Faculdade de Engenharia da Universidade do Porto



Utilização de Técnicas de Processamento do Sinal na Previsão Eólica

Fernando José Lopes Bernardo

VERSÃO FINAL

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Eletrotécnica e de Computadores
Major Automação

Orientador: Adriano da Silva Carvalho (Professor Catedrático)
Coorientador: João Nuno Monteiro da Silva e Sousa (Mestre)

Fevereiro de 2015

© Fernando José Lopes Bernardo, 2015

Resumo

Começa a haver uma forte tendência a nível mundial para os países diminuírem a dependência do petróleo, motivada pela necessidade de controlar as emissões de dióxido de carbono para a atmosfera e, pela necessidade resultante duma maior segurança ao nível do abastecimento e da acessibilidade do sistema de energia elétrica. Descentralizar o sistema, melhora a eficiência da produção, reduz os custos, reduz impactes da rede de transmissão/distribuição, e reduz as emissões de gases que provocam o efeito de estufa. A aposta no sistema de produção descentralizado de energia, nos últimos anos, tem como resultado a proliferação de centrais de geração de eletricidade baseadas em energias renováveis, no sistema electroprodutor nacional, especialmente as que funcionam a energia eólica. É neste contexto que surge a necessidade de se proceder à integração eficiente de energias renováveis (limpas), no sistema de energia elétrica. A previsão é frequentemente tida como uma ferramenta importante para enfrentar a variabilidade e a incerteza, inerentes à produção de energia eólica, servindo também para gerir de forma mais eficiente os sistemas que a recebem, principalmente quando se atingem elevados níveis de produção. Existem benefícios diretos obtidos pelo aumento da precisão nas previsões de curto prazo, além dos já referidos, e devem-se ao fato de se reduzirem os custos de produção do sistema, a possibilidade da redução na quantidade de energia do recurso vento à qual terá de se recorrer, evitando a construção novas unidades de reserva, dado que deixam de ser necessárias.

Nesta dissertação apresentam-se alguns métodos de previsão do vento a muito curto prazo, faz-se uma comparação crítica de diferentes técnicas implementando uma plataforma de testes, utilizando métricas objetivas.

Página em branco

Abstract

There is a strong trend worldwide to countries decrease the dependence on oil motivated by the need to control carbon dioxide emissions to the atmosphere and the resulting need for greater security to the level of supply and accessibility of the electricity system. Decentralize the system, improves production efficiency, reduces costs, reduces impact of the network transmission/distribution, and reduces emissions of gases that cause the greenhouse effect. The focus on decentralized energy production system in recent years has resulted in the proliferation of electricity generation plants based on renewable energies in the national electricity system, especially those operating with wind energy. It is in this context that it is important to carry out the efficient integration of renewable energy on the electric power system. The forecast is often seen as an important tool to face the variability and uncertainty inherent in the production of wind power, also serving to manage more efficiently the system that receives it, especially when it reaches a high level of production. Direct benefits are obtained by increasing the precision in the short term forecasting, besides those already mentioned, due to the fact that they reduce system production costs, the possibility of reducing the amount of wind energy which avoid build new reserve units, since they are no longer needed.

This thesis presents some very short-term wind forecasting methods and a critical comparison of different techniques implementing a test platform, using objective metrics.

Página em branco

Agradecimentos

Agradeço a todas as pessoas e instituições que contribuíram para o sucesso desta dissertação, especialmente:

Ao Engenheiro João Sousa e ao Professor Adriano Carvalho pelo apoio, orientação e paciência, o que contribuiu positivamente para o desenvolvimento deste trabalho.

Á minha família pela educação que me proporcionou.

Aos amigos que me apoiaram durante a dissertação.

Página em branco

Índice

Resumo iv
Abstract vi
Agradecimentos viii
Lista de figuras xii
Lista de tabelas xiv
Abreviaturas e Símbolos xv
Notações xvi

Capítulo 1 1

Introdução 1
1.1- Objetivos 1
1.2 - Estrutura 4

Capítulo 2 5

Estado da arte 5
2.1 – Impacto na economia 5
2.2 Previsão do vento 10
2.2.1 Introdução 10
2.2.2 Modelos Numéricos de Previsão do Tempo 11
2.2.2.1. Assimilação dos dados para inicialização e validação do modelo 14
2.2.2.2 Definições e horizontes temporais 14
2.2.3 Previsão do vento a muito curto prazo 15
2.2.3.1 Introdução 15
2.2.3.2 Previsão da velocidade do vento usando métodos estatísticos 16
2.3 Constituição de turbinas eólicas 18
2.4 Previsão de muito curto prazo segundo algumas teorias 21
2.4.1 As três classes principais 21
2.4.2 Comparação entre as técnicas estatísticas e as neuronais 21
2.5 O modelo ANFIS 23
2.6 Avaliação das previsões 25
2.6.1 Introdução 25
2.6.2 Avaliação da performance da PEV 26
2.6.3 Dados para treino e teste do modelo 26
2.6.4 -Definição dos erros de medição 26
2.6.4.1 -Erros de previsão 26
2.6.4.2 -Avaliação dos modelos 27
2.6.4.3 -Comparação entre modelos 28

Capítulo 3 29

Modelos de previsão 29
3.1 Modelos de referência 29

3.2 Séries temporais 30
3.2.1 -Estacionariedade 30
3.2.2 Processos Estocásticos..... 31
3.2.2.1 Sequência Aleatória e Passeio Aleatório..... 32
3.2.2.2 Processos Estacionários 32
3.2.2.3 Função de Auto covariância e Função de Auto correlação 33
3.2.2.4 Modelo clássico..... 34
3.2.2.5 Processos de médias móveis 37
3.2.2.6 Processos auto regressivos 38
3.2.2.7 Modelos mistos ARMA 39
3.3 Redes Neuronais 40

Capítulo 4 42

Modelos de previsão com *software* MS Excel 42
4.1 Caraterísticas dos dados..... 43
4.2 Aplicação de modelos de previsão usando modelos autorregressivos e o analisador de dados do MS Excel 44
4.2.1 Previsão usando o Analisador de Dados de Regressão Linear..... 44

Capítulo 5 50

Previsões usando modelos de otimização 50
5.1 O Solver do Excel 50
5.2 Previsão da velocidade do vento otimizando métodos autorregressivos 52

Capítulo 6 55

Previsão de curto prazo da velocidade do vento usando redes neuronais..... 55
6.1 Previsão usando a RN disponível no MATLAB para um horizonte de 10 minutos..... 56
6.2 Previsão usando a RN *nntool* disponível no MATLAB para um horizonte de 4 horas..... 63
6.3 Previsão e modelização da RN para séries temporais usando o MATLAB 64

Capítulo 7 69
Conclusões 69
7.1 Principais conclusões..... 69
7.2 Perspetivas de desenvolvimento futuro 71

Referências 72

Lista de figuras

Figura 1.1 - Curva de potência de uma turbina eólica [2]. 2
Figura 2.1 - Erro percentual para cada central eólica e erro agregado. 8
Figura 2.2 - Número de dimensões. 12
Figura 2.3 - Grau e tipo de estruturas (exemplos). 12
Figura 2.4 - Formas do domínio. 13
Figura 2.5 - Coordenadas verticais (exemplos). 13
Figura 2.6 – Resolução. 13
Figura 2.7 - Estrutura de previsão de muito curto prazo (adaptado de [13]). 15
Figura 2.8 - Incidência do vento nas pás do rotor. 18
Figura 2.9 - Constituição de uma turbina eólica. 19
Figura 2.10 - Ligação da turbina à rede elétrica [61]. 20
Figura 2.11 - Rede neuronal simples. É apenas um exemplo entre as várias permutações que podem existir. 23
Figura 2.12 - Representação de um conjunto fuzzy para determinar a qualidade da velocidade do vento (fraca, média ou). Não há qualquer ponto de corte. 24
Figura 3.1 - Gráfico de controlo de defeitos [50]. 30
Figura 3.2- Série temporal estacionária. 30
Figura 3.3 - Série temporal não estacionária. 31
Figura 3.4 - Série Original e tendência linear (T). 35
Figura 3.5 - Variações cíclicas, sazonais e irregulares. 35
Figura 3.6 - Património líquido de um banco: série anual, tendência linear e projeção. 37
Figura 3.7 - Modelo NN de três camadas. 41
Figura 4.1 - *Modelo de comunicação* [57]. 43
Figura 4.2 - Arquitetura geral do sistema de comunicações dentro de um parque eólico [58]. 44
Figura 4.3 - Dados com um atraso t-1 entre duas colunas. 45
Figura 4. 4 - Seleção da opção *Regressão* em MS Excel. 45
Figura 4.5 - Entradas para o analisador de dados *Regressão*. 46
Figura 4.6 - Resultados obtidos usando a regressão linear com atraso de t-1. 46
Figura 4.7 - Sumário dos resultados da regressão AR(1) no instante *t+1* em janeiro de 2011. 47
Figura 4.8 - Previsão t+1 colocada diretamente em t+24. 49
Figura 5.1 - Exemplo de preparação do método AR no Excel. 51
Figura 5.2 - Utilização do Solver no método AR(3). 52
Figura 6.1 - Preparação das variáveis 56
Figura 6.2 – Acesso à rede neuronal e exemplos de variáveis 57
Figura 6.3 – Importação de variáveis para a RN. 57
Figura 6.4 – Campos a preencher para a criação da RN. 58
Figura 6.5 – Definição da RN. 58
Figura 6.6 – Definição dos parâmetros da rede para a fase de treino. 59
Figura 6.7 – Fase de treino da rede. 59
Figura 6.8 – Diagramas da rede resultantes da fase de treino. 60
Figura 6.9 – Exemplo de variáveis geradas pela RN. 60
Figura 6.10 – RN com parâmetros pré definidos pela nntool. 61
Figura 6.11 – Preparação da RN para a fase de simulação. 62
Figura 6.12 – Parametrização de uma nova rede. 62
Figura 6.13 – Valores de R para a fase de treino da RN para uma previsão de 4 hora. 63
Figura 6.14 – Diagrama aproximado da NARX com duas camadas 65
Figura 6.15 – Saída da NARX: a) Arquitetura em Paralelo e b) Arquitetura em Série-Paralelo. 65

Figura 6.16 – Seleção da rede e dos dados da série. 66
Figura 6.17 – Divisão dos dados e definição da rede..... 67
Figura 6.18 – Auto correlação dos erros para a NAR após a fase de treino. 67
Figura 6.19 – Resultado da RN para diferentes entradas. 68

Lista de tabelas

Tabela 2.1- Capacidade total instalada da energia do vento por região a nível mundial [4]. ...6
Tabela 2.2 - Valores de ponta da procura de carga no sistema. 8
Tabela 2.3 - Preços do gás ($/MMBTU) usados no estudo (baseados em dados históricos). 9
Tabela 2.4 - Sumário dos benefícios para o caso de estudo....9
Tabela 2.5 - Resumo dos benefícios para variações no preço do gás. 10
Tabela 2.6 - Vantagens e desvantagens dos modelos de redes neuronais. 22
Tabela 2.7 - Vantagens e desvantagens dos modelos estatísticos. 22
Tabela 2.8 - Comparação entre o ANFIS e a Persistência para pequenos ensaios da performance do ANFIS. 25
Tabela 3.1 - Património por ano civil. 36
Tabela 4.1 - Performance dos modelos de regressão para o instante t+1. 47
Tabela 4.2 - Performance da regressão para t+1 com dados de janeiro de 2011. 47
Tabela 4.3 - Simulações usando a Regressão e horizonte t+24 aplicando substituições sucessivas das previsões com dados de agosto de 2010. 48
Tabela 4.4 - Simulações usando a Regressão Linear e horizonte t+24 aplicando substituições sucessivas das previsões (dados de janeiro de 2011). 48
Tabela 4.5 - Resultados de Regressão Linear para t+24 avançando a previsão t+1. 49
Tabela 5.1 - Evolução dos erros e da performance do método auto regressivo para t+1 aplicando o Solver (observações de agosto de 2010). 52
Tabela 5.2 - Evolução dos erros e da performance do método auto regressivo para t+1 aplicando o Solver (observações de janeiro de 2011). 52
Tabela 5.3 - Previsão para um horizonte de 4 horas e coeficientes calculados a partir do Solver (observações realizadas em agosto de 2010). 53
Tabela 5.4 - Previsão para um horizonte de 4 horas e coeficientes calculados a partir do Solver (observações de janeiro de 2011).... 53
Tabela 5.5 - Resultado dos erros e da performance para os meses de 2012 e um horizonte de previsão de 4 horas. 53
Tabela 6.1 – Resultados da rede *network1* para um horizonte de previsão t+1 (10 minutos) em relação à persistência. 61
Tabela 6.2 – Performance para a RN *network2*.... 63
Tabela 6.3 – Resultados da RN para um horizonte de previsão de 4 horas 63
Tabela 6.4 – MSE e ganho da NAR (horizonte de previsão de 10 minutos). 68

Abreviaturas e Símbolos

Lista de abreviaturas (ordenadas por ordem alfabética)

AAEE	Associação Europeia para a Energia Eólica
ANFIS	*Adaptive Neuro Fuzzy Inference System*
AR	Auto Regressivo
ARMA	Auto Regressivo de Média Móvel
ARIMA	Auto Regressivos Integrados e de Médias Móveis
CA	Corrente Alternada
CC	Corrente contínua
DEEUA	Departamento de Energia dos Estados Unidos da América
EC	Critério Aplicado ao Erro
ERCOT	*Electric Reliability Council of Texas*
EUA	Estados Unidos da América
FEUP	Faculdade de Engenharia da Universidade do Porto
f-ARIMA	ARIMA modificado
LRC	Correlação de longo prazo
MAE	Erro Médio Absoluto
MSE	Erro Médio Quadrático
MNPT	Modelos Numéricos de Previsão do Tempo
RN	Rede Neuronal
RNA	Rede Neuronal Artificial
RSME	Raiz Quadrada do Erro Médio Quadrático
PCMCP	Previsão da Carga a Muito Curto Prazo
PEV	Previsão da Energia do Vento
PMPV	Projeto de Melhoria da Previsão do Vento
SDE	Desvio Padrão dos erros
SSAD	Sistemas de Supervisão e Aquisição de Dados
SVM	Máquina com suporte de vetores
3-D	3 dimensões

Lista de símbolos

f	Função genérica
Ω	Ohm
X(t)	Variável no instante t

Notações

Pinst	:Potência instalada da central eólica (em kW ou MW)
k =1,2,…,k_{max}	:Intervalo de tempo da previsão (ou número futuro de períodos de previsão
k_{max}	:Horizonte máximo da previsão
N	:Número total de dados usados no modelo em avaliação
P(t)	:Potência medida no instante t (em kW ou MW), que normalmente corresponde à potência média do período de tempo anterior a *t*
$\hat{P}$ (t+k|t)	:Previsão da potência para o instante de previsão *t*+*k* com origem no tempo *t*
$\bar{P}$	:Média de todas as observações disponíveis da potência do vento até ao instante *t*
e(t+k|t)	:Erro correspondente ao instante de tempo *t*+*k* para a previsão efetuada no instante de origem *t* (em kW ou MW)
Ɛ(t+k|t)	:Erro de previsão normalizado (normalizado para a capacidade total instalada).
f.a.c.v	:Função de Auto covariância.
f.a.c.	:Função de Auto Correlação

Capítulo 1

Introdução

A energia está a tornar-se um fator condicionante dos modelos de desenvolvimento socioeconómicos futuros à escala global, regional e nacional. Satisfazer a procura de energia no momento e no local em que é necessária, e sob a forma adequada, é um dos principais desafios com que a sociedade se confronta no decorrer deste século.

O atual paradigma de desenvolvimento é insustentável a médio e longo prazo, devido às crises e ruturas, resultantes de uma escassez crescente dos combustíveis fósseis e da degradação ambiental resultante. Sem fontes de energia aceitáveis do ponto de vista económico e menos nocivas para o ambiente, não é possível assegurar a manutenção do atual paradigma.

1.1- Objetivos

Começa a haver uma forte tendência a nível mundial para os países diminuírem a dependência do petróleo, motivada pela necessidade de controlar as emissões de dióxido de carbono para a atmosfera e, pela necessidade resultante duma maior segurança ao nível do abastecimento e da acessibilidade. Numa perspetiva de curto e médio prazo, a aposta na produção descentralizada de energia é uma das soluções chave para um paradigma energético mais sustentável. Esta aposta surge também, como uma das abordagens mais eficazes para a eletrificação de áreas remotas, que pode trazer inúmeras outras vantagens em termos de emissões de carbono e segurança energética, em ambientes urbanos. Descentralizar o sistema, melhora a eficiência da produção, reduz os custos, reduz impactos da rede de transmissão/distribuição, e reduz as emissões de CO2.

Idealiza-se assim, uma estratégia energética assente na mudança de paradigma, que tem como principais impulsionadores, a mudança de comportamentos e a produção descentralizada de energia. È assim natural, que a solução esteja nas energias renováveis, na eficiência energética e na modernização dos sistemas de transporte, na promoção de

mercados mais transparentes e concorrentes, na adaptação de todos os sectores da economia e da produção de energia [1].

A aposta no sistema de produção descentralizado de energia, nos últimos anos, tem como resultado a proliferação de centrais de geração de eletricidade baseadas em energias renováveis, no sistema electroprodutor nacional, especialmente as que funcionam a energia eólica. É neste contexto que surge a necessidade de otimizar o funcionamento dos aerogeradores, sendo possível fazê-lo através do conhecimento antecipado da evolução do recurso vento (quer a componente velocidade quer a componente direção). Esta necessidade de otimização leva a que várias entidades estudem metodologias de previsão da produção de aerogeradores a muito curto prazo, recorrendo às variáveis meteorológicas explicativas (como por exemplo a velocidade do vento).

A previsão da geração de eletricidade com base na velocidade e direção do vento, a uma determinada altura do solo (entre os cinquenta e os cem metros), apresenta diversos desafios.

Devido à curva de transferência dos geradores existentes, a conversão de energia cinética do vento em energia elétrica, varia de forma não linear [2], sendo a saída do gerador praticamente nula para um determinado limite inferior de velocidade (cerca de 3 m/s, dependendo da máquina em questão), sofre um rápido crescimento até que a máquina atinja a sua potência nominal (tipicamente 12 m/s), e mantém-se constante até que seja atingida a velocidade de corte (cerca dos 25 m/s). Na figura 1.1 pode ver-se a curva de potência de uma turbina eólica.

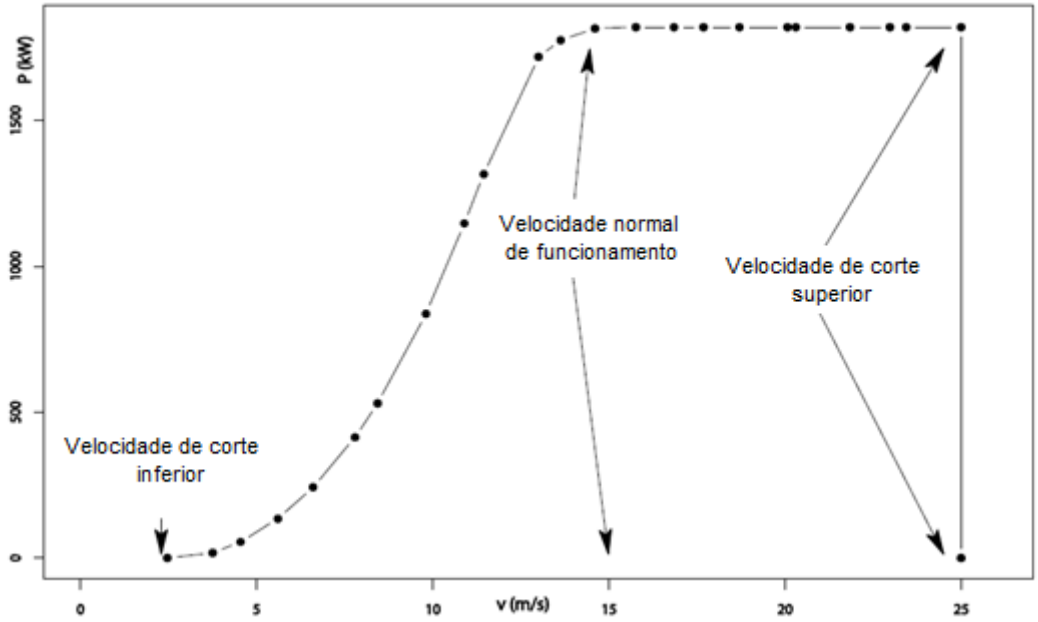


Figura 1.1 - Curva de potência de uma turbina eólica [2].

Num parque eólico os geradores podem interagir entre si, e a função de transferência desta interação pode variar significativamente devido a vários fatores tais como: a direção do vento; o arranque conturbado dos geradores; efeitos que a topologia do local provoca nas variações da velocidade (aumento ou diminuição), implicando uma variação na energia disponível. Dada a não linearidade da função de transferência anteriormente citada, os erros de previsão da velocidade do vento, serão afetados de forma heterogénea em termos da energia realmente obtida. Os erros a baixas velocidades são irrelevantes uma vez que a saída

do sistema é nula. Por sua vez, erros na zona constante da curva de potência (entre os 12 e os 25 m/s), são também irrelevantes, porque a saída é constante, isto se não forem consideradas alterações na direção e na intensidade da turbulência do vento. Erros obtidos entre as velocidades baixas e moderadas (aproximadamente entre 3 e 12 m/s) são fortemente penalizados porque, um pequeno erro de previsão, provoca um erro elevado na saída em potência. Por último, os erros obtidos junto da velocidade de corte (cerca dos 25 m/s) que é, quando o sistema muda abruptamente da potência máxima para uma saída nula, são os que têm pior impacto no sistema de previsão.

Os erros de previsão criam uma determinada volatilidade, por exemplo, no sistema financeiro ligado às centrais de produção baseadas em energia eólica e ao sistema electroprodutor nacional em geral. Assim sendo, a Previsão de Carga a Muito Curto Prazo (PCCP), são uma parte importante no planeamento e operação de sistemas de potência, dado que, permitem a criação de um modelo para a previsão da volatilidade do referido sistema, sendo que o próprio desempenho das previsões, pode ser avaliado através do cálculo dos erros de previsão. No entanto, as PCMCPs são difíceis de aplicar devido aos comportamentos não-lineares e aleatórios, dos vários sistemas de carga, tais como: condições atmosféricas, variações nos ambientes sociais e económicos, entre outros.

Dada importância da PCMCP, a investigação nesta área tem dado origem ao desenvolvimento de numerosos processos de previsão. Estes métodos podem ser classificados de forma grosseira em dois tipos: os métodos baseados em inteligência artificial e métodos clássicos.

Nas últimas décadas tem-se feito um grande investimento na abordagem às redes neuronais artificiais (RNAs). Os métodos das RNAs, são particularmente atrativos porque têm a capacidade de lidar com a relação não linear que existe na sua saída, incluindo, os fatores que afetam essa saída diretamente, nomeadamente quando se usam dados históricos. Um sistema complexo é decomposto em elementos mais simples, de mais fácil compreensão. Por sua vez, os elementos mais simples podem ser unidos para formar um sistema mais complexo. As redes neuronais usam esta estratégia.

Entre as abordagens clássicas, as mais populares são as que usam as técnicas da série temporal estocástica. As séries temporais, são constituídas por um conjunto de observações ordenadas no tempo, podendo ser discretas ou contínuas. Um processo estocástico é um modelo que descreve a estrutura probabilística de uma sequência de operações e, utiliza-se quando se tem um fenómeno aleatório que varia com o tempo. O objetivo da análise de séries temporais estocásticas é o de construir modelos capazes de modelizar o sistema, sendo que uma das aplicações mais importantes, consiste na previsão de valores futuros da série, a curto ou a longo prazo. Considera-se que uma previsão tem um horizonte temporal de muito curto prazo quando se pretende efetuar uma previsão para um instante que vai desde alguns segundos a poucas horas.

A importância das PCMCPs leva a que cada vez mais se investiguem e se desenvolvam novas metodologias, sendo que o presente trabalho pretende, de alguma forma, dar o seu contributo nesse sentido. Por este motivo, foram definidos alguns objetivos, que assentam fundamentalmente no seguinte: revisão do estado da arte na previsão a muito curto prazo da velocidade do vento; comparação crítica das diferentes técnicas implementando uma plataforma de testes; propor e implementar novas metodologias baseadas nas metodologias existentes, utilizando métricas objetivas e bases de dados adequadas.

1.2 - Estrutura

Este trabalho está dividido seis temas, introduzidos nesta secção em cada um dos seguintes parágrafos.

Inicialmente, o trabalho pretende contextualizar o tema da previsão eólica a muito curto prazo mostrando o seu interesse no desenvolvimento energético a nível internacional. A escassez crescente de alguns recursos, bem como a poluição que provocam, levam a que se aposte cada vez mais nas energias renováveis, onde se inclui a eólica. A utilização do recurso vento coloca uma série de desafios aquando dos erros de previsão e devido à curva de transferência dos aerogeradores.

No segundo capítulo, abordam-se temas como o impacto das previsões na economia, quer na Europa quer nos Estado Unidos da América. Num ambiente de mercado, a quantidade de energia eólica gerada torna-se importante na determinação dos preços diários, e as variações na energia eólica estimada, irão influenciar os preços da energia e das reservas operacionais. Em termos económicos é importante ter-se uma ideia dos benefícios que se obtêm quando se usam modelos de previsão precisos. Apresentam-se algumas técnicas de previsão do vento em função do horizonte temporal para os quais a previsão deverá ser efetuada

Com o aumento da produção da energia eólica e da sua ligação ao sistema elétrico, a previsão da energia do vento, é cada vez mais uma aposta entre os operadores do sistema, as empresas geradoras e os reguladores, que se uniram para apoiar e desenvolver melhores modelos de previsão, mais confiáveis e precisos. No terceiro capítulo, exploram-se alguns modelos de previsão, tais como: modelo de persistência; processos estocástico e redes neuronais.

No quarto capítulo, utilizam-se modelos auto regressivos na previsão da velocidade do vento a muito curto prazo, apoiados nos modelos de regressão linear.

Existem métodos que permitem calcular os coeficientes num modelo auto regressivo através da utilização de critérios de otimização, tais como a minimização do MAE. No quinto capítulo foram efetuadas várias simulações e apresentados diversos resultados para critérios de otimização.

As RNAs foram abordadas no capítulo seis, onde se apresentam alguns resultados após se realizarem algumas simulações.

No capítulo final apresentam-se algumas das conclusões mais pertinentes e identificam-se algumas perspetivas de desenvolvimento futuro.

Capítulo 2

Estado da arte

Devido ao impacto da energia no meio ambiente, a incorporação eficiente de energias renováveis (limpas), no sistema de energia elétrica, está a tornar-se cada vez mais importante.

Na Europa, atualmente vários países usam a energia eólica com um volume considerável, dentro de um intervalo de 7 a 20% do consumo geral de eletricidade, nomeadamente em países como a Alemanha, Espanha, Portugal e Dinamarca.

O Departamento de Energia dos EUA (DEEUA), descreve recentemente, um cenário em que a energia eólica poderá fornecer 20% da procura de eletricidade dos EUA em 2030 [3].

2.1 – Impacto na economia

A AEEE (Associação Europeia para a Energia Eólica) prevê neste continente um aumento até 64% na capacidade instalada para a produção de energia através do vento, sendo que em 2013 esta capacidade já atingiu os 117 GW. Esta instituição disponibiliza no seu sítio a tabela 2.1, que regista toda a capacidade instalada de energia do vento para cada uma das regiões. A liderar esta tabela encontra-se a Europa e em segundo lugar a Ásia [4].

A previsão é, frequentemente tida como uma ferramenta importante para enfrentar a variabilidade e a incerteza, inerentes ao recurso vento, servindo também para gerir de forma mais eficiente os sistemas que a recebem, principalmente quando se atinge um elevado nível de produção. Além disso, num ambiente de mercado, a quantidade de energia elétrica obtida a partir da energia eólica influencia a determinação dos preços diários, e as variações na energia eólica estimada, irão influenciar os preços da energia e das reservas operacionais.

Vários estudos investigaram o benefício, em temos económicos, que se obtém através do funcionamento das redes quando os seus operadores tomam as decisões apoiadas em modelos de previsão da energia do vento para vários horizontes temporais.

Tabela 2.1- Capacidade total instalada da energia do vento por região a nível mundial [4].

GLOBAL INSTALLED WIND POWER CAPACITY (MW) – REGIONAL DISTRIBUTION					
		End 2012	New 2013	Total (End of 2013)	
AFRICA & MIDDLE EAST	Ethiopia	81	90	171	
	Egypt	550	-	550	
	Morocco	291	-	291	
	Tunisia	104	-	104	
	Iran	91	-	91	
	Cape Verde	24	-	24	
	Other [1]	24	-	24	
	Total	**1,165**	**90**	**1,255**	
ASIA	PR China	75,324	16,088	91,412	
	India	18,421	1,729	20,150	
	Japan	2,614	50	2,661	
	Taiwan	571	43	614	
	South Korea	483	79	561	
	Thailand	112	111	223	
	Pakistan	56	50	106	
	Sri Lanka	63	-	63	
	Mongolia	-	50	50	
	Other [2]	71	16	87	
	Total	**97,715**	**18,216**	**115,927**	
EUROPE	Germany	31,270	3,238	34,250	
	Spain	22,784	175	22,959	
	UK	8,649	1,883	10,531	
	Italy	8,118	444	8,552	
	France	7,623	631	8,254	
	Denmark	4,162	657	4,772	
	Portugal	4,529	196	4,724	
	Sweden	3,746	724	4,470	
	Poland	2,496	894	3,390	
	Turkey	2,312	646	2,959	
	Netherlands	2,391	303	2,693	
	Romania	1,905	695	2,600	
	Ireland	1,749	288	2,037	
	Greece	1,749	116	1,865	
	Austria	1,378	308	1,684	
	Rest of Europe [3]	4,956	832	5,737	
	Total Europe of which EU-28 [4]	**109,817** 106,454	**12,031** 11,159	**121,474** 117,289	
LATIN AMERICA & CARIBBEAN	*Brazil	2,508	953	3,461	
	Chile	205	130	335	
	Argentina	142	76	218	
	Costa Rica	148	-	148	
	Nicaragua	146	-	146	
	Honduras	102	-	102	
	Dominican Republic	33	52	85	
	Uruguay	56	4	59	
	Carribean [5]	136	-	136	
	Others [6]	54	20	74	
	Total	**3,530**	**1,235**	**4,764**	
NORTH AMERICA	USA	60,007	1,084	61,091	
	Canada	6,204	1,599	7,803	
	Mexico	1,537	380	1,917	
	Total	**67,748**	**3,063**	**70,811**	
PACIFIC REGION	Australia	2,584	655	3,239	
	New Zealand	623	-	623	
	Pacific Islands	12	-	12	
	Total	**3,219**	**655**	**3,874**	
	World total	**283,194**	**35,289**	**318,105**	Source: GWEC

1 Israel, Jordan, Kenya, Libya, Nigeria, South Africa
2 Bangladesh,Philippines, Vietnam
3 Bulgaria, Cyprus, Czech Republic, Estonia, Finland, Faroe Islands, FYROM, Hungary, Iceland, Latvia, Liechtenstein, Lithuania, Luxembourg,Malta,Norway, Romania, Russia, Switzerland, Slovakia, Slovenia, Ukraine.
4 Austria, Belgium, Bulgaria, Cyprus, Croatia, Czech Republic, Denmark, Estonia, Finland, France, Germany, Greece, Hungary, Ireland, Italy, Latvia, Lithuania, Luxembourg, Malta, Netherlands, Poland, Portugal, Romania, Slovakia, Slovenia, Spain, Sweden, UK
5 Caribbean: Aruba, Bonaire, Curacao, Cuba, Dominica, Guadalupe, Jamaica, Martinique, Granada
6 Bolivia, Colombia, Ecuador, Peru, Venezuela
Note:
*** Projects fully commissioned, grid connections pending in some cases**
Project decommissioning of approximately 374 MW and rounding affect the final sums

Fonte: http://www.gwec.net/wp-content/uploads/

Estes estudos concluem que vários custos são reduzidos quando os decisores recorrem a tecnologias de previsão. Atualmente, alguns departamentos nos Estados Unidos tais como, o Departamento de Energia dos Estados Unidos, a Administração Nacional para a Atmosfera e Oceanos, a indústria privada e, a comunidade académica, decidiram unir-se para criar o projeto designado por Projeto de Melhoria da Previsão do Vento (PMPV) , com o duplo objetivo de melhorar a previsão do vento a curto prazo (de 0 a 6 horas) e, de determinar a redução de custos que os operadores das redes podem alcançar, quando baseiam as suas decisões apoiadas nos modelos de previsão. O projeto PMPV foca-se num potencial ganho económico, que possa vir a resultar, da previsão do vento a muito curto prazo, para um horizonte de 0 a 6 horas. A ferramenta utilizada foi o *software ge-MAPS* (MAPS) [4], que foi desenhada e baseada atendendo a vários compromissos, entre eles, as restrições impostas por questões de segurança e o modelo de programação da produção. O *software*, calcula o preço marginal da produção para um determinado local, baseando-se no mercado elétrico. O MAPS, simula a operação hora-a-hora do mercado de energia, das unidades de produção necessárias para satisfazerem a carga pedida ao sistema a cada hora, dando as informações necessárias para minimizar os custos do sistema de produção. Os custos estão relacionados com constrangimentos na produção (por exemplo, tempos máximos e mínimos de subida/descida, níveis de capacidade máximos e mínimos, constrangimentos na transmissão (incluindo os constrangimentos causados pelo fluxo da potência baseada em CC e de contingência), entre outros constrangimentos do sistema (tais como as unidades de reserva de produção). O custo do sistema de produção, é definido como sendo o somatório dos custos de combustível, custos variáveis de manutenção e produção, custos de arranque e custos de emissão, para todos os geradores escolhidos para fornecerem energia.

