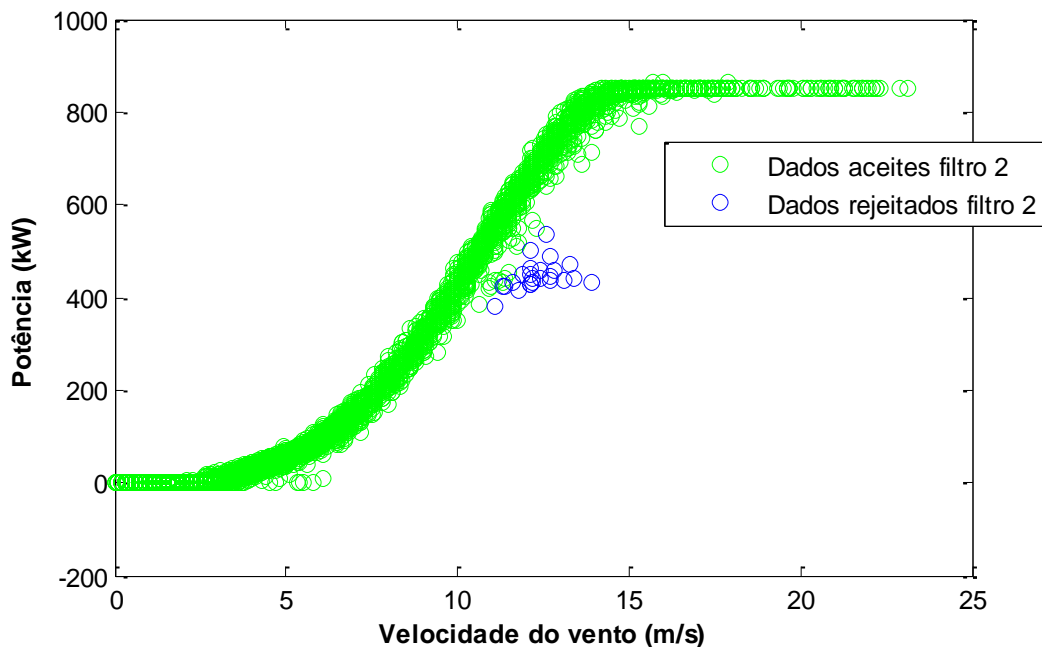


Figura 20 - Resultados do filtro 2

Observando a Figura 19 e como referido no fluxograma da Figura 18 é possível verificar o polinómio que foi ajustado, apenas no intervalo entre os 0m/s e os 16 m/s pois é só nesta zona que a curva de potência tem um comportamento que justifica a aproximação polinomial. A partir dos 16

m/s a curva de potência é uma constante e é impossível ajustar um polinómio para essa zona, qualquer que seja o grau do polinómio, pois ele tende a subir muito ou a descer em relação à curva de potência. Esta situação foi resolvida no filtro 1 onde foram removidos grande parte dos *outliers* para velocidades do vento superiores a 16 m/s logo não era necessário ajustar o polinómio para estes valores de velocidade do vento, esta também foi a razão que justifica o facto do filtro 2 não poder ser utilizado antes do filtro 1 uma vez que existiam as limitações de potência o que iria fazer com que fosse impossível ajustar o polinómio com esses dados.

Os exemplos ilustrados nas Figuras 19 e 20 referem-se apenas a uma das torres do parque eólico. Para cada torre é sempre necessário ter em atenção que o polinómio terá de ser ajustado de acordo com as seguintes equações:

$$\text{Limite superior} = (P_1x^n + P_2x^{n-1} + \dots + P_nx + P_{n+1}) + k \cdot \sigma; \quad (10)$$

$$\text{Limite inferior} = (P_1x^n + P_2x^{n-1} + \dots + P_nx + P_{n+1}) - k \cdot \sigma; \quad (11)$$

onde:

- $P_1, P_2, \dots, P_n, P_{n+1}$  correspondem aos coeficientes do polinómio;
- $x^n$  corresponde ao grau dos coeficientes do polinómio;
- $k$  corresponde a um fator de multiplicação, e;
- $\sigma$  corresponde ao desvio padrão.

Para além da necessidade de ajustar os coeficientes do polinómio e o grau dos coeficientes outro parâmetro que terá de ser ajustado é o parâmetro  $k$ . Ajustando este parâmetro é possível aumentar ou diminuir os limites inferior e superior para que desta forma sejam eliminados uma maior ou menor quantidade de dados. Este fator foi ajustado tendo em conta que para a construção dos modelos é necessária uma quantidade razoável de dados, pelo que este foi ajustado dependendo da situação e poderá ser distinto para os diferentes aerogeradores.

Em relação aos dados de Cabo Verde não existiam os problemas de limitação de potência, o problema era diferente, existiam também falhas nos registos as quais foram resolvidas construindo um processo de filtragem diferente do construído para o parque eólico do Loiral.




Figura 21 - Exemplo dos dados do parque eólico de Cabo Verde

Analisando a Figura 21, visualizam-se pontos vermelhos que correspondem aos *outliers* que se pretende eliminar. Alguns deles por falhas de leituras dos sensores, quando há um erro de leitura é registado o valor de potência -99,9, outros quando a velocidade do vento é superior a 5 m/s que é o instante em que este aerogerador começa a produzir energia e os valores de produção são iguais a 0 e ainda quando a turbina deveria estar a produzir mais energia do que a registada, como por exemplo quando a velocidade do vento é superior a 14m/s e a potência registada é muito inferior à potência nominal. Para resolver este problema foi construído um filtro em que o seu funcionamento é explicado no fluxograma na figura 22:

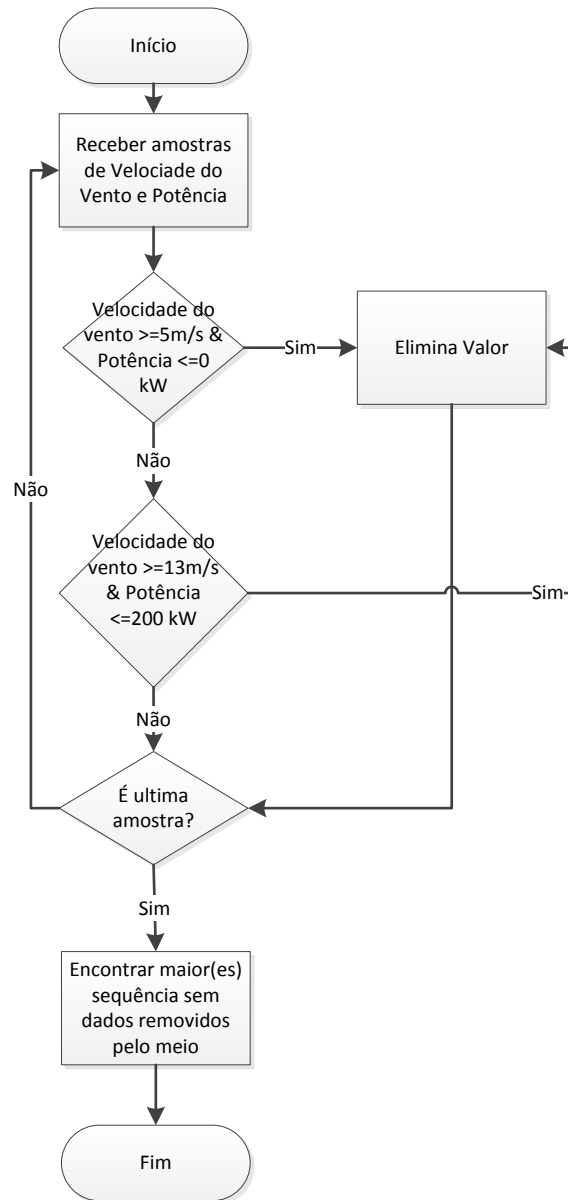


Figura 22 - Fluxograma do filtro de Cabo Verde

Através deste filtro é possível eliminar quase a totalidade dos *outliers* presentes nos dados, mas não é possível eliminar todos, para isso é necessário escolher as maiores sequências que apresentem a menor quantidade possível de *outliers* e desta forma é possível obter sequências em que a presença de *outliers* é quase nula como se visualiza na Figura 23.

IV. Descrição e Tratamento dos Dados dos Parques Eólicos

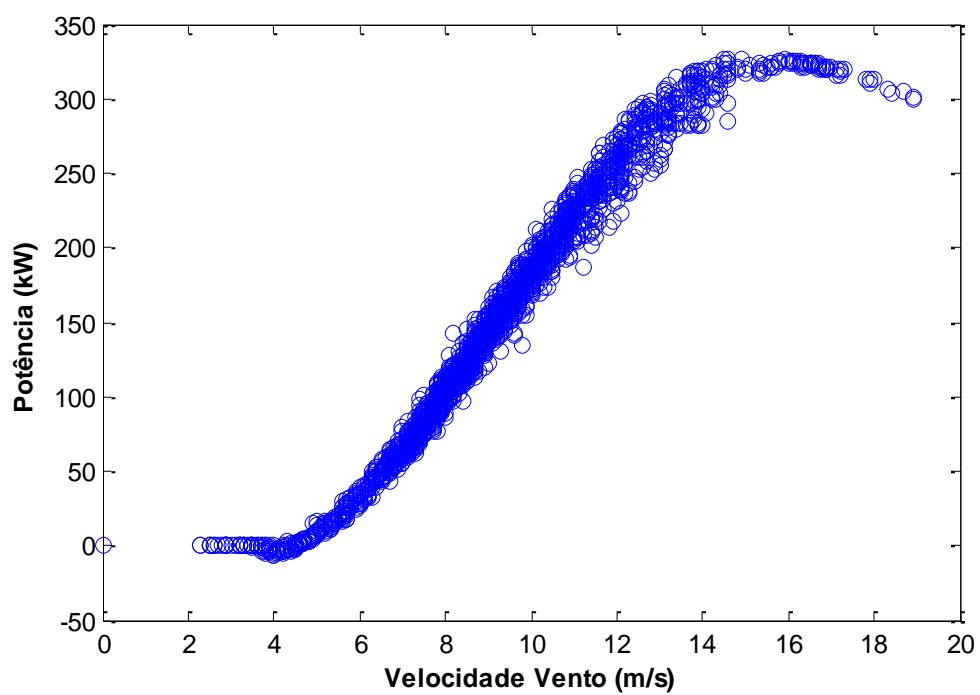


Figura 23 - Sequência de dados após a filtragem

---

## IV.3. CONCLUSÃO

---

Neste capítulo foi apresentada uma breve descrição dos parques eólicos que foram objeto de estudo neste trabalho, fazendo-se uma descrição da sua localização, o tipo de aerogeradores existentes e os dados que foram registados para cada um dos parques eólicos.

