

Faculdade de Engenharia da Universidade do Porto



Previsão de Potência Eólica com base em Modelos de Prospecção de Similaridade Histórica

Tiago Filipe Ferreira dos Santos

Dissertação realizada no âmbito do
Mestrado Integrado em Engenharia Electrotécnica e de Computadores
Major Energia

Orientador: Prof. Doutor Cláudio Monteiro

Julho de 2009

© Tiago Filipe Ferreira dos Santos, 2009

Resumo

Actualmente existe um elevado investimento na energia eólica a nível mundial. Contudo, esta energia devido à sua elevada volatilidade ainda produz diversos problemas, quer para a gestão de redes e de parques eólicos, quer para a gestão dos mercados de electricidade.

Assim torna-se fulcral efectuar a sua previsão com um elevado nível de precisão de modo a minimizar os impactos causados.

Efectivamente, existe um elevado número de modelos capazes de efectuar a sua previsão, contudo a sua grande maioria apenas fornece um ponto de previsão de potência de base eólica. Porém, esta informação por vezes revela-se escassa.

Sendo o objectivo minimizar as penalizações sofridas pela energia eólica devido à sua volatilidade, no presente trabalho é apresentado um novo sistema capaz de efectuar previsão de potência de base eólica, que tem em consideração o conjunto de dados históricos referentes a um aerogerador ou parque eólico.

O sistema desenvolvido distingue-se dos actuais por fornecer um elevado conjunto de informação. Particularmente, o utilizador terá acesso a informação do tipo: pontos de Potência Eólica Prevista; Incerteza associada à previsão; Eventos de Rampa que poderão surgir ao longo do horizonte temporal. Para além desta informação o novo sistema dispõe de uma ferramenta capaz de efectuar a simulação de cenários.

Para avaliar o desempenho do sistema desenvolvido procedeu-se à realização de testes, através de previsões para um aerogerador de um parque eólico e estabeleceu-se uma comparação com o modelo de Persistência e com o modelo baseado em redes neuronais.

A previsão apresentada é para um horizonte temporal de 24 horas, com discretização de meia em meia hora. Contudo, o sistema desenvolvido tem a possibilidade de efectuar previsão para outros horizontes temporais.

Palavras-chave: Energia Eólica, Previsão de Potência Eólica, Prospeção de Dados, Sistemas de Previsão.

Abstract

Nowadays there is a large investment in wind energy worldwide. However, this energy due to their high volatility also produces several problems for the management of networks and wind farms and for the management of the electricity markets.

Thus it becomes crucial to make his prediction with a high level of accuracy to minimize the impacts caused.

Indeed, there is a large number of models capable of making its forecast, though the vast majority provide only a point forecast, of the wind power. However this information is sometimes scarce.

Being the objective to minimize the penalties incurred by the wind power due to its volatility, in this work is presented a new system with capacity of making wind forecast takes into account all historical data relating to a wind park or aerogenerators.

The developed system is different from the current because it provides a high set of information. Particularly, the user will have access to information such as: point forecasting; uncertainty; events of ramp.

Besides this information, the new system provides a tool capable of performing the simulation of scenarios.

To evaluate the performance of the developed system, tests were made, through aerogenerators forecasts from a wind park and a comparison was established with the model of Persistence and a model based on neuronal networks.

Prediction is carried out considering a time horizon of 24 hours, with a discretization every half hour. However, the developed system has the ability to make estimates for other time horizons.

Keywords: Data Mining, Forecasting system, Wind Power, Wind Power Forecasting.

Agradecimentos

Serve o presente momento para homenagear e agradecer a todas as pessoas e instituições que contribuíram, directa ou indirectamente, para a elaboração e sucesso desta dissertação, evidenciando as seguintes:

Ao meu orientador, Professor Doutor Cláudio Monteiro, uma palavra de amizade e de profundo agradecimento pelo seu apoio contínuo, incansável orientação e conselhos prestados que contribuíram de forma benéfica para o desenrolar desta dissertação.