Os principais benefícios diretos obtidos pelo aumento da precisão nas previsões de muito curto prazo, devem-se ao facto de se reduzirem os custos de produção do sistema, causados pelo compromisso mais eficiente entre os geradores com tempo de arranque médio (por exemplo, com tempos de arranque inferior a 6 h), e a possibilidade da redução na quantidade de energia do vento à qual terá de se recorrer. Outros potenciais benefícios residem na redução de custos, através da diminuição do pagamento de multas pelos parques eólicos, que podem surgir quando acontecem desvios na previsão (aplicável em mercados que permitem a participação de unidades eólicas em tempo real ou com um dia de antecedência, com requisitos de desequilíbrio na energia fornecida). Entre as vantagens de se usarem melhores processos de previsão, encontram-se a diminuição do custo total da eletricidade apresentado ao consumidor, possível diminuição nas emissões de CO2, e das unidades de arranque, dependendo do compromisso entre algumas alterações específicas e as decisões que se tomam quanto à prontidão na resposta, caso surjam alterações nas previsões do vento.

Na simulação [5] consideram-se fixas as unidades de produção com um arranque superior a 6 horas (centrais nucleares, a gás, etc.). As únicas unidades às quais foi permitido mudarem de estado (parado/em funcionamento), foram as que têm um arranque inferior a 6 horas. Após várias simulações, com modelos de previsão cada vez mais apurados, os erros de previsão diminuíram e, consequentemente diminuiu a dependência deste tipo de unidades (turbinas de combustão, pequenas centrais a vapor, etc.).

Outro benefício que advém do facto de se utilizarem sistemas mais precisos na previsão da energia do vento está relacionado com os custos que se evitam, pela não construção de novas unidades de reserva, dado que deixam de ser necessárias. Em alguns estados nos EUA,

as unidades de reserva necessárias, dependem da maior ou menor integração de centrais eólicas na rede e do impacto causado pelos erros de previsão a que estas estão sujeitas.

Na figura 2.1, apresenta-se a amostragem para vários aerogeradores, que sofreram uma melhoria na previsão do recurso vento (uma percentagem da sua capacidade instalada), e a melhoria da rede se as saídas, desses geradores forem agregadas. Para qualquer instante de tempo representado na figura, verifica-se que em alguns geradores, a sua previsão peca por defeito, no entanto, para os restantes peca por excesso. Cada gerador pode estar sujeito a erros de previsão relativamente elevados, o erro de previsão resultante do agregado desses geradores pode ser muito baixo. O erro resultante do agregado deve-se ao facto, de se somarem previsões realizadas a cada um dos aerogeradores individualmente, em que algumas erram por defeito e outras por excesso.

Na análise de resultados que a ERCOT [5] obteve através da simulação da produção, para estimar os benefícios resultantes da introdução de maior precisão na previsão a muito curto prazo, podem retirar-se várias conclusões. A simulação foi levada a cabo durante seis meses e pelo período de outubro de 2011 a março de 2012. O sistema de energia da ERCOT foi calibrado para o referido período em termos dos seguintes parâmetros: capacidade do sistema, preços dos combustíveis, pico de carga, capacidade instalada, saídas das unidades de produção e capacidade das linhas de transmissão. Os dados que serviram de apoio à simulação foram baseados em diversas suposições que se apresentam nas tabelas 2.2 a 2.4.

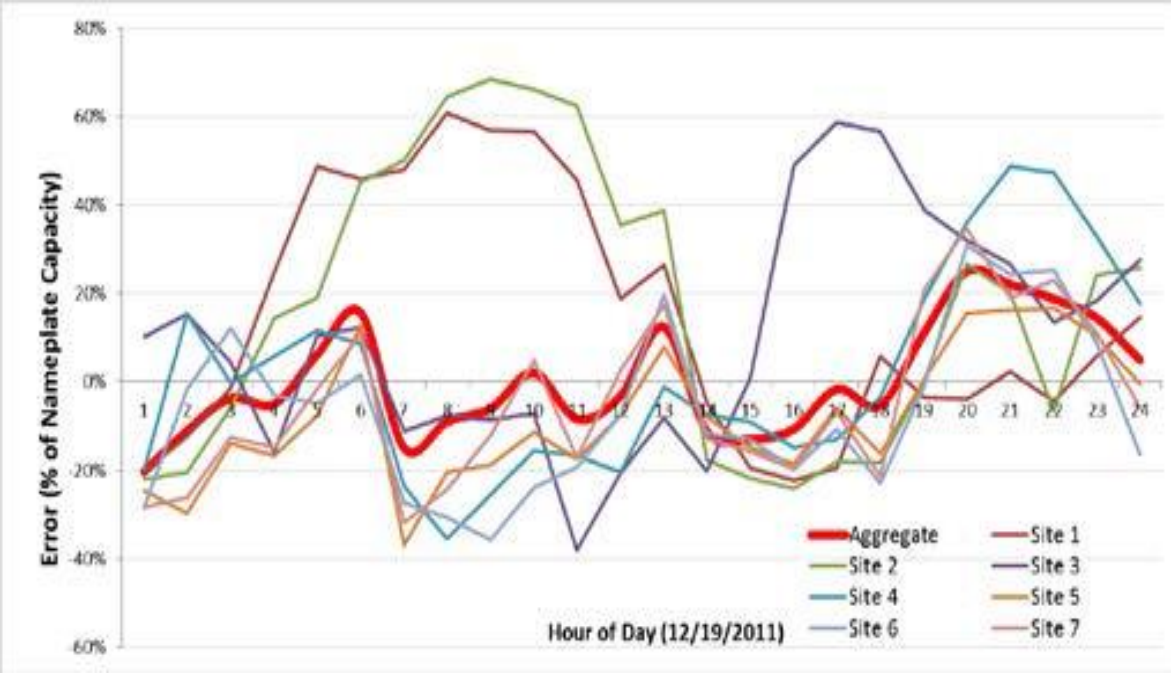


Figura 2.1 - Erro percentual para cada central eólica e erro agregado.

Tabela 2.2 - Valores de ponta da procura de carga no sistema.

Mês	Pico de carga (MW)
Outubro	49,328
Novembro	41,375
Dezembro	50,049
Janeiro	46,914
Fevereiro	42,093
Março	42,607

Tabela 2.3 - Preços do gás ($/MMBTU) usados no estudo (baseados em dados históricos).

Ano	Mês	Houston	South	North	West
2011	Outubro	3.45	3.45	3.42	3.40
2011	Novembro	3.21	3.18	3.14	3.19
2011	Dezembro	3.15	3.11	3.09	3.15
2012	Janeiro	2.65	2.62	2.61	2.62
2012	Fevereiro	2.44	2.46	2.45	2.45
2012	Março	2.10	2.07	2.09	2.08

Os resultados obtidos para os custos de produção, o preço de carga, a redução do vento, e os custos pagos pelos aerogeradores quando provocam desequilíbrio energético, estão registados na tabela 2.5. No período de seis meses, existiu uma redução nos custos do sistema de produção de aproximadamente de 1 milhão de dólares. O menor custo da produção ficou a dever-se a um planeamento mais eficiente entre as unidades de reserva com tempos de arranque inferiores a 6 horas. Verifica-se também que o preço total pago pelos consumidores, como resultado da simulação para o preço marginal num determinado local, decresce significativamente devido à gestão mais eficiente nos tempos de operação das unidades convencionais, resultante de previsões com uma eficiência melhorada.

Na tabela 2.5 verifica-se que houve um maior benefício no preço apresentado ao consumidor durante o período de janeiro a março comparando-o com o período de outubro a dezembro. Explica-se esta diferença, pelo facto dos erros de previsão serem substancialmente maiores (por excesso) no novo sistema de previsão, em comparação com o sistema usado durante o mês de dezembro, o que contribuiu para o aumento dos preços da energia (isto porque se esperava obter mais energia do vento e como esta previsão falhou, a mesma teve de ser fornecida por unidades convencionais). Daí que, o preço da energia em dezembro, tenha absorvido os benefícios que se obtiveram durante os meses de outubro e novembro. A pequena redução nos custos do sistema de produção para seis meses (aproximadamente 0,005% do custo total do sistema de produção), deveu-se ao facto da melhoria da precisão do sistema de previsão ter sido ligeira (em ~1%), e também pelo facto do custo estar diretamente relacionado com os preços do gás natural, isto porque, os geradores de combustão a gás, ditam o preço da energia na ERCOT durante grande parte do tempo. Para se poder perceber melhor a variação dos custos pode recorrer-se às tabelas 2.4 e 2.5.

Tabela 2.4 - Sumário dos benefícios para o caso de estudo.

	Benefícios ($)		
Parâmetro	Out.-Dez. **2011**	Jan.-Mar. **2012**	**Total**
Custo de produção ($)	833,355	137,706	971,061
Preço da carga ($)	3,898,864	28,316,608	32,215,472
Redução no vento a gerar (MWh)	10,407	24,400	34,807
Custo do desiquilibrio energético pago pelos geradores eólicos ($)	1,562,626	845,930	2,408,556

Tabela 2.5 - Resumo dos benefícios para variações no preço do gás.

Parâmetro	Benefícios ($)		
	Out.-Dez. **2011**	Jan.-Mar. **2012**	**Total**
Custo de produção ($)	1,173,509	1,119,428	2,292,937
Preço da carga ($)	1,535,411	21,823,012	23,358,423
Redução no vento a gerar (MWh)	17,197	21,103	38,301
Custo do desiquilíbrio energético pago pelos geradores eólicos ($)	693,983	295,842	989,825

Comparando as tabelas 2.4 e 2.5, conclui-se que duplicando o preço do gás origina a redução do mesmo valor no sistema de produção quando se aplica um novo e mais preciso modelo de previsão a muito curto prazo. Se bem que há benefícios próprios quando se usam previsões com melhor desempenho, a duplicação dos preços do gás natural faz com que existam ainda mais benefícios quando se substituem estas unidades por unidades eólicas, uma vez que os modelos de previsão a curto prazo mais precisos vão otimizar a utilização das centrais eólicas existentes. Embora os benefícios apresentados possam considerar-se modestos em relação à evolução da economia em geral, há outros benefícios que podem ser levados em consideração. Por exemplo, ao melhorarem-se as previsões num intervalo de 0 a 6 horas, o total de unidades de reserva para compensar os erros de previsão deverá diminuir. Numa primeira análise aos benefícios estimados para o caso de se conseguirem melhores modelos de previsão a curto prazo no sistema da ERCOT, verifica-se que existe uma redução de gastos sustentada nos custos do sistema de produção, no preço apresentado ao consumidor, uma redução na energia do vento programada e uma redução de pagamentos a efetuar nos casos em que há desequilíbrios entre a energia eólica prevista e a gerada. Os ganhos obtidos nesta simulação para o período de seis meses, prevê-se que se mantenham para os períodos restantes.

2.2 Previsão do vento

2.2.1 Introdução

Com o aumento da produção da energia eólica e da sua ligação ao sistema elétrico, a Previsão da Energia do Vento (PEV), está rapidamente a tornar-se um tema importante para o setor de energia elétrica, e por esse motivo, os operadores do sistema, as empresas geradoras e os reguladores, uniram-se para apoiar e desenvolver melhores modelos de previsão, mais confiáveis e precisos. Proprietários e operadores de centrais eólicas, obtendo melhores resultados na previsão da energia eólica, podem participar de forma mais competitiva nos mercados de eletricidade, contra fontes de energia mais estáveis [6]. Em geral, a PEV pode ser usada para diversos fins, tais como: planeamento do sistema produtivo e do sistema de transmissão, cálculo das reservas mínimas em funcionamento, evolução da economia, otimização do armazenamento de energia (por exemplo, armazenamento bombeado hidroelétrico), e comercialização da energia.

A obtenção de diversos benefícios que resultam da utilização de modelos de previsão mais precisos, determina que diversas instituições invistam na investigação e desenvolvimento

dos mesmos. Surge assim, a necessidade de se rever e analisar diversos modelos do estado da arte no MNPT e a sua aplicação às condições operacionais nos sistemas de energia. Atualmente o estado da arte inclui breves abordagens a temas tais como:

- Utilização de Modelos Numéricos de Previsão do Tempo (MNPT);
- Uma apresentação geral de alguns modelos em desenvolvimento;
- Alguns resultados e conclusões.

Encontra-se muita documentação pertinente relativamente às experiências realizadas na europa, onde este tipo de investigação já existe há bastante tempo. Vários projetos têm sido desenvolvidos, uns cofinanciados pela comissão europeia e outros financiados apenas a nível nacional. Como exemplos podem referir-se: MORE-CARE [7], ANEMOS [8], POW'WOW, WILMAR e o ANEMOS.plus

2.2.2 Modelos Numéricos de Previsão do Tempo

Os modelos Numéricos de Previsão do Tempo estão em vigor desde 1950, após o trabalho pioneiro de Charney, Fjortoft, e von Neumann [9], que usou uma versão de baixa resolução das equações dinâmicas altamente filtradas. Já em 1955, Charney [10] defendeu o uso de um conjunto mais preciso de equações, as chamadas ''Equações primitivas''. Este conjunto foi uma versão das equações que descrevem a dinâmica da atmosfera com uma grande aproximação: a equação do impulso vertical foi substituída pela condição hidrostática. Modelos de equações primitivas foram amplamente utilizados na década de 1960 pela comunidade científica, apesar de terem entrado totalmente no negócio da previsão atmosférica apenas no final dos anos 1970.

Durante os anos 1970, como as equações primitivas se tornaram a corrente principal, os modelos atmosféricos tornaram-se globais, e uma série de processos relevantes foram progressivamente adicionados a esses modelos. O desenvolvimento ao longo da história do modelo, um modelo numérico de previsão, é geralmente caracterizado como um conjunto de três componentes principais: o núcleo "dinâmico", que implica lidar com o conjunto básico de equações do fluxo viscoso adiabático; o pacote "físico", que inclui um número variável de equações que representam os processos tais como a radiação, transições de fase, convecção ou turbulência; e o código de assimilação de dados.

Os modelos de equações primitivas globais continuam a ser o núcleo do processo de previsão do tempo. Nas últimas três décadas, os modelos evoluíram significativamente em termos de resolução, parametrizações mais precisas, melhores sistemas de assimilação de dados, acompanhando o ritmo dos avanços científicos e o progresso nos sistemas de observação (ou seja, com as novas plataformas remotas de sensores), utilizando tecnologia de computador. Ao mesmo tempo, o intervalo de previsão foi estendido para um horizonte com mais do que uma semana, e novas técnicas estatísticas foram incorporadas no processo de previsão para lidar com os dados e as incertezas dos modelos.

Apesar do progresso contínuo na previsão do tempo, entende-se que há limites para a previsibilidade do fluxo atmosférico. Procurando resultados no MNPT e em modelos não lineares mais simples, Lorenz (1963, 1969) [11], [12], descobriu que, estabelecendo diferenças muito pequenas no estado inicial, estas tendem a crescer com o período, levando a previsões qualitativamente diferentes para diferentes horizontes temporais. Dado que não

existe um limite para a precisão do estado inicial, isto significa que, mesmo com um modelo perfeito, há um limite superior para a utilidade das previsões.

As maiores dificuldades verificam-se no cálculo dos valores iniciais e dos valores limitantes. Num modelo global, o estado inicial e tridimensional da atmosfera (3-D), geralmente referido como o "instante de análise," é calculado a partir das observações. No entanto, como as observações são raras e têm erros, os códigos de assimilação dos dados do MNPT, evolui para os processadores de dados, que tentam obter a "melhor" estimativa possível do estado inicial de um conjunto diversificado de observações possivelmente conflituantes, obtidos de radiossondas, estações de superfície, aviões, satélites, etc.

Os modelos necessitam de condições que definam a evolução das variáveis nos limites do seu domínio. As condições iniciais definem o estado da atmosfera no seu estado presente, ou seja, estado inicial. As condições limite definem o estado da atmosfera nas fronteiras do domínio. No caso de modelos globais, os limites do domínio situam-se entre a superfície terrestre e os pontos determinados pelo alcance da previsão. No caso de modelos projetados para áreas com as suas fronteiras delimitadas, as condições que envolvem o tempo são também necessárias nas fronteiras laterais do domínio. O domínio é caraterizado pelo número de dimensões, grau e tipo de estrutura, forma, coordenadas verticais e a sua resolução.

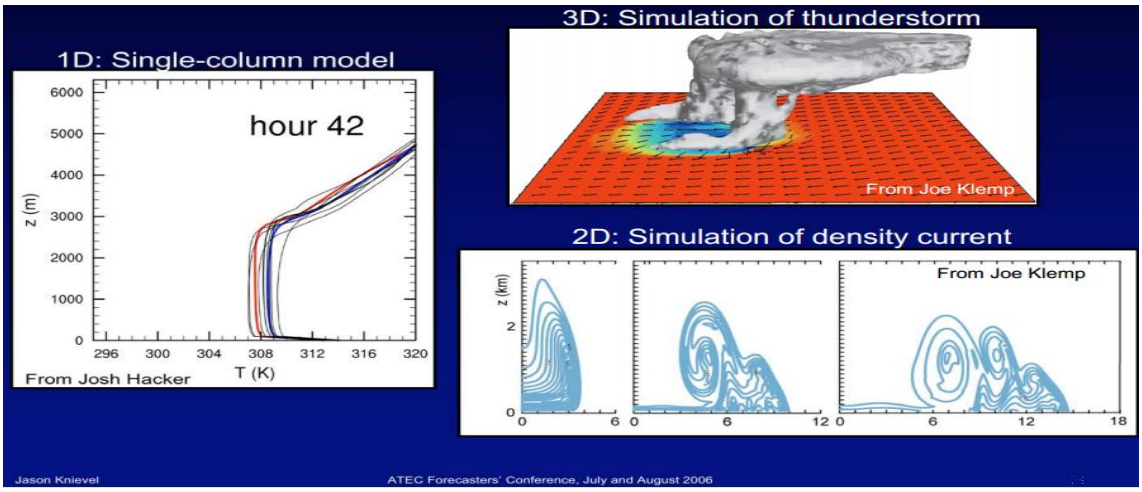


Figura 2.2 - Número de dimensões.

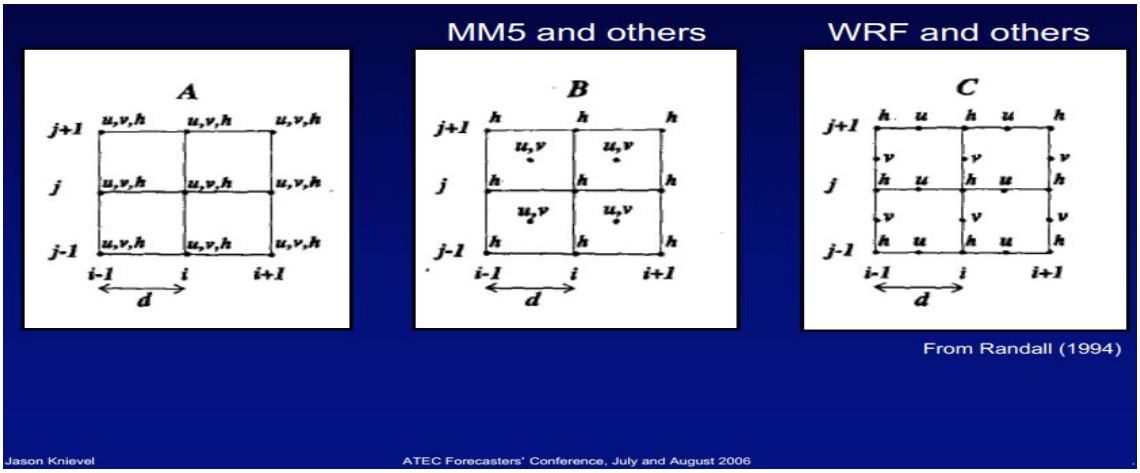


Figura 2.3 - Grau e tipo de estruturas (exemplos).

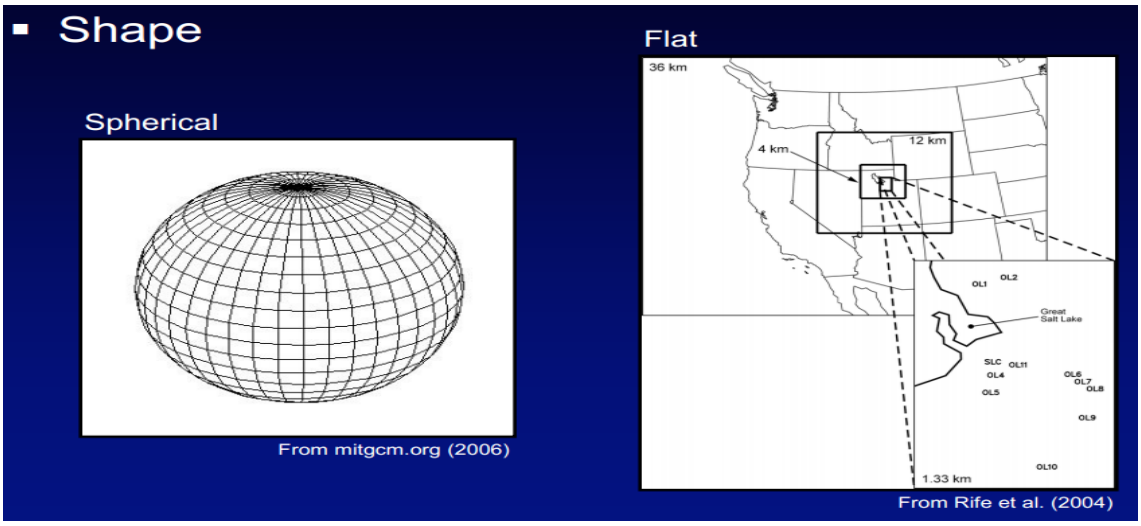


Figura 2.4 - Formas do domínio.

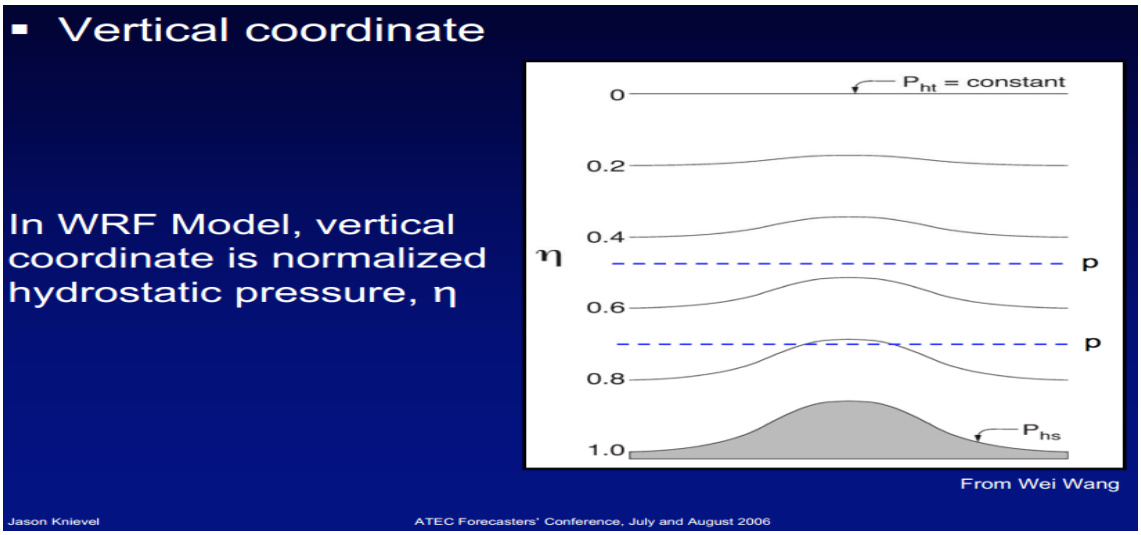


Figura 2.5 - Coordenadas verticais (exemplos).

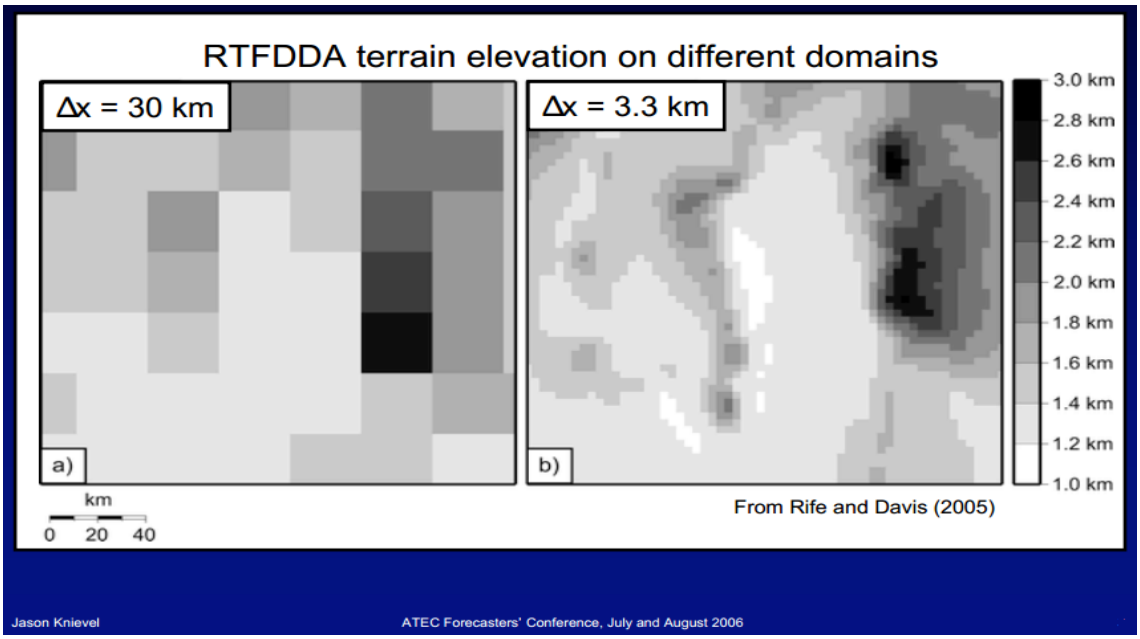


Figura 2.6 – Resolução.

2.2.2.1. Assimilação dos dados para inicialização e validação do modelo

A rede de radiossondas foi durante décadas a principal tecnologia para monitorizar a atmosfera, sendo capaz de fornecer observações em 3-D. Juntamente com uma densa rede de estações terrestres constituíram uma rede sinóptica, tornando as observações síncronas em todo o planeta. No entanto, esta rede é muito heterogénea no espaço deixando áreas elevadas fora de observação. Por este motivo, começaram a usar-se dados não sinópticos no processo de assimilação de dados, que passaram a ser oriundos de observações elaboradas via satélite, sendo esta via, a maior fornecedora de dados. Existem também várias fontes para modelos de nível mais baixo, por exemplo imagens de radares, que podem ser relevantes para os MNPTs de âmbito regional.

2.2.2.2 Definições e horizontes temporais

A energia eólica prevista em um determinado instante, t, para um período posterior, t + k, é a potência média, $p_{t+k|t}$, que o parque eólico deverá produzir no período considerado de tempo (por exemplo, 1 hora), caso estivesse a funcionar sob o efeito de um vento equivalente e constante. As previsões são feitas para um horizonte de tempo, t, sendo este o comprimento total do período de previsão (por exemplo, 72 horas à frente) no futuro. A duração do intervalo de tempo (número de minutos), está relacionada com o intervalo do horizonte e com os instantes em que as medições são observadas. Normalmente, para horizontes na ordem de 24 a 72 horas, o intervalo de tempo tem a duração de uma hora. Neste caso, em etapas internas ao período (por exemplo, etapas consideradas dentro de uma hora) as variações de energia e seus impactos não são consideradas. Isto acontece porque nos MNPTs se utiliza muitas vezes como entrada a velocidade do vento, sendo que os dados aparecem como valores constantes, que depois são usados para o cálculo do valor no instante seguinte. Por exemplo, uma previsão de 1,5 megawatts (MW) para um tempo posterior, t + 8, corresponde à geração média ao longo de 1 hora. Na prática, o valor medido da potência, p_{t+k}, é obtido a partir de uma média de medições efetuadas a alta resolução (por exemplo, 15 min.), que podem ser valores instantâneos da potência ou valores integrados de energia, dependendo do sistema de aquisição de dados. Um sistema de previsão é caracterizado pelo seu horizonte temporal, que é o período de tempo futuro para o qual a geração eólica será prevista (por exemplo, no dia seguinte). Os problemas de previsão do sistema de energia, como a previsão de carga, são caracterizados de acordo com o seu horizonte temporal - muito curto prazo, curto prazo, médio prazo, ou longo prazo. Geralmente, os modelos para as PEVs podem ser divididos em três categorias:

- Muito curto prazo. O intervalo de tempo ou horizonte temporal é de algumas horas, mas não há unanimidade quanto ao número de horas. Um valor limite de 4 horas para este horizonte de tempo é proposto em [12], e em [54], o valor é de 9 horas;
- Curto prazo. O horizonte de tempo varia entre o limite estabelecido no ponto anterior até 48 ou 72 horas. Este horizonte de tempo é principalmente interessante para negociar com os mercados relativamente ao dia seguinte. Estas previsões podem também ser utilizadas para a programação de atos de manutenção, particularmente quando o horizonte de tempo é de 72 horas;

- Médio prazo. O horizonte de tempo varia entre o limite de curto prazo até um limite de 7 dias. Como o horizonte de tempo aumenta, o mesmo acontece com os erros de previsão.