Em relação aos dados houve a necessidade de efetuar um estudo de forma a verificar se o registo dos dados para cada parque eólico era efetuado de forma contínua e foi verificado que para alguns dos parâmetros registados isso não acontecia, o que implica limitações nos dados que podem ser utilizados. Outro aspeto que causou limitações nos dados que podem ser utilizados foi o facto de nos dados do ano 2009 para o parque eólico do Loiral serem introduzidas limitações de potência na produção dos aerogeradores devido ao consumo de energia ser inferior à produção, o que fez com que a quantidade de *outliers* aumentasse e por conseguinte a quantidade de dados que podem ser utilizados nos modelos tivesse de ser muito menor.

Para resolver estas situações foi necessário recorrer a técnicas de filtragem para eliminar a maior parte dos *outliers* para que os dados utilizados fossem os mais aproximados possíveis às curvas de potência teóricas dos aerogeradores de cada parque eólico, pois o processo de registo dos dados nem sempre funciona da melhor forma, principalmente porque o vento varia muito em 10 minutos e isso faz com que o valor registado nem sempre corresponda à realidade devido a essa variância.

Após este estudo foi verificado que os melhores dados a utilizar seriam os dos parques eólicos do Loiral e de Cabo Verde uma vez que os dados do parque eólico das Pedras apresentam muitos erros. Realizado este estudo e efetuada a filtragem, os dados resultantes e que foram selecionados são os melhores dentro das limitações existentes para a construção dos modelos que serão apresentados no capítulo seguinte.



---

## V. TESTE E AVALIAÇÃO DOS MODELOS DE PREVISÃO EÓLICA

---

## **V.1. INTRODUÇÃO**

---

Neste capítulo são apresentados os diversos modelos construídos com redes neuronais e comparados os resultados das previsões obtidas para os diferentes modelos e para os diferentes parques eólicos através do critério de erro quadrático médio. São também apresentados vários testes em que é comparado o desempenho de colocar diferentes entradas na rede neuronal ou até colocar várias entradas e verificar qual ou quais os modelos que apresentam os melhores resultados.

---

## V.2. PROCESSO DE CONSTRUÇÃO DOS MODELOS

---

O processo de construção dos modelos utilizado nesta tese foi semelhante para os diferentes parques eólicos. Como é referido no capítulo anterior no processo de construção do modelo, existe a fase de pré processamento dos dados. Esta fase, neste trabalho, é sempre utilizada recorrendo aos filtros apresentados no capítulo anterior.

Posteriormente, foi realizada uma análise de correlação por forma a verificar quais as variáveis que podem ser mais relevantes para os modelos que vão ser construídos, estes serão apresentados seguidamente.

Realizadas estas fases, foram elaboradas diferentes estruturas de modelos sendo que o seu desempenho foi avaliado e os modelos foram comparados entre si. Este processo de construção dos modelos foi realizado de uma forma empírica, ou seja, foram efetuadas combinações de diferentes entradas na rede neuronal, pois não existia conhecimento à priori de qual o modelo que proporcionaria os melhores resultados.

### V.2.1. Escolha do ambiente MATLAB

O ambiente escolhido para a construção e simulação dos modelos presentes neste trabalho foi o MATLAB e a versão utilizada foi a 2011b. Este foi escolhido porque possui *Toolboxes*, com ferramentas disponíveis para identificação e controlo de sistemas e também pelas suas capacidades gráficas.

As *Toolboxes Neural Network Based Control System Design Toolkit for use with MATLAB* [27] e *MATLAB Neural Network Toolbox™* [32] foram as utilizadas neste trabalho, contêm diversas funções desde a implementação de algoritmos como o *Levenberg-Marquart* [12, 13], *Gauss-Newton* [19], entre outros muito utilizados em redes neuronais, possuem ainda funções de validação de modelos e capacidades gráficas que permitem rapidamente verificar a qualidade dos dados recolhidos ou do controlo/simulações efetuadas.

## V.2.2. Análise da correlação

De forma a verificar quais as variáveis que possuem maior significância para a construção dos modelos, a serem utilizadas como entrada das redes neuronais procedeu-se ao estudo das correlações.

Este método consiste em medir o grau da correlação (e a direção dessa correlação - se positiva ou negativa) entre duas variáveis.

Este coeficiente, normalmente representado por  $\rho$  assume apenas valores entre -1 e 1.

$\rho = 1$  Significa uma correlação positiva perfeita entre as duas variáveis;

$\rho = -1$  Significa uma correlação negativa perfeita entre as duas variáveis - Isto é, se uma aumenta, a outra diminui na mesma proporção, e;

$\rho = 0$  Significa que as duas variáveis não dependem linearmente uma da outra. No entanto, pode existir uma dependência não linear. Assim, o resultado  $\rho = 0$  deve ser investigado por outros meios.

Calcula-se o coeficiente de correlação segundo a seguinte fórmula:

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (12)$$

Na qual  $x_1, x_2, \dots, x_n$  e  $y_1, y_2, \dots, y_n$  são os valores medidos de ambas as variáveis. Para além disso

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (13)$$

e

$$\bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \quad (14)$$

são as médias aritméticas de ambas as variáveis.

Tabela 10 - Correlação entre todas as variáveis para o mês de Janeiro parque eólico de Cabo Verde

Variáveis	Velocidade 1	Velocidade 2	Direção	Pressão	Temperatura	Prod 1 (KW)	Prod 2 (KW)	Prod 3 (KW)
Velocidade 1	1,00	0,99	-0,04	-0,06	-0,02	0,60	0,75	0,75
Velocidade 2	0,99	1,00	-0,05	-0,04	0,01	0,59	0,74	0,73
Direção	-0,04	-0,05	1,00	-0,18	-0,27	-0,02	-0,04	-0,04
Pressão	-0,06	-0,04	-0,18	1,00	0,09	0,04	0,00	0,00
Temperatura	-0,02	0,01	-0,27	0,09	1,00	-0,02	0,06	0,03
Prod 1 (KW)	0,60	0,59	-0,02	0,04	-0,02	1,00	0,82	0,79
Prod 2 (KW)	0,75	0,74	-0,04	0,00	0,06	0,82	1,00	0,96
Prod 3 (KW)	0,75	0,73	-0,04	0,00	0,03	0,79	0,96	1,00

Analisando a tabela 10, em relação ao mês de Janeiro para o ano 1997, verificamos uma forte correlação entre a velocidade no sensor 1 e o sensor 2, o que indica que não existe grande variação de vento entre esses dois locais de medição.

Também existe uma correlação forte a moderada entre a velocidade do sensor 1 e do sensor 2 em relação as produções das torres 1,2 e 3, sendo menor para a torre 1. Este resultado era esperado pois a produção de energia advém da velocidade do vento, embora se possa constatar que esta relação não é linear como seria de esperar pela equação 1.

Este mesmo procedimento foi efetuado para os restantes meses de cada ano, obtendo-se resultados idênticos. A opção de realizar o estudo de correlação para o parque eólico de Cabo Verde, apesar de este ter maiores intervalos sem leituras, deve-se ao facto de terem sido medidas mais variáveis e assim pode-se verificar a dependência entre essas variáveis.

Embora este estudo de correlação seja para verificar se existe relação linear entre as variáveis permite verificar que existe alguma relação linear principalmente entre os dois locais de medição da velocidade do vento e ainda entre a velocidade do vento e a produção nos aerogeradores.

As relações entre as outras variáveis principalmente entre a direção e produção, temperatura e produção e entre pressão e produção são mais difíceis de verificar por este método pois esta relação pode ser não linear. Apesar deste fator, através desta análise a forte relação entre a velocidade do vento e a produção indica que este parâmetro é de elevada importância e deverá ser incluído no modelo baseado em redes neuronais.

Contudo não pode ser descartada com este método a inclusão de variáveis como a temperatura, direção do vento e produção no modelo pois estas podem ter influência na produção de energia como foi verificado em termos teóricos, a produção é função da densidade do ar e por sua vez a densidade do ar é função da pressão atmosférica e da temperatura.

### V.2.3. Seleção dos dados a utilizar para construir os modelos

Após a análise de quais as variáveis que podem ter mais influência no modelo, foi realizada uma análise dos dados dos três parques eólicos. Como foi verificado, o parque eólico de Cabo Verde possui muitas falhas de registo. Contudo foram medidos um maior número de parâmetros do que

nos parques do Loiral e Pedras. Em relação aos parques das Pedras e Loiral estes têm uma maior sequência de dados sem interrupções, mas não foram registados parâmetros importantes, como a temperatura, a pressão atmosférica e a direção do vento para o ano de 2009.

Por forma a verificar quais os dados que melhor descrevem o comportamento de um aerogerador foram construídos gráficos da relação entre a velocidade do vento e a produção do aerogerador para os três parques, Figuras. 24, 25 e 26.