À empresa Smartwatt e seus colaboradores pela disponibilidade de recursos, colaboração e apoio prestados no desenvolvimento desta dissertação.

Ao Engenheiro João Sousa pela sua amizade, apoio e disponibilidade manifestada na revisão do presente documento.

A todos os colegas e amigos, especialmente ao Carlos Oliveira, Elsa Ferraz e Hélder Teixeira, pelo apoio e amizade nas longas e difíceis batalhas ao longo destes últimos cinco anos. Seremos eternamente o “Quarteto Maravilha”.

À minha família, especialmente à minha mãe por todos os sacrifícios, que permitiram a concretização deste sonho.

À minha namorada Ana por toda a paciência, apoio e carinho dispensados na realização deste curso. A Ti, agradeço toda a disponibilidade e cooperação para vencer os árduos e constantes desafios que emergiram nesta etapa da minha vida.

A todos um muito obrigado sincero...

Índice

Resumo	iii
Abstract.....	v
Agradecimentos	vii
Índice.....	ix
Lista de figuras	xi
Lista de tabelas	xiii
Abreviaturas e Símbolos	xiv
Capítulo 1	1
Introdução.....	1
1.1- Enquadramento	2
1.2- Motivação	5
1.3- Objectivos.....	6
1.4- Estrutura da Dissertação	7
Capítulo 2	9
Estado da Arte.....	9
2.1- Introdução	9
2.2- Modelos Numéricos - Numerical Weather Prediction (NWP)	11
2.2.1- Modelos Globais	11
2.2.2- Modelos Regionais/Locais.....	12
2.3- Modelos de Referência.....	13
2.4- Previsão de Potência Eólica baseada em Previsão Numérica	14
2.4.1- Modelos Físicos	14
2.4.2- Modelos Estatísticos	17
2.4.3- Modelos Híbridos	19
2.5- Avaliação dos Modelos de Previsão	20
2.6- Comparação Entre Modelos de Previsão	23
2.7- Incerteza nos Modelos de Previsão Eólica	24
2.7.1- Representação da Incerteza.....	24
2.7.1.1- Previsões Probabilísticas	24
2.7.1.2- Índices de Risco	25
2.7.1.3- Cenários para a Previsão Eólica	26
2.7.2- Estimacão da Incerteza	26
2.8- Eventos de Rampa	28

2.9- Modelos de Previsão Operacionais no Mercado.....	30
2.9.1- <i>Previento</i>	30
2.9.2- <i>WPPT</i>	31
2.9.3- <i>Zephyr</i>	32
2.9.4- <i>ARMINES Wind Power Prediction System (AWPPS)</i>	32
2.9.5- <i>Sipreólico</i>	33
2.9.6- <i>WEPROG MSEPS</i>	33
2.9.7- <i>SOWIE</i>	33
2.9.8- Quadro Resumo	34
2.10- Conclusões.....	35
Capítulo 3	37
Prospecção de Similaridade Histórica - PROSIH	37
3.1- Introdução	37
3.2- Fundamento	38
3.3- Base de Conhecimento do Modelo PROSIH	40
3.4- Base do Modelo PROSIH.....	41
3.4.1- Mecanismo de Prospecção de Similaridade Histórica	41
3.4.1.1- Análise do Parâmetro Sigma - σ	43
3.4.2- Matriz de Probabilidades (MP)	46
3.4.3- Formulação do Problema em Estudo	48
3.5- Ferramentas do Modelo PROSIH.....	51
3.5.1- Previsão de um Ponto de Potência.....	52
3.5.2- Previsão de Incerteza - u	53
3.5.3- Previsão de Eventos de Rampa	54
3.5.4- Simulação.....	57
3.6- Síntese.....	62
Capítulo 4	67
Teste do Modelo	67
4.1- Introdução	67
4.2- Teste à Previsão de um Ponto de Potência	68
4.2.1- Análise do Erro na Previsão de um Ponto de Potência	69
4.3- Teste à Previsão de Incerteza	73
4.4- Teste à Previsão de Eventos de Rampa.....	77
4.5- Teste à Simulação	81
4.5.1- Previsão de um Ponto de Potência.....	81
4.5.2- Previsão da Incerteza	84
4.5.3- Previsão de Eventos de Rampa	87
4.6- Conclusões	91
Capítulo 5	93
Conclusões	93
5.1- Conclusões Gerais	93
5.2- Conclusões Finais	95
5.3- Trabalhos Futuros	96
Referências	97