Presentemente, dado o seu valor económico, as previsões que despertam maior interesse para a comunidade de investigação e desenvolvimento, são as de muito curto prazo e as de curto prazo.

2.2.3 Previsão do vento a muito curto prazo

No presente documento considera-se a previsão a muito curto prazo para um horizonte de tempo com a duração de 4 horas.

2.2.3.1 Introdução

A criação de sistemas de previsão a muito curto prazo, assenta em modelos estatísticos, baseados na abordagem efetuada às séries temporais, tais como os filtros de Kalman[92], Auto Regressivo com Média Móvel (ARMA), Autorregressivo com entrada exógena (ARX) e os métodos de previsão de Box-Jenkins. Estes tipos de modelos só tomam como entrada os valores passados da variável usada na previsão (por exemplo: velocidade do vento, vento gerado, etc.). Ao mesmo tempo, estes podem também usar outras variáveis explicativas (por exemplo: direção do vento, temperatura, etc), o que pode melhorar o erro de previsão. Como esses métodos são meramente baseados em dados produzidos no passado, eles só conseguem superar o modelo de persistência (modelo de referência) para horizontes de previsão entre 3 e 6 horas. O máximo que um modelo consegue melhorar em relação à persistência para este horizonte temporal está entre os 15% a 20% [13]. Para horizontes de tempo maiores do que 3-6 horas, devem ser utilizados como entradas os MNPTs.

Do ponto de vista estatístico, estes modelos podem ser chamados modelos de uma só variável ou multivariados. O modelo de uma só variável considera apenas os *p* valores da energia eólica gerada no passado.

O modelo de uma variável pode ser expresso como, $\hat{p}_{t+k} = f(p_t, p_{t-1}, \dots, p_{t-n}) + e_t$, onde e_t , é um ruído branco e f, é uma função genérica que pode ser linear ou não linear. Os modelos multivariados não só usam os valores passados da variável de interesse, mas também os valores passados ou presentes de outras variáveis. Estes valores do passado (por exemplo: obtidos no local de onde são disponibilizados os dados meteorológicos) são medidos pelo sistema SCADA do parque eólico. O modelo multivariado pode ser expresso como sendo, $\hat{p}_{t+k} = f(p_t, p_{t-1}, \dots, p_{t-n}, x_t, x_{t-1}, \dots x_{t-n}) + e_t$, que é uma função dos valores passados de *p* e de um conjunto de valores passados das variáveis explicativas *x*. A estrutura do modelo de previsão a muito curto prazo é mostrada na figura 2.7.

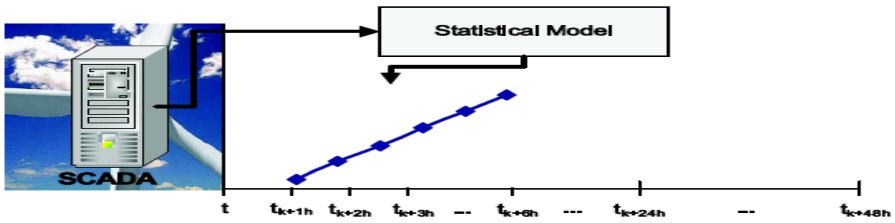


Figura 2.7 - Estrutura de previsão de muito curto prazo (adaptado de [13]).

2.2.3.2 Previsão da velocidade do vento usando métodos estatísticos

Esta abordagem está relacionada apenas com a previsão da velocidade do vento. No entanto, a previsão da velocidade do vento é muitas vezes convertida em potência através da curva de potência de um fabricante de aerogeradores.

O primeiro modelo de previsão do vento, usado especificamente na previsão de geração de energia eólica, usando filtros Kalman, foi apresentado em [14]. Um filtro de Kalman [15], que usa os últimos seis valores medidos como entradas, foi proposto para prever a velocidade do vento para os minutos seguintes. Os resultados são bons quando comparados com a persistência, se os horizontes temporais são compostos por valores médios, com intervalos inferiores a 10 minutos. A melhoria foi menor usando valores médios para períodos superiores e era inexistente para médias de 1 hora. Em [16], foi usado um filtro de Kalman para controlar uma turbina eólica de velocidade variável.

Para os modelos com base na metodologia de Box-Jenkins, o Autorregressivo Integrado de Média Móvel (ARIMA) abordado em [17], foi o primeiro a ser utlizado na previsão da velocidade do vento. Por exemplo, Contaxis et al. [18] empregaram um modelo auto regressivo (AR) (mais precisamente um AR (3)) para a previsão da velocidade do vento, para horizontes temporais que variam entre 30 min. e as 5 horas. Os resultados que obtiveram foram usados para controlar um sistema híbrido a *diesel*/vento e proceder ao agendamento do seu funcionamento a curto prazo; Kamal et al. [19] utilizaram um modelo ARIMA para prever a velocidade do vento e estimar intervalos de confiança; Schlink et al. [20], empregaram esses modelos para a previsão da velocidade do vento para os próximos 10 minutos num aeroporto; Poggi et al. [21], utilizaram um modelo auto regressivo para cada mês, a fim de prever a velocidade do vento para as 3 horas seguintes; Torres et al. [22], usou cinco modelos Autorregressivos de Média Móvel (ARMA) para prever a velocidade média horária para um horizonte temporal de 10 horas em cinco locais diferentes, com diferentes características topográficas.

Com estes modelos, ao longo de nove anos, foi possível alcançar uma redução no erro de 20%, em comparação com a persistência; Tantareanu [23], descobriu que os modelos ARMA podem executar previsões até 30% melhores do que a persistência de 3 a 10 passos à frente, em médias para quatro valores e uma frequência de 2,5 Hz para os dados amostrados.

Kavasseri et al. [24] apresentou o modelo ARIMA-fracionário (f-ARIMA) para prever a velocidade do vento no dia seguinte. A velocidade do vento prevista é convertida em energia eólica, utilizando a curva de potência do fabricante. Na sequência dos resultados apresentados em [25], os autores sugerem um modelo ARIMA modificado (f-ARIMA) para lidar com correlações de longo alcance (LRCs). Um processo de LRC é caracterizado por uma deterioração lenta da função de auto correlação.

El-Fouly et al. [26] apresenta uma nova técnica para a previsão da velocidade do vento para a próxima hora com base no modelo de previsão de Grey [27]. A velocidade do vento é então convertida em energia eólica através da curva de potência do fabricante. A melhoria registada, em comparação com a persistência, é na gama dos 12% para a previsão de produção de energia eólica.

Métodos alternativos de previsão são baseados em técnicas de inteligência artificial, nomeadamente redes neurais (RNs), máquinas com suporte de vetor (SVMs), ou sistemas de

inferência fuzzy (FISs). Alexiadis et al. [55] propôs um modelo baseado numa RN para a previsão da velocidade do vento para a ilha de Syros (na Grécia), utilizando dados históricos do vento recolhidos na ilha e de outras ilhas vizinhas, como variáveis de entrada. Os resultados mostram uma melhoria de 32% em relação à persistência no erro de previsão para um horizonte de 1 hora; O mesmo método foi empregado em [29] para um local diferente na Grécia, e a melhoria em relação a persistência foi de 27% para um horizonte de tempo de 2 horas.

Sfetsos avalia diferentes modelos [30]: um modelo de persistência, modelos ARIMA, RN, e sistemas neuronais-fuzzy. O modelo com os melhores resultados foi o RN, levando a uma melhoria média de 20-40%, quando comparado com a persistência. Em trabalhos mais recentes, Sfetsos [31] usa dois modelos baseados na RN para prever a velocidade do vento para um horizonte de tempo de uma hora. O primeiro modelo utiliza os últimos valores conhecidos da velocidade do vento por hora como entradas, e os resultados são apenas 3% melhores do que aqueles registados para os modelos de persistência. O segundo modelo usa uma série temporal da velocidade do vento e dados com 10 minutos de intervalo como entradas, além de usar a saída RN iterativa para prever num horizonte de 60 minutos. A melhoria do segundo modelo em relação à persistência é mais de 10%.

Cadenas e Rivera [32] testaram quatro configurações RN para a previsão da velocidade do vento de hora em hora. O modelo com melhor desempenho foi um simples RN com duas camadas e três neurônios.

Maqsood et al. [33], apresentam a ideia de usar mais de um modelo de previsão de três variáveis meteorológicas (incluindo a velocidade do vento) para um intervalo futuro de 24 horas. Em [34] são considerados quatro tipos diferentes de RNs: perceptron multicamada (MLP), a rede neural recorrente de Elman, a função de base radial (RBF), e as redes neurais Hopfield. Uma RN de cada tipo foi treinada para cada estação do ano. O melhor resultado foi obtido com a uma rede neural RBF, mas aumenta a precisão quando todos os modelos são combinados (ou seja, um conjunto de modelos).

Abdel-Aal et al. [35], desenvolveu uma aplicação de redes abdutivas com base no método do grupo de manipulação de dados (GMDH) [36], para prever a velocidade média do vento de hora em hora. Os autores demonstraram que a principal vantagem das redes abdutivas sobre as RN é a rápida convergência durante a fase de treino, seleção automática de ambas as variáveis de entrada e de estrutura do modelo. O modelo conseguiu uma melhoria de 8,2% em relação à persistência para a previsão com o período de uma hora. O modelo também foi utilizado para a previsão da velocidade do vento para 6 e 24 horas, tendo alcançado uma melhoria em relação a persistência de 14,6% e 13,7%, respetivamente.

Potter [37], apresenta um sistema Adaptativo Neuronal de Inferência Difusa (ANFIS) [38], para previsão da velocidade do vento para um horizonte de tempo de 2.5-min. A entrada de dados é a velocidade do vento medida, a qual é então ajustada por meio de ranhuras que diminuem consideravelmente o erro de previsão em relação a persistência.

Ramírez-Rosado e Fernández-Jiménez [39] e [40], apresentam um modelo de três fases: (1) é calculada a velocidade média do vento para os últimos 24 valores aplicando a transformada de Fourier; (2) 23 sistemas de inferência fuzzy (Takagi-Sugeno) preveem os coeficientes da transformada de Fourier para a hora seguinte; e (3) a velocidade média do vento é prevista para a hora seguinte com base nos coeficientes previstos na aplicação da transformada de Fourier.

2.3 Constituição de turbinas eólicas

O funcionamento de uma turbina eólica envolve vários campos do conhecimento, tais como: meteorologia, aerodinâmica, eletricidade, controlo, bem como engenharia civil, mecânica e estrutural.

O seu princípio de funcionamento baseia-se na conversão da energia cinética, (que é resultante do movimento de rotação causado pela incidência do vento nas pás do rotor da turbina) em energia elétrica. As pás das máquinas modernas são dispositivos aerodinâmicos com perfis especialmente desenvolvidos, equivalentes às asas dos aviões, e que funcionam pelo princípio físico da sustentação.

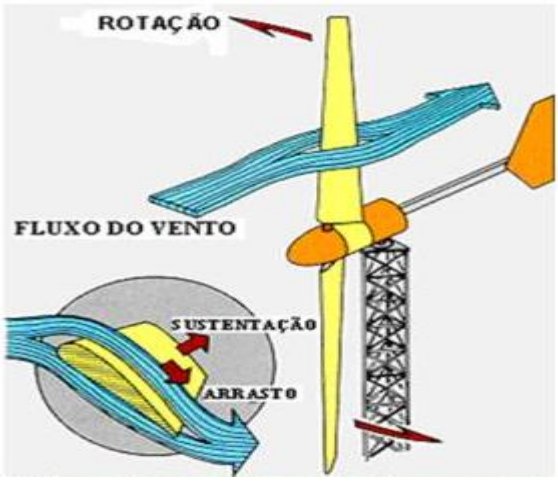


Figura 2.8 - Incidência do vento nas pás do rotor.

Existem diversos tipos de turbinas eólicas. Atualmente as máquinas disponíveis de grande porte têm na sua maioria três pás e são de eixo horizontal. No entanto, existem também máquinas com duas, três, quatro e mais pás de eixo horizontal, além das máquinas Darrieus e Savonius de eixo vertical, bem como diversos outros dispositivos. Essas inúmeras variantes são normalmente utilizadas apenas para máquinas de pequeno porte.

Os rotores de eixo horizontal são os mais usados em experiências internacionais. São predominantemente movidos por forças de sustentação (atuam perpendicularmente ao escoamento), e devem possuir mecanismos capazes de permitir que o disco varrido pelas pás esteja sempre em posição perpendicular ao vento.

Já as turbinas de eixo vertical captam a energia dos ventos sem precisar de alterar a posição do rotor com a mudança na direção dos ventos. Podem ser movidas por forças de sustentação e por forças de arrasto.

A turbina eólica para geração de energia elétrica é composta pelos seguintes subconjuntos:

- Rotor - é o componente que efetua a transformação da energia cinética dos ventos em energia mecânica de rotação. No rotor são fixadas as pás da turbina. Todo o conjunto é ligado a um eixo que transmite a rotação das pás para o gerador, muitas vezes, através de uma caixa multiplicadora;
- Nacele - é o compartimento instalado no alto da torre e que abriga todo o mecanismo do gerador, o qual pode incluir: caixa multiplicadora, freios, embraiagem, controlador eletrónico e o sistema hidráulico;

- Torre - é o elemento que sustenta o rotor e a nacele, na altura adequada ao funcionamento da turbina eólica (este item estrutural de grande porte contribui muito para o custo inicial do sistema);
- Caixa de multiplicação (transmissão) – é o mecanismo que transmite a energia mecânica do eixo do rotor ao eixo do gerador. Nem todos os aerogeradores incorporam este elemento, que tem como objetivo adaptar a geração de energia à velocidade de rotação mecânica, suavizando a onda de saída;
- Gerador – é o sistema que tem como função converter a energia mecânica do eixo em energia elétrica;
- Mecanismos de controlo – as turbinas eólicas são projetadas para fornecerem a potência nominal de acordo com a velocidade do vento prevalecente, ou seja, a velocidade média nominal que ocorre com mais frequência durante um determinado período;
- Anemómetro - mede a intensidade e a velocidade do vento, normalmente, de 10 em 10 minutos;
- Pás do rotor - captam o vento e convertem sua potência ao centro do rotor;
- Catavento (sensor de direção) – permite conhecer a direção do vento. Este elemento que fornece informação ao controlador da máquina para que este posicione o rotor perpendicular à direção do vento.



Figura 2.9 - Constituição de uma turbina eólica.

Quanto ao funcionamento dos aerogeradores em função dos ventos, verifica-se que para ventos com baixa velocidade, estes não têm energia suficiente para acionar o gerador, (que só funciona a partir de uma determinada velocidade), a qual normalmente varia entre 2,5m/s e 4 m/s. Com o aumento da velocidade do vento, a potência no eixo da máquina aumenta gradualmente até atingir a potência nominal do aerogerador, sendo que esta velocidade, varia geralmente entre 9,5m/s e 15,0m/s. Para velocidades superiores à nominal, em muitas máquinas, a potência permanece constante até uma velocidade superior de corte, na qual a turbina deve sair automaticamente de operação para evitar que sofra danos estruturais. É importante saber que a energia disponível varia com o cubo da velocidade do vento, de forma que o dobro de velocidade representa um aumento de oito vezes em energia.

Para a utilização dos aerogeradores, é necessário perceber-se quanta energia elétrica cada um deles produz em determinado local. Estima-se com fiabilidade a energia produzida por uma máquina eólica conhecendo, além das características da máquina que será utilizada (curva potência em função da velocidade do vento), a distribuição estatística da velocidade do vento no local onde ela será instalada. Tais dados, relacionados com o vento, normalmente só são obtidos por meio de levantamentos específicos do potencial eólico efetuado no próprio local de interesse. Quanto à velocidade média mínima que permite a utilização de máquinas eólicas, geralmente para aplicações em larga escala com máquinas de grande porte, é necessária uma velocidade média de, no mínimo, 6,5 m/s a 7,5 m/s. Já para a utilização em pequenos sistemas isolados, incluindo os sistemas mecânicos para bombagem de água, assume-se uma média de 3,5m/s a 4,5m/s. Estes valores consideram tanto a viabilidade técnica quanto a económica. A ligação das turbinas à rede é feita geralmente por meio dos seguintes dispositivos:

- Conversor – equipamento eletrónico (composto por retificador e inversor) que converte a energia gerada pela turbina, geralmente em CA, de tensão e frequência variáveis, para níveis adequados à injeção na rede;
- Transformador – equipamento elétrico que aumenta o nível de tensão gerado pelo conversor, para a tensão da rede, da ordem de dezenas ou centenas de kV (linha de transmissão);
- Os sistemas conectados à rede, geralmente não são dotados de armazenamento de energia (baterias), de forma que produzem energia somente quando existe disponibilidade de vento.



Figura 2.10 - Ligação da turbina à rede elétrica [61].

2.4 Previsão de muito curto prazo segundo algumas teorias

Entre as três classes principais de técnicas de previsão da velocidade do vento a muito curto prazo, anteriormente identificadas (métodos estatísticos, métodos de RNs e os métodos MNPT), as duas primeiras mostraram ser as mais adequadas ao problema.

2.4.1 As três classes principais

Os métodos estatísticos e RNs mostram ter uma performance melhor que o método da persistência. No entanto, começam a perder precisão nas previsões para horizontes para além de algumas horas. O método da persistência mede o valor atual da velocidade do vento, e usa-o como sendo a velocidade do vento, no instante para o qual se pretende fazer a previsão. Os métodos MNPT dão resultados piores que a persistência para horizontes temporais inferiores a poucas horas.

Os modelos baseados em métodos estatísticos e métodos neuronais, aplicados a previsões de muito curto prazo, que vão desde alguns minutos a poucas horas, mostram apresentar melhores resultados. Neles é usada uma série de entradas que na sua maioria são obtidas através de medições realizadas no presente e no passado, obtidas em vários parques eólicos ou de dados fornecidos por observatórios atmosféricos, principalmente dos que estão a montante desses parques. Uma das entradas com maior relevância é dada pela medida da velocidade do vento no instante atual para o local de interesse. Esta é uma das razões pela qual a previsão baseada nestes modelos é relativamente precisa para horizontes de tempo de muito curto prazo. No entanto são métodos relativamente simples, que produzem resultados pouco fiáveis para previsões com um horizonte de tempo superior a 5 horas.

2.4.2 Comparação entre as técnicas estatísticas e as neuronais

A principal diferença entre os métodos estatísticos e os neuronais reside na forma como são desenvolvidos. Os métodos estatísticos são auto recursivos, isto é, usam o valor resultante da diferença entre a velocidade atual do vento e a velocidade prevista para o instante atual, para ajustar os parâmetros do modelo.

Os modelos neuronais usam dados recolhidos no passado, retirados em intervalos de tempo com a mesma duração, de modo a descobrirem a relação entre as velocidades (do vento) de entrada e de saída. Como é difícil obter medições que sejam fortemente correlacionadas com previsões a longo prazo, a precisão destes modelos vai-se degradando à medida que a janela temporal das previsões aumenta. Assim, estas técnicas podem ser muito promissoras para a previsão do vento a muito curto prazo, mas devem ser combinadas com outros métodos (maioritariamente MNPT), de modo a fornecerem previsões aceitáveis para janelas temporais maiores. Nas tabelas 2.7 e 2.8 podem observar-se as principais vantagens e desvantagens de ambos os modelos.

Tabela 2.6 - Vantagens e desvantagens dos modelos de redes neuronais.

Vantagens	Mais preciso para previsões a curto prazo
	Lê valores passados para prever valores futuros
	Não requer muitos conhecimentos sobre as condições atmosféricas, exceto para a variável de entrada.
	Pode fornecer os valores médios e de pico para a velocidade do vento para pequenos períodos.
Desvantagens	Não tem precisão para períodos de tempo longos.
	Pode precisar de dados observados ao longo de um ano para encontrar padrões sazonais.
	Têm de ser usadas redes especiais para adaptação *online* .
	Necessitam de redes individuais para períodos diferentes do horizonte de previsão, a não ser que sejam usadas redes especiais.

Tabela 2.7 - Vantagens e desvantagens dos modelos estatísticos.

Vantagens	Mais preciso para previsões a curto prazo.
	Adaptam-se a uma situação real utilizando algoritmos matemáticos auto recursivos.
	Pode fornecer os valores médios e de pico para a velocidade do vento para pequenos períodos.
Desvantagens	Não tem precisão para períodos de tempo longos.
	Pode precisar de processos de ajustamento e testes para produzir bons resultados.
	Necessita da assistência de um perito para cada situação específica.
	Precisa de um sistema de cópia de segurança ou de um período de treino caso o computador tenha uma avaria.

2.5 O modelo ANFIS

Vários estudos recentes oferecem novas metodologias para a previsão da velocidade do vento a muito curto prazo utilizando várias ferramentas matemáticas, tais como: fuzzy logic [41], *wavelets* [42], e redes neuronais fuzzy [43]. Estes estudos têm conseguido algum sucesso mas continuam na fase de desenvolvimento. Existe uma outra técnica que apresenta resultados satisfatórios nos problemas de previsão [44]. Este método usa sistemas neuronais *fuzzy* de dedução e adaptação [*Adaptative Neuronal Fuzzy Inference Systems* (ANFIS)] [45]. Este modelo tem a capacidade de ser flexível, e tem a rapidez necessária para lidar com dados flutuantes, tornando-o adequado para efetuar previsões a muito curto prazo.

ANFIS é uma mistura de dois modelos 'inteligentes'. Combina o poder computacional de baixo nível de uma rede neuronal com a razoável capacidade de um Sistema de Dedução *Fuzzy* [46]. Tenta combinar os melhores aspetos das duas tecnologias.

O sistema ANFIS pode ser desenvolvido usando a ferramenta "*Matlab Fuzzy Toolbox*". A melhor forma de se perceber o funcionamento do modelo ANFIS é fazendo a sua divisão em duas partes. Na primeira, o sistema leva a cabo uma operação de treino da rede neuronal baseada num elevado número de dados. Terminada a fase de treino desta rede, o sistema funciona exatamente da mesma forma que um sistema *fuzzy*.

A Rede Artificial Neuronal (RAN) é um sistema baseado nas funções biológicas do cérebro. Utiliza números e equações para representar os neurónios e as sinapses, como se pode ver na figura 2.11. Logo que os dados dão entrada no sistema, algumas ligações são fortalecidas e outras são enfraquecidas, de modo a que, a rede neuronal encontra padrões que se relacionam com os dados. No entanto, se a quantidade de dados inseridos na rede para a fase de treino não for suficiente para modelar adequadamente as caraterísticas dos dados, a rede neuronal irá falhar. Se por outro lado, a rede neuronal for sujeita a uma fase de treino de forma insistente e sujeita a um pequeno número de dados, existe a possibilidade de a rede memorizar esses dados em vez de encontrar padrões entre eles.

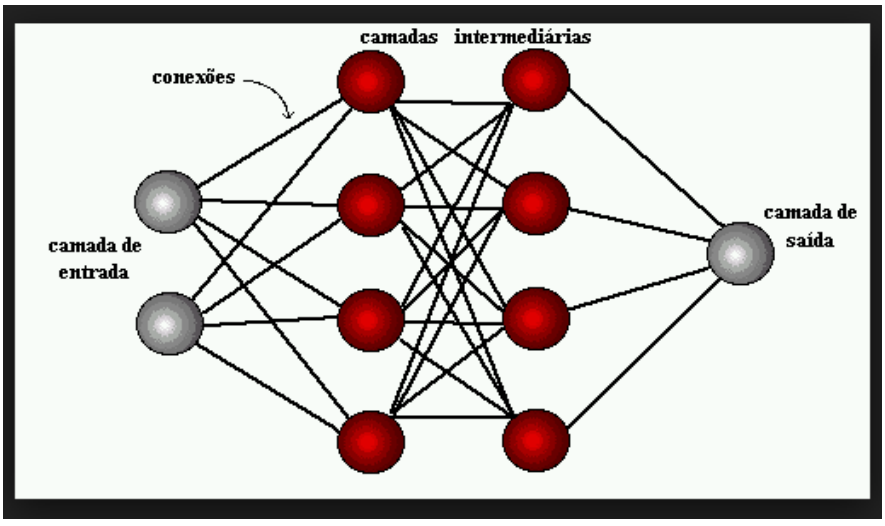


Figura 2.11 - Rede neuronal simples. É apenas um exemplo entre as várias permutações que podem existir.

Os sistemas *fuzzy* são constituídos por conjuntos de heurísticas (regras se-então) que vão sendo aplicadas aos dados que vão surgindo na entrada. Tal como a maioria dos "sistemas inteligentes", estes são desenvolvidos por (ou com) alguém que tenha conhecimentos adquiridos neste campo específico. Este tipo de sistemas usa uma resposta do tipo 'sim/não', mas o sistema fuzzy disponibiliza na sua saída respostas não binárias. Esta saída é obtida através de funções pertinentes. A figura 2.12, representa graficamente um conjunto fuzzy para identificação da velocidade do vento.



Figura 2.12 - Representação de um conjunto fuzzy para determinar a qualidade da velocidade do vento (fraca, média ou). Não há qualquer ponto de corte.

As vantagens de um sistema ANFIS são:

- O sistema usa as habilidades da rede neuronal para classificar os dados e encontrar padrões.
- Depois desenvolve um sofisticado sistema fuzzy, que é mais fácil de compreender pelo utilizador e que tem menos probabilidade de memorização de erros que uma rede neuronal.
- O ANFIS tem as vantagens de um sistema sofisticado fuzzy enquanto remove (ou reduz) a necessidade de um perito como utilizador.

No entanto, a desvantagem deste sistema reside no facto de o projeto necessitar de um elevado número de dados na fase de treino para desenvolver um sistema com boa precisão.

Tal como se faz nas restantes redes neuronais, o ANFIS, utiliza um conjunto de dados para a fase de treino. Este conjunto é constituído por múltiplos subconjuntos de entrada, e uma saída objetivo (desejada), para cada um dos subconjuntos. O ANFIS desenvolve-se a partir de um algoritmo híbrido, combinando o estimador dos mínimos quadráticos e o método do gradiente descendente [45]. Em primeiro lugar, as funções iniciais de ativação, vão sendo atribuídas aleatoriamente a cada neurónio de modo a que a sua extensão se propague pelo domínio das entradas, e que o tamanho dos conjuntos do sistema *fuzzy* permita uma justaposição adequada. De seguida inicia-se a fase de treino, em que cada um dos períodos desta fase é constituído por um conjunto de passos para a frente e para trás, atualizando as ligações sinápticas de acordo com os dados de entrada e dos resultados desejados. Cada passo para a frente ajusta o neurónio que se encontra à sua frente camada a camada, de modo a minimizar o erro. Quando se atinge a saída da última camada, o passo para trás começa, e as camadas antecedentes vão sendo atualizadas permanecendo contantes, as que já tinham sido

atualizadas no passo anterior. No entanto, a diferença entre o ANFIS e a RN quanto se pretende fazer um sistema de previsão, está na escolha dos parâmetros do modelo.

Pode usar-se o modelo ANFIS no *MATLAB*. Para isso o utilizador tem de definir o número de entradas; o número de funções, tipo e forma; e o número de períodos da fase de treino. Alterando cada um destes parâmetros, mesmo para valores muito pequenos, pode ser a diferença entre um sistema que parece não funcionar e um sistema que fornece os resultados desejados [44].

Em determinado ponto do desenvolvimento deste sistema foram apresentados alguns resultados para alguns dados e determinadas condições, sendo apresentados na tabela 2.8.

Tabela 2.8 - Comparação entre o ANFIS e a Persistência para pequenos ensaios da performance do ANFIS.

Altura da torre	Parâmetro	Erro percentual médio	
		Persistência	ANFIS
50 metros	Médio	38.4%	3.4%
	Máximo	47.2%	2.8%
100 metros	Médio	50.4%	3.5%
	Máximo	62.8%	3.3%

A investigação sobre este sistema ainda não é conclusiva mas os resultados parecem promissores [47].

2.6 Avaliação das previsões

No mercado de energia elétrica, quando a tomada de decisões é projetada para o dia seguinte, estas decisões acontecem um dia antes em relação ao vento que será gerado na central eólica. Daqui se depreende, que a integração destas centrais na rede elétrica, depende muito de um bom modelo de previsão.

2.6.1 Introdução

Os erros associados às previsões da energia do vento podem levar a desafios acrescidos aos gestores e operadores do sistema elétrico. Daí que, uma das principais prioridades no campo da investigação nos sistemas de energia elétrica, seja a de se conseguirem melhores performances nos processos de previsão, de modo a que a produção de energia eólica possa continuar a aumentar.

Importa nos modelos de previsão, utilizar ferramentas que avaliem a sua performance, através da análise dos erros de cada um dos sistemas desenvolvidos. Esta performance deve ser comparada com a performance de alguns modelos de referência, tais como: persistência, média global e novo modelo de referência.

Os MNPTs, são caraterizados por uma determinada incerteza que lhes é inerente, isto quer dizer que, nenhum destes modelos pode alguma vez ser exato. Torna-se por isso essencial que as previsões sobre a força do vento sejam avaliadas adequadamente, não apenas para o modelo estar corretamente avaliado na sua performance mas também para se poder compreender melhor o que carateriza a incerteza das previsões.

A avaliação da qualidade dos métodos de previsão é feita, comparando as previsões da energia do vento para dado instante, com a observação que é feita para esse mesmo instante. Então, a qualidade de um determinado método é avaliada através da análise da diferença entre a previsão e o observado na realidade, para o mesmo instante de tempo

2.6.2 Avaliação da performance da PEV

A avaliação de um conjunto de previsões é possível quando estão disponíveis observações relacionadas com essas mesmas previsões. Atualmente a maioria das centrais eólicas estão equipadas com SSAD, mas podem existir intervalos de tempo em que não são disponibilizadas quaisquer observações. Por outro lado, mesmo que todos os dados fossem disponibilizados, existiria sempre a possibilidade de alguns serem de fraca qualidade. Neste caso, não se podem avaliar corretamente as previsões. Assim sendo, cabe aos analistas decidirem como lidar com os dados disponíveis, tendo em conta a sua qualidade geral.

Avaliar previsões implica considerar vários critérios que devem ser aplicados e combinados adequadamente, por forma a criar-se um suporte de apoio às conclusões obtidas.

2.6.3 Dados para treino e teste do modelo

Um método de previsão deve ser capaz de fornecer previsões adequadas na presença de dados novos e independentes, durante a sua fase de teste. Esta capacidade é geralmente conhecida como 'generalização', e a sua importância na avaliação da qualidade dos métodos de previsão é fundamental, porque traduz a capacidade que o método tem para prever em diferentes circunstâncias. Portanto, é muito importante avaliar os erros obtidos para os dados que não tenham sido utilizados para construir o modelo de previsão.

A fim de se atingir este objetivo, os dados são geralmente divididos em dois grupos diferentes, de acordo com as suas características no tempo: (1) o conjunto de dados de formação (treino), e (2) o conjunto de dados de teste. O conjunto de dados para a fase de treino é usado para construir o modelo, levando em consideração a validação de decisões e/ou de regras relativas à estrutura do modelo. No entanto, uma vez que o conjunto de dados para a fase de treino, não fornece estimativas adequadas para os erros de previsão, é necessário o uso de dados novos e independentes, designado por conjunto de dados de teste. Assim, os modelos de previsão devem ser desenvolvidos e ajustados, usando dados para a construção do modelo (dados de treino) não considerando os dados de teste, ao passo que as medidas dos erros devem ser baseadas somente utilizando os dados de teste.