Figura 24 - Curva de potência do aerogerador de Cabo Verde no ano de 1995




Figura 25 - Curva de potência do aerogerador do Loiral no ano de 2009

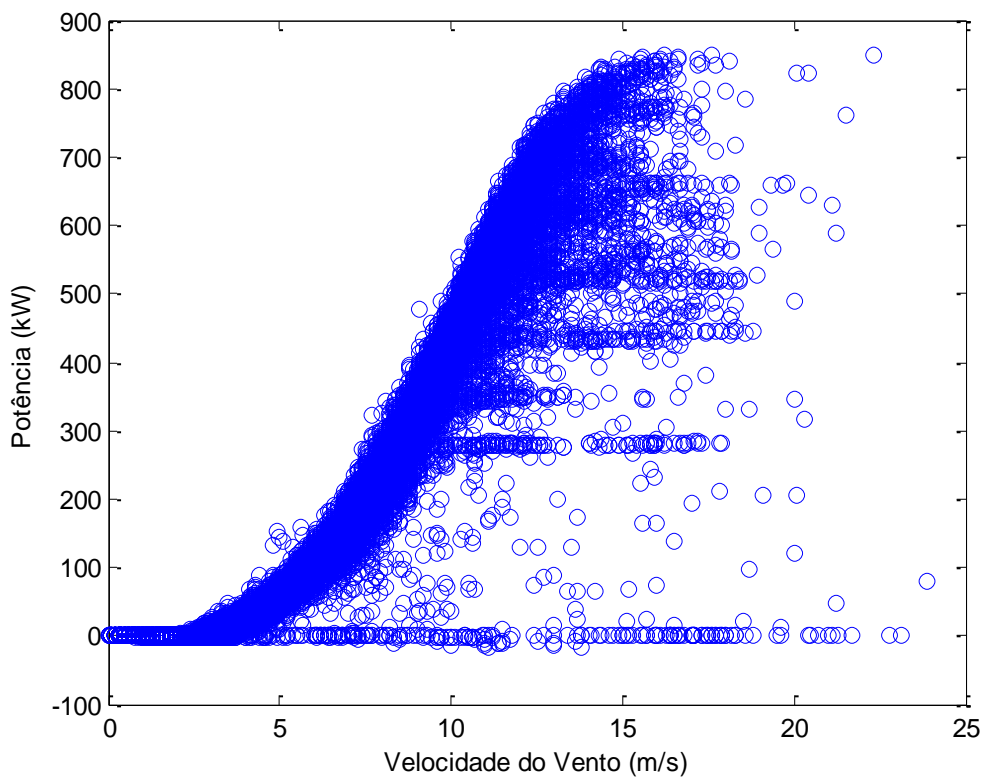


Figura 26 - Curva de potência do aerogerador das Pedras no ano de 2009

Através da análise das Figuras 24, 25 e 26 é possível verificar que através das medições realizadas nos parques eólicos os dados que melhor descrevem a curva de potência teórica são os do parque eólico do Loiral e de Cabo Verde, embora possuam uma quantidade elevada de *outliers*. Já para os dados do parque eólico das Pedras a quantidade de *outliers* é maior e estes dados não descrevem bem a curva de potência teórica, isto pode indicar que a recolha dos dados não foi realizada da melhor forma.

Embora os dados do parque eólico do Loiral para o ano 2008 não possuam o registo das variáveis como a temperatura, a pressão atmosférica e a densidade do ar estes dados que serão utilizados para a construção de modelos assim como os dados de 2011 para este parque. Em relação aos dados do parque eólico de Cabo Verde os dados utilizados serão os de 1995 e 1996, pois possuem uma menor quantidade de *outliers* e de falhas no registo. Já em relação aos dados do parque das Pedras estes não serão utilizados, porque possuem uma quantidade muito elevada de *outliers* o que irá levar a que os modelos construídos não tenham bom desempenho e ainda pelo motivo que o processo de funcionamento é idêntico ao do parque eólico do Loiral, pois os aerogeradores possuem características iguais.

Após a seleção de quais os dados que vão ser utilizados estes dados foram filtrados recorrendo aos filtros apresentados no capítulo anterior e posteriormente divididos em duas sequências diferentes, uma que será utilizada para treino e outra para validação do modelo.

Para os dados do Loiral de 2008 os dados utilizados foram os seguintes:

Tabela 11 - Dados de treino do parque do Loiral no ano de 2009

Parâmetro	Torre 1	Torre 2	Torre 3	Torre 4	Torre 5	Torre 6
Valor médio da potência (kW)	202	180.1	185.6	206.5	152.9	187.8
Variância (kW)	280.5	265.2	267.9	289.5	244.2	274.6
Valor mínimo	-0.5	-0.05	-0.5	-0.1	-0.2	-0.3
Valor máximo	850.9	864.6	850.9	860.7	864.8	864.9
Tamanho da amostra	6453	4576	7488	5863	4473	6444

Tabela 12 - Dados de teste do parque do Loiral no ano de 2009

Parâmetro	Torre 1	Torre 2	Torre 3	Torre 4	Torre 5	Torre 6
Valor médio da potência (kW)	221	308	224.7	143.8	319.6	167
Variância (kW)	294.4	350.6	297.8	221.2	379.3	244.6
Valor mínimo	0.1	0	-0.1	0	-0.1	0
Valor máximo	851.2	864.8	851.1	851.1	864.9	851.3
Tamanho da amostra	1724	1145	1840	3535	1119	1913

Em relação aos dados do parque de Cabo Verde os dados utilizados foram:

Tabela 13- Dados de treino do parque de Cabo Verde

Parâmetro	Torre 1	Torre 2	Torre 3
Valor médio da potência (kW)	163	159.6	160.7
Variância (kW)	94.4	93	92.3
Valor mínimo	4.2	2.5	5.3
Valor máximo	316.1	312.4	314.4
Tamanho da amostra	981	981	981

Tabela 14 - Dados de teste do parque de Cabo Verde

Parâmetro	Torre 1	Torre 2	Torre 3
Valor médio da potência (kW)	227.4	222.9	227.2
Variância (kW)	79.8	78.1	78.7
Valor mínimo	13.3	11.3	18.7
Valor máximo	324.7	320.5	328.9
Tamanho da amostra	691	691	691

Por fim para os dados do parque do Loiral para o ano 2011 os dados utilizados foram:

Tabela 15 - Dados de treino do parque do Loiral no ano de 2011

Parâmetro	Torre 6
Valor médio da potência (kW)	248.1
Variância (kW)	283.4
Valor mínimo	-2.6
Valor máximo	864.1
Tamanho da amostra	2738

Tabela 16- Dados de teste do parque do Loiral no ano 2011

Parâmetro	Torre 6
Valor médio da potência (kW)	353.2
Variância (kW)	275.1
Valor mínimo	-2.3
Valor máximo	864.1
Tamanho da amostra	913

As tabelas 11,12,13,14,15 e 16 apresentam informação dos dados da produção de energia que foram utilizados na construção dos modelos. Para os dados do Loiral 2009 foram construídos modelos para todas as torres do parque, assim como para o parque de Cabo Verde, já nos dados do Loiral 2011 foram apenas utilizados dados de uma torre pois ao efetuar a filtragem não era possível obter um conjunto razoável de dados devido as muitas falhas no registo para as restantes torres.

#### **V.2.4. Modelos baseados em redes neuronais**

Para construir um modelo baseado em redes neuronais a maior dificuldade é escolher quais as entradas da rede neuronal, por exemplo, colocar a velocidade do vento à entrada e à saída a produção de energia, ou colocando mais do que uma entrada por exemplo velocidade do vento e pressão atmosférica mas podem ser feitas mais combinações além destas duas como colocar a direção do vento e a temperatura também como entrada. A razão pela qual foi decidido colocar a velocidade do vento e a pressão atmosférica e apenas utilizar estas duas como entrada foi pela equação 1 que mostra que a produção de energia é função destes dois parâmetros.

Como é impossível saber antecipadamente qual o modelo que irá proporcionar os melhores resultados este processo tem de ser feito por tentativa e erro.

Estando escolhido qual o modelo que se pretende treinar inicia-se o seu treino e posteriormente a sua avaliação que é realizada da seguinte forma:

A cada iteração de treino da rede neuronal esta é avaliada para os dados de teste e o processo de treino continua até que o número máximo de iterações de treino seja atingido. Atingido o número máximo de iterações de treino é escolhida a iteração de treino em que o erro de validação é mínimo. Este processo é uma implementação possível da técnica de paragem antecipada do treino e assim é garantido que o erro do modelo é o mínimo possível.

Para cada um destes modelos são criadas diferentes redes neuronais com o número de neurónios a variar entre 2 e 15 para o parque de Cabo Verde e entre 2 e 10 para o parque do Loiral. Para cada número de neurónios são treinadas 10 redes neuronais diferentes no caso do parque de Cabo Verde e 5 redes neuronais para o parque do Loiral.

Este procedimento de treinar várias redes neuronais para cada uma das diferentes arquiteturas reside no facto de que os pesos iniciais são diferentes para cada arquitetura e existem pesos que proporcionam melhores resultados, sendo que, este procedimento foi efetuado para cada um dos modelos construídos.

Também foram realizados testes em que os pesos iniciais são fixos de forma a poder comparar os modelos, mas é necessário ter em atenção que só é possível comparar modelos que sejam semelhantes, por exemplo, modelos que tenham uma entrada e uma saída, não se podem comparar

modelos que tenham apenas uma entrada e uma saída com um modelo que tenha duas entradas e uma saída.

Todos os modelos aqui construídos foram baseados no modelo NNARX e no ARX que são modelos não lineares baseados em redes neurais. O modelo NNARX funciona da seguinte forma:

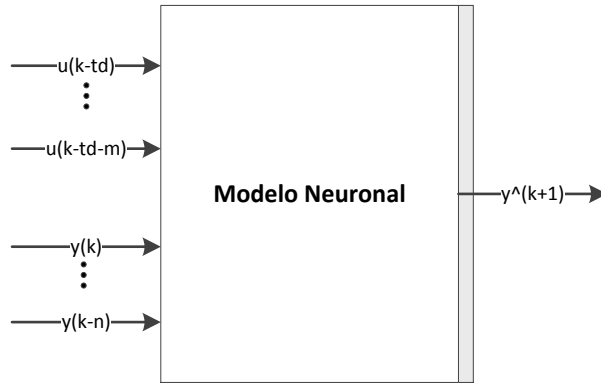


Figura 27 - Modelo NNARX

O modelo NNARX é uma extensão do modelo ARX [33]. Por exemplo será designado NNARX um modelo cujas entradas são as mesmas que o correspondente modelo ARX, ou seja valores passados dos sinais de entrada e saída a figura 27 representa o diagrama de um modelo desta classe.

## V.3. RESULTADOS

Aqui são apresentados apenas os resultados para os melhores testes, porque muitos outros foram realizados, mas os seus resultados não foram satisfatórios. Como por exemplo, utilizar dados em que os valores de registo em falta foram substituídos recorrendo ao método da persistência ou tentar a aproximação dos valores de produção em falta recorrendo a polinómios, ou até mesmo através da utilização dos dados sem efetuar filtragem.

Os resultados serão apresentados sob a forma de tabelas, uma com os testes realizados utilizando pesos fixos e outra para os testes realizados utilizando os pesos aleatórios. Cada uma dessas tabelas contém uma coluna com os valores do EQM em que para uma mais fácil interpretação dos resultados foi utilizado uma escala de cores que varia entre verde, amarelo, laranja e vermelho. Nessa coluna quanto mais intenso for o verde significa que o valor de EQM é mais próximo do mínimo e quanto mais próximo estiver do vermelho significa que o EQM está mais próximo do máximo. A saída da rede neuronal  $y(t)$  será apresentada da recorrendo à seguinte nomenclatura:

$$y(t) = F(u_1(t-1), \dots, u_1(t-n), u_2(t-1), \dots, u_2(t-n), \dots, u_n(t-1), \dots, u_n(t-n), y(t-1), \dots, y(t-n))$$

onde,  $t$  representa o instante de tempo atual  $u_1, u_2, \dots, u_n$  representam as entradas da rede neuronal. Como neste trabalho foram utilizadas no máximo duas entradas em simultâneo  $u_1$  representará sempre a velocidade do vento e  $u_2$  a pressão atmosférica.