Lista de figuras

Figura 1 - Modo de Funcionamento do Centro de Despacho Hierárquico [6].	4
Figura 2 - Esquema do Modo de Funcionamento dos Modelos Físicos.	15
Figura 3 - Exemplo de um Processo de <i>Downscaling</i> [11].	16
Figura 4 - Diagrama do Modelo de Meso-Escala Físico [11].	16
Figura 5 - Modo de Funcionamento dos Modelos Estatísticos.	17
Figura 6 - Estrutura dos Modelos Híbridos.	19
Figura 7 - Forma de Identificar Eventos de Rampa [39].	28
Figura 8 - Esquema do Modelo de Previsão de Eventos de Rampa [39].	29
Figura 9 - Gráfico ACF.	38
Figura 10 - Gráfico PACF.	38
Figura 11 - Gráfico ACF.	39
Figura 12 - Gráfico PACF.	39
Figura 13 - Representação Gráfica da Gaussiana Local.	42
Figura 14 - Conjunto de Gaussianas Locais para cada Variável de Entrada.	43
Figura 15 - Influência da Variável Sigma (σ).	44
Figura 16 - Curva de Potência de um Aerogerador.	45
Figura 17 - Relação entre ΔV e ΔP .	45
Figura 18 - Representação da Matriz de Probabilidades para n Intervalos.	48
Figura 19 - Representação da Função $f(x, y)$.	51
Figura 20 - Função de Distribuição de Probabilidade Conjunta $f_{x,y}$.	54
Figura 21 - Ilustração da Distribuição dos Diferentes Níveis que Caracterizam os Eventos de Rampa.	56

Figura 22 - Função $g(x)$.	58
Figura 23 - Função $G(x)$.	59
Figura 24 - Função Discreta $g(x)$.	59
Figura 25 - Função Discreta $G(x)$.	60
Figura 26 - Exemplo do Princípio de Funcionamento da Simulação.	60
Figura 27 - Exemplo do Resultado Final de uma Simulação.	61
Figura 28 - Constituição do Modelo PROSIH.	63
Figura 29 - Esquema de Funcionamento do Modelo de Previsão Desenvolvido na dissertação.	65
Figura 30 - Comparação entre os erros (NMAPE) dos diferentes modelos para o horizonte temporal de previsão.	68
Figura 31 - Estrutura da Rede Neuronal utilizada.	69
Figura 32 - Comparação da Potência Real com a Prevista pelo Modelo PROSIH.	70
Figura 33 - Relação entre a Velocidade do Vento Prevista e a Velocidade Real.	71
Figura 34 - Relação entre a Direcção do Vento Prevista e a Direcção Real.	71
Figura 35 - Comparação da Potência Real com a Prevista pelo Modelo PROSIH.	72
Figura 36 - Relação entre a Velocidade do Vento Prevista e a Velocidade Real.	72
Figura 37 - Relação entre a Direcção do Vento Prevista e a Direcção Real.	73
Figura 38 - Representação gráfica da Incerteza associada a um determinado Instante de Previsão.	74
Figura 39 - Distribuição da Incerteza, ordenada decrescentemente, por Probabilidade.	75
Figura 40 - Hipótese H_0 versus Hipótese H_1 .	76
Figura 41 - Previsão de Eventos de Rampa representada graficamente.	78
Figura 42 - Hipótese H_0 versus Hipótese H_1 .	79
Figura 43 - Influência do tipo de Rampas no modelo de Previsão de Eventos de Rampa.	80
Figura 44 - Influência dos diferentes modelos ao longo do Horizonte Temporal de Previsão.	82
Figura 45 - Comparação entre os erros (NMAPE) dos diferentes modelos para o Horizonte Temporal de Previsão.	82
Figura 46 - Comparação dos erros (NMAPE) entre os diferentes Modelos de Fusão.	83