No entanto, o conjunto de dados de teste pode ser utilizado para o auto ajuste do modelo durante a fase de teste.

2.6.4 -Definição dos erros de medição

2.6.4.1 -Erros de previsão

O erro de previsão é definido como sendo a diferença entre o valor medido e o valor previsto. Dado que se considera a previsão para cada horizonte de tempo separadamente, o erro de previsão para o horizonte $t+k$ é definido como sendo:

$e(t+k|t)=P(t+k)-\hat{P}(t+k|t)$ (2.1)

Por vezes é conveniente introduzir o Erro de Previsão Normalizado para a capacidade instalada, no sentido de se compararem os erros entre centrais diferentes.

$e(t+k|t)=\frac{1}{Pinst}\,e(t+k|t)=\frac{1}{Pinst}\,(P(t+k|t)-\hat{P}\,(t+k|t))$ (2.2)

Qualquer erro de previsão pode ser decomposto em dois, o erro sistemático μ_e e o erro aleatório $\mathbf{x}_e$.

$e=\mu_e+\mathbf{x}_e.$ (2.3)

onde μ_e é uma constante e $\mathbf{x}_e$ é uma variável aleatória com média zero.

2.6.4.2 -Avaliação dos modelos

O modelo de referência, que corresponde ao erro sistemático, surge como sendo o erro médio ao longo do período em avaliação, e é calculado para cada um dos horizontes temporais.

$BIAS(k)=\hat{\mu}_e=\bar{e}_k=\frac{1}{N}\sum_{t=1}^{N} e(t+k|t).$ (2.4)

Existem dois critérios básicos para avaliar a performance dos sistemas de previsão: o erro médio absoluto (MAE) e a raiz do valor médio quadrático (RMSE). O erro médio absoluto é dado por:

$MAE(k)=\frac{1}{N}\sum_{t=1}^{N}|e(t+k|t)|.$ (2.5)

Antes de se introduzir o RSME apresenta-se o erro médio quadrático.

$MSE(k)=\frac{1}{N}\sum_{t=1}^{N} e^2\,(t+k|t).$ (2.6)

Sendo a raiz quadrada do erro médio quadrático dado por:

$RMSE(k)=\sqrt{(\frac{1}{N}\sum_{t=1}^{N} e^2\,(t+k|t)}$ (2.7)

Pode usar-se em alternativa ao RSME, o critério do Desvio Padrão dos Erros (SDE):

$SDE(k)=\sqrt{(\frac{1}{N-(p+1)}\sum_{t=1}^{N}(e(t+k|t)-\bar{e}k)^2}$ (2.8)

onde p representa o número de parâmetros estimados para os dados levados em consideração. Assim, para os dados utilizados na fase de teste p=0. O número p de

parâmetros deve ser incluído no critério anterior, quando se aplica o conjunto de dados na fase de treino.

Estatisticamente, os valores do BIAS e do MAE estão associados ao primeiro momento do erro de previsão, assim estas medidas, estão relacionadas com a energia produzida na central. Os valores do RMSE e do SDE estão associados ao momento de segunda ordem, e assim associados à variância do erro de previsão.

2.6.4.3 -Comparação entre modelos

Quando se desenvolve um determinado modelo, é importante quantificar os benefícios que esse modelo proporciona, comparando-o com um modelo referência. O ganho, ou melhoria do modelo em relação ao modelo de referência selecionado para um dado período de tempo, é dado pela expressão:

$$G_{ref}=100\left(\frac{ECref(k)-EC(k)}{ECref(k)}\right)(\%) \quad (2.9)$$

onde *EC* é o critério de avaliação utilizado, podendo escolher-se entre o MAE, o RMSE ou até o SDE e, EC_{ref} é o critério usado como referência.

Outra alternativa para verificar a qualidade dos modelos de previsão, consiste em calcular o coeficiente de determinação R^2 para cada instante futuro de previsão.

$$R^2=\frac{MSE0(k)-MSE(k)}{MSE0(k)} \quad (2.10)$$

onde *MSE*0 (k) é o erro médio quadrático para a média global do modelo [equação (2.6)], sendo esta média calculada a partir dos dados disponíveis.

O coeficiente de determinação, representa a capacidade que o modelo tem para explicar a variância dos dados. O valor de R^2 está entre 0 e 1, sendo que quando é zero, o modelo não tem qualquer interesse e quando é 1, o modelo é perfeito.

O valor R^2 deve usar-se na seleção do modelo quando ainda está na fase de treino mas deve evitar-se como ferramenta principal para a seleção do modelo, quando se está a avaliar a sua performance [48].

Capítulo 3

Modelos de previsão

3.1 Modelos de referência

O modelo de persistência do vento ou previsão de energia, assume que o vento (velocidade e direção) ou a energia, em um determinado momento futuro, será o mesmo que o valor medido no instante em que a previsão é feita, o que pode ser formulado como, $\hat{p}_{t+k} = p_t$. A nível operacional, usam-se as medidas mais recentes disponíveis da velocidade do vento ou da energia, fornecidas pelo controlo de supervisão e aquisição de dados (SSAD). A persistência é, obviamente, um método muito simples e é referido aqui, uma vez que é usado como referência para avaliar a performance de métodos mais avançados. Um método mais avançado só tem interesse se supera a persistência. O vento, no entanto, é de algum modo persistente na natureza, por isso este método é difícil de superar, especialmente no curto prazo (1-6 h).

Em [49], é descrito um novo modelo de referência para a PEV. O modelo de referência proposto combina a persistência e o valor médio, onde o peso é dado por uma função da correlação entre p_t e p_{t+k}. A relação pode ser formulada como:

$$\hat{p}_{t+k} = p_t * a_k + (1 - a_k)\bar{p}, \tag{3.1}$$

onde p_t é o último valor medido e registado do vento que se faz sentir no instante t, $\bar{p}$ é o valor médio estimado dado pelos valores do vento anteriormente medidos através da equação $\bar{p} = \frac{1}{N}\sum_{t=1}^{N} p_t$, e a_k é o coeficiente de correlação entre p_t e p_{t+k}. A principal desvantagem deste método é que os coeficientes a_k têm de ser estimados ou fixados por meio de algumas considerações ou pressupostos. Os autores afirmam que, se o horizonte de previsão do tempo é maior do que três horas, então deve usar-se o novo modelo de referência em substituição do modelo de persistência.

3.2 Séries temporais

Uma Série Temporal é definida como sendo um conjunto de observações sobre uma variável, ordenadas no tempo e registadas em períodos regulares. Podemos enumerar os seguintes exemplos de séries temporais: temperaturas máximas e mínimas diárias em determinado local, vendas mensais de uma empresa, valores diários no fecho da Bolsa, resultado de um eletroencefalograma, gráfico de controlo de um processo produtivo, etc. O objetivo da análise de séries temporais é identificar padrões não aleatórios numa variável de interesse, e a observação deste comportamento passado pode permitir fazer previsões sobre o futuro, orientando a tomada de decisões. Na figura 3.1, como exemplo, pode observar-se uma série temporal usada para controlo de defeitos de um determinado produto.

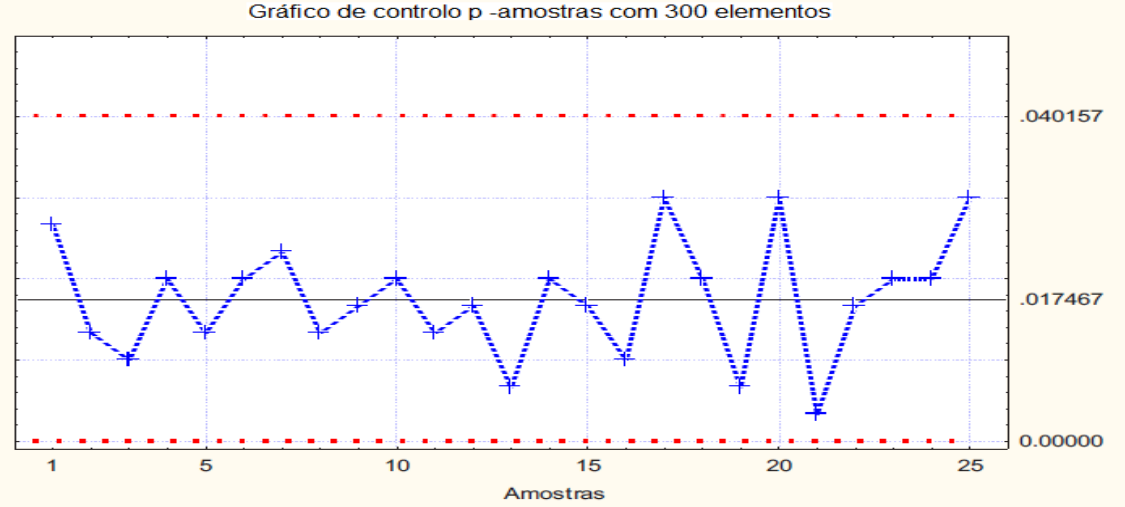


Figura 3.1 - Gráfico de controlo de defeitos [50].

3.2.1 -Estacionariedade

Uma série temporal é dita estacionária quando ela se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável. Na prática, a maioria das séries que se encontram apresentam algum tipo de não estacionariedade, por exemplo, tendência.

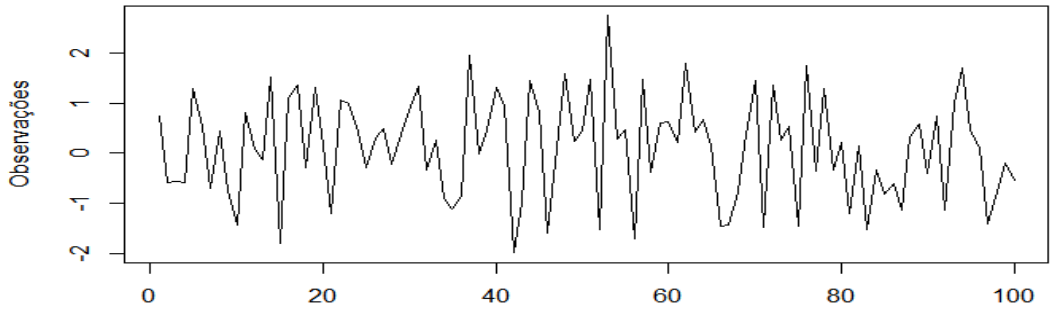


Figura 3.2- Série temporal estacionária.

Uma série pode ser estacionária por períodos curtos ou longos, o que implica uma mudança de nível e/ou inclinação. A classe dos modelos ARIMA será capaz de descrever de maneira satisfatória séries estacionárias e séries não estacionárias que não apresentem um comportamento explosivo. Este tipo de não estacionariedade, chamado de comportamento homogéneo, verifica-se quando a série pode ser estacionária, flutuando ao redor de um nível por um certo tempo, depois mudar de nível e flutuar ao redor de um novo nível, e assim por diante, ou então mudar de inclinação.

A maioria dos procedimentos de análise estatística de séries temporais supõe que estas sejam estacionárias, portanto, será necessário transformar os dados originais se estes não formam uma série estacionária. A transformação mais comum consiste em tomar diferenças sucessivas da séries original, até se obter uma série estacionária. A primeira diferença Z(t) é definida por:

$$\Delta Z(t) = Z(t) - Z(t-1) \tag{3.2}$$

então, a segunda diferença é:

$$\Delta^2 Z(t) = \Delta[\Delta Z(t)] = \Delta[Z(t) - Z(t-1)] \tag{3.3}$$

$$\Delta^2 Z(t) = Z(t) - 2Z(t-1) + Z(t-2) \tag{3.4}$$

$$\Delta^n Z(t) = \Delta[\Delta^{n-1} Z(t)] \tag{3.5}$$

Normalmente será suficiente tomar uma ou duas diferenças para que a série se torne estacionária.

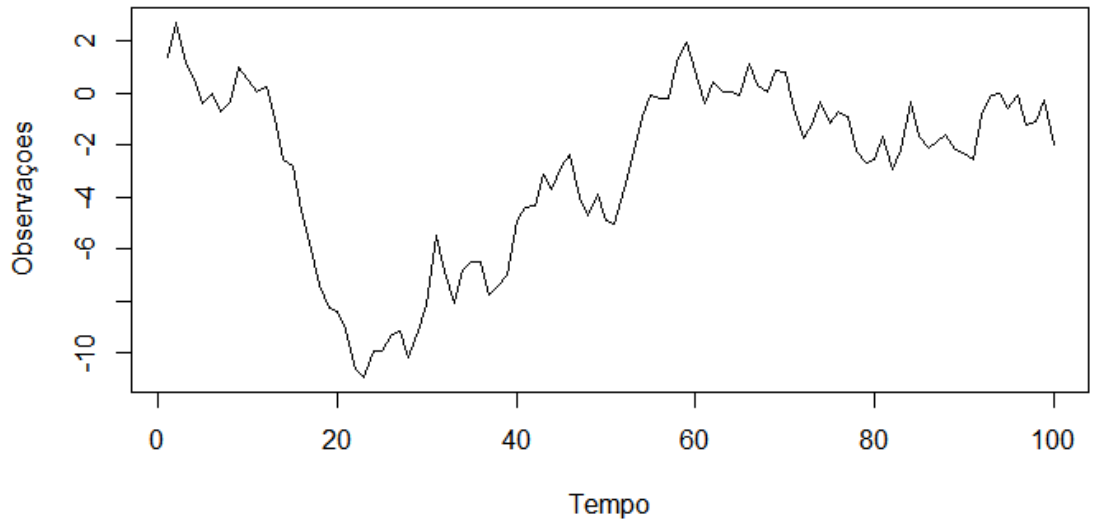


Figura 3.3 - Série temporal não estacionária.

3.2.2 Processos Estocásticos

Seja T um conjunto arbitrário. Um processo estocástico é uma família $Z = \{Z(t), t \in T\}$, tal que, para cada $t \in T$, Z(t) é uma variável aleatória.

Nestas condições, um processo estocástico é uma família de variáveis aleatórias, que se supõem definidas num mesmo espaço de probabilidades (Ω, A, P). O conjunto T é normalmente formado pelo conjunto dos inteiros Z = {±1, ±2, ±3,...}.

Para se dizer que um processo estocástico está especificado, são necessárias certas condições. Sejam t_1, t_2,..., t_n elementos quaisquer de T e considerando-se,

$$F(z_1,\ldots,z_n;t_1,\ldots,t_n) = P[Z(t_1) \le z_1,\ldots,Z(t_n) \le z_n] \quad (3.6)$$

Então, o processo estocástico $Z = \{Z(t), t \in T\}$ estará especificado se forem conhecidas as distribuições finito-dimensionais, para todo n ≥ 1. As funções de distribuição devem satisfazer as duas condições seguintes:

- (Condição de Simetria) para qualquer j_1,...,j_n, dos índices 1,2,...,n temos:

$$F(z_{j_n},\ldots,z_{j1};t_1,\ldots,t_n) = F(z_1,\ldots,z_n;t_1,\ldots,t_n) \quad (3.7)$$

- (Condição de Compatibilidade) para m < n,

$$F(z_1,\ldots,z_m,+\infty,\ldots,-\infty;t_1,\ldots,t_m,t_{m+1},\ldots,t_n) = F(z_1,\ldots,z_m;t_1,\ldots,t_m) \quad (3.8)$$

3.2.2.1 Sequência Aleatória e Passeio Aleatório

No exemplo seguinte, representa-se um processo estocástico que pode ser designado de Sequência Aleatória.

Considere-se $\{X_n, n = 1,2,...\}$ uma sequência de variáveis aleatórias definidas no mesmo espaço amostral Ω. Aqui, T = {1,2,...} e é um processo com parâmetro discreto, ou uma sequência aleatória. Para todo n ≥ 1, podem escrever-se:

$$P[X_1 = a_1,\ldots,X_n = a_n] = P[X_1 = a_1]P[X_2 = a_2|X_1 = a_1] \times \cdots \times \quad (3.9)$$

$$P[X_n = a_n|X_1 = a_1,\ldots,X_{n-1} = a_{n-1}]. \quad (3.10)$$

Aqui, os a_j's representam os estados do processo e o espaço dos estados pode ser tomado como o conjunto dos reais. O caso mais simples é aquele em que existe uma sequência $\{X_n, n \ge 1\}$ de variáveis aleatórias mutuamente independentes e, neste caso temos:

$$P[X_1 = a_1,\ldots,X_n = a_n] = P[X_1 = a_1]\ldots P[X_n = a_n]. \quad (3.11)$$

Este exemplo é conhecido como Sequência Aleatória.

Outro exemplo de processo estocástico, que tem grande importância nas áreas da economia e finanças, é designado de Passeio Aleatório, e representa-se da seguinte forma:

Dada uma sequência aleatória $\varepsilon_t \ge 1$ com variáveis aleatórias e $(\mu_\varepsilon, \sigma_\varepsilon^2)$. Definindo-se a sequência:

$$X_t = \varepsilon_1 + \cdots + \varepsilon_t. \quad (3.12)$$

Segue-se que $E(X_t) = t\mu_\varepsilon$ e $Var(X_t) = t\sigma_\varepsilon$, ou seja, ambas dependem de t.

3.2.2.2 Processos Estacionários

Um processo é estacionário, se todas as características do comportamento do processo não são alteradas no tempo, ou seja, o processo desenvolve-se no tempo em torno da média, de modo que a escolha da origem dos tempos não é importante.

Um processo estocástico $Z = \{Z(t), t \in T\}$, diz-se estritamente estacionário se todas as distribuições finito-dimensionais permanecem as mesmas sob translações no tempo, ou seja,

$$F(z_1, \ldots, z_n; t_1 + \tau, \ldots, t_n + \tau) = F(z_1, \ldots, z_n; t_1, \ldots, t_n), \qquad (3.13)$$

para quaisquer $t_1, \ldots, t_{n+\tau}$ de T.

Em particular, se um processo é estritamente estacionário significa que todas as distribuições unidimensionais são invariantes sob translações do tempo, logo a média $\mu(t)$ e variância *V(t)* são constantes, isto é, $\mu(t) = \mu, \quad V(t) = \sigma^2$, para todo $t \in T$.

Um processo estocástico $Z(t) = \{Z(t), t \in T\}$ é fracamente estacionário ou estacionário de segunda ordem se e somente se:

1. $E[Z(t)] = \mu(t) = \mu$, constante, para todo $t \in T$;
2. $E[Z^2(t)] < \infty$, para todo $t \in T$;
3. $\gamma(t_1, t_2) = Cov[Z(t_1), Z(t_2)]$ é uma função de $|t_1 - t_2|$.

Designa-se por processo estacionário quando o processo for fracamente estacionário. Existem modelos que são apropriados para tratar os processos estacionários homogêneos, isto é, processos cujo nível e/ou inclinação mudam com o decorrer do tempo. Tais processos podem tornar-se estacionários por meio de diferenças sucessivas.

Um processo estocástico $Z = \{Z(t), t \in T\}$ diz-se *Gaussiano* (ou normal) se para qualquer conjunto $t_1, t_2, \ldots, t_n$ de T, as variáveis aleatórias $Z(t_1), \ldots, Z(t_n)$ têm distribuição normal n-variada.

Se um processo for Gaussiano (ou normal) ele será determinado pelas médias e covariâncias; em particular, se ele for estacionário de segunda ordem, ele será estritamente estacionário.

3.2.2.3 Função de Auto covariância e Função de Auto correlação

A covariância entre duas variáveis aleatórias reais X e Y, é definida como a medida de como duas variáveis variam conjuntamente. A covariância é por vezes chamada de medida de dependência linear entre as duas variáveis aleatórias. Mede o grau de dependência linear entre duas variáveis.

$$COV\ (X, Y) = \sum (x_i - \bar{X}) * (y_i - \bar{Y}) \qquad (3.14)$$

onde:

xi = valor da variável X
$\bar{X}$ = média da variável X
yi = valor da variável Y
$\bar{Y}$ = média da variável

Seja $\{X_t, t \in Z\}$ um processo estacionário real discreto de média zero. A sua função de auto covariância (f.a.c.v.) é definida por $\gamma_\tau = E[X_t X_{t+\tau}]$.

A facv γ_τ deve satisfazer as seguintes propriedades:

1. $\gamma_0 > 0$;
2. $\gamma_{-\tau} = \gamma_\tau$;
3. $|\gamma_\tau| \leq \gamma_o$;
4. γ_τ é não negativa definida, tal que $\sum_{j=1}^{n} \sum_{k=1}^{n} a_j a_k \gamma_{\tau_j - \tau_k} \geq 0,$

para quaisquer números reais $a_1, \ldots, a_n$, e $\tau_1, \ldots, \tau_n$ pertencente a Z.

Prova: 1. e 2. decorrem imediatamente da definição de γ_τ.

3. Basta notar que

$$E[X_{t+\tau} \pm X_t]^2 = E[X_{t+\tau}^2 \pm 2X_{t+\tau}X_t + X_t^2] \geq 0$$

mas, sabe-se que

$$X_{t+\tau}^2 \pm 2X_{t+\tau}X_t + X_t^2 = \gamma^2 \pm 2\gamma_\tau + \sigma^2 \geq 0$$

ou seja,

$$2\gamma_0 \pm 2\gamma_\tau \geq 0 \Longrightarrow |\gamma_\tau| \leq \gamma_0$$

4.Tem-se que:

$$\sum_{j=1}^{n} \sum_{k=1}^{n} a_j a_k \gamma_{\tau_j - \tau_k} = \sum_{j=1}^{n} \sum_{k=1}^{n} a_j a_k E[X_{\tau_j} X_{\tau_k}] = E[\sum_{j=1}^{n} a_j X_{\tau_j}]^2 \geq 0$$

A f.a.c.v. de um processo estacionário tende para zero quando $|\tau| \to 0.$

Uma importante ferramenta para se identificar as propriedades de uma série temporal, consiste numa série de quantidades chamadas coeficientes de auto correlação amostral. A ideia é similar ao coeficiente de correlação usual, ou seja, para n pares de observações das variáveis x e y, existe um coeficiente que mede a extensão do relacionamento entre as duas variáveis. Aqui no entanto, pretende-se medir a correlação entre as observações de uma mesma variável em diferentes horizontes de tempo, isto é, correlações entre observações desfasadas 1, 2, . . .n períodos de tempo.

A função de *auto correlação* do processo é definida por:

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0}, \tau \in Z \qquad (3.15)$$

Possui as mesmas propriedades da função de auto covariância γ_τ, exceto que agora $\rho_0 = 1$.

A função de auto correlação é utilizada para identificarmos um modelo adequado para a série temporal.

3.2.2.4 Modelo clássico

Segundo o modelo clássico todas as séries temporais são compostas de quatro padrões:

Tendência (T), é o comportamento de longo prazo da série, que pode ser causada pelo crescimento demográfico, ou mudança gradual de hábitos de consumo, ou qualquer outro aspeto que afete a variável de interesse no longo prazo;

Variações cíclicas ou ciclos (C), representam flutuações nos valores da variável com duração superior a um ano, e que se repetem com certa periodicidade, que podem ser resultado de variações da economia (períodos de crescimento ou recessão), ou fenómenos climatéricos como o *El Niño* (que se repete com periodicidade superior a um ano);

Variações sazonais ou sazonalidade (S), referem-se a flutuações nos valores da variável com duração inferior a um ano, e que se repetem todos os anos, geralmente em função das estações do ano (ou em função de feriados ou festas populares). Se os dados forem registados anualmente não haverá influência da sazonalidade na série;

Variações irregulares (I), que são as flutuações inexplicáveis, resultado de fatos fortuitos e inesperados como catástrofes naturais, atentados terroristas, decisões intempestivas de governos, etc.

A decomposição da série permitirá identificar quais os componentes que estão a atuar naquele conjunto em particular, além de possibilitar obter índices e/ou equações para realizar previsões para períodos futuros da série.

Se Y for considerada a variável de interesse, a equação da série temporal será:

Y = f(T,C,S,I). Podem observar-se algumas componentes que constituem as séries nas figuras 3.4 e 3.5.

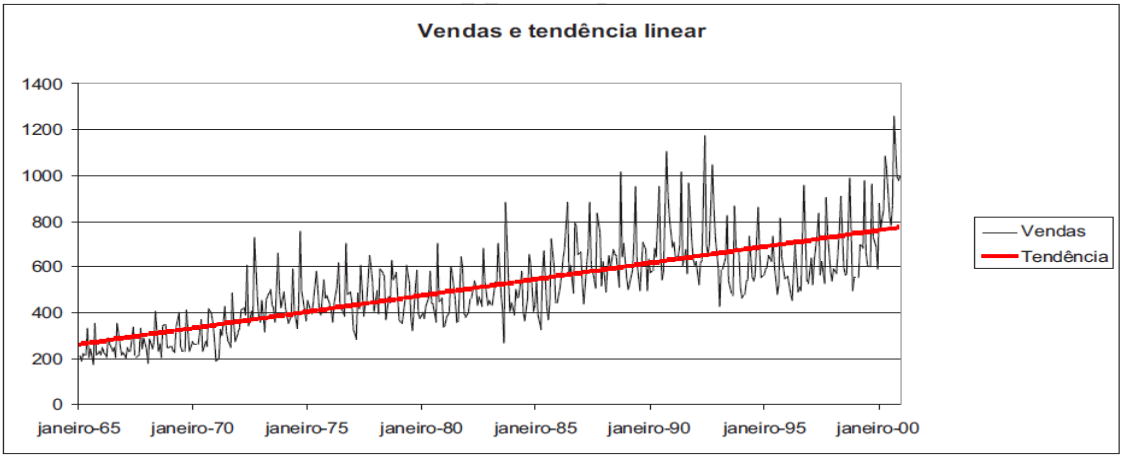


Figura 3.4 - Série Original e tendência linear (T).

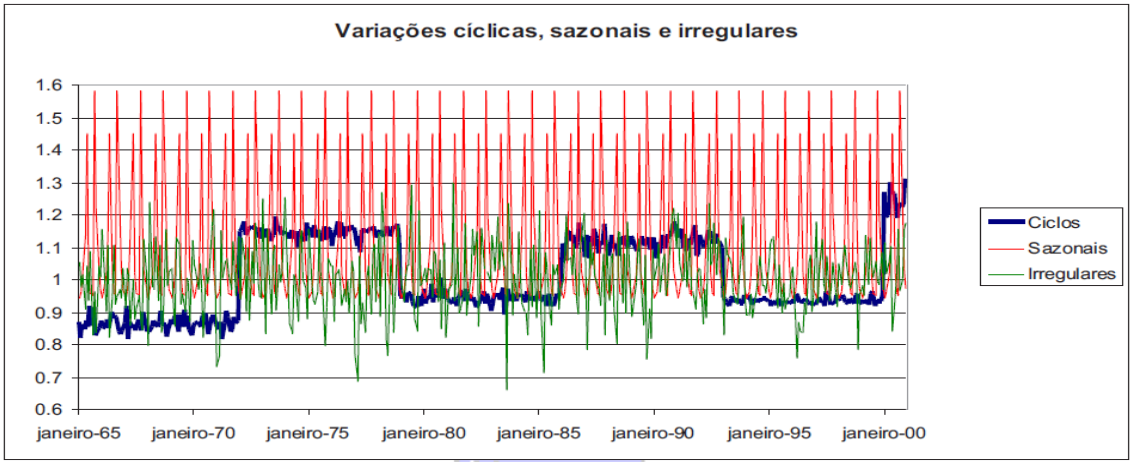


Figura 3.5 - Variações cíclicas, sazonais e irregulares.

A componente T da série pode ser obtida através dos métodos seguintes: tendência linear, médias móveis, e ajuste exponencial. A tendência depois de calculada é subtraída à função original para se poderem observar as componentes restantes.

Caso se pretenda obter a tendência pelo método de tendência linear, utiliza-se o método dos mínimos quadrados, para obtenção dos coeficientes da reta que melhor se ajustam aos dados. A diferença aqui é que a variável independente será sempre o tempo (medido diretamente, por exemplo, anos de 1970, 1971, ou através de contagem de períodos, 1, 2, 3). É importante referir que através de programas estatísticos, ou mesmo de um programa como o Microsoft Excel, é possível ajustar outros modelos que não o linear. Para o caso linear, a reta de tendência será: T = a + b*t, onde: T -é o valor da tendência

- t - é o valor do instante de tempo
- b - é o coeficiente angular da reta (positivo indica tendência crescente, se negativo a tendência é decrescente)
- a - é o coeficiente linear da reta

As equações dos coeficientes estão expressas em 3.16 e 3.17.

$$b = \frac{n \times \sum_{i=1} (t_i \times y_i) - \sum_{i=1} t_i \times \sum_{i=1}^{n} y_i}{n \times \sum_{i=1}^{n} (t_i{}^2) - \left(\sum_{i=1}^{n} t_i \right)^2} \qquad (3.16)$$

$$a = \frac{\sum_{i=1}^{n} y_i - b \times \sum_{i=1}^{n} t_i}{n} \qquad (3.17)$$

onde y_i é um valor qualquer da variável observada na série temporal, t_i é o período associado a y_i, e n é o número de períodos da série. Para se encontrarem os coeficientes basta calcular os somatórios (tal como em análise de regressão linear simples). No exemplo apresentado na tabela seguinte, pode calcular-se a tendência linear através da sua expressão T = a + b*t, juntamente com as equações (3.15) e (3.16).

Tabela 3.1 - Património por ano civil.

Ano	Património (Y) (R$1.000.000)	Tempo (t)	t.Y	t^2
1985	30	1	30	1
1986	32	2	64	4
1987	32	3	96	9
1988	35	4	140	16
1989	37	5	185	25
1990	38	6	228	36
1991	42	7	294	49
1992	41	8	328	64
1993	44	9	396	81
1994	46	10	460	100
1995	47	11	517	121
Soma	424	66	2768	506

Então a equação de tendência é: T = 27,96 + 1,76 * t. O ano de 1996 corresponderá ao período 12, e 1997 ao período 13 da série temporal. Substituindo estes valores na equação acima, podem prever-se os valores para os períodos 12 e 13 da forma seguinte:
T1996 = 27,96 + (1,76 * 12) = 49,08
T1997 = 27,96 + (1,76 *13) = 50,84
Pode então apresentar-se um gráfico (feito no Microsoft Excel) da série original, a reta de tendência e a projeção para os anos de 1996 e 1997. Ver figura 3.6.

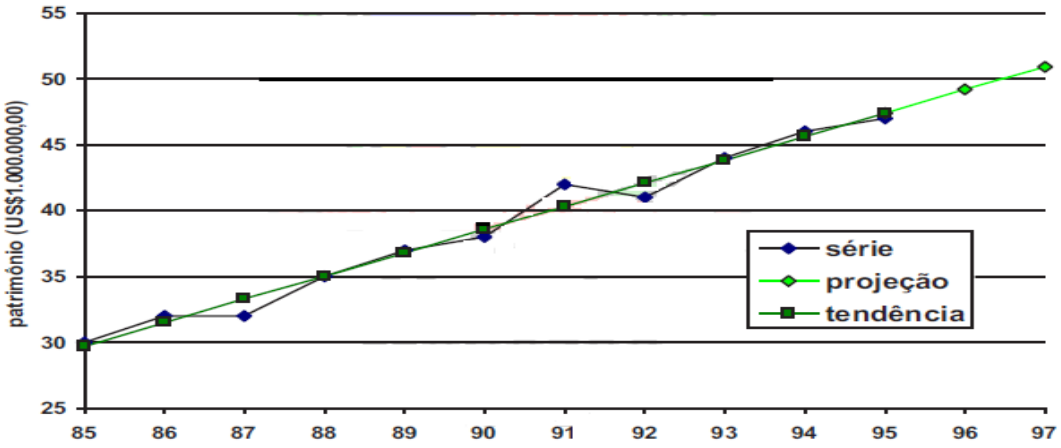


Figura 3.6 - Património líquido de um banco: série anual, tendência linear e projeção.