### V.3.1. Resultados parque eólico do Loiral no ano de 2009

Para o parque eólico do Loiral no ano de 2009, como referido apenas estavam disponíveis dados relativos à velocidade do vento e produção de energia o que fez com que seja possível apenas utilizar a velocidade do vento como entrada da rede neuronal. Foram construídos modelos para as 6 torres, mas apenas serão apresentados os resultados para uma das torres que neste caso é a apresenta o erro mais baixo (torre 4) e os resultados obtidos foram os seguintes, utilizando pesos fixos:

Tabela 17 - Resultados do parque eólico do Loiral no ano de 2009 pesos fixos

Saída	Nº Neurónios	EQM (kW)
$y(t)=F(u(t-1),y(t-1))$	2	14,31
	3	13,89
	4	15,43
	5	15,12
	6	17,17

	7	16,45
	8	15,04
	9	16,78
	10	18,25
$y(t)=F(u(t-2),y(t-1))$	2	13,47
	3	18,31
	4	21,23
	5	16,64
	6	18,80
	7	20,71
	8	13,99
	9	23,86
	10	23,34
	$y(t)=F(u(t-3),y(t-1))$	2
3		16,87
4		17,22
5		17,70
6		23,29
7		25,36
8		20,74
9		24,78
10		22,10
$y(t)=F(u(t-4),y(t-1))$		2
	3	18,13
	4	19,10
	5	22,29
	6	22,80
	7	25,19
	8	21,86
	9	21,83
	10	22,32
	$y(t)=F(y(t-1))$	2
3		10,43
4		9,64
5		9,48
6		10,93
7		10,32
8		12,03
9		12,33
10		9,68

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

Tabela 18 - Resultados parque eólico do Loiral no ano de 2009 pesos aleatórios

Saída	Nº Neurónios	EQM Teste 1 (kW)	EQM Teste 2 (kW)	EQM Teste 3 (kW)	EQM Teste 4 (kW)	EQM Teste 5 (kW)	Mínimo (kW)
$y(t)=F(u(t-1),y(t-1))$	2	13,57	12,89	13,06	12,79	13,00	12,79
	3	14,75	16,10	14,43	13,75	14,12	13,75
	4	15,05	14,53	14,04	15,98	13,39	13,39
	5	16,48	16,40	16,92	15,09	14,05	14,05
	6	16,55	13,75	17,60	15,38	15,30	13,75
	7	15,44	14,99	14,49	14,16	15,60	14,16
	8	17,45	16,85	14,21	14,76	16,59	14,21
	9	15,16	16,42	18,15	16,99	14,94	14,94
	10	14,29	19,62	20,61	22,25	14,81	14,29
	$y(t)=F(u(t-2),y(t-1))$	2	11,41	13,28	14,13	11,71	14,14
3		18,33	18,60	16,68	18,35	18,33	16,68
4		21,76	14,33	16,59	11,85	15,14	11,85
5		20,60	12,49	16,94	21,50	19,94	12,49
6		18,66	18,75	16,09	19,14	15,72	15,72
7		19,10	17,00	18,80	20,09	14,11	14,11
8		18,32	16,44	21,58	17,35	20,26	16,44
9		13,07	21,21	17,42	22,70	15,70	13,07
10		16,78	21,73	17,69	19,80	19,56	16,78
$y(t)=F(u(t-3),y(t-1))$		2	17,83	18,50	15,94	14,83	15,27
	3	18,91	16,54	17,05	19,18	18,91	16,54
	4	23,28	18,13	18,96	17,01	17,19	17,01
	5	19,83	18,02	16,86	31,08	19,83	16,86
	6	19,71	21,10	23,59	20,24	16,94	16,94
	7	21,88	25,12	21,78	19,61	24,27	19,61
	8	24,49	24,77	21,75	20,76	25,02	20,76
	9	20,04	23,79	24,38	17,42	21,20	17,42

	10	28,01	22,80	22,53	19,04	19,97	19,04
$y(t)=F(u(t-4),y(t-1))$	2	15,82	18,38	15,79	17,06	18,66	15,79
	3	21,03	20,48	20,48	20,96	18,91	18,91
	4	22,92	22,87	21,57	22,80	20,20	20,20
	5	20,45	18,79	23,41	22,56	23,20	18,79
	6	19,96	23,06	22,91	24,13	22,37	19,96
	7	18,87	23,02	21,84	19,64	22,44	18,87
	8	21,99	22,73	23,65	22,78	21,21	21,21
	9	20,76	22,60	19,45	22,44	21,97	19,45
	10	23,39	22,97	21,81	23,86	21,71	21,71
	$y(t)=F(y(t-1))$	2	9,05	8,43	9,38	9,67	9,18
3		9,58	19,68	10,31	8,82	10,06	8,82
4		9,95	11,97	10,03	9,68	10,03	9,68
5		8,65	9,16	10,06	10,05	12,53	8,65
6		10,20	9,56	13,98	11,89	10,71	9,56
7		14,62	10,06	14,58	11,50	9,67	9,67
8		10,90	9,99	9,64	11,07	12,06	9,64
9		9,02	10,65	10,19	12,36	9,64	9,02
10		10,52	9,93	11,13	10,90	11,00	9,93

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

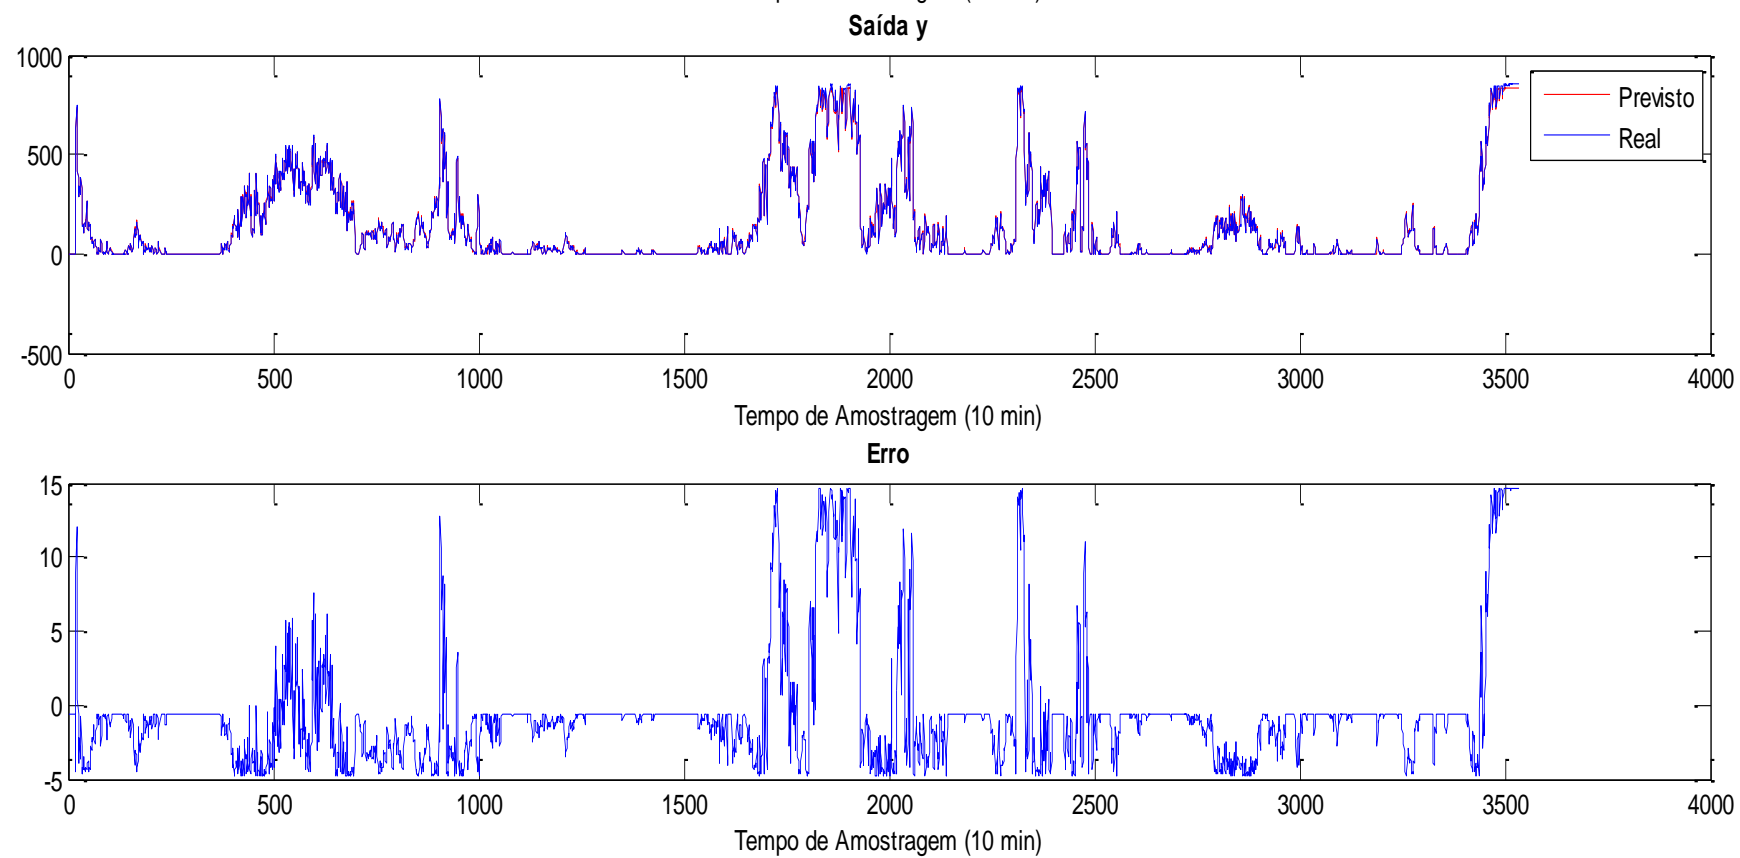


Figura 28 - Resultados da melhor simulação para o parque eólico do Loiral no ano de 2009

Analisando as tabelas 17 e 18 verifica-se que o modelo que obtém os melhores resultados é  $y(t) = F(y(t-1))$  e o melhor teste apresenta um EQM médio de 8,43 com uma arquitetura de 2 neurónios. Através da figura 28 é possível observar os resultados de simulação onde se observa que a rede neuronal consegue prever bem o comportamento do aerogerador.

### V.3.2. Resultados no parque eólico do Loiral no ano de 2011

Para os dados do parque eólico do Loiral no ano de 2011 apenas está disponível para uma das torres um conjunto razoável de dados, sendo que neste ano já se registou a pressão atmosférica. Os modelos foram construídos usando a combinação de duas entradas, a pressão atmosférica e a velocidade do vento. O método de construção dos modelos e apresentação dos resultados é semelhante aos do ano 2008.

Tabela 19 - Resultados no parque eólico do Loiral no ano 2011 pesos fixos

Saída	Nº Neurónios	EQM (kW)
$y(t)=F(u1(t-1),u2(t-1),y(t-1))$	2	47,01
	3	34,76
	4	26,42
	5	45,79
	6	79,53
	7	26,73
	8	32,78
	9	48,84
	10	72,74
	$y(t)=F(u1(t-2),u2(t-1),y(t-1))$	2
3		58,75
4		66,39
5		95,80
6		122,13
7		71,28
8		43,54
9		59,04
10		54,28
$y(t)=F(u1(t-3),u2(t-1),y(t-1))$		2
	3	37,93
	4	32,36
	5	44,21
	6	70,25
	7	43,65
	8	32,94
	9	25,92
	10	31,31
	$y(t)=F(y(t-1))$	2
3		21,17
4		25,82
5		28,31

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

	6	31,06
	7	31,17
	8	34,83
	9	36,03
	10	32,41

Tabela 20 - Resultados parque eólico Loiral ano 2011 pesos aleatórios

Saída	Nº Neurónios	EQM Teste 1 (kW)	EQM Teste 2 (kW)	EQM Teste 3 (kW)	EQM Teste 4 (kW)	EQM Teste 5 (kW)	Mínimo (kW)
$y(t)=F(u1(t-1),u2(t-1),y(t-1))$	2	42,30	32,65	27,00	55,43	33,97	27,00
	3	31,53	23,57	27,81	37,75	35,14	23,57
	4	37,46	50,64	74,10	56,30	33,48	33,48
	5	28,50	28,74	64,56	34,73	48,91	28,50
	6	26,88	115,91	65,78	52,13	54,53	26,88
	7	44,68	55,36	38,34	84,78	23,26	23,26
	8	42,42	71,35	73,91	70,00	50,81	42,42
	9	38,98	113,07	40,02	48,72	83,54	38,98
	10	66,07	123,67	148,20	43,80	220,81	43,80
	$y(t)=F(u1(t-2),u2(t-1),y(t-1))$	2	17,02	162,54	34,40	17,37	52,84
3		42,05	52,87	39,41	79,86	68,42	39,41
4		50,56	61,88	81,37	41,95	42,80	41,95
5		104,35	197,08	40,77	76,31	50,05	40,77
6		78,77	139,35	62,96	75,11	127,23	62,96
7		82,59	110,82	67,57	54,45	58,58	54,45
8		46,30	91,69	88,89	46,96	78,80	46,30
9		85,60	109,01	54,80	78,78	189,42	54,80
10		62,94	60,12	81,80	177,88	156,45	60,12
$y(t)=F(u1(t-3),u2(t-1),y(t-1))$		2	20,62	35,74	35,90	28,74	19,73
	3	40,25	42,77	60,74	42,54	35,42	35,42
	4	102,00	152,08	30,56	57,13	25,76	25,76
	5	26,19	45,00	26,27	68,60	35,11	26,19
	6	45,68	87,12	82,30	42,75	46,02	42,75
	7	71,19	24,18	65,20	37,49	24,07	24,07
	8	40,90	60,95	32,82	90,68	52,20	32,82
	9	321,89	43,54	107,51	42,68	19,00	19,00
	10	84,16	56,50	43,18	24,44	71,03	24,44
	$y(t)=F(y(t-1))$	2	17,13	21,44	33,35	33,34	24,36
3		21,24	35,41	26,53	17,48	18,73	17,48
4		36,22	28,14	19,94	21,64	21,38	19,94

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

	5	34,11	28,99	25,87	37,91	26,45	25,87
	6	20,28	20,19	36,12	31,25	34,63	20,19
	7	30,43	31,17	34,23	21,64	18,89	18,89
	8	21,10	17,19	32,22	33,78	32,61	17,19
	9	26,58	17,72	10,18	26,99	22,16	10,18
	10	30,81	27,24	34,33	35,20	27,91	27,24




Figura 29 - Resultados melhor simulação no parque eólico do Loiral no ano de 2011

Analisando as tabelas 19 e 20 verifica-se que o modelo que obtém os melhores resultados é  $y(t) = F(u_1(t-2), u_2(t-1), y(t-1))$  utilizando pesos fixos e o melhor teste apresenta um EQM de 8,92 com uma arquitetura de dois neurónios. Contudo, os resultados utilizando os pesos aleatórios não são tão conclusivos, pois a maioria dos valores mínimos estão no modelo  $y(t) = F(y(t-1))$  o que pode indicar que este modelo apesar de possuir valores de erro mais elevado será o mais indicado.

### V.3.3. Resultados parque eólico Cabo Verde

Para o parque eólico Cabo Verde os resultados serão apresentados de forma semelhante aos do parque do Loiral para o ano de 2011, pois neste parque também está disponível o registo da pressão atmosférica. Os modelos foram construídos colocando a velocidade do vento e a pressão atmosférica como entradas. Serão apenas apresentados os resultados para uma das torres que é a que se obteve os melhores resultados, mas os resultados das outras torres são muito semelhantes aos aqui apresentados.

Tabela 21 - Resultados para o parque eólico de Cabo Verde pesos fixos

Entrada	Nº Neurónios	EQM (kW)
$y(t)=F(u_1(t-1),y(t-1))$	2	4,13
	3	5,19
	4	4,64
	5	6,62
	6	6,49
	7	6,88
	8	6,64
	9	5,95
	10	5,40
	$y(t)=F(u_1(t-2),y(t-1))$	2
3		2,64
4		3,01
5		3,75
6		11,20
7		12,94
8		3,48
9		6,91
10		6,40
$y(t)=F(u_1(t-3),y(t-1))$		2
	3	2,51
	4	4,04
	5	4,31

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

	6	4,90
	7	6,85
	8	4,07
	9	4,26
	10	7,31
$y(t)=F(u1(t-3),u2(t-1),y(t-1))$	2	3,00
	3	17,08
	4	29,25
	5	45,05
	6	9,11
	7	22,43
	8	38,40
	9	30,58
	10	29,06
	$y(t)=F(y(t-1))$	2
3		4,55
4		3,79
5		4,58
6		6,53
7		3,68
8		4,28
9		5,21
10		5,12

Tabela 22 - Resultados para o parque eólico de Cabo Verde pesos aleatórios

Entrada	Nº Neurónios	EQM Teste 1 (kW)	EQM Teste 2 (kW)	EQM Teste 3 (kW)	EQM Teste 4 (kW)	EQM Teste 5 (kW)	EQM Teste 6 (kW)	EQM Teste 7 (kW)	EQM Teste 8 (kW)	EQM Teste 9 (kW)	EQM Teste 10 (kW)	Mínimo (kW)
Y=F(u1(t-1),y(t-1))	2	3,12	3,33	4,13	4,48	4,13	4,10	4,13	4,13	2,93	4,13	2,93
	3	4,27	5,23	4,55	4,36	6,22	4,36	4,64	4,32	5,01	4,28	4,27
	4	5,79	4,01	5,44	6,06	6,00	7,69	5,89	4,10	4,92	5,64	4,01
	5	5,57	6,41	5,35	6,16	4,87	5,50	4,11	7,25	5,44	9,32	4,11
	6	6,43	9,06	9,96	9,30	6,44	5,71	4,71	5,06	6,03	6,62	4,71
	7	11,81	6,56	7,69	8,49	6,02	6,31	5,78	11,64	5,29	6,15	5,29
	8	5,63	7,04	9,20	5,66	5,50	5,20	9,04	4,85	9,75	7,60	4,85
	9	9,53	6,95	6,26	4,15	7,10	4,67	4,82	7,04	7,47	8,22	4,15
	10	5,98	5,17	8,30	11,33	6,06	15,10	5,23	8,18	6,19	5,78	5,17
	Y=F(u1(t-2),y(t-1))	2	2,60	3,76	2,60	3,70	2,62	3,34	3,39	3,90	4,34	4,05
3		3,32	3,52	5,03	3,40	2,77	5,02	3,76	3,36	3,75	3,58	2,77
4		4,29	3,66	5,82	5,16	3,14	5,16	4,86	4,40	4,47	3,03	3,03
5		6,05	3,24	3,67	5,97	4,87	2,69	3,59	3,44	4,14	5,98	2,69
6		3,68	6,61	3,40	3,15	4,18	6,74	3,25	4,48	4,64	4,79	3,15
7		8,76	6,38	9,13	4,51	8,95	7,85	7,82	6,25	9,03	6,31	4,51
8		7,44	5,80	5,46	5,51	6,10	4,34	6,50	5,99	9,29	5,55	4,34
9		3,88	8,04	6,08	5,13	5,02	7,55	5,71	7,73	10,19	6,60	3,88
10		4,34	5,21	6,21	5,13	7,93	5,07	9,98	7,83	12,09	10,55	4,34
Y=F(u1(t-3),y(t-1))		2	3,03	3,36	3,76	2,89	2,95	3,57	3,45	2,36	2,98	3,02
	3	3,37	1,90	3,21	3,62	6,70	2,60	3,79	2,52	4,85	2,88	1,9
	4	2,55	4,27	3,78	3,72	3,57	4,44	3,59	4,53	5,87	3,24	2,55
	5	4,47	3,98	3,38	3,24	3,37	4,78	4,06	4,08	3,78	3,18	3,18
	6	5,35	5,99	3,35	5,70	3,99	4,33	4,13	5,01	3,35	5,52	3,35
	7	3,02	5,00	4,47	4,74	4,09	3,76	4,03	2,17	4,49	3,68	2,17
	8	6,42	5,15	4,59	3,04	4,39	4,57	6,08	5,79	5,34	6,17	3,04
	9	6,30	4,94	3,62	5,94	5,02	6,99	2,92	7,41	8,39	5,44	2,92
	10	5,47	5,93	6,65	2,81	5,79	5,87	3,77	5,17	9,10	5,55	2,81