3.2.2.5 Processos de médias móveis

Considere-se um processo linear $\{X_t, t \in Z\}$, considera-se que este processo é de médias móveis de ordem q, denotado por MA(q), se satisfizer a equação de diferenças:

$$X_t = a_t - \theta_1 a_{t-1} - \ldots - \theta_q a_{t-q} \tag{3.18}$$

onde $\mu, \theta_1, \ldots, \theta_q$ são constantes reais, a_t é um processo discreto puramente aleatório, e $a_t \sim N(0, \sigma^2)$.

Segue que X_t é estacionário, de média μ. Supondo $\mu = 0$, e calculando a função de auto covariância (f.a.c.v.) do processo, tem-se que:

$$\gamma_j = E(X_t X_{t-j}) = E\left\{ \left[a_t - \sum_{k=1}^{q} \theta_k a_{t-k} \right] \left[a_{t-j} - \sum_{l=1}^{q} \theta_l a_{t-l-j} \right] \right\} \tag{3.19}$$

$$\gamma_j = E(a_t a_{t-j}) - \sum_{k=1}^{q} E(a_{t-j} a_{t-k}) - \sum_{l=1}^{q} E(a_t a_{t-j-l}) + \sum_{k=1}^{q} \sum_{l=1}^{q} \theta_k \theta_l E(a_{t-l} a_{t-j-l}) \tag{3.20}$$

Como os a_t são não correlacionados, fica:

$$\gamma_a(j) = E(a_t a_{t-j}) = \begin{cases} \sigma_a^2, & j = 0, \\ 0, & j \neq 0 \end{cases} \tag{3.21}$$

$$\gamma_0 = Var(X_t) = \sigma_X^2 = \sigma^2(1 + \theta_1^2 + \ldots + \theta_q^2) \quad (3.22)$$

Então,

$$\gamma_j = \gamma_a(j) - \sum_{k=1}^{q} \gamma_a(k-j) - \sum_{l=1}^{q} \gamma_a(j+l) + \sum_{k=1}^{q}\sum_{l=1}^{q} \theta_k\theta_l E(a_{t-l}a_{t-j-l})\gamma_a(j+l+k) \quad (3.23)$$

Assim, a partir da f.a.c.v. obtemos a f.a.c seguinte:

$$\rho_j = \frac{\gamma_j}{\gamma_0} = \begin{cases} \dfrac{-\theta_j + \theta_1\theta_{j+1} + \theta_2\theta_{j+2} + \cdots + \theta_q\theta_{q-j}}{1 + \theta_1^2 + \theta_2^2 + \cdots + \theta_q^2} & ,j = 1,,q, \\ 0 & ,q > q. \end{cases} \quad (3.24)$$

3.2.2.6 Processos auto regressivos

Diz-se que $X_t, t \in Z$ é um processo auto regressivo de ordem p e representa-se por $X_t \sim AR(p)$ se o processo puder ser escrito na seguinte forma:

$$X_t = \phi_0 + \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t \quad (3.25)$$

Onde, $\phi_0, \phi_1, \ldots, \phi_p$ são parâmetros reais e ε_t é um processo discreto puramente aleatório, com $E(\varepsilon_t) = 0$ e $Var(\varepsilon_t) = \sigma^2$.

Um caso particular simples de grande importância é o processo auto regressivo de primeira ordem *p* = 1, AR(1):

$$X_t = \phi X_{t-1} + \varepsilon_t \quad (3.26)$$

Fazendo substituições sucessivas, X_{t-1}, X_{t-2}, etc, na equação acima obtém-se:

$$X_t = \varepsilon_t + \phi\varepsilon_{t-1} + \phi^2\varepsilon_{t-2} + \ldots = \sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j} \quad (3.27)$$

onde a convergência é em média quadrática. Logo, a condição $|\phi|<1$ é suficiente para que X_t seja estacionário.

Pode calcular-se a função de auto covariância (f.a.c.v.), multiplicando ambos os lados de (3.25), por $X_{t-\tau}$, e tomando a esperança:

$$E(X_t X_{t-\tau}) = \phi E(X_{t-1}E_{t-\tau}) + \phi^2 E(X_{t-2}X_{t-\tau}) + \ldots + \phi^p E(X_{t-p}X_{t-\tau}) + E(\varepsilon_t X_{t-\tau})$$
$$\gamma_\tau = \phi\gamma_{\tau-1} = \ldots = \phi^\tau\gamma_0 \quad (3.28)$$

no entanto,

$$\gamma_0 = \sigma_X^2 = \sigma^2 \sum_{j=0} \phi^{2j} = \frac{\sigma^2}{1-\phi^2} \quad (3.29)$$

portanto, segue que:

$$\gamma_\tau = \frac{\sigma^2}{1-\phi^2}\phi^{|\tau|}, \quad \tau \in Z \tag{3.30}$$

Assim, a partir da função de auto covariância pode calcular-se também a função de auto correlação (f.a.c.):

$$\rho_\tau = \frac{\gamma_\tau}{\gamma_0} = \phi^{|\tau|}, \quad \tau \in Z \tag{3.31}$$

No caso geral, as funções de auto covariância e auto correlação, são dadas por:

$$\gamma_j = \phi_1\gamma_{j-1} + \phi_2\gamma_{j-2} + \ldots + \phi_p\gamma_{j-p}, \quad j>0 \tag{3.32}$$

$$\rho_j = \phi_1\rho_{j-1} + \phi_2\rho_{j-2} + \ldots + \phi_p\rho_{j-p}, \quad j>0, \tag{3.33}$$

respetivamente.

Substituindo, j = 1, 2, ... , p, em (31) obtém-se:

$$\begin{aligned}
\rho_1 &= \phi_1 + \phi_2\rho_2 + \ldots + \phi_p\rho_{p-1} \\
\rho_2 &= \phi_1\rho_1 + \rho_2 + \ldots + \phi_p\rho_{p-2} \\
\vdots \quad &= \quad \vdots \\
\rho_p &= \phi_1\rho_{p-1} + \phi_2\rho_{p-2} + \ldots + \phi_p
\end{aligned} \tag{3.34}$$

que é um método recursivo para calcular as auto correlações, conhecidas como equações de *Yule-Walker*.

3.2.2.7 Modelos mistos ARMA

Juntando os modelos AR e MA pode obter-se uma representação adequada com um número inferior de parâmetros. Os processos auto regressivos de médias móveis (ARMA) formam uma classe de modelos muito úteis e parcimoniosos para descrever dados de séries temporais. O modelo ARMA(p, q) é dado por:

$$X_t = \phi_1 X_{t-1} + \cdots \phi_p X_{t-p} + a_t - \theta_1 a_{t-1} - \cdots - \theta_q a_{t-q} \tag{3.35}$$

Um modelo frequentemente utilizado é o ARMA(1,1), ou seja:

$$X_t = \phi X_{t-1} + a_t - \theta a_{t-1} \tag{3.36}$$

No caso geral, calcula-se a f.a.c.v. por:

$$\gamma_j = \phi_1\gamma_{j-1} + \phi_2\gamma_{j-2} + \cdots + \phi_p\gamma_{j-p} + \gamma_{Xa}(j) - \theta_1\gamma_{Xa}(j-1) - \cdots - \theta_q\gamma_{Xa}(j-q) \tag{3.37}$$

onde $\gamma_{Xa}(j)$ é a covariância cruzada entre X_t e a_t, definida por:

$$\gamma_{Xa}(j) = \begin{cases} = 0, & j > 0, \\ \neq 0, & j \leq 0. \end{cases} \tag{3.38}$$

Assim, a f.a.c.v. fica:

$$\gamma_j = \phi_1 \gamma_{j-1} + \phi_2 \gamma_{j-2} + \cdots + \phi_p \gamma_{j-p}, \quad j > q \tag{3.39}$$

e a f.a.c. é obtida por:

$$\rho_j = \frac{\gamma_j}{\gamma_0} = \phi_1 \rho_{j-1} + \phi_2 \rho_{j-2} + \cdots + \phi_p \rho_{j-p}, \quad j > q. \tag{3.40}$$

Um processo ARMA(p,q) tem f.a.c. infinita, a qual decai de acordo com exponenciais e/ou sinusoides amortecidas após o atraso p-q. Essa observação é importante na identificação do modelo aos dados observados.

3.3 Redes Neuronais

As redes são constituídas por um conjunto de nós e pelas ligações entre eles. Os nós podem ser vistos como unidades computacionais que recebem várias entradas, e as processam de modo a obter-se uma saída. O processamento pode ser muito simples (apenas somar as entradas, por exemplo), ou algo complexo (um nó pode eventualmente conter uma nova rede). As ligações determinam o fluxo da informação entre os vários nós e podem ser unidirecionais ou bidirecionais. As interações entre os nós através das ligações dão origem ao comportamento global da rede, o qual não pode ser observado nos elementos da mesma. Este comportamento global diz-se ser emergente. Verifica-se que a capacidade da rede excede em muito a capacidade de cada um dos seus elementos, fazendo da rede uma ferramenta muito poderosa. As redes que usam os nós como sendo ´neurónios artificiais', são designadas por redes neuronais artificiais. Um neurónio artificial é um modelo computacional inspirado nos neurónios naturais.

As RN são unidades de processamento interligadas de forma simples desenhadas para realizar tarefas em particular, de modo análogo ao que acontece no cérebro [52]. Cada uma das unidades, chamadas de neurónios artificiais, efetua a soma ponderada das suas entradas, nas quais é adicionado um termo constante chamado de tendência. Esta soma passa através de uma função de transferência: linear, sigmóide ou tangente hiperbólica. Os neurónios artificiais estão organizados numa estrutura que define a arquitetura da rede. As redes têm normalmente os neurónios estruturados por camadas: uma camada de entrada, várias camadas não visíveis, e uma camada de saída [52].

Na figura 3.7 representa-se a arquitetura de um modelo RN de três camadas. Por forma a melhorar a arquitetura de uma rede, devem desenhar-se várias arquiteturas diferentes e escolher a mais adequada. Estas combinações devem recorrer a diferentes números de camadas não visíveis, diferentes números de neurónios por camada e diferentes tipos de funções de transferência.

A configuração aqui representada refere-se a uma tangente hiperbólica, dada por:

$$f(s) = \frac{e^{s} - e^{-s}}{e^{s} + e^{-s}} \tag{3.41}$$

A sua camada de saída é dada por:

$$f'(s') = s' \tag{3.42}$$

Nas equações (3.41) e (3.42), *s* é a entrada ponderada da camada invisível, f(*s*) é a função de transferência sigmóide hiperbólica tangente, da camada invisível, s' é a entrada ponderada da camada de saída, e f'(s') representa a função de transferência puramente linear da camada de saída.

Esta configuração demonstrou ser a mais equilibrada se for garantido que a camada invisível tem um número suficiente de neurónios [53]. Se a rede tiver poucos neurónios, não será suficiente flexível para ajustar os dados. Se por outro lado, tiver neurónios em excesso, a rede poderá ajustar os dados em demasia. O número de neurónios estimado para a camada invisível deverá ser determinado por tentativa e erro.

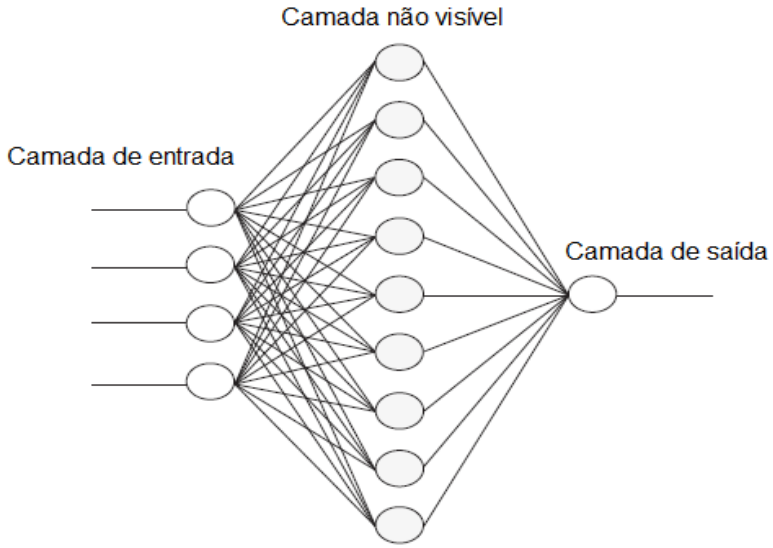


Figura 3.7 - Modelo NN de três camadas.

Efetuar previsões com redes neuronais artificiais assenta em dois passos: um para a fase de treino e outro para a fase de aprendizagem. A fase de treino da rede necessita de um conjunto constituído por: dados históricos, dados de entrada e dados desejados para a saída da mesma. A escolha adequada do número de entradas para a fase de treino da rede influencia fortemente o sucesso desta fase. No processo de aprendizagem da rede, esta cria um mapeamento entre a entrada e a saída, ajustando os pesos e as tendências em cada iteração baseando-se, na minimização dos erros obtidos entre a saída calculada e a saída desejada. O processo de minimização é repetido até que se verifique um critério de convergência válido.

Capítulo 4

Modelos de previsão com *software* MS Excel

A previsão consiste em estimar o valor de uma variável (ou conjunto de variáveis) num instante de tempo futuro. Um problema de previsão, normalmente, tem como objetivo providenciar elementos que apoiem a decisão e o planeamento para uma situação específica num tempo futuro. Tipicamente, este exercício é desenvolvido segundo a premissa de que, conseguindo-se prever o futuro, se podem alterar comportamentos no presente, por forma a ficar-se em melhor posição no instante previsto.

Existem dois esquemas de previsão que podem ser usados para prever a totalidade de um horizonte de tempo (esquemas também conhecidos como previsão *multi-look-ahead*). Um dos esquemas consiste em implementar, para cada instante de tempo futuro da previsão, um modelo de previsão para cada um desses instantes no futuro. Isto implica que é precioso implementar 48 modelos para prever 48 instantes no futuro. Outro esquema inclui a implementação de um modelo único e usá-lo de forma iterativa. Este modelo consiste em se colocar o valor obtido para a primeira previsão, no lugar do valor que foi utilizado para se obter a primeira previsão, e a partir daqui, efetuar-se uma nova previsão mas agora mais um período à frente. Este procedimento repete-se até se chegar ao último valor pretendido. A vantagem desta última solução é a de ser necessário trabalhar apenas um modelo. No entanto, o erro cumulativo passa de um instante de tempo para o outro, aumentando o erro global da previsão.

A escolha para a utilização destes modelos depende da finalidade das previsões, daí que deve ponderar-se a utilização de um MNPT, fazendo antecipadamente uma análise entre os custos deste modelo e a sua utilidade de previsão. Por exemplo, se as PEVs são entradas para um algoritmo de previsão, para horizontes variando de 10 minutos a 1 hora, o uso de

previsões de muito curto prazo é suficiente e não são necessários custos adicionais com um NWP.

4.1 Caraterísticas dos dados

Os dados usados foram recolhidos e facultados pela empresa *Prewind*, situada no Porto, obtidos através de um Sistema de Supervisão e Aquisição de Dados (SSAD). Esta informação baseia-se em uma série de medidas efetuadas através de um SSAD para as diversas variáveis existentes na estação meteorológica da FEUP [56]. Tais variáveis diferem de parque para parque, mas regem-se por normas, tais como as IEC 61400-25 "Communications for monitoring and control of wind power plants" [57], que definem a informação mínima obrigatória que este tipo de sistemas necessita registar, e os métodos que se podem utilizar na troca de informação entre os dispositivos e os sistemas de comunicação necessários a essa operação [58]. A figura 4.1 ilustra o modelo de comunicações proposto pela norma IEC 61400-25.

O SSAD é um sistema baseado na ideologia *Master – Slave* (Mestre - Escravo), onde a unidade central, normalmente situada na subestação do parque, funciona como *Master*, enquanto cada aerogerador, estações meteorológicas ou aparelhos de medida, funcionam como *Slave*. Nesta ideologia o *Master* é o dispositivo que dá as ordens de funcionamento e os *Slave's* respondem aos seus pedidos, como demonstra a figura 4.2. Cada aerogerador tem uma unidade de controlo, que comunica com o *Master* por *TCP/IP* através de uma rede *ethernet*, normalmente em fibra ótica [58].

Esta rede normalmente segue a especificação RS-485, que é uma vertente do modelo OSI [59], que apresenta como vantagens o baixo custo dos equipamentos e cabos, a elevada robustez e disponibilidade. O meio físico é constituído por um cabo de dois fios com par entrançado, recorrendo a protocolos de comunicação como por exemplo o *ModBus*, *DeviceNet* ou *ProfiBus*, entre outros, dependendo da tecnologia utilizada dentro dos parques e dos fabricantes dos dispositivos de controlo.

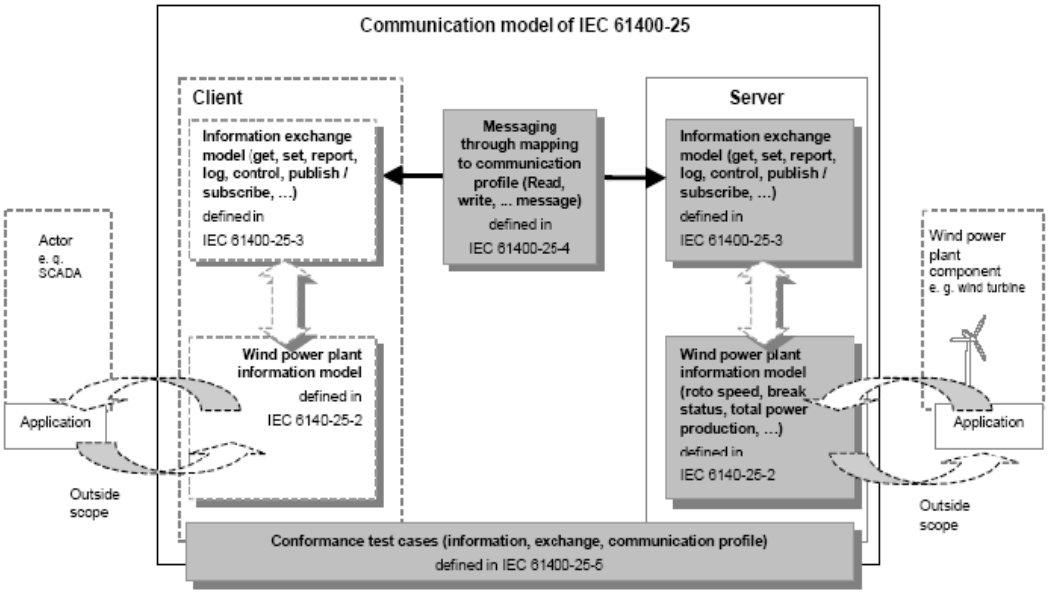


Figura 4.1 - *Modelo de comunicação* [57].

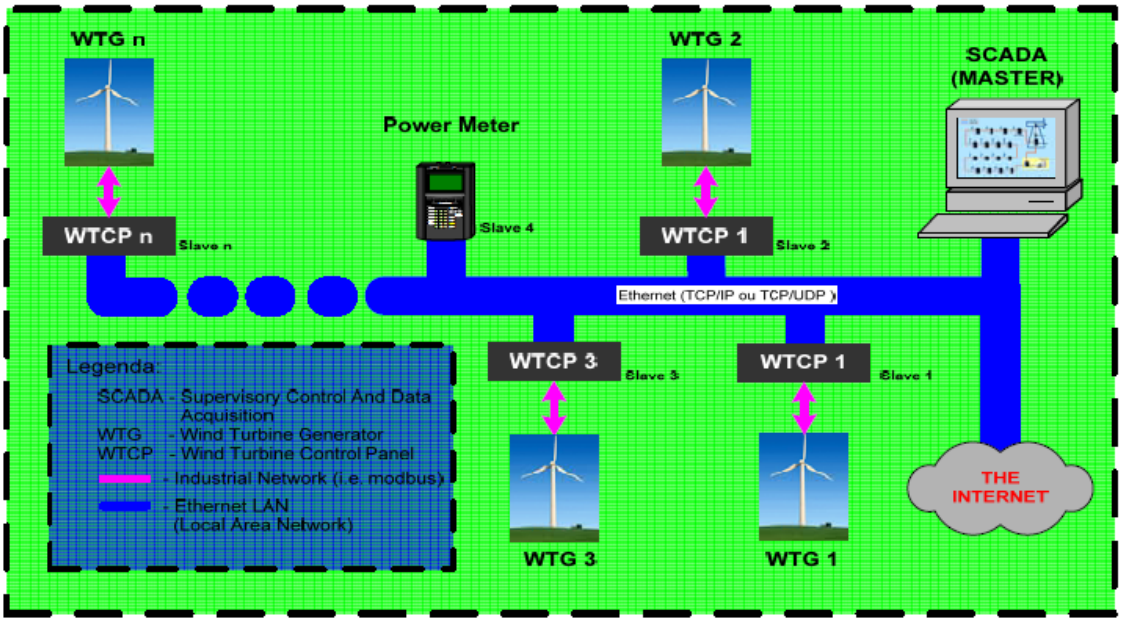


Figura 4.2 - Arquitetura geral do sistema de comunicações dentro de um parque eólico [58].

No entanto, em alternativa à abordagem referida anteriormente, podem-se utilizar redes *ethernet* recorrendo ao protocolo TCP, integrando neste os protocolos mencionados anteriormente. As principais vantagens desta alternativa estão relacionadas com a capacidade de transmissão de dados a longas distâncias e o controlo das colisões inerentes ao protocolo *TCP*, para além das vantagens dos protocolos industriais [56].

4.2 Aplicação de modelos de previsão usando modelos autorregressivos e o analisador de dados do MS Excel

O *Microsoft Office Excel* é um editor de ficheiros produzido pela *Microsoft* para computadores e que pode ser usado em sistemas diversos tais como: *Microsoft Windows*; computadores *Macintosh* da *Apple* Inc.; dispositivos móveis como o *Windows Phone*; *Android* ou o *iOS*. Apresenta recursos que incluem uma interface intuitiva, bem como, ferramentas com elevada capacidade de cálculo e de construção de gráficos.

4.2.1 Previsão usando o Analisador de Dados de Regressão Linear

A análise de regressão consiste na realização da análise estatística com o objetivo de verificar a existência de uma relação funcional entre uma variável independente, com uma ou mais variáveis independentes. Um dos métodos que se pode utilizar para obter a relação funcional é conhecido como método dos mínimos quadrados.

Os dados usados nesta simulação, representam os valores médios para intervalos de dez minutos referentes à velocidade do vento, durante o mês de agosto de 2010. Estes valores foram transportados para uma coluna da folha do livro Excel, onde se efetuou uma regressão, passando os dados para uma segunda coluna de modo a ciar-se o atraso *t-1* entre as duas colunas, tal como se apresenta na figura seguinte.

	A	B
1		
2		
3		
4		
5		
6		
7		
8	V(t)	V(t-1)
9	2,2	
10	3,1	2,2
11	2,5	3,1
12	2,7	2,5
13	2,1	2,7
14	1,4	2,1
15	1,2	1,4
16	1,3	1,2

Figura 4.3 - Dados com um atraso t-1 entre duas colunas.

Interessa aqui, analisar a relação entre os valores da velocidade do vento para um instante t com os valores da mesma variável para um instante *t-1*. Por outras palavras, pretende-se prever a velocidade do vento para um determinado instante conhecendo o seu valor para o instante imediatamente anterior. Usando a ferramenta Excel, seleciona-se a opção Análise de Dados, em Dados, escolhendo a opção *Regressão*. Ver figura 4.4.

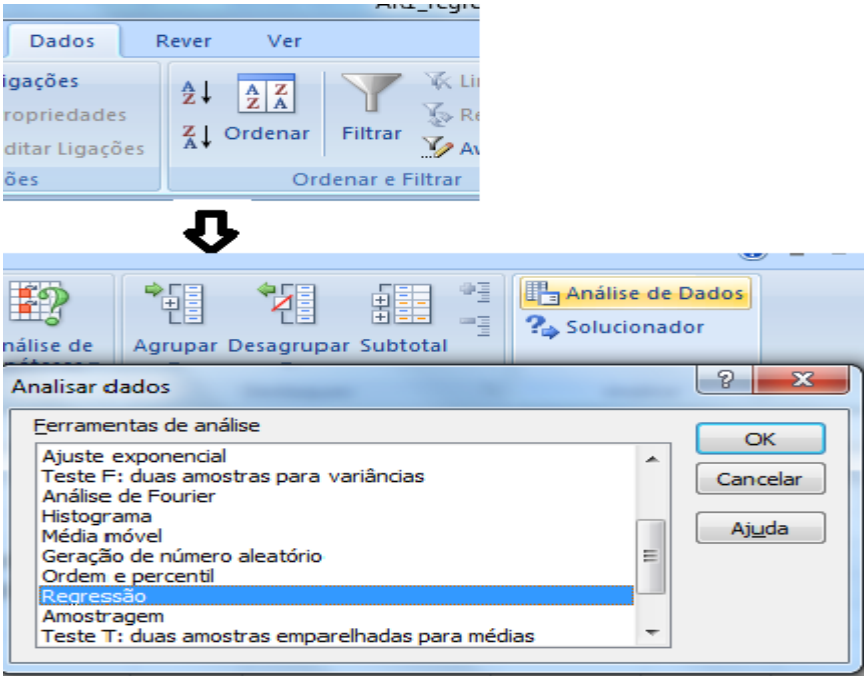


Figura 4. 4 - Seleção da opção *Regressão* em MS Excel.

Ativando o analisador de dados, preenche-se o campo Y (A8;..) e de seguida o campo X (B8:..), em que Y é a variável a prever ou variável dependente, sendo X a variável explicativa ou independente. Ver figura 4.5.

Esta operação devolve um conjunto de valores indicadores da adequação do método aos dados analisados, entre eles:

- O *Quadrado de R*=0,833 – indica que 83% da variação da velocidade no instante t é dependente da velocidade do vento no instante t-1. Quanto mais próximo de 1 estiver este valor, melhor a curva de regressão se adequa aos dados;
- F de significância e Valor P – diz-se que os resultados são fiáveis (estatisticamente significantes), se este valor for inferior a 0,05. Caso este valor fosse superior a 0,05 os dados não seriam adequados e dever-se-ia retirar da análise as variáveis com o valor superior a 0,05, fazendo-se de seguida uma nova regressão;
- Coeficientes – a equação de regressão tem em conta os coeficientes que se obtiveram através da análise de dados, onde V(t+1) =0,2423+0,9128*V(t);
- Residuais – mostra a distância que existe entre os valores previstos e os valores que foram efetivamente medidos, para cada instante.

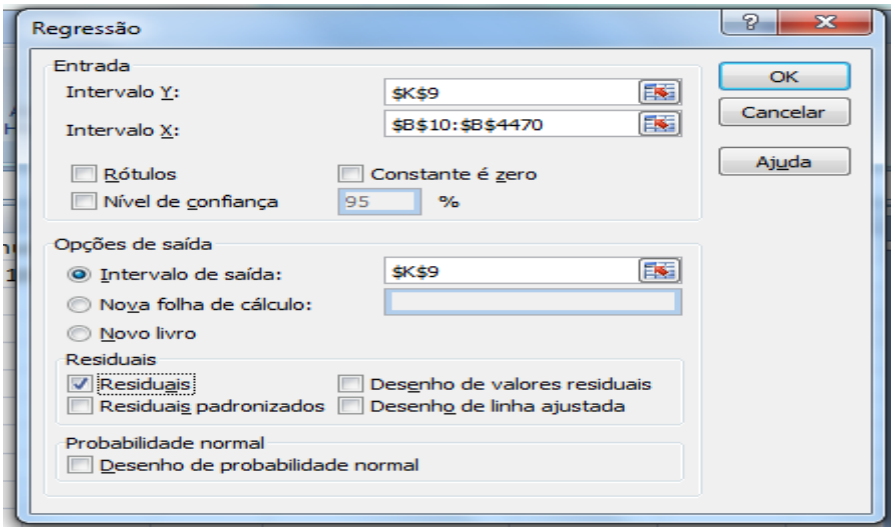


Figura 4.5 - Entradas para o analisador de dados *Regressão*.

Podem observar-se os resultados na figura 4.6.

SUMÁRIO DOS RESULTADOS

Estatística de regressão	
R múltiplo	0,912773693
Quadrado de R	0,833155814
Quadrado de R ajus	0,833118396
Erro-padrão	0,62824553
Observações	4461

ANOVA

	gl	*SQ*	*MQ*	*F*	*F de significância*
Regressão	1	8788,433	8788,433	22266,5342	0
Residual	4459	1759,934	0,394692		
Total	4460	10548,37			

	Coeficientes	*rro-padrã*	*Stat t*	*valor P*	*95% inferior*	*95% superio*	*feric*
b0	0,242317564	0,019409	12,48508	3,4682E-35	0,204267149	0,280368	0,2
b1	0,912763918	0,006117	149,2198	0	0,900771738	0,9247561	0,9

Figura 4.6 - Resultados obtidos usando a regressão linear com atraso de t-1.

O mesmo método foi utilizado para previsões com regressão de ordem dois, três, quatro, cinco e seis, e horizonte temporal t+1.

A performance dos modelos foi obtida aplicando-se a equação (2.9), tendo em conta o critério do erro médio absoluto, sendo que os primeiros resultados se podem observar na tabela 4.1.

Tabela 4.1 - Performance dos modelos de regressão para o instante t+1.

	AR(1)	Persister	AR(2)	Persister	AR(3)	Persister	AR(4)	Persisten	AR(5)	Persister	AR(6)	Persisten
MAE	0,45053	0,4536	0,44421	0,57285	0,44197	0,6564	0,441	0,697734	0,4407	0,7499	0,4407	0,788173
MSE	0,39452	0,41251	0,37761	0,62595	0,37144	0,76907	0,3667	0,861797	0,3665	0,97667	0,3658	1,074033
RMSE	0,6281	0,64227	0,6145	0,79117	0,60946	0,87697	0,6056	0,92833	0,6054	0,98827	0,6048	1,036356
Perfor.	0,6763		22,4559		32,6679		36,797		41,231		44,088	

Para dados menos robustos, tais como os que foram verificados em janeiro de 2011, o modelo sofre algumas alterações. O SSAD, forneceu 4462 dados históricos para o mês de agosto de 2010 e 4291 para janeiro de 2011, ou seja, em janeiro foram registados menos 171 instantes de tempo. A aplicação da Regressão produziu os resultados seguintes:

Tabela 4.2 - Performance da regressão para t+1 com dados de janeiro de 2011.

	AR(1)	Persister	AR(2)	Persister	AR(3)	Persister	AR(4)	Persisten	AR(5)	Persister	AR(6)	Persisten
MAE	0,6984	0,46296	0,57233	0,58176	0,54286	0,65881	0,5343	0,713501	0,532	0,74829	0,5336	0,793872
MSE	3,66147	4,41481	3,16717	4,6314	0,28955	4,84777	2,8973	4,962596	2,8379	5,03093	2,8088	5,161575
RMSE	1,9135	2,10115	1,77965	2,15207	0,5381	2,20177	1,7022	2,227688	1,6846	2,24297	1,6759	2,27191
Perfor.	-50,857		1,62144		17,6005		25,12		28,906		32,785	

O *Quadrado de R*, apresenta valores entre 0,43 para AR(1) e os 0,56 para AR(6), mostrando que a adequação da curva de regressão aos dados é, apenas, na ordem dos 43% a 56%, aproximadamente metade comparativamente ao mês de agosto de 2010.