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

Y=F(u1(t-3),u2(t-1),y(t-1))	2	5,54	5,83	3,39	7,13	4,53	7,10	5,87	2,54	7,85	7,31	2,54
	3	7,85	16,74	17,50	4,72	9,96	18,15	13,11	5,46	24,21	5,24	4,72
	4	5,29	19,73	21,25	22,40	16,76	31,13	15,80	12,86	31,76	15,76	5,29
	5	36,96	13,36	8,97	38,81	43,39	15,64	19,51	12,52	26,93	39,20	8,97
	6	22,31	21,57	23,31	44,19	47,03	10,83	41,13	26,17	27,22	41,02	10,83
	7	30,24	17,30	15,26	25,27	23,29	39,17	33,68	28,29	21,94	42,87	15,26
	8	31,13	61,94	24,07	28,71	25,18	19,62	34,58	30,04	22,67	39,32	19,62
	9	9,80	42,44	36,81	22,91	57,31	31,54	23,46	27,24	32,74	37,41	9,8
	10	25,36	22,00	27,55	39,07	52,30	33,69	68,73	23,56	27,72	20,28	20,28
	Y=F(y(t-1))	2	3,26	2,66	2,18	2,19	2,82	2,01	2,85	2,47	3,48	2,46
3		2,14	2,47	2,55	4,08	4,79	4,66	2,37	1,59	4,49	4,45	1,59
4		4,23	4,22	4,68	4,43	4,25	3,93	5,51	2,36	4,22	4,15	2,36
5		5,02	4,15	4,17	5,63	3,90	4,28	4,31	4,28	4,69	5,01	3,9
6		4,26	4,08	5,13	5,46	5,05	4,34	6,42	4,33	4,10	4,35	4,08
7		5,81	4,88	5,89	5,74	4,40	5,83	4,58	4,28	4,79	5,72	4,28
8		4,22	6,01	4,20	5,36	4,06	3,61	5,53	6,08	5,07	4,52	3,61
9		5,57	2,64	4,03	6,29	4,22	4,21	4,82	4,94	5,49	4,76	2,64
10		3,90	5,01	5,72	4,07	5,51	5,40	4,41	5,02	4,63	3,25	3,25




Figura 30 - Resultados melhor simulação parque eólico Cabo Verde

V. *Teste e Avaliação dos Modelos de Previsão Eólica*

Através da análise das tabelas 21 e 22 o modelo que obtém o menor valor de EQM é  $y(t) = F(y(t - 1))$  e o respetivo erro de 1,59 utilizando uma arquitetura de 3 neurónios embora também através do modelo  $y(t) = F(u(t - 3), y(t - 1))$  se obtenha bons resultados. Contudo, através da análise da tabela dos pesos fixos não é possível chegar a esta conclusão daí a necessidade de efetuar vários testes para cada modelo de forma a verificar qual dos modelos proporciona os melhores resultados.

---

## V.4. CONCLUSÃO

---

Neste capítulo foram apresentados os resultados dos testes e avaliação dos modelos para dois parques eólicos diferentes, nomeadamente o parque do Loiral e o de Cabo Verde.

Em relação aos dados do parque do Loiral estes estão divididos em dois, os do ano 2009 e de 2011, nos dados do ano 2008 existe apenas o registo de velocidade do vento e da produção de energia já nos dados de 2011 para além destas duas variáveis estão disponíveis a pressão atmosférica direção do vento e temperatura. Seria de esperar que através da inclusão de uma variável como a pressão atmosférica e a velocidade do vento os resultados dos modelos fossem melhores, pois de acordo com a equação 1 a produção de energia é dependente destes dois parâmetros logo era expectável que os resultados destes modelos fossem melhores que os modelos  $y(t) = F(y(t - 1))$ , mas tal facto não aconteceu.

Como já referido nos parques eólicos da RAM existem limitações de potência introduzidas, que apesar de ter sido efetuada uma filtragem, mascara os dados, impossibilitando a criação de modelos com melhor qualidade.

Em relação aos dados de Cabo Verde estes têm muitas falhas nos dados, o que faz com que as sequências de dados sem limitações sejam curtas e não permitam também obter modelos de elevada qualidade. Apesar destas limitações, estes dados permitem concluir que o tempo de amostragem de 10 minutos deve ser profundamente analisado pois poderá não ser o mais correto. Como é conhecido da teoria de sistemas este é um parâmetro fundamental para a criação de um modelo.

De um modo geral como os dados estão muito afetados por limitações, a informação que consegue ser extraída dos dados é baixa, como se pode concluir os modelos de melhor qualidade terem frequentemente apenas 2 ou 3 neurónios. Pelo mesmo motivo conclui-se que o melhor modelo para representar os dados é o designado método da persistência, o que confirma também a análise de sistemas eólicos não deveriam ter amostragens com esta periodicidade.



---

## VI. CONCLUSÕES

---

## VI. Conclusões

Este trabalho incidiu sobre como as redes neuronais podem ajudar a resolver problemas de previsão de energia eólica. Como é conhecido, as redes neuronais são um bom método para resolver diversos tipos de problemas, pois possuem boa adaptabilidade, capacidade de generalização e de descoberta de padrões em dados históricos, o que se adequa no tipo de problema presente neste trabalho.

Para este trabalho estavam disponíveis dados relativos a três parques eólicos, dois situados na RAM e o outro em Cabo Verde. Geralmente existe um sistema responsável pelo armazenamento dos dados recolhidos pelos sensores. Sendo que é armazenada a média das leituras a cada intervalo de 10 minutos desses dados. Usualmente existem registos de variáveis como a velocidade do vento, a temperatura, a pressão atmosférica, a direção e por último a produção de energia nos aerogeradores.

Habitualmente estes dados possuem alguns *outliers* devido a erros de leitura dos sensores, mau funcionamento dos sensores e por último quando as torres são desligadas para manutenção. A principal dificuldade existente neste trabalho é que os dados que estavam disponíveis apresentavam muitas limitações, como por exemplo, não estavam disponíveis registos dos parâmetros usuais neste tipo de problemas. Outro problema existente no caso dos parques eólicos da RAM foram as limitações de potência introduzidas pela empresa que gere a rede elétrica, estas limitações de energia são introduzidas pois a rede elétrica nem sempre possui capacidade para consumir toda a energia que é produzida pelos aerogeradores o que fez acrescentar ainda mais as limitações já existentes nos dados.

Para solucionar este problema foi necessário recorrer a técnicas de filtragem para eliminar grande parte desses outliers. Essas técnicas tiveram de ser diferentes para cada parque eólico, pois os problemas existentes em cada um eram diferentes. Associado ao problema da filtragem reside o facto de que na modelação de sistemas com redes neuronais existe a necessidade de manter uma sequência de dados, ou seja, o registo tem de ser contínuo para o sistema calcular corretamente a saída o que vem acrescentar mais um problema pois ao efetuar a filtragem são eliminados dados e essa sequência é perdida.

Com todas as limitações existentes nos dados foi difícil construir modelos, pois a quantidade de dados em sequência após a filtragem não é muito elevada. Embora com estas limitações, foram construídos diversos modelos com redes neuronais, apenas para os parques do Loiral e de Cabo Verde já os dados do parque das Pedras foram descartados por razões já apresentadas anteriormente.

Dos modelos construídos foi verificado que, em geral, o modelo que melhor descreve o comportamento de um aerogerador é  $y(t) = F(y(t - 1))$  este facto não era esperado pois segundo a equação 1 a potência produzida por um aerogerador é dependente da velocidade do vento. Este facto não deixa de ser verdadeiro, pelas conclusões obtidas através dos modelos aqui apresentados, pois sabemos que o vento é o principal responsável pela energia produzida por um aerogerador.

O problema para se obter estes resultados foram as grandes limitações de dados existentes que levam a que os modelos não tenham um desempenho razoável, outra possível razão é o período de amostragem que devia ser mais longo por questões que têm a ver com a teoria de identificação de sistemas.

Apesar de tudo, está identificado na literatura que o método da persistência (considerar que a produção atual é igual à da amostra anterior) é frequentemente identificado como o que apresenta o melhor resultado para previsões de curto prazo, como é o caso do que foi realizado neste trabalho.

---

## VII. REFERÊNCIAS

---

- [1] [http://e2p.inegi.up.pt/relatorios/Portugal\\_Parques\\_Eolicos\\_201112.pdf](http://e2p.inegi.up.pt/relatorios/Portugal_Parques_Eolicos_201112.pdf)
- [2] Bessa, R., "Treino On Line de Redes Neurais com Critérios de Informação Aplicado à Previsão Eólica" Disponível em: <http://repositorio-aberto.up.pt/bitstream/10216/10798/2/Tese%20MADSAD%20%20Ricardo%20Bessa.pdf>
- [3] <http://www.parqueeolicoalegria.com.br/energia-eolica>
- [4] VESTAS V52 850 52.0, Disponível em : [www.kulak.com.pl/Wiatraki/pdf/vestas%20v52.pdf](http://www.kulak.com.pl/Wiatraki/pdf/vestas%20v52.pdf)
- [5] Pereira M., "Um estudo do aerogerador variável e sua aplicação para fornecimento de energia elétrica contante" Universidade Federal de Juiz de Fora, Tese de Mestrado 2004.
- [6] Dias F. "Técnicas de controlo não-linear baseadas em Redes Neurais: do algoritmo à implementação" Universidade de Aveiro Departamento de Eletrónica e Telecomunicações, Tese de Doutoramento 2005
- [7] SEGUNDO, Francisco et al. "Redes Neurais Treinadas por Filtro de Kalman Aplicadas à Previsão da Velocidade dos Ventos para o Planeamento da Operação de Parques Eólicos" Disponível em: <http://www.dee.ufc.br/~rleao/Artigos/Redes%20Neurais%20Treinadas%20por%20Filtro%20de%20Kalman%20Aplicadas%20a%20Previsao%20da%20Velocidade%20dos%20Ventos%20para%20o%20Planejamento%20da%20Operacao%20de%20Parques%20Eolicos.pdf> Acedido em 2 de Janeiro 2012.
- [8] Catalão, J.P.S et al. "Redes Neurais para Previsão da Potência Eólica" Disponível em <http://www.deetc.isel.ipl.pt/jetc05/jetc08/papers/p423.pdf> Acedido em 28 de Dezembro 2011.
- [9] Cybenko G., "Approximation by superposition of sigmoidal function" *Mathematics of Control, Signals and Systems*, 2:492-499, 1989.
- [10] Hornik K., Stinchombe M., and White H., "Multilayer feedforward networks are universal approximators", *Neural Networks*, 2:359-366, 1989.
- [11] Funahashi K., "On the approximate realization of continuous mappings by neural networks", *Neural Networks*, 2:183-192, 1989.
- [12] Marquardt, D., "An algorithm for least-squares estimation of nonlinear parameters", *SIAM J.Appl. Math.*, 11:431-441, 1963.
- [13] Levenberg, K., "A method for the solution of certain problems in least squares", *Quart. Appl. Math.*, 2:164-168, 1944.
- [14] Condition Monitoring System for Wind Turbines, Disponível em: <http://www.skf.com/files/190928.pdf> Acedido em 7 de Setembro 2012.
- [15] Nilsson, J., Bertling, L., Maintenance Management of Wind Power Systems Using Condition Monitoring Systems—Life Cycle Cost Analysis for Two Case Studies. *IEEE Transactions on Energy Conversion*, Vol 22, no 1, March 2007.
- [16] Fangfang, D., "Comparative Study of Maintenance Strategies for Wind Turbine Systems" Concordia University Montréal, Master Thesis 2010
- [17] Zhigang, T., Tongdan, J., Bairong, W., Fangfang, D., "Condition based maintenance optimization for wind power generation systems under continuous monitoring" *Renewable Energy*, 2011

VII. *Referências*

- [18] Kim, K., Parthasarathy, G., Uluyol, O., Foslien, W., Shuangwen, S., Fleming, P., "Use of SCADA Data for Failure Detection in Wind Turbines" Energy Sustainability Conference and Fuel Cell Conference, 2011.
- [19] Coleman, T.F. and Y. Li, "A Reflective Newton Method for Minimizing a Quadratic Function Subject to Bounds on some of the Variables," SIAM Journal on Optimization, Vol. 6, Number 4, pp 1040–1058, 1996.
- [20] Cameron WP, Michael N. Very short-term wind forecasting for Tasmanian power generation. IEEE Transactions on Power Systems 2006; 21(No. 2):1–8.
- [21] Landberg L. Short-term prediction of the power production from wind farms. Journal of Wind Engineering and Industrial Aerodynamics 1998; 80(No. 1–2): 207–20.
- [22] Li S, Wunsch DC, O’Hair E, Giesselmann MG. Comparative analysis of regression and artificial neural network models for wind turbine power curve estimation. Journal of Solar Energy Engineering 2001; 123(No. 4):327–32.
- [23] Goh SL, Popovic DH, Mandic DP. Complex-valued estimation of wind profile and wind power. In: Proceedings of 12th IEEE Mediterranean Electro technical Conference; 2004. p. 1037–40.
- [24] Lange M, Focken U. Physical approach to short-term wind power prediction. Berlin: Springer Verlag; 2006.
- [25] Barbounis TG, Theocharis JB, Alexiadis MC, Dokopoulos PS. Long-term wind speed and power forecasting using local recurrent neural network models. IEEE Transactions on Energy Conversion 2006; 21(No. 1):273–84.
- [26] Lennart Ljung: System Identification – Theory for the user Prentice Hall 1987.
- [27] Nørgaard M. Neural network based control system design toolkit for use with matlab, version 2. Technical report, Technical University of Denmark, 1996.
- [28] Mason R., Young J., "Multivariate Statistical Process Control with Industrial Applications " ASA-SIAM, 4:53-80, 2002.
- [29] Andrade H., "Aspetos e condições do sistema de controlo e supervisão do parque e caracterização do regime de vento em São Vicente", Mindelo 2008.
- [30] Enereem, "Plano de implementação parque eólico Loiral", Enereem energias renováveis, Janeiro 2007.
- [31] Enereem, "Plano de implementação parque eólico Pedras", Enereem energias renováveis, Janeiro 2007.
- [32] Beale M. H., Hagan M. T., Demuth H. B.: "Neural Network Toolbox™ R2011B" The Math Works, Inc.3 Apple Hill Drive Natick, September 2011.
- [33] Nørgaard M., "System Identification and Control with Neural Networks". PhD thesis, Department of Automation, Technical University of Denmark, 1996.



---

# ANEXOS

---

---

# ANEXO A

---

Neste anexo está presente o artigo apresentado na Conferência CONTROLO'12 que aborda a modelação utilizando redes neuronais para o parque eólico do Loiral.

## LOIRAL WIND PARK MODELLING USING ARTIFICIAL NEURAL NETWORKS

**Dário Fernandes<sup>1</sup>, Dario Baptista<sup>1</sup>, Beatriz Jardim<sup>2</sup>, Agostinho Figueira<sup>2</sup> and Fernando Morgado-Dias<sup>1</sup>**

*<sup>1</sup>Madeira Interactive Technologies Institute and Centro de Competências de Ciências Exactas e da Engenharia, Universidade da Madeira*

*Campus da Penteada, 9000-039 Funchal, Madeira, Portugal.*

*Tel:+351 291-705150/1, Fax: +351 291-705199*

*<sup>2</sup>Empresa de Electricidade da Madeira, Avenida do Mar e das Comunidades Madeirenses, nº 32, 9064-501 Funchal, Madeira, Portugal*

*Tel:+351 291-211 300*

*morgado@uma.pt*

**Abstract:** The capacity to predict accurately the energy production in a wind park is extremely relevant both from an economical point of view and to control the stability of the electrical grid. Many different models have been used for this purpose, such as physical, statistical, neuro-fuzzy and artificial neural networks. The data available from wind parks is usually noisy and has measurements that are unexpected regarding the available inputs. Dealing with this data and determine system characteristics is not an easy task but, in this work, Artificial Neural Networks are used to predict power generation based on in site wind measurements. The results show that Artificial Neural Networks are a tool that should be considered under these difficult conditions, since they provide a reasonable precision in the predictions. When compared with the results presented in the literature the obtained results are in the same order of values, although the data used in this work seems to have a large amount of outliers. Copyright CONTROLO2012

**Keywords:** Artificial Intelligence, Neural Networks, modeling, wind power, wind turbine.

## 1. INTRODUCTION

At the beginning of the second millennium, energy sources like wind, water and wood dominated the production of heat and power. More recently, new sources - coal, oil, gas and nuclear have replaced these traditional sources particularly in the industrialized countries.

Currently there are several ways to harness more efficiently the natural resources of the planet. One of these resources is wind power, besides being a source of non-polluting and renewable energy, wind energy has the advantage of being installed in remote places, and can satisfy energy needs that were not covered before.

For a better use of this natural resource many studies about the nature of the wind have been developed. As a result models and tools were developed that are able to predict wind conditions and electrical production from this resource.

This article addresses the use of neural networks, which are tools that can be used in forecasting models to predict the wind power production of a small wind park in Madeira, Portugal. Through the model constructed and using data from a wind park we will check the reliability of this model for wind power prediction.

## 2. STATE OF ART

During the last decade several studies were conducted on the ability to forecast the production of energy from the wind.

Through these studies various solutions were developed and some of them have already been implemented for use in real world situations.

Table 1 summarizes the main solutions that have been developed up to date in the context of forecast energy production based on wind power.

Table 1 Main solutions developed to predict the wind energy production.

Model	Used Method	Operating Since
Prediktor	Physical	1994
WPPT	Statistical	1994
Zephyr	Physical and Statistical	-
Previento	Physical	-

AWPPS	Statistical and neuro-fuzzy	1998
RAL	Statistical	-
LocalPred-RegioPred	Physical	2001
Sipreólico	Statistical	2002
HIRPOM	Physical	-
AWPT	Statistical and Neural Network	-

As can be seen, the different models used various methods to develop models, such as physical, statistical, a combination of both, statistical and neuro-fuzzy and finally statistical and Artificial Neural Networks (ANN) (Giebel, et al., 2003). The present work only covers the study of the use of ANN for wind park modeling.

Until now a few studies have been made using ANN for wind power prediction, in which it seems that good results can be obtained by this method (Giesselmann, 2001).

## 3. WIND PARK IDENTIFICATION

The park object of study is located on the island of Madeira in the municipality of Calheta and its location can be seen in figure 1. This park is called Loiral Wind Park and was built in order to provide energy for domestic consumption in the municipalities of São Vicente and Ponta do Sol.



Fig. 1. Wind Park localization in Madeira Island



Fig. 2. Image of Loiral Wind Park

The estimated production is of 14.4 MWh / year. The park consists of 6 VESTAS turbines with a unit power of 850 KW, with each tower reaching 49 meters in height. An image of the park can be seen in figure 2.

#### 4. MODELLING DATA FROM THE WIND PARK

##### 4.1 Description of the data

The data used was registered from 1 September 2009 until August 31, 2010. Sampling period is ten minutes. The data only contains information about mean wind speed and average active power for each wind generator.

##### 4.2 Data Pre Processing

In this study, a large amount of data has been collected which contains errors caused by measurement errors or malfunctioning of the sensors, but the biggest problem concerning data is that maximum power limitations are introduced whenever the production is considered too high for the consumption. The occurrence of these errors was revealed by lack of data in the sample or by data whose value was outside the expected range (outliers). At this stage the pre-processing of data consists in two filters, as represented in figure 3:




Fig.3. Block diagram of the data filtering process

The initial data is composed of 52.560 samples for each of the 6 turbines.

Filter 1 (figure 4) consist of removing the data according to the following condition:

$$\text{If } v_i > \text{rated speed and} \\ < (\text{rated capacity} - 100\text{KW})$$

Where, rated speed is the wind speed that drives the turbine to produce at the rated capacity; rated capacity is the maximum power that the turbine can produce,  $v_i$  is the wind speed at sample  $i$  and  $P_i$  is the power produced at sample  $i$ . The idea behind the first filtering is to eliminate the situations when the power was limited by the control center.

After running filter 1, the largest sequences with no data removed in between are passed through filter 2.

Only these sequences are used in order to keep the data sequence because the models can be of order superior to 1.

Filter 2 consists on approximate the data by a polynomial curve and reject the data that is further away from the polynomial curve, using the following intervals:

$$\text{Up limit} = \text{Polynomial} + k \cdot \sigma \quad (1)$$

$$\text{Low limit} = \text{Polynomial} - k \cdot \sigma \quad (2)$$

After running filter 2 and adjusting  $k$  (it may vary for different turbines) in order to obtain sequences large enough for ANN training and testing in each turbine, data is ready for training.

Figures 4 and 5 illustrate the effect of the filters in the data.