SUMÁRIO DOS RESULTADOS

Estatística de regressão	
R múltiplo	0,658637506
Quadrado de R	0,433803364
Quadrado de R ajus	0,433671322
Erro-padrão	1,913942684
Observações	4290

ANOVA

	gl	*SQ*	*MQ*	*F*	*F de significância*
Regressão	1	12034,78	12034,78	3285,34065	0
Residual	4288	15707,7	3,663177		
Total	4289	27742,48			

	Coeficientes	*rro-padrã*	*Stat t*	*valor P*	*95% inferior*
Interceptar	1,252202428	0,051305	24,40721	2,607E-123	1,15161886
Variável X 1	0,658670252	0,011492	57,31789	0	0,636140908

Figura 4.7 - Sumário dos resultados da regressão AR(1) no instante *t+1* em janeiro de 2011.

O mesmo analisador de dados, com uma regressão de ordem 3, foi testado para se prever o valor da velocidade do vento para um horizonte temporal de 4 horas à frente (*t+24*, dado que os intervalos de tempo têm 10 minutos) e, novamente, para dados relativamente ao mês de agosto de 2010. Para se verificar a performance de cada uma das simulações calculou-se o ganho aplicando o MAE como critério de avaliação. A tabela seguinte mostra os resultados obtidos quer para os erros absolutos médios quer para o ganho.

Tabela 4.3 - Simulações usando a Regressão e horizonte t+24 aplicando substituições sucessivas das previsões com dados de agosto de 2010.

Regressão linear de ordem 1, 2 e 3 para t+24 (dados de agosto de 2010)

Tipo de previsão	AR1(24)	AR2(24)	AR3(24)
MAE	1,223982005	1,18773633	1,176200909
MSE	2,221342327	2,128197458	2,111131536
MAE(P)	1,403742954	1,403653586	1,403519062
MSE(P)	3,179711387	3,17969779	3,179512745
Performance do modelo	12,80583089	15,38251731	16,19629962

No método, o valor da previsão para o instante t+24, foi obtido seguindo a metodologia em que, para se prever o instante t+2, se substitui o valor da velocidade do vento para t+1, pela previsão que foi calculada para o instante t+1. O mesmo processo é aplicado para o instante t+3 e vão-se efetuando previsões e substituições sucessivamente, até se chegar à previsão t+24. A performance foi obtida usando como critério de referência o MAE da persistência e o MAE como critério do modelo AR.

O mesmo critério aplicado a valores medidos em janeiro de 2011 deu como resultados os que se apresentam na tabela 4.4.

Tabela 4.4 - Simulações usando a Regressão Linear e horizonte t+24 aplicando substituições sucessivas das previsões (dados de janeiro de 2011).

Tipo de previsão	AR1(24)	AR2(24)	AR3(24)
MAE	1,679284274	1,655542171	1,559301524
MSE	6,466345828	6,347806713	5,881576217
MAE(P)	1,222212327	1,239306142	1,257064478
MSE(P)	6,529855683	6,567219925	6,560892896
Performance do modelo	-37,39709842	-33,58621536	-24,04308221

Outro esquema sujeito a simulação está relacionada com o avanço direto da primeira previsão *t+1* transportando-a para *t+24*. Usando as regressões de ordem 1,2 e 3, calcula-se

t+1 e aplica-se esse resultado em t+24, tal como se indica na figura 4.8. Os resultado da simulação estão representados na tabela 4.5.

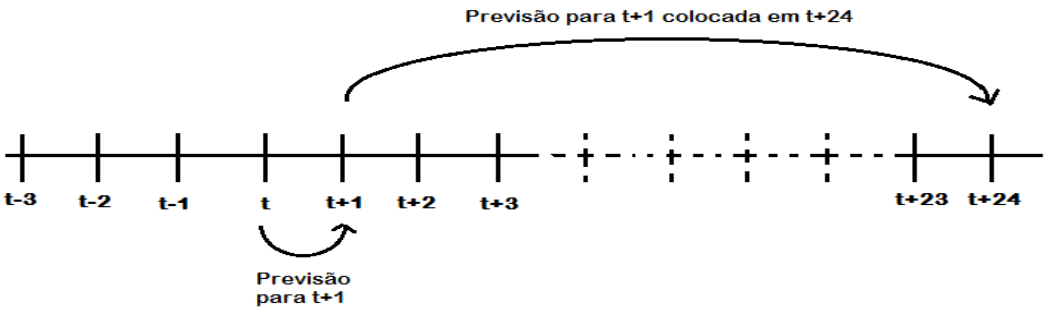


Figura 4.8 - Previsão t+1 colocada diretamente em t+24.

Tabela 4.5 - Resultados de Regressão Linear para t+24 avançando a previsão t+1.

Regressão linear de ordem 1, 2 e 3 para t+24 (dados de agosto de 2010)

Avanço direto da previsão t+1 para t+24

Tipo de previsão	AR1(24)	AR2(24)	AR3(24)
MAE	1,343954408	1,350381603	1,354589682
MSE	2,920313616	2,930370207	2,940140181
MAE(P)	1,403742954	1,403653586	1,403519062
MSE(P)	3,179711387	3,17969779	3,179512745
Performance do modelo	4,259223245	3,795237157	3,486192705

Capítulo 5

Previsões usando modelos de otimização

Modelar significa representar o sistema físico real, em forma física ou simbólica, de forma adequada com o objetivo de se predizer o seu comportamento. Simular prende-se com o facto de submeter modelos a ensaios sob diversas condições, para observar como eles se comportam. Um modelo de otimização, pretende encontrar a solução mais adequada entre várias soluções alternativas, tendo em conta um critério de avaliação das soluções alternativas, para identificar a mais adequada. Este critério de avaliação chama-se função objetivo, a qual pretendemos maximizar ou minimizar. As soluções alternativas devem ser passíveis de execução indicando a presença de restrições que devem ser respeitadas.

Expresso de outra forma: tem-se uma função *f*, chamada de função objetivo, definida no conjunto de soluções alternativas, representado por Ω.
Um problema de otimização matemática é definido por: min *f* (x), tal que x ϵ Ω.

5.1 O Solver do Excel

O Excel inclui uma ferramenta chamada *Solver* que usa técnicas da investigação operacional para encontrar a melhor solução em um problema de otimização. Esta ferramenta ativa-se junto das aplicações do Excel, antes de poder ser utilizada, e encontra-se na barra de dados, de onde se pode executar.

Disponibilizada a aplicação, deverá formular-se o modelo. Neste caso, pretende-se usar o *Solver* para efetuar previsões relativamente a uma série temporal cujos dados representam a velocidade média do vento, em intervalos de dez minutos. Entre os vários métodos que se podem aplicar a séries temporais, foi escolhido o auto regressivo, por ter sido referido com um dos que obteve melhores resultados nas previsões a muito curto prazo, nomeadamente o autorregressivo de ordem três.

Num processo autorregressivo, o valor presente da série temporal $X_t, t \in Z$, é expresso linearmente em termos dos valores passados da série e da perturbação aleatória ε_t ocorrida

no instante *t*. A ordem deste processo depende do valor mais antigo sobre o qual a regressão tem lugar. Esta abordagem foi feita em 3.2.2.6, em que o processo é dado pela expressão $X_t = \phi_0 + \phi_1 X_{t-1} + \cdots + \phi_p X_{t-p} + \varepsilon_t$, e onde, $\phi_0, \phi_1, \ldots, \phi_p$ são parâmetros reais e ε_t é um processo discreto puramente aleatório.

O método aplicado na realização de previsões pode, por vezes, originar valores que são maiores que o valor real (erro negativo) ou pode, apresentar valores mais baixos (erro positivo). A precisão do método de previsão é avaliada através do cálculo dos erros de previsão. Entre os vários métodos usados para medir essa precisão, os dois mais populares são o MAE e o MSE.

A formulação para um AR de ordem 3 (AR(3)), por exemplo, pode ser dada por:

- X_t - Valor real observado no instante t.
- $\hat{X}_t$ - Valor previsto para o instante t.
- e_t - erro de previsão = $X_t - \hat{X}_t$
- $\hat{X}_t = ø_0 + ø_1 * X_{t-1} + ø_2 * X_{t-2} + ø_3 * X_{t-3}$
- MAE = (Σ | e_t |)/n
- MSE = (Σ e_t^2)/n

em que n representa a quantidade de observações utilizadas no método.

Inicialmente, os dados e as fórmulas podem introduzir-se no Excel segundo a estrutura aplicada na figura 5.1, ficando o problema preparado para a aplicação do processo de otimização.

O objetivo é encontrar-se a melhor solução, alterando os coeficientes $ø_0$, $ø_1$, $ø_2$ e ø3, usando o *Solver* como ferramenta de otimização. Como se pretende minimizar o erro entre a previsão realizada e o valor observado (da velocidade do vento), a função objetivo (ou alvo) é a função que representa o MAE, tentando minimizá-la o máximo possível. As restrições do método passam por garantir que os coeficientes $ø_0$, $ø_1$, $ø_2$ e $ø_3$ tenham valores superiores a 0 e inferiores a 1, e que, a soma dos coeficientes seja menor que um, para se garantir que o processo é estacionário. Observe-se a figura 5.2.

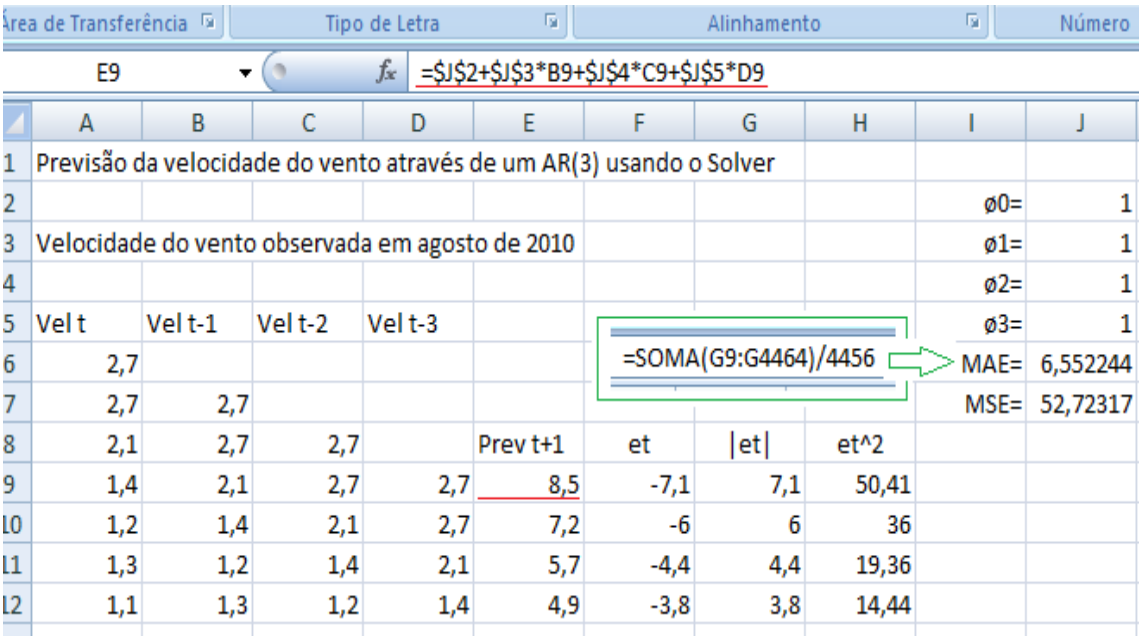


Figura 5.1 - Exemplo de preparação do método AR no Excel.

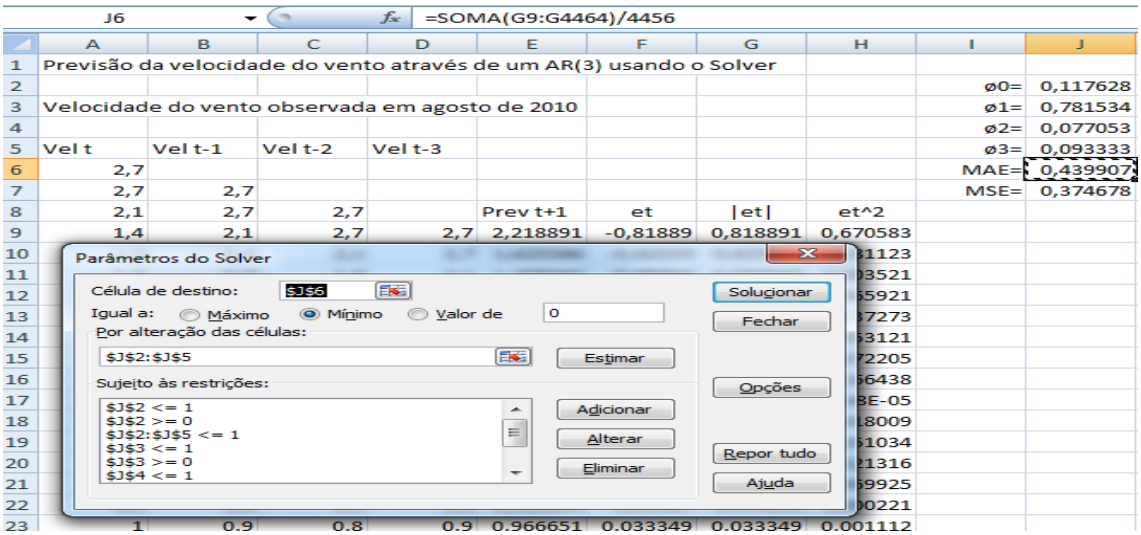


Figura 5.2 - Utilização do Solver no método AR(3).

5.2 Previsão da velocidade do vento otimizando métodos autorregressivos

Aplicando o processo anterior na previsão da velocidade do vento para o instante t+1, usando auto regressão de ordem 1, 2 e 3, obtiveram-se os resultados da tabela seguinte.

Tabela 5.1 - Evolução dos erros e da performance do método auto regressivo para t+1 aplicando o Solver (observações de agosto de 2010).

	AR1(1)	AR2(1)	AR3(1)
MAE	0,447981022	0,442276654	0,439906882
MSE	0,396509343	0,380316161	0,374677851
MAE(P)	0,453052065	0,573159785	0,656328546
MSE(P)	0,412010772	0,626481149	0,769192101
Performance	1,119306887	22,83536525	32,9745925

Com a mesma ferramenta de otimização, foram efetuadas novas simulações no sentido de se perceber qual a resposta do método quando aplicado a novos dados, pertencentes ao mês de janeiro de 2011. Os resultados aparecem na tabela 5.2.

Tabela 5.2 - Evolução dos erros e da performance do método auto regressivo para t+1 aplicando o Solver (observações de janeiro de 2011).

Método auto regressivo com dados de janeiro de 2011

	AR1(1)	AR2(1)	AR3(1)
MAE	1,886850869	0,455051884	0,455040644
MSE	8,116785427	3,68299572	3,683714645
MAE(P)	2,136314685	0,581762649	0,658810634
MSE(P)	9,513813543	4,631404104	4,847771968
Performance	11,67729728	21,78049155	30,92997898

O mesmo método aplicado a meses e anos diferentes, para um horizonte temporal *t+1*, manteve um ganho aproximado de 30%, a partir da solução do *Solver* para um AR3.

A ferramenta de otimização aplicada ao método auto regressivo foi usada para efetuar previsões relativamente a um horizonte de 4 horas, ou seja, *t+24* intervalos de tempo. Os resultados tendo em consideração os critérios MAE, MSE e ganho, estão apresentados nas tabelas 5.3 e 5.4.

Tabela 5.3 - Previsão para um horizonte de 4 horas e coeficientes calculados a partir do Solver (observações realizadas em agosto de 2010).

Método auto regressivo com dados de Agosto de 2010

	AR1(24)	AR2(24)	AR3(24)
MAE	1,285217158	1,354385533	1,282869333
MSE	2,737790758	2,92917044	2,715076081
MAE(P)	1,403699526	1,43125	1,458519522
MSE(P)	3,179842093	3,283138538	3,389119838
Performance	8,440721552	5,370443135	12,04304681

Tabela 5.4 - Previsão para um horizonte de 4 horas e coeficientes calculados a partir do Solver (observações de janeiro de 2011).

Método auto regressivo com dados de janeiro de 2011

	AR1(24)	AR2(24)	AR3(24)
MAE	1,232602246	1,193397915	1,186552263
MSE	4,99658714	5,210374592	5,114827014
MAE(P)	1,222212327	1,239015702	1,257064478
MSE(P)	6,529855683	6,565680853	6,560892896
Performance	-0,85009114	3,681776368	5,609275933

Na tabela 5.5, apresentam-se os resultados obtidos da aplicação do método a valores medidos da velocidade do vento para diversos meses de 2012, tendo em conta um horizonte de previsão de 4 horas.

Tabela 5.5 - Resultado dos erros e da performance para os meses de 2012 e um horizonte de previsão de 4 horas.

Janeiro	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,044288289	1,037174356	1,032463353	4464
MSE	1,810859997	1,78671227	1,770258491	
MAE(P)	1,099031532	1,109146204	1,118183867	
MSE(P)	2,010164414	2,050779455	2,083968004	
Performance	4,981043835	6,488941485	7,666048149	

Fevereiro	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,193495184	1,187047043	1,18300267	
MSE	2,432289969	2,415267443	2,402229192	
MAE(P)	1,292678227	1,306094917	1,320289157	4176
MSE(P)	2,768318882	2,831616478	2,879489157	
Performance	7,672678381	9,114794997	10,3982136	

Março	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,044288289	1,260173247	1,258278132	
MSE	1,810859997	2,452945506	2,44233978	
MAE(P)	1,099031532	1,352083803	1,368792249	4464
MSE(P)	2,010164414	2,861777427	2,934828752	
Performance	4,981043835	6,797696699	8,073841523	

Setembro	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,159840227	1,153171229	1,101796241	
MSE	2,127953124	2,101863921	1,930949392	
MAE(P)	1,218735763	1,232469382	1,244915978	3536
MSE(P)	2,359105923	2,414098547	2,459780689	
Performance	4,832510716	6,434087015	11,4963371	

Outubro	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,062963822	1,052197983	1,047441473	
MSE	1,900982138	1,873228066	1,860976518	
MAE(P)	1,094166667	1,104054967	1,120887787	4464
MSE(P)	2,067083333	2,119353458	2,181899504	
Performance	2,851745105	4,696956722	6,552512697	

Novembro	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,151477473	1,144724209	1,137605502	
MSE	2,206186009	2,180773756	2,158964227	
MAE(P)	1,231246343	1,234309133	1,250205038	1733
MSE(P)	2,512404915	2,583665105	2,64370826	
Performance	6,478709193	7,25790017	9,006485539	

Dezembro	AR1(24)	AR2(24)	AR3(24)	N
MAE	1,107597351	1,096402992	1,089054222	
MSE	2,068381729	2,042361384	2,024276193	
MAE(P)	1,116734234	1,129015544	1,139770167	4464
MSE(P)	2,165772523	2,223268754	2,271602073	
Performance	0,818178867	2,888583054	4,449664144	

N: Quantidade de dados disponíveis em cada um dos meses

Capítulo 6

Previsão de curto prazo da velocidade do vento usando redes neuronais

Em muitas áreas da sociedade as pessoas tentam prever o futuro, especialmente no sistema económico. Ao longo dos anos, muitos *softwares* foram desenvolvidos para este efeito, incluindo as Redes Neuronais.

Uma RN é um *software* de computador (podendo também envolver *hardware*) que simula um modelo simples das células neuronais que existem nos humanos. O propósito desta simulação tem como objetivo captar as caraterísticas de cada uma das células. Pode levar-se uma RN a desempenhar determinada tarefa utilizando-se para isso os procedimentos seguintes:

- Fornecer dados originais à rede para que esta realize uma fase de treino. Estes dados são formados por um conjunto de atividades padrão e são introduzidos nas unidades de entrada da rede em simultâneo com um conjunto de atividades padrão, o qual é desejado à saída da rede;
- Compara-se o valor que se obteve na saída com o valor pretendido nessa mesma saída;
- Alteram-se os pesos de cada conexão de modo a que a rede produza os resultados que mais se aproximem dos valores desejados.

Após a fase de treino, a rede recolheu informação sobre os padrões que existem nos dados, estando agora preparada para a introdução-de novos dados, podendo a mesma ser usada para diferentes propósitos. A RN pode ser usada para:

- Prever eventos futuros baseando-se em padrões observados nos dados introduzidos na fase de treino;
- Classificação de dados novos em grupos pré-definidos baseando-se nas caraterísticas observadas nos dados usados na fase de treino;
- Agrupar os dados de treino em grupos naturais baseando-se para isso em caraterísticas similares que se encontram entre os dados aplicados na fase de treino.

6.1 Previsão usando a RN disponível no MATLAB para um horizonte de 10 minutos

Abrindo o *software* Matlab, preparam-se os dados para a rede no *Workspace* do programa. Esses dados podem ser copiados de células de uma folha de *Excel*, por exemplo, para o *workspace*, selecionando-se a opção *New*. Introduzem-se desta forma as variáveis necessárias para a rede que contêm os dados de entrada, dados alvo e dados com uma amostra, tal como pode verificar-se na figura 6.1.

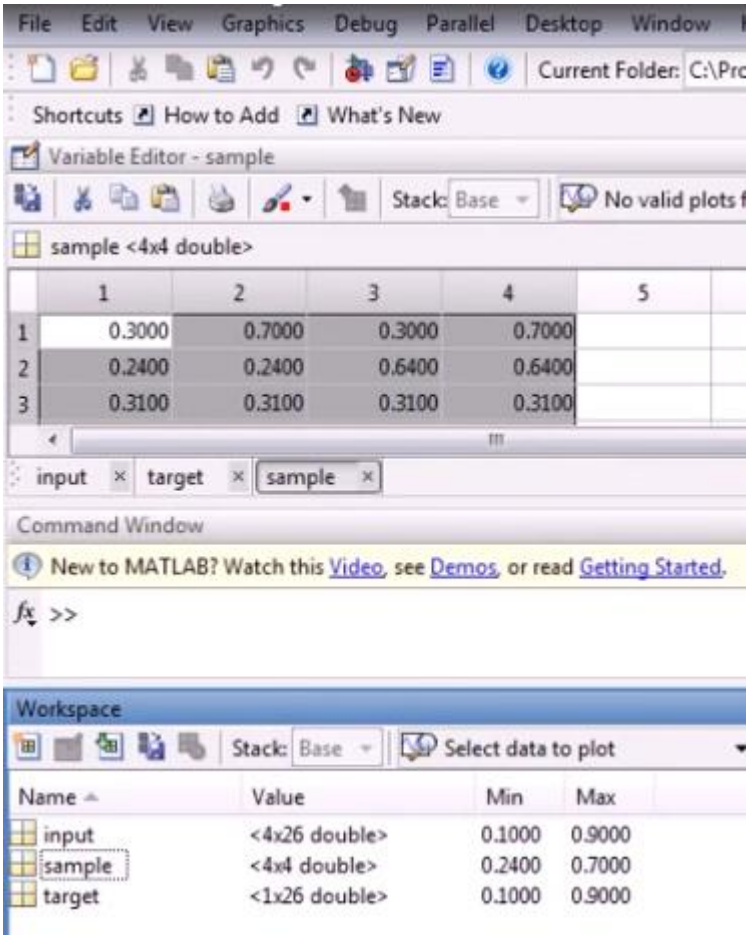


Figura 6.1 - Preparação das variáveis

Os dados quando transportados para o Excel aparecem no formato de colunas mas devem ser transpostas para linhas, de modo a que as variáveis no MATLAB estejam na estrutura apropriada. Criadas as três variáveis, recorre-se à ferramenta para aceder à rede neuronal do programa, designada por *nntool*,a partir da linha de comandos e da forma como se indica na figura 6.2.

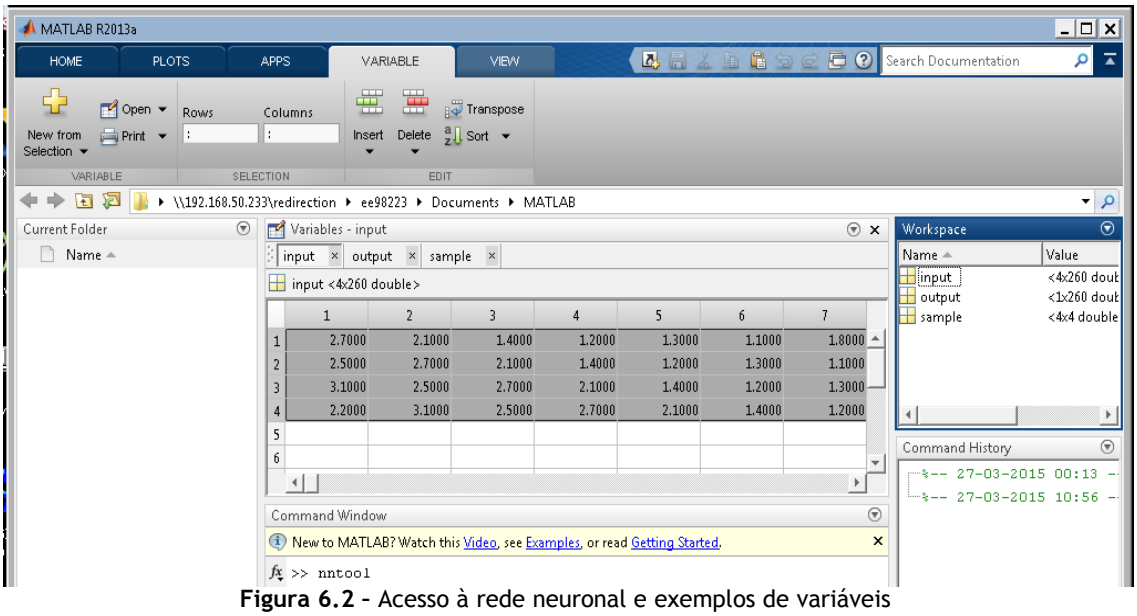


Figura 6.2 – Acesso à rede neuronal e exemplos de variáveis

O anterior comando disponibiliza o acesso à rede neuronal e permite a inserção das variáveis na mesma através da opção *import*. Surge agora a necessidade de se definir o destino das variáveis importadas para a rede como sendo variáveis de entrada, saída ou alvo. Ver figura 6.3.

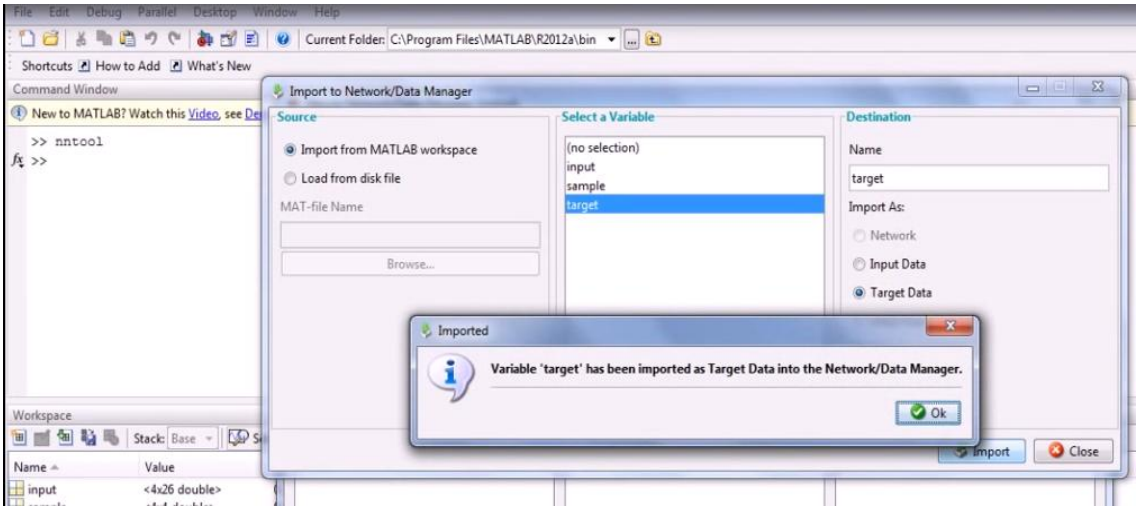


Figura 6.3 – Importação de variáveis para a RN.

Concluída a importação das variáveis, na opção *New* pode criar-se uma nova rede, na qual se devem definir novamente as variáveis, e preencher as restantes janelas. Ver figura 6.4.

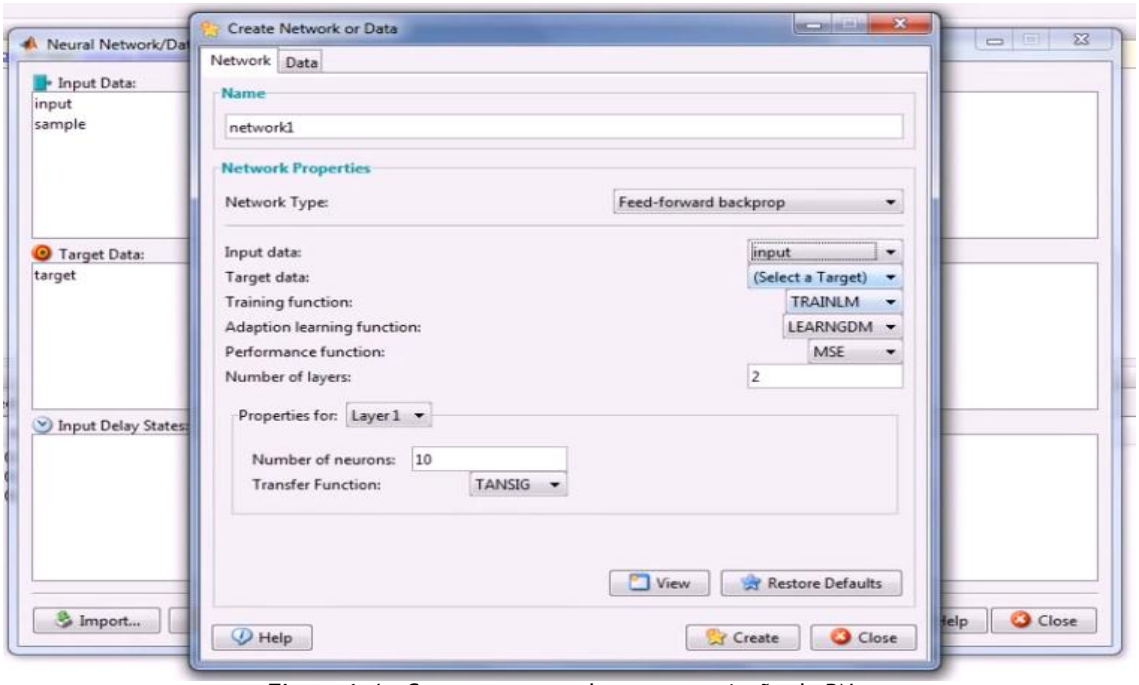


Figura 6.4 – Campos a preencher para a criação da RN.

Os diversos campos da rede foram preenchidos com base nos conhecimentos, experiências e resultados obtidos por profissionais, estando esta informação disponível no sítio do MATLAB dedicado às RNs. Ver figura 6.5.