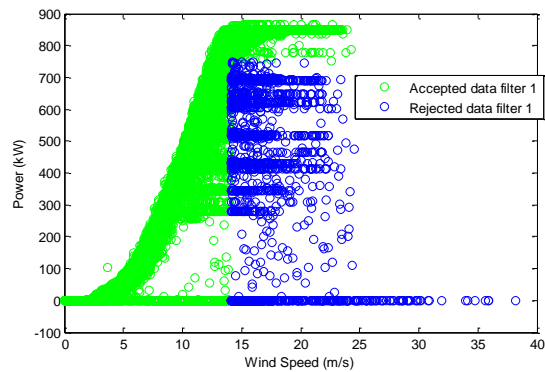


Fig. 4. Example of the effect of filter 1




Fig. 5. Example of the effect of filter 2

A turbine is expected to produce a certain amount of energy for a given wind speed.

The power  $P(W)$  is proportional to the cube of the wind speed and given by:

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

Where,  $A(m^2)$  is the cross section area of the turbine rotor and  $\rho$  is the specific mass of air under conditions of normal temperature and pressure ( $1,225 \text{ Kg/m}^3$  (Bessa, 2008)).

An example of this behavior is shown in Figure 6 and 7.

Another aspect that had to be taken into consideration was the individual productions of each tower.

Figure 8 shows the combined production of the 6 turbines that compose the park and figure the production of a singular turbine.

Analyzing figures 6 and 7 it is possible to see that for the data supplied, under the same wind speed the energy production of each tower can be quite different. This is due to the topography of the terrain near each wind turbine. Due to these variations and trying to minimize the error for the models, an ANN was used for each wind turbine. Splitting the information will allow the models to deal with less complexity and will be more accurate.




Fig. 6. Relation between the power generated and the cubic wind speed in the turbine 2

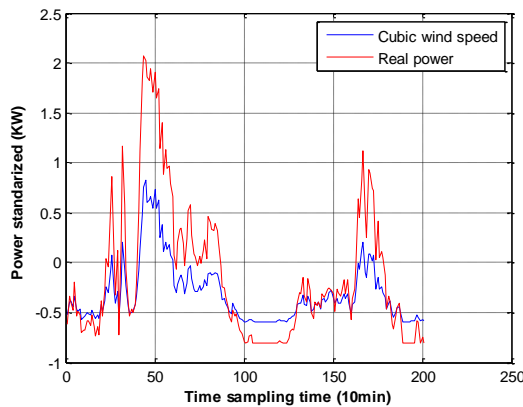


Fig. 7. Relation between the power generated and the cubic wind speed in the turbine 6




Fig. 8. Power curve for the wind park.

#### 4.3 Modelling the wind park data.

As was mentioned above, this study only uses ANN models. The use of this kind of model allows forecasting power generated by the wind and this technique has shown to be convenient and efficient.

In "classical" system identification to build a system model it is essential to determine the order of the system, that is, determine the order of the equations necessary to characterize the system with some degree of accuracy or find a balance between the complexity of the model and its accuracy.




Fig. 9. Power curve for wind park turbine 2.

To determine the order of the model function the Lipschitz function (He and Asada, 1993) was used.

This function is mostly used for systems with order superior to one and the obtained results are not clear. Alternatively several models were tested, increasing the order to verify if it would compensate to use higher orders. The results showed that the system order is 1.

This means that for calculating an output value of the ANN, the model needs one prior value of wind speed and energy production.

#### 4.4 Neural Network's Results

After defining the set of data for use in training the ANN, it is necessary to define the network's architecture. The structure selected was a feedforward ANN. The hyperbolic tangent was used in the hidden layer as activation function and a linear function was selected for the output neuron. The training algorithm used was the Levenberg-Marquardt (Levenberg, 1944, Marquardt, 1963). The training and test errors were monitored using the Mean Square Error (MSE) measurements. The training was performed using the neural network toolbox of Matlab (Beale, *et al.*, 2011) and another toolbox that runs with Matlab, NNSYSID (Nørgaard, 2000), to check which solution produced the best results. The information about the data used for training and test is presented in tables 2 and 3. As explained earlier in this section, models were built for each tower.

Table 2 Data used for training and test simulation 1 (turbine 4)

Variable	Training	Test
Mean(kW)	206,47	143,78
Variance (kW)	289,47	221,23
Minimum value	-0,13	-0,03
Maximum value	860,7	851,08
Size (samples)	5863	3535

Table 3 Data used for training and test simulation 2 (turbine 2)

Variable	Training	Test
Mean(kW)	205,72	307,98
Variance (kW)	288,86	350,61
Minimum value	-0,04	-0,01
Maximum value	864,75	850,75
Size (samples)	4576	1145

To select the best topology for the ANN several identical tests were performed for both toolboxes. Those included testing different models, different model orders and different number of neurons in the hidden layer. The final tests were done using NNARX models, using random initial weights, testing from 4 to 12 neurons in each toolbox and 10

ANN were created for each situation, in a total of 180 for each tower and amounting to 1080 ANN trained for the wind park final tests. The Early Stopping technique was used to select the number of iterations. The best (simulation 1) and the worst (simulation 2) result obtained among the 6 wind towers are summarized in table 4 and 5.

Table 4 Results of the test error for simulation 1 (turbine 4)

Toolbox	Number of neurons	Test Error (MSE)
Matlab	4 neurons	12,87
NNSYSID	4 neurons	12,54


Table 5 Results of the test error for simulation 2 (turbine 2)

Toolbox	Number of neurons	Test Error (MSE)
Matlab	8 neurons	25,03
NNSYSID	12 neurons	25,41

Figure 10 presents the results of simulation 1 obtained, with the Matlab toolbox. Figure 11 shows the results of simulation obtained with the NNSYSID toolbox. Analyzing the data in Tables 4 and 5 it can be seen that very similar results were obtained using both toolboxes.

## 5. RESULT COMPARISON

There are several papers published regarding the same theme that this article discusses. Some papers are targeted to predict the power generated based on forecasts of wind speed and other data and others, which is the case in this article, are based on historical data of wind parks, where the objective is to verify if ANN have an acceptable behavior. The reason for analyzing the results of other studies is to compare the error values, so that it can be verified if the errors obtained in this paper are acceptable.



In (Catalão, 2008) a prediction was provided for two days with the error obtained for each day reaching 13,16% and 12,59% respectively. In another work (Bessa, 2008), tests were carried out for three wind parks and obtained error rates of around 3%. Analyzing these results and comparing with the obtained in this study, the results obtained for this work are satisfactory.

Comparing figures 10 and 11, and the summary presented in tables 4 and 5, it is clear that these can reasonably predict energy production with an acceptable average error, when considering the limitations of the available data, regarding additional variables that could be used and the maximum power limitations imposed by the control center.

## 6. CONCLUSION

The results of this article are encouraging because although a relatively large error value was obtained, it has the same order of magnitude obtained by other solutions of the same type, which is due to the uncertain nature of the wind. In spite of that, even the results obtained for the worst wind tower are acceptable when compared with the literature examples.

Given these results, it can be stated that the models used, ANN, are a good alternative for predicting power output for a given wind speed. Although these results are for static data, i.e., data relating to a period of one year, it is concluded that given a good prediction of the wind for a given time interval, it is possible to anticipate the production of energy in the wind farm, making it possible to adjust the parameters to maximize the turbine energy production.

For this study a strong limitation was the lack of other variables that could be used to build better models, such as pressure, temperature and humidity level. Another major limitation is the maximum power limitation introduced in the production for which there is no information that allows rejecting this data for model estimation.

## ACKNOWLEDGMENTS

The authors would like to acknowledge the Portuguese Foundation for Science and Technology for their support for this work through project PEst-OE/EEI/LA0009/2011.

The authors would also like to acknowledge Empresa de Electricidade da Madeira for their support, the data that is used in this paper and additional information about the wind park and its operation.

## REFERENCES

- Bessa, R. "Treino On Line de Redes Neurais com Critérios de Informação Aplicado à Previsão Eólica", Faculdade de Economia da Universidade do Porto, Master Thesis 2008.
- Catalão, J.P.S., Mendes V.M.F., Departamento de Engenharia Electromecânica, Covilha Portugal, "Redes Neurais para Previsão da Potência Eólica", Scientific Paper 2008.
- Nørgaard M., Ravn O., Poulsen N.K. and Hansen L.K.: "Neural Networks for Modelling and Control of Dynamic Systems", Department of Automation Technical University of Denmark, Springer 2000.
- Nørgaard M.: "Neural Network Based System Identification Toolbox" Technical Report 00-E-891, Department of Automation Technical University of Denmark, 2000.
- Beale M. H., Hagan M. T., Demuth H. B.: "Neural Network Toolbox™ R2011B" The Math Works, Inc.3 Apple Hill Drive Natick, MA 01760-2098, September 2011.
- Giesselmann Michael G., Senior Member, IEEE: "Using Neural Networks to Estimate Wind Turbine Power Generation", IEEE TRANSACTIONS ON ENERGY CONVERSION, VOL. 16, NO. 3, SEPTEMBER 2001.
- Giebel G., Brownsword R., Kariniotakis, G., Denhard, M., Draxl, C.: "The state of the art in short-term prediction of wind power", technical report from the Anemos project, 2003
- He X., Asada H. : "A New Method for Identifying Orders of Input-Output Model For Nonlinear Dynamic Systems," Proc. of the American Control Conf., S.F., California, 1993.
- Kusiak, A., Zheng, H., Song, Z.: "Models for monitoring wind farm power", Renewable Energy 34, 583-590, 2009.
- Cameron WP, Michael N. Very short-term wind forecasting for Tasmanian power generation.IEEE Transactions on Power Systems 2006;21(No. 2):1-8.

- Li S, Wunsch DC, O'Hair E, Giesselmann MG. Comparative analysis of regression and artificial neural network models for wind turbine power curve estimation. *Journal of Solar Energy Engineering* 2001;123(No. 4):327-32.
- Goh SL, Popovic DH, Mandic DP. Complex-valued estimation of wind profile and wind power. In: *Proceedings of 12th IEEE Mediterranean Electrotechnical Conference*; 2004. p. 1037-40.
- Barbounis TG, Theocharis JB, Alexiadis MC, Dokopoulos PS. Long-term wind speed and power forecasting using local recurrent neural network models. *IEEE Transactions on Energy Conversion* 2006;21(No. 1):273-84.
- Levenberg, K., "A method for the solution of certain problems in least squares". *Quart. Appl. Math.*, 2:164-168, 1944.
- Marquardt, D., "An algorithm for least-squares estimation of nonlinear parameters", *SIAM J. Appl. Math.*, 11:431-441, 1963.