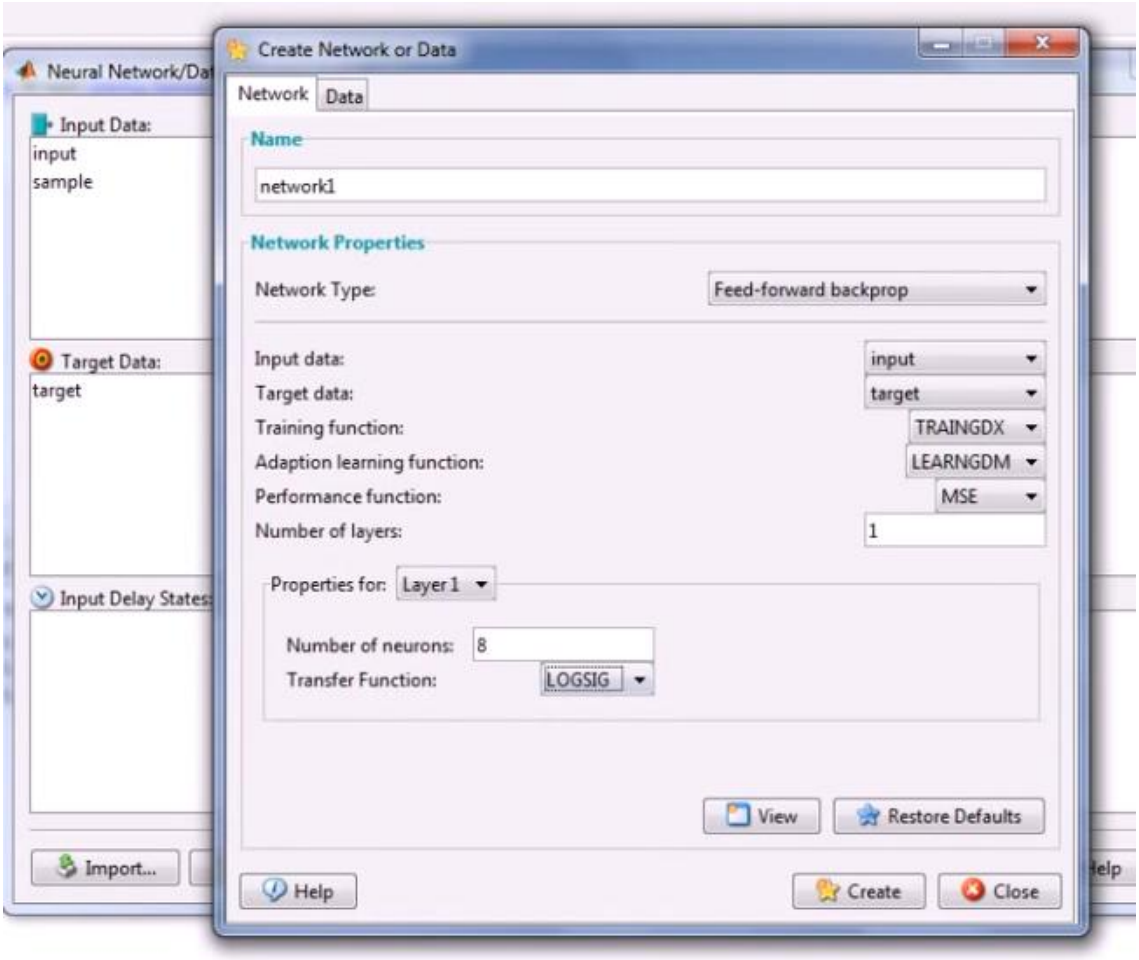


Figura 6.5 – Definição da RN.

Criada a tabela em *Create* (como a da figura 6.6), a rede encontra-se em condições de passar à sua fase de treino logo que os respetivos campos sejam preenchidos, podendo neste caso, optar-se por recolher esta informação baseada em experiências de técnicos experientes no sítio do MATLAB designado para o efeito.

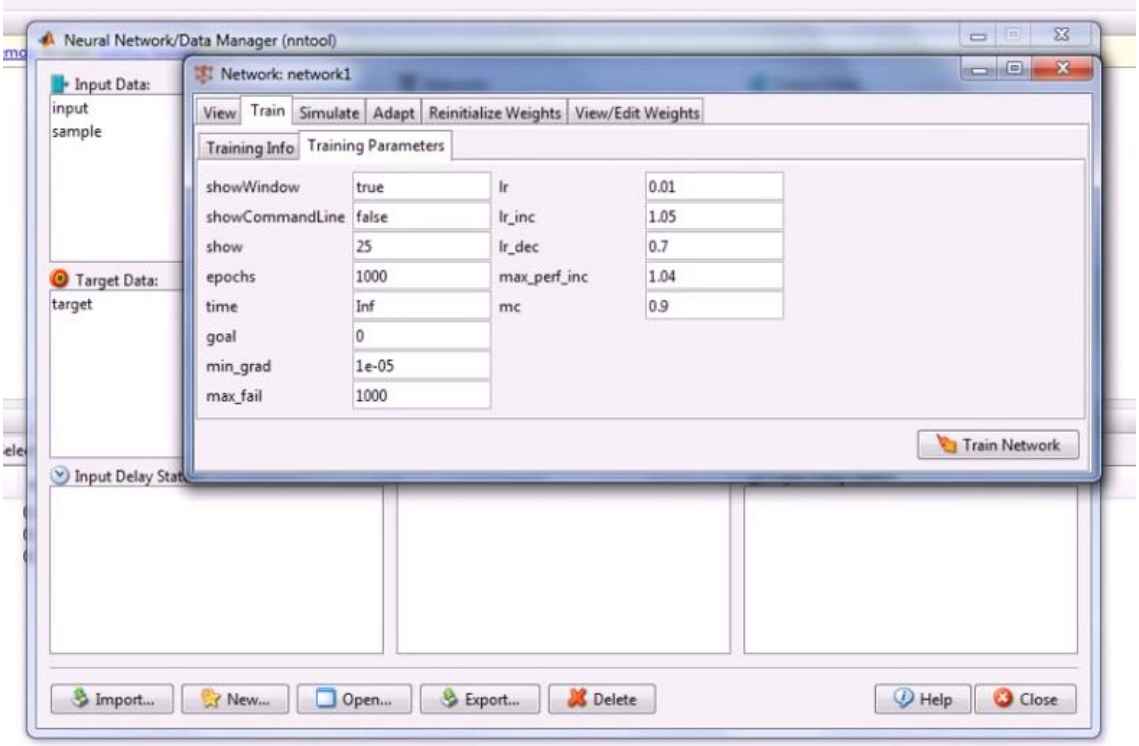


Figura 6.6 – Definição dos parâmetros da rede para a fase de treino.

Concluída a fase de parametrização passa-se à fase de treino, onde se deve analisar o diagrama de regressão, uma vez que a rede tem de ser validada. Ver figuras 6.7 e 6.8.

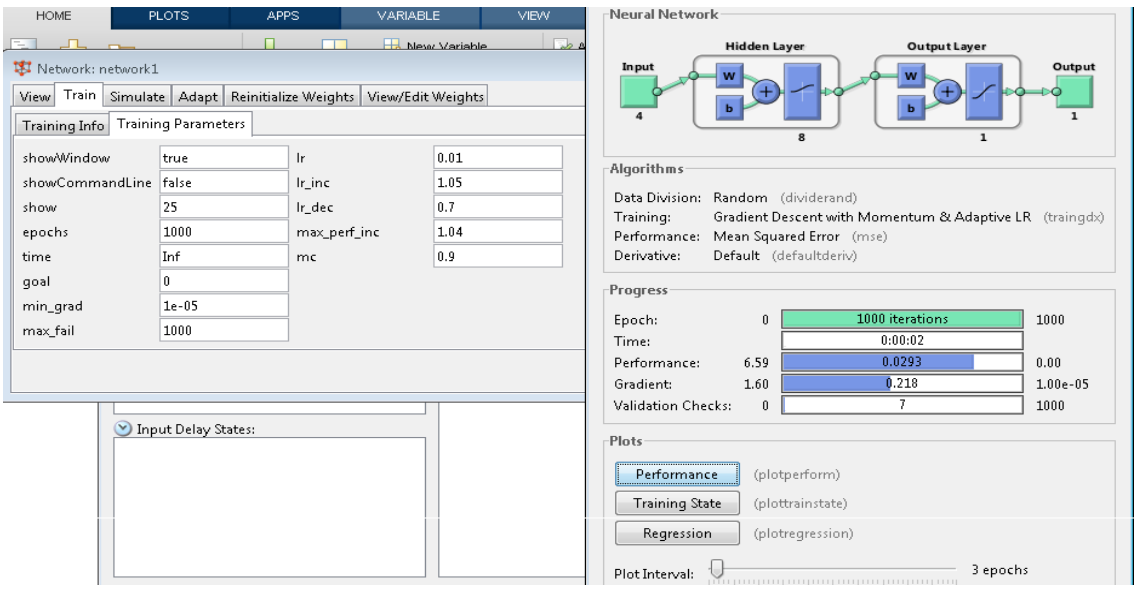


Figura 6.7 – Fase de treino da rede.

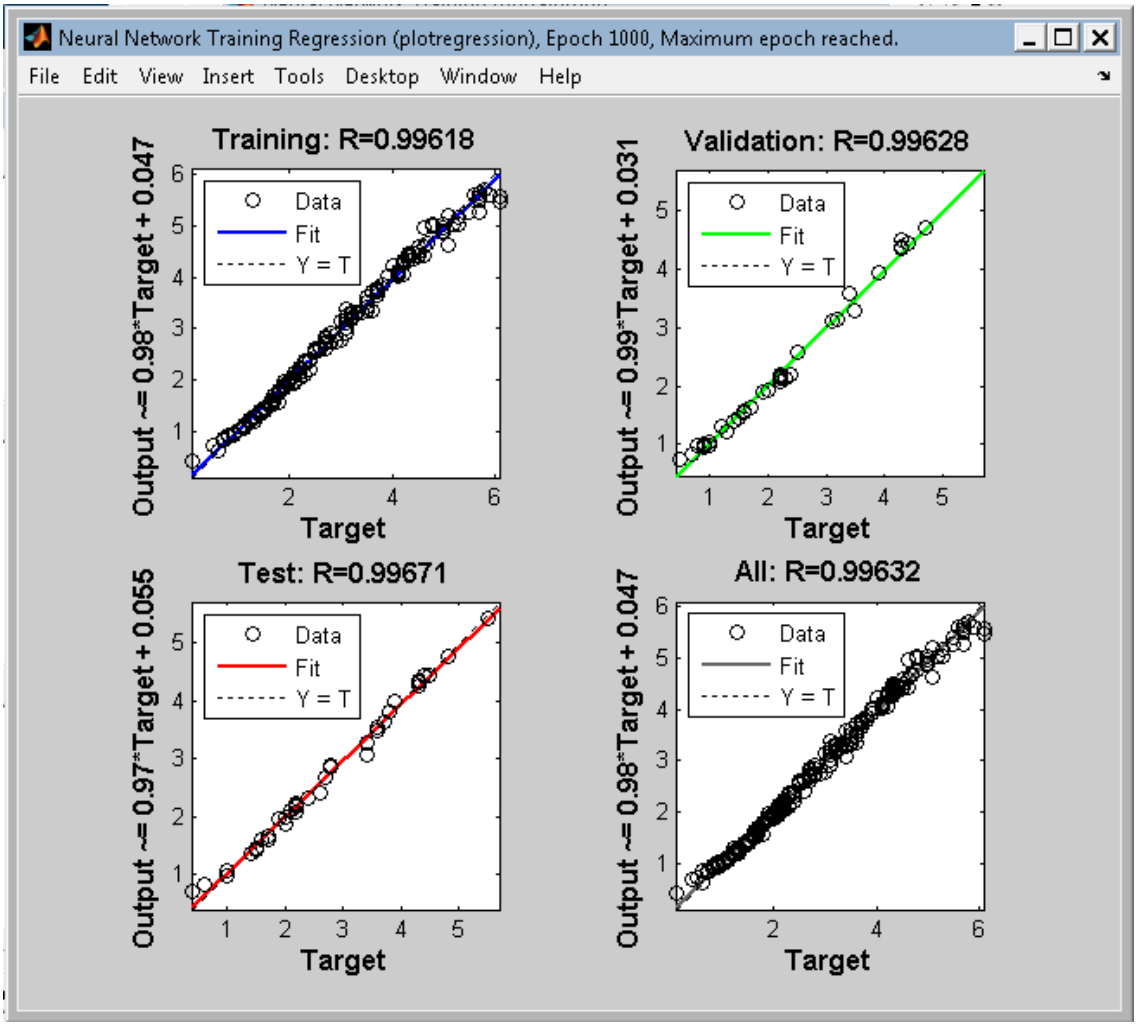


Figura 6.8 - Diagramas da rede resultantes da fase de treino.

Exportando-se os dados gerados pela rede, estes aparecem no ambiente de trabalho do MATLAB. Na figura 6.9, encontram-se os dados de saída e os erros obtidos entre os resultados desejados e os dados de saída, gerados pela rede.

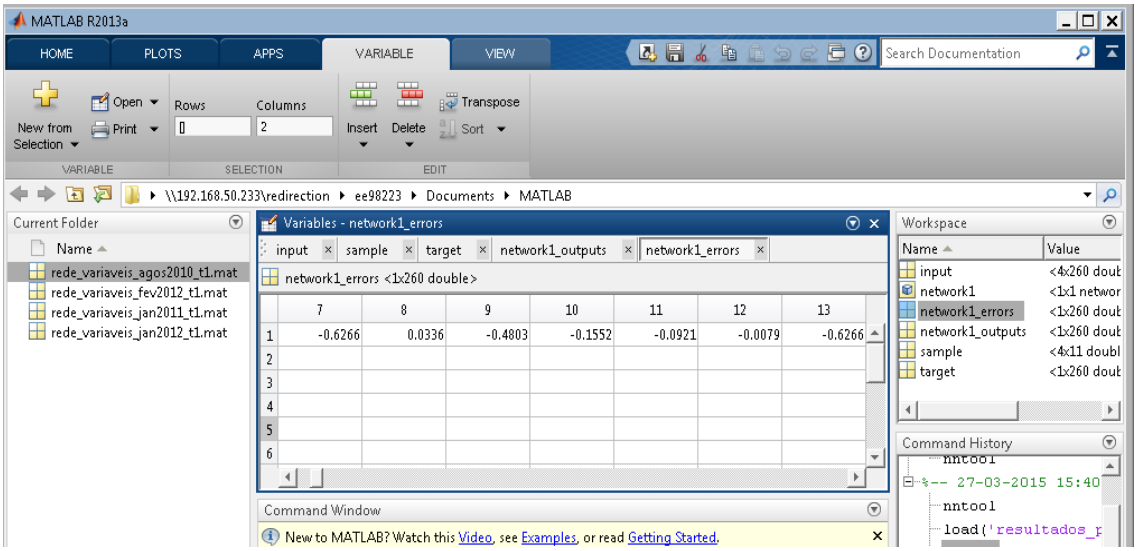


Figura 6.9 - Exemplo de variáveis geradas pela RN.

Caso os parâmetros não fossem alterados, os valores de R obtidos são muito inferiores aos obtidos pela rede anterior. Ver figura 6.10.

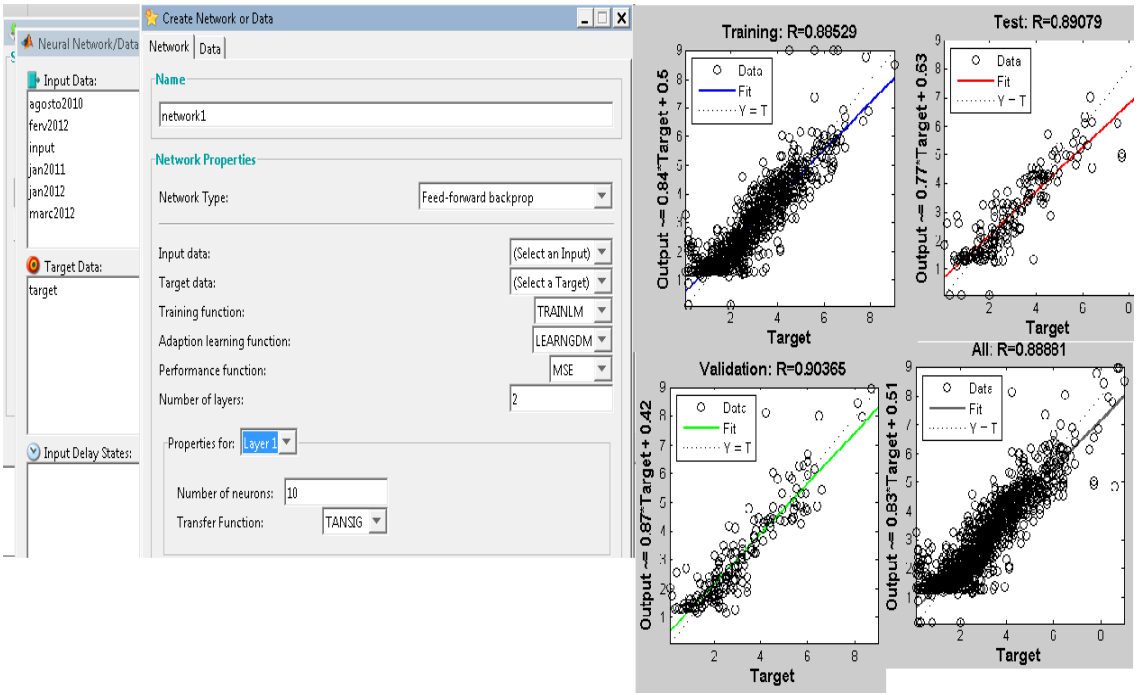


Figura 6.10 – RN com parâmetros pré definidos pela nntool.

A rede parametrizada na figura 6.10 recebeu variáveis com 1200 dados históricos em que existe uma regressão de ordem 4, ou seja, consideram-se os quatros valores anteriores para se calcular o instante seguinte. A rede foi usada para gerar soluções para dois meses escolhidos em anos diferentes, para um horizonte de previsão t+1, apresentando-se os resultados obtidos na tabela seguinte. Os resultados demonstram que essa rede deve ser melhorada.

Tabela 6.1 – Resultados da rede *network1* para um horizonte de previsão t+1 (10 minutos) em relação à persistência.

Janeiro de 2011		Janeiro de 2012	
MAE=	0,565587	MAE=	0,412263
MAE(P)=	0,439833	MAE(P)=	0,3985
Ganho=	-28,5912	Ganho=	-3,45364

Os resultados da tabela anterior obtiveram-se simulando a *network1*.

Na figura 6.11 representa-se um exemplo de como usar a RN na fase de simulação. Terminada a fase de treino, inicia-se a fase de simulação da RN para novos dados, que se encontram, neste exemplo, na varável *sample*. Seleciona-se a opção *Simulate* e altera-se a variável de entrada para *sample*, da forma que se apresenta na figura 6.11.

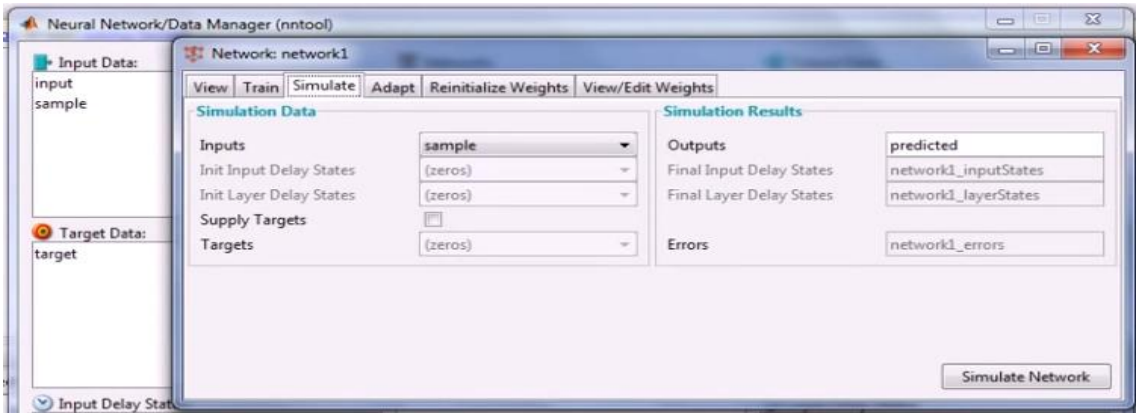


Figura 6.11 - Preparação da RN para a fase de simulação.

A velocidade do vento, sendo persistente no tempo, é difícil encontrar uma RN que tenha uma melhor performance que o método de persistência para horizontes de tempo inferiores ou iguais a 10 minutos. Uma nova rede é testada, sendo que os parâmetros da mesma são obtidos de uma fonte com mais experiência no campo das RN, como por exemplo, o sítio na rede global de dados disponibilizado pelo MATLAB e destinado a este tipo de redes. Ver figura 6.12.

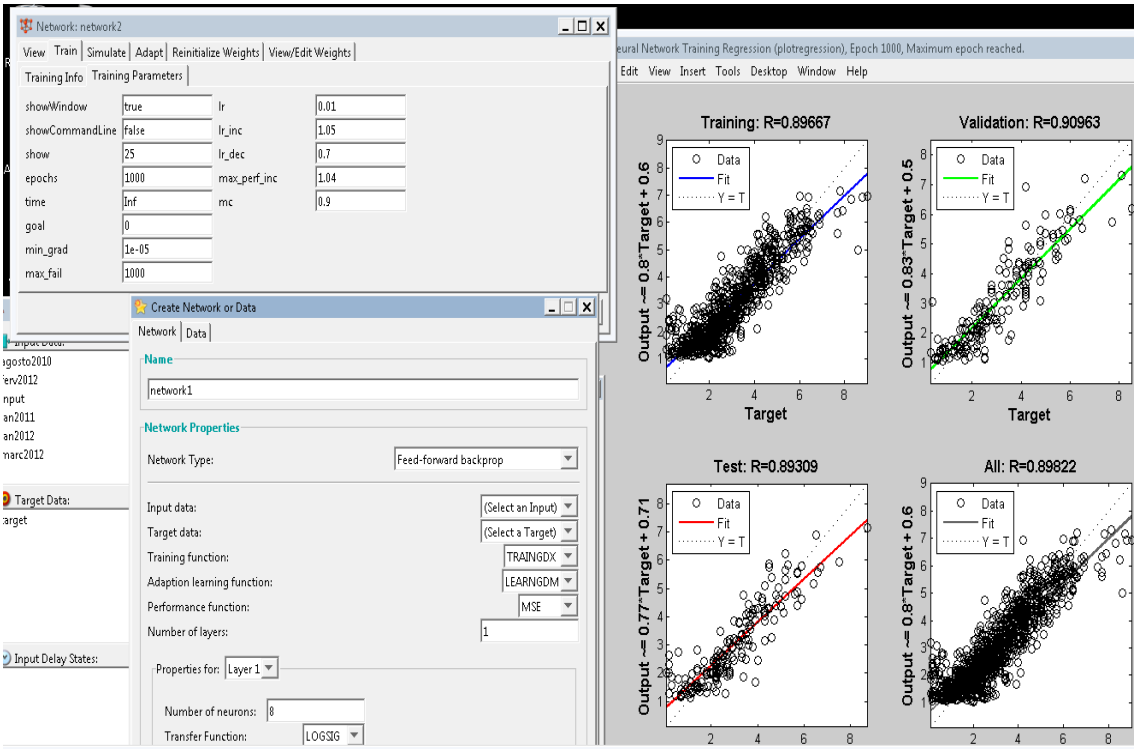


Figura 6.12 - Parametrização de uma nova rede.

A performance da nova rede foi bastante melhor que a *network1*, como pode verificar-se na tabela 6.2. Num dos meses o ganho foi positivo, indicando que a rede nesse caso tem uma performance melhor que o método de persistência.

Tabela 6.2 - Performance para a RN *network2*

Agosto de 2010		Janeiro de 2011		Janeiro de 2012		Fevereiro de 2012		Março de 2012	
MAE=	0,526104	MAE=	0,329848	MAE=	0,420124	MAE=	0,427064	MAE=	0,415482
MAE(P)=	0,5552	MAE(P)=	0,303	MAE(P)=	0,4142	MAE(P)=	0,4274	MAE(P)=	0,4082
ganho=	5,240563	Ganho=	-8,86057	Ganho=	-1,43014	Ganho=	0,078548	Ganho=	-1,78393

6.2 Previsão usando a RN *nntool* disponível no MATLAB para um horizonte de 4 horas

A rede para a qual se obtiveram os melhores resultados foi simulada para efetuar previsões para um horizonte temporal de 4 horas. O critério usado para calcular o ganho continua a ser o MAE, estando na tabela 6.3, representados os valores obtidos.

Tabela 6.3 - Resultados da RN para um horizonte de previsão de 4 horas

Agosto de 2010		Janeiro de 2011		Janeiro de 2012		Fevereiro de 2012		Março de 2012	
MAE=	1,427186	MAE=	0,939505	MAE=	1,02915	MAE=	0,846152	MAE=	1,106857
MAE(P)=	2,0388	MAE(P)=	0,848	MAE(P)=	1,0838	MAE(P)=	1,0984	MAE(P)=	1,0578
ganho=	29,99873	Ganho=	-10,7906	Ganho=	5,042451	Ganho=	22,96502	Ganho=	-4,63769

A rede apresenta uma performance muito diferente para meses distintos havendo situações em que a rede apresenta resultados inferiores ao método de persistência. Na fase de treino, o valor de R, que mede a adequação dos dados ao método, apresenta valores baixos, tal como se indica na figura 6.13. Na fase de treino foram usados 1200 dados históricos referentes ao mês de Agosto de 2010 sendo que, na fase de simulação foram utilizados 500. Manteve-se uma regressão de ordem 4.

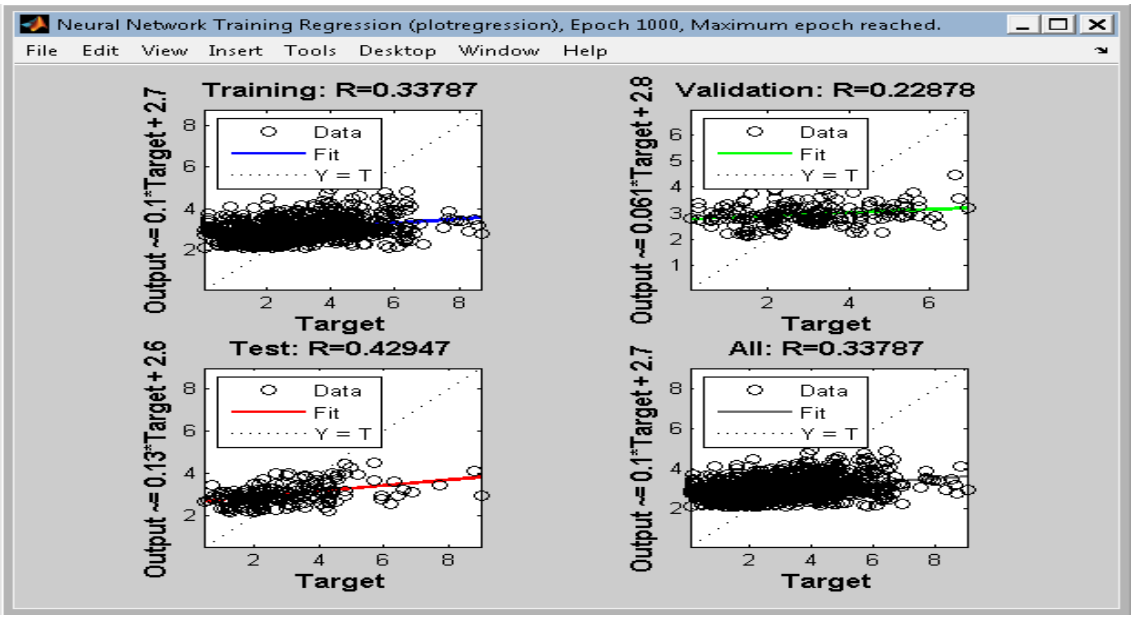


Figura 6.13 - Valores de R para a fase de treino da RN para uma previsão de 4 hora.

6.3 Previsão e modelização da RN para séries temporais usando o MATLAB

No MATLAB, o desenho da rede para a previsão de uma solução em função de valores passados de uma variável, pode realizar-se de duas formas:

- Usando uma interface gráfica, *ntstool*;
- Utilizando funções na linha de comandos.

Geralmente, a melhor forma é começar com o guia do *MATLAB* com o intuito de se gerar o código para a linha de comandos.

Ao definir-se o problema para a caixa de ferramentas *ntstool*, deve construir-se um conjunto de vetores de entrada TS. Estes vetores devem apresentar-se como sendo um conjunto de colunas de uma célula matricial. Seguidamente é necessário criar um conjunto de vetores alvo, que contêm as saídas desejadas para cada entrada. As redes neuronais para séries temporais no MATLAB, disponibiliza soluções para três tipos diferentes de problemas envolvendo séries temporais. O primeiro tipo de rede é aplicado quando se pretendem prever valores futuros de uma série temporal $y(t)$ a partir de valores passados dessa mesma série, e de valores passados de uma segunda série $x(t)$. Esta forma de previsão designa-se por auto regressão não linear com entrada exógena ou rede NARX, e pode ser escrita por:

$$y(t)=f(y(t-1),\ldots,y(t-d), x(t-1),\ldots.,x(t-d)) \quad (6.1)$$

O segundo tipo de problemas de séries temporais envolve apenas uma série. A previsão dos valores futuros de uma série y(t), depende apenas dos valores passados dessa série. Esta forma de previsão é designada por auto regressão não linear ou NAR, podendo representar-se da seguinte forma:

$$y(t)=f(y(t-1),\ldots.,y(t-d)) \quad (6.2)$$

O terceiro tipo de série temporal é similar ao NARX, onde estão envolvidas duas séries, sendo x(t) a série de entrada e, y(t) a série de saída ou alvo. Neste tipo de problemas pretende-se prever os valores de y(t) a partir dos valores passados de x(t), desconhecendo-se os valores passados de y(t). Este modelo pode ser representado da seguinte forma:

$$y(t)=f(x(t-1),\ldots.,x(t-d)) \quad (6.3)$$

A rede NARX é uma rede dinâmica recorrente com ligações de realimentação juntando várias camadas que constituem a rede. Na figura seguinte, apresenta-se o diagrama para uma rede constituída por duas camadas [60].

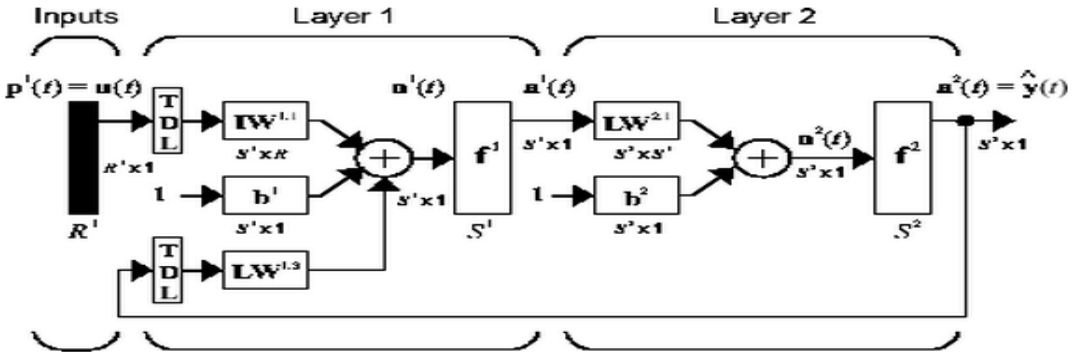


Figura 6.14 – Diagrama aproximado da NARX com duas camadas

A saída da rede NARX pode ser definida como sendo a saída estimada de um sistema dinâmico não linear, em que o objetivo é tentar modelizar o referido sistema. Na arquitetura *standard*, a saída serve para alimentar a entrada da RN, tal como se indica na figura 6.15 a).

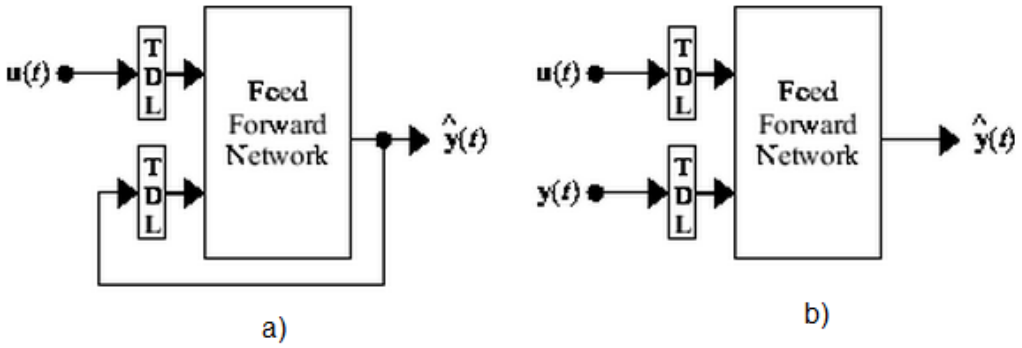


Figura 6.15 – Saída da NARX: a) Arquitetura em Paralelo e b) Arquitetura em Série-Paralelo.

Dado que a saída desejada se encontra disponível na fase de treino, pode criar-se a arquitetura Série-Paralelo, onde é usada a saída alvo ou desejada, em alternativa ao uso de uma realimentação em que a saída que alimenta a entrada é estimada. Este tipo de arquitetura está representado na figura 6.15 b). O conjunto das arquiteturas oferece duas vantagens. A primeira está relacionada com a precisão com que a entrada da rede é alimentada. A segunda resulta do facto da arquitetura da rede ser alimentada no sentido da entrada para a saída existindo de seguida a possibilidade de se usar a propagação no sentido inverso durante a fase de treino. Um conjunto de dados pode ser usado na fase de treino da rede neuronal de modo a que esta possa efetuar previsões, sendo que as previsões melhoram se as séries forem compostas por valores passados. O conjunto pode aparecer na forma de uma função que contém a série de entrada e a série alvo. No *MATLAB* as entradas devem aparecer no formato *cell*, criadas pelo comando *inputX=num2cell(InputX)*.

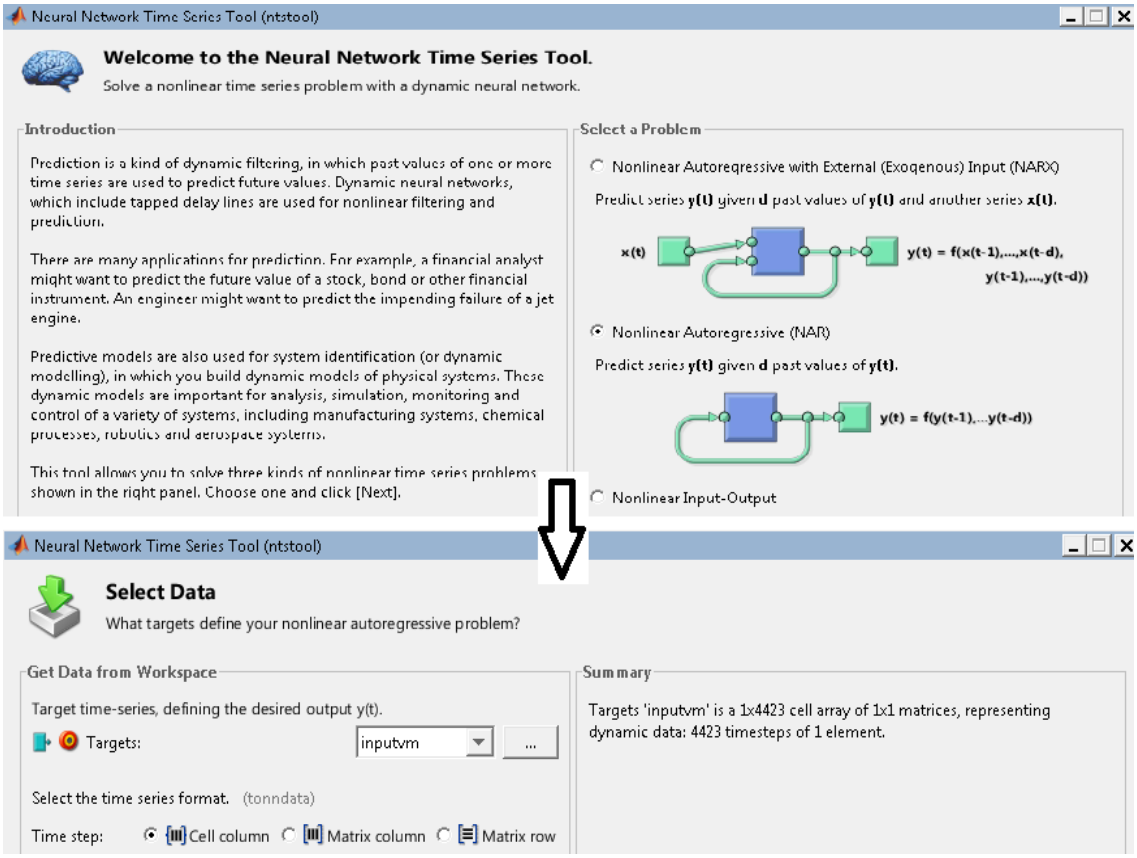


Figura 6.16 – Seleção da rede e dos dados da série.

No caso de ser selecionada uma rede NAR, cria-se uma apenas uma célula para a entrada, contendo os valores passados da mesma e, sobre a qual se irão efetuar as previsões. Na figura 6.16 apresentam-se alguns dos procedimentos a seguir. A célula de entrada escolhida tem 4423 dados representando os valores médios da velocidade do vento, referentes ao mês de janeiro de 2010, sendo importada para a rede a partir do espaço de trabalho do *MATLAB*. Os dados de entrada devem ser divididos em três conjuntos: treino; validação e teste. A divisão selecionada atribui 70% dos dados para a fase de treino, 15% para a validação e 15% para teste. A rede é constituída por 10 neurónios, 4 atrasos e o algoritmo escolhido para a fase de treino designa-se por *Levenberg-Marquardt*. Este algoritmo foi escolhido porque apresenta a melhor solução na maioria dos casos.

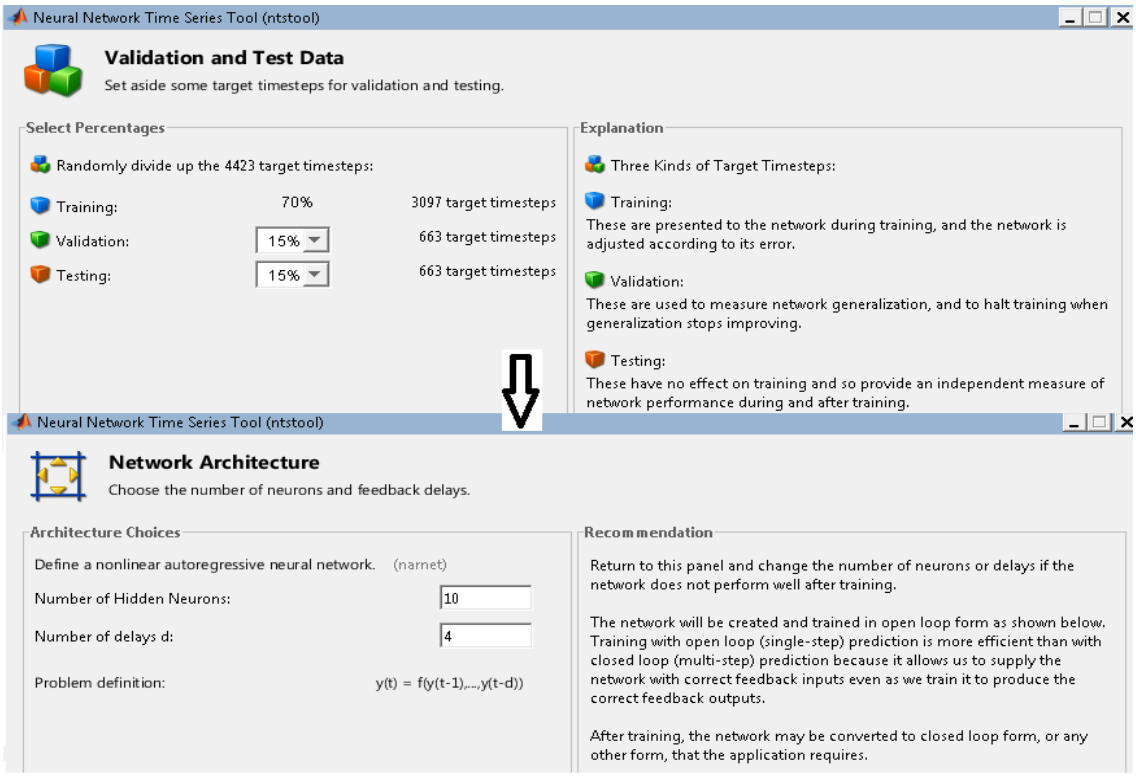


Figura 6.17 – Divisão dos dados e definição da rede.

Selecionados os campos anteriores sucede-se a fase de treino da RN, que durará até que o erro de validação pare de decrescer durante seis iteração.

A RN disponibiliza o acesso a um conjunto de diagramas, entre eles, o que representa a função de auto correlação entre os erros, que é usado para a sua validação. Este diagrama descreve como os erros de previsão estão relacionados no tempo. Num modelo de previsão perfeito, deverá existir apenas um valor diferente de zero na função de auto correlação, que deve acontecer no atraso zero, dado que se usa como critério o MSE. Seria uma situação em que os erros de previsão não estariam relacionados entre si (ruído branco). Se os valores da correlação entre os erros forem significativos, existirá a possibilidade de se melhorar a previsão, aumentando o número de atrasos da série, por exemplo.

Após a fase de treino da RN obteve-se o diagrama da figura 6.18, verificando-se que as correlações estão na sua maioria dentro do intervalo de confiança 95% junto ao eixo horizontal de valor 0, exceto no atraso zero, em que o valor da correlação é significativo.

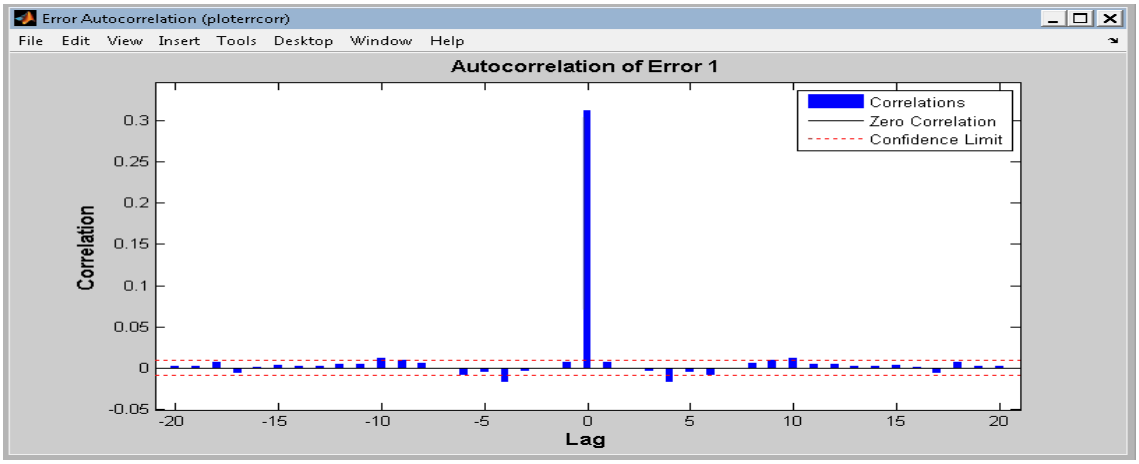


Figura 6.18 – Auto correlação dos erros para a NAR após a fase de treino.

A rede pode ser testada para novos dados. A performance da rede pode ser a desejada para os dados iniciais mas a sua performance pode ser inferior para novos dados, indicando que a RN pode ter sido sobre dimensionada. A solução neste caso pode passar pela redução de neurónios melhorando-se desta forma o resultado da rede. Na figura 6.19 apresentam-se os resultados para os dados iniciais (janeiro de 2010) e os resultados da rede para novos dados designados por *inputvm2* (4464 valores médios da velocidade referentes a outubro de 2012). Sendo a rede satisfatória, pode usar-se o painel do *Matlab* para gerar uma função ou um diagrama para se proceder à sua simulação. O diagrama ou o código gerado podem servir para se compreender melhor como a rede constrói a sua saída em função da entrada que lhe é aplicada.

Na tabela 6.4 apresenta-se o ganho obtido entre a RN e o modelo de persistência para meses e anos distintos, usando como critério o MSE. Pela tabela verifica-se que quando o MSE da persistência tem um valor inferior a 0.3, o ganho da NAR existe mas é pouco significativo. À medida que o MSE aumenta, os resultados da rede em relação à persistência são significativos, chegando aos 62%.



Figura 6.19 - Resultado da RN para diferentes entradas.

Tabela 6.4 - MSE e ganho da NAR (horizonte de previsão de 10 minutos).

Mês	Janeiro de 2010	Janeiro de 2011	Agosto de 2011	Março de 2012	Outubro de 2012	Novembro de 2012
MSE da Persistência	0,347	4,415	0,268	0,3	0,268	0,358
MSE da NAR	0,291	2,72	0,266	0,297	0,265	0,356
Ganho da NAR (%)	19,24	62,316	0,752	1,01	1,1321	0,5618

Capítulo 7

Conclusões

7.1 Principais conclusões

As expetativas relativamente às PCMCP são elevadas porque se reconhece que são o meio necessário para tornar a energia eólica tão competitiva como outras fontes de energia mais tradicionais, quando se pensa em termos de mercado da energia elétrica.

São vários os benefícios que se obtêm quando se melhora a precisão das previsões a muito curto prazo, dado que se reduzem custos associados à produção do sistema, causados pelo compromisso mais eficiente entre os geradores com tempo de arranque médio, diminuem-se as emissões de CO_2 para o ambiente, entre outros.

A criação de sistemas de previsão a muito curto prazo assenta em modelos estatísticos, baseados na abordagem efetuada às séries temporais, sendo que estes tipos de modelos, só tomam como entrada os valores passados da variável usada na previsão, podendo por vezes recorrer a variáveis explicativas.

Dada importância da PCMCP, a investigação nesta área tem dado origem ao desenvolvimento de numerosos processos de previsão. Estes processos podem ser classificados de forma grosseira em dois tipos: os métodos baseados em inteligência artificial e métodos clássicos. Os métodos das RNs, são particularmente atrativos porque têm a capacidade de lidar com a relação não linear que existe entre a saída, e os fatores que afetam essa saída diretamente, nomeadamente quando se usam dados históricos. Entre as abordagens clássicas, as mais populares são as que usam as técnicas da série temporal estocástica.

Os problemas de previsão do sistema de energia eólica são caracterizados de acordo com o seu horizonte temporal - muito curto prazo, curto prazo, médio prazo, ou longo prazo.

Nos modelos de previsão, utilizam-se ferramentas que avaliem a sua performance, através da análise dos erros de cada um dos sistemas desenvolvidos. Esta performance deve ser comparada com a performance de alguns modelos de referência, tais como: persistência, média global e novo modelo de referência. A avaliação da qualidade dos métodos de previsão

é feita, comparando as previsões da energia do vento para dado instante, com a observação que é feita para esse mesmo instante. A qualidade de um determinado método é avaliada através da análise da diferença entre a previsão e o observado na realidade, para o mesmo instante de tempo. O modelo de persistência do vento ou previsão de energia assume que o vento (velocidade e direção) ou a energia, em um determinado momento futuro, será o mesmo que o valor medido no instante em que a previsão é feita, o que pode ser formulado como, $\hat{p}_{t+k} = p_t$. Quando se desenvolve um determinado modelo, é importante quantificar os benefícios que esse modelo proporciona, comparando-o com um modelo referência, designando-se estes benefícios por ganho ou performance.

Série Temporal é um conjunto de observações sobre uma variável, ordenadas no tempo, registadas em períodos regulares. A análise de séries temporais permite identificar padrões não aleatórios numa variável de interesse, e a observação deste comportamento passado pode permitir fazer previsões sobre o futuro, orientando a tomada de decisões. Entre os diversos modelos, surgem os de Box-Jenkins como sendo dos mais conceituados para estimação e previsão de séries temporais. Estes modelos pertencentes a família dos auto regressivos-médias-móveis (ARMA), e estão subdivididos em dois outros modelos: o auto regressivo (AR) e médias móveis (MA).

No estado da arte, são referidos inúmeros métodos de previsão e apresentados alguns valores para a performance ou ganho dos mesmos em relação ao modelo de persistência. Estes resultados advêm da criação de uma plataforma de testes envolvendo os diversos modelos e a utilização de valores medidos para as variáveis em estudo. Neste contexto, desenvolveu-se uma plataforma de testes e apresentaram-se os seus resultados. Os dados foram obtidos através de um SSAD e o método inicial de previsão foi desenvolvido tendo por base a utilização de sistemas de análise estatística de dados, juntamente com um dos modelos de Box-Jenkins para séries estacionárias. Os ganhos resultantes da simulação para um horizonte de previsão de 10 minutos (*t+1*), apresentam valores acima dos 17%, quando a regressão é de ordem 3 ou superior. No entanto, o valor da performance varia significativamente quando o método é aplicado a valores medidos em meses ou anos distintos. O mesmo processo, para um horizonte temporal de 4 horas, aplicado em dois meses diferentes, apresenta ganhos positivos num mês e ganhos negativos no outro, tornando o método indesejável. Os critérios usados para obtenção da performance foram sempre o MAE e de persistência.

A previsão da velocidade do vento melhora a sua performance quando se junta o modelo auto regressivo com sistemas de otimização. A ferramenta de otimização calcula os valores dos coeficientes auto regressivos por forma a minimizar o MAE. O método aplicado a dois meses e anos distintos para um AR(3), obteve ganhos de aproximadamente 30% para um horizonte temporal de 10 minutos. A aplicação do método para um horizonte temporal de quatro horas apresenta sempre melhores resultados que o modelo de persistência. Foram selecionados dados referentes a três anos diferentes e um total de nove meses. A performance inferior tem um valor aproximado de 4,5% sendo o valor superior de 12,04%. O valor médio do ganho para os nove meses é de 8,37%, sendo superior ao apresentado no estado da arte.

7.2 Perspetivas de desenvolvimento futuro

Um sistema de previsão tem como objetivo principal a melhoria da sua performance. Esta depende sempre do erro residual entre o valor medido e o valor previsto para um dado instante de tempo. O desafio para estes sistemas será sempre minorar o erro remanente.

O estado da arte apresenta vários métodos usados nos sistemas de previsão cujos resultados parecem ser promissores. Atendendo a este facto, a simulação ou criação de novas plataformas de testes para novos métodos de previsão, pode levar à descoberta de processos que garantam previsões com melhor ganho.

Com base no trabalho efetuado, deve adaptar-se o modelo de forma a incorporar o erro de previsão na função objetivo, dessa forma aumenta-se a controlabilidade do sistema devido à componente de observabilidade. Outro fator que pode melhorar o sistema obtido, é executar o método de otimização sempre que se pretende fazer uma previsão, desta forma os parâmetros vão ser sempre ajustados à história recente da série.

Usar o código gerado pela *ntstool* para fechar a malha da rede alimentando-a com as previsões que vai efetuando, permitindo à rede fazer previsões para diferentes períodos temporais.

Referências

[1] PINHO, Manuel, Resposta da Europa à questão da energia, Lisboa: Jornal _Expresso‘, 31. Maio. 2008

[2] C. Monteiro, R. Bessa, V. Miranda, A. Botterud, J. Wang, and G. Conzelmann, Wind Power Forecasting: State-of-the-Art 2009.

[3] U.S. Department of Energy (DOE), “20% Wind Energy by 2030: Increasing Wind Energy’s Contribution to U.S. Electricity Supply,” DOE Office of Energy Efficiency and Renewable Energy Report, July 2008. Available at: http://www1.eere.energy.gov/windandhydro/wind_2030.html.

[4] GE Energy, GE MAPS Software for Informed Economic Decisions Fact Sheet,2011,www.geenergy.com/content/multimedia/files/downloads/EC_Download_WilliamsS_Concorda MAPS Engine Fact Sheet GEA19669-dvz.pdf, Feb 2015.

[5] K. Orwig, B.-M. Hodge, G. Brinkman, E. Ela, and M. Milligan, Economic Evaluation of Short-Term Wind Power Forecasts in ERCOT: Preliminary Results

[6] J. Usaola, O. Ravelo, G. González, F. Soto, M.C. Dávila, and B. Díaz-Guerra, “Benefits for Wind Energy in Electricity Markets from Using Short Term Wind Power Prediction Tools; a Simulation Study,” *Wind Engineering*, vol. 28, no. 1, pp. 119–127, 2004.

[7] MORE-CARE, “More Advanced Control Advice for Secure Operation of Isolated Power Systems with Increased Renewable Energy Penetration and Storage,” EU Project ERK5-CT1999-00019.

[8] G. Kariniotakis, et al., “ANEMOS: Development of a Next Generation Wind Power Forecasting System for the Large-Scale Integration of Onshore & Offshore Wind Farms,” in *Proceedings of the European Wind Energy Conference & Exhibition EWEC 2003*, Madrid, Spain, June 16–19, 2003.

[9] J. Charney, R. Fjortoft, and J. von Neumann, “Numerical integration of the barotropic vorticity equation,” *Tellus*, vol. 2, pp. 237–254, 1950.

[10] J. Charney, “The use of the primitive equations of motion in numerical prediction,” *Tellus*, vol. 7, pp. 22–26, 1955.

[11] E.N. Lorenz, “Deterministic nonperiodic flow,” *Journal of Atmospheric Sciences*, vol. 20, pp. 131–140, 1963.

[12] E.N. Lorenz, “The predictability of a flow which possesses many scales of motion,” *Tellus*, vol. 21, pp. 289–307, 1969.

[13] Gregor Giebel, G. Kariniotakis, and R. Brownsword, “State of the Art on Short-term Wind Power Prediction,” ANEMOS Deliverable Report D1.1, 2003.

[14] E.A. Bossanyi, “Short-Term Wind Prediction Using Kalman Filters,” *Wind Engineering*, vol. 9, no. 1, pp. 1–8, 1985.

[15] R.E. Kalman, “A new approach to linear filtering and prediction problems,” *Journal of Basic Engineering*, vol. 82, no. 1, pp. 35–45, 1960.

[16] H. Vihriälä, P. Ridanpää, R. Perälä, and L. Söderlund, "Control of a variable speed wind turbine with feedforward of aerodynamic torque," in *Proceedings of the European Wind Energy Conference EWEC'99*, pp. 881–884, Nice, France, March 1–5, 1999.

[17] G.E. Box and G. Jenkins, *Time Series Analysis, Forecasting and Control*, Holden Day,1976.

[18] G.C. Contaxis and J. Kabouris, "Short term scheduling in a wind/diesel autonomous energy system," *IEEE Transactions on Power Systems*, vol. 6, no. 3, pp. 1161–1167, 1991.

[19] L. Kamal and Y.Z. Jafri, "Time series models to simulate and forecast hourly average wind speed in Quetta," *Solar Energy*, vol. 61, no. 1, pp 23–32, 1997.

[20] U. Schlink and G. Tetzlaff, "Wind speed forecasting from 1 to 30 minutes," *Theoretical and Applied Climatology*, vol. 60, pp. 191–198, 1998.

[21] P. Poggi, M. Muselli, G. Notton, C. Cristofi, and A. Louche, "Forecasting and simulating wind speed in Corsica by using an autoregressive model," *Energy Conversion and Management*, vol. 14, no. 20, pp. 3177–3196, 2003.

[22] J.L. Torres, A. García, M. de Blas, and A. de Francisco, "Forecast of hourly averages wind speed with ARMA models in Navarre," *Solar Energy*, vol. 79, no. 1, pp. 65–77, 2005.

[23] C. Tantareanu, "Wind prediction in short-term: a first step for a better wind turbine control, *Nordvestjysk Folkecenter for Vedvarende Energi*, October 1992.

[24] R.G. Kavasseri and K. Seetharaman, "Day-ahead wind speed forecasting using f-ARIMA models," *Renewable Energy*, vol. 34, no. 5, pp. 1388–1393, May 2009.

[25] R.G. Kavasseri and R. Nagarajan, "Evidence of crossover phenomena in wind speed data," *IEEE Transactions on Circuits and Systems*, vol. 51, no. 11, pp. 2255–2262, Nov. 2004.

[26] T.H.M. El-Fouly, E.F. El-Saadany, and M.M.A. Salama, "Grey Predictor for Wind Energy Conversion Systems Output Power Prediction," IEEE Transactions on Power System, vol. 21, no. 3, pp. 1450–1452, 2006.

[27] J.L. Deng, "Introduction to grey system theory," Journal of Grey System, vol. 1, no. 1, pp. 1–24, 1989.

[28] M.C. Alexiadis, P.S. Dokopoulos, H.S. Sahsamanoglou, and I.M. Manousaridis, "Shortterm forecasting of wind speed and related electric power," Solar Energy, vol. 63, no. 1, pp. 61–68, 1998.

[29] M.C. Alexiadis, P.S. Dokopoulos, and H.S. Sahsamanoglou, "Wind speed and power forecasting based on spatial correlation models," IEEE Transactions on Energy Conversion, vol. 14, no. 3, pp. 836–837, 1999.

[30] A. Sfetsos, "A comparison of various forecasting techniques applied to mean hourly wind speed time series," Renewable Energy, vol. 21, no. 1, pp. 23–35, 2000.

[31] A. Sfetsos, "A novel approach for the forecasting of mean hourly wind speed time series," Renewable Energy, vol. 27, no. 2, pp. 163–174, 2002.

[32] E. Cadenas and W. Rivera, "Short term wind speed forecasting in La Venta, Oaxaca, México, using artificial neural networks," Renewable Energy, vol. 34, no. 1, pp. 274–278, Jan. 2009.

[33] I. Maqsood, M. Khan, G. Huang, and R. Abdalla, "Application of soft computing models to hourly weather analysis in southern Saskatchewan, Canada," Engineering Applications of Artificial Intelligence, vol. 18, no. 1, pp. 115–125, 2005.

[34] Christopher M. Bishop, Neural Networks for Pattern Recognition, Oxford and New York: Oxford University Press, 1995.

[35] R.E. Abdel-Aal, M.A. Elhadidy, and S.M. Shaahid, "Modeling and forecasting the mean hourly wind speed time series using GMDH-based abductive networks," Renewable Energy, vol. 34, no. 7, pp. 1686–1699, July 2009.

[36] A.G. Ivakhnenko, “Polynomial theory of complex systems,” IEEE Transactions on Systems, Man and Cybernetics, SMC-1(4), pp. 364–378, 1971.

[37] C.W. Potter and M. Negnevistky, “Very short-term wind forecasting for Tasmanian power generation,” IEEE Transactions on Power Systems, vol. 21, no. 2, pp. 965–972, 2006.

[38] J.-S.R. Jang, “ANFIS: Adaptive Network-based Fuzzy Inference Systems,” IEEE Transactions on Systems, Man, and Cybernetics, vol. 23, pp. 665 --685, 1993.

[39] I.J. Ramírez-Rosado and L.A. Fernández-Jiménez, “A new model for short-term wind electric power forecasting,” in Proceedings of International Conference on Modeling, Identification, and Control, Innsbruck, Austria, pp. 66–69, 2001.

[40] I.J. Ramírez-Rosado and L.A. Fernández-Jiménez, “An advanced model for short-term forecasting of mean wind speed and wind electric power,” Control and Intelligent Systems, vol. 31, no. 1, pp. 21–26, 2004.

[41] G. N. Kariniotakis, et al., "Evaluation of Advanced Wind Power and Load Forecasting Methods for the Optimal Management of Isolated Power Systems," Proceedings of the European Wind Energy Conference, Nice, France, 1999.

[42] K. Hunt and G. P. Nason, "Wind Speed Modelling and Short-Term Prediction using Wavelets," Wind Engineering, vol. 25, pp. 55-61, 2001.

[43] A. G. Dutton, et al., "Load and Wind Power Forecasting Methods for the Optimal Management of Isolated Power Systems with High Wind Penetration," Wind Engineering, vol. 23, pp. 69-87, 1999.

[44] C. Potter and M. Negnevitsky, "Short Term Power System Forecasting Using an Adaptive Neural- Fuzzy Inference System," Australian and New Zealand Intelligent Information Systems Conference (ANZIIS), vol. 8, pp. 465-470, 2003.

[45] J.-S. R. Jang and C.-T. Mizutani, Neuro-Fuzzy and Soft Computing: A Computational Approach to Learning and Machine Intelligence. Eaglewood Cliffs, NJ: Prentice Hall, 1997.

[46] M. Negnevitsky, Artificial Intelligence: A Guide to Intelligent Systems. Harlow: Pearson Education, 2002.

[47] Australasian Universities Power Engineering Conference (AUPEC).

[48] Henrik Madsen, Pierre Pinson, George Kariniotakis, Henrik Aa. Nielsen and Torben S. Nielsen,Technical University of Denmark, Informatics and Mathematical Modelling, 2800 Lyngby, Denmark.

[49] C. Moerhlen, “Uncertainty in wind energy forecasting,” Ph.D. dissertation, University College Cork, Ireland, May 2004.

[50] INE 7001 Análise de Séries Temporais.

[51] Ricardo s. “Ehlers, Análise de séries temporais”, Quinta edição publicada em 2009.

[52] Haykin S. In: Neural Networks: A Comprehensive Foundation. New Jersey: Prentice-Hall; 1999.

[53] Principe JC, Euliano NR, Lefebvre WC. In: Neural and Adaptive Systems:Fundamentals Through Simulations. New York: Wiley; 2000.

[54] C. Moerhlen, “Uncertainty in wind energy forecasting,” Ph.D. dissertation, University College Cork, Ireland, May 2004.

[55] M.C. Alexiadis, P.S. Dokopoulos, H.S. Sahsamanoglou, and I.M. Manousaridis, “Shortterm forecasting of wind speed and related electric power,” Solar Energy, vol. 63, no. 1, pp. 61–68, 1998.

[56] João Nuno Monteiro da Silva e Sousa, “Previsão da Produção Eléctrica em Parques Eólicos”, Dissertação, Dezembro 2007.

[57] IEC61400-25, "Wind Power Management," 2006.

[58] O. Anaya-Lara, N. Jenkins, and J. McDonald, "Communications Requirements and Technology for Wind Farm Operation and Maintenance," presented at First International Conference on Industrial and Information Systems, ICIIS 2006, Sri Lanka, 2006.

[59] H. Zimmermann, "OSI reference model. The ISO model of architecture for open system interconnection," IEEE Trans. Commun., vol. COM-28, no. 4, pp. 425-432, 1980.

[60] http://www.mathworks.com/help/nnet/ug/design-time-series-narx-feedback-neural-networks.html, Abril 2015.

[61] http://www.pucrs.br/ce-eolica/faq.php?q=21#21, Abril 2015