Lista de tabelas

Tabela 1 - Modelos de Previsão Numérica Globais.	12
Tabela 2 - Modelos de Previsão Numérica Locais/Regionais.	12
Tabela 3 - Alguns dos Principais Modelos no Mercado.	34
Tabela 4 - Representação de uma n-upla de Transição.	40
Tabela 5 - Média dos Erros dos diferentes Modelos ao longo do Horizonte Temporal de Previsão.	69
Tabela 6 - Tabela que permite a escolha da hipótese.	78
Tabela 7 - Resultados obtidos para as Previsões dos diferentes Eventos de Rampa.	80
Tabela 8 - Comparação da média dos erros (NMAPE) dos diferentes Modelos, ao longo do Horizonte Temporal de Previsão.	84
Tabela 9 - Comparação entre a Ferramenta de Simulação (Previsão de Incertezas) e a Ferramenta de Previsão de Incertezas.	85
Tabela 10 - Comparação entre a Ferramenta de Simulação (Previsão de Eventos de Rampa) e a Ferramenta de Previsão de Eventos de Rampa.	88

Abreviaturas e Símbolos

Lista de abreviaturas

ACF	<i>Autocorrelation Function</i>
ALADIN	<i>Aire Limitée Adaptation dynamique Développement InterNational</i>
ARPS	<i>Advanced Regional Prediction System</i>
AWPPS	<i>ARMINES Wind Power Prediction System</i>
CDF	<i>Computational Fluid Dynamic</i>
<i>cdf</i>	<i>Cumulative Distribution Function</i>
CE	Comunidade Europeia
DTU	<i>Denmark technical University</i>
EU	União Europeia
EUA	Estados Unidos da América
EWEA	<i>European Wind Energy Association</i>
FEUP	Faculdade de Engenharia da Universidade do Porto
FH	Mecanismo de prospecção de similaridade histórica
GEM	<i>Global Environmental Multiscale Model</i>
GEM-LAM	<i>Global Environmental Multiscale Limites Area Model</i>
GFS	<i>Global Forecast System</i>
GME	<i>German Weather Service</i>
IGCM	<i>Intermediate General Circulation Model</i>
IMM	<i>Institute for Informatics and Mathematical Modelling</i>
KDE	<i>Kernel Density Estimation</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MM5	<i>Fifth Generation Circulation Model</i>
MOS	<i>Model Output Statistics</i>
MP	Matriz de Probabilidades
MRI	<i>Meteo-Risk Index</i>
MSE	<i>Mean Square Error</i>

NMAPE	<i>Normalized Mean Absolute Percentage Error</i>
NPRI	<i>Normalized Prediction Risk Index</i>
NRMSPE	<i>Normalized Root Mean Square Percentage Error</i>
NWP	<i>Numerical Weather Predictions</i>
PACF	<i>Partial Autocorrelation Function</i>
pdf	<i>Probability Density Function</i>
pdf	<i>Probability Distribution Function</i>
pmf	<i>Probability Mass Function</i>
PROSIH	Prospecção de Similaridade Histórica
QRF	<i>Quantil Regression Forests</i>
RMSE	<i>Root Mean Square Error</i>
RMSPE	<i>Root Mean Square Percentage Error</i>
RN	Redes Neurais
SCADA	<i>Supervisory Control And Data Acquisition</i>
SOWIE	<i>Simulation Model for the Operational Forecast of the Wind Energy Production in Europe</i>
UM	<i>Unified Model</i>
WPPT	<i>Wind Power Prediction tool</i>
WRF	<i>Weather Research and Forecasting Model</i>

Lista de símbolos

ξ_e	Erro aleatório
μ_e	Erro sistemático
μ	Média
u	Incerteza
σ	Sigma
$\hat{P}_{(t+k t)}$	Potência prevista para o instante $t + k$ no instante t
$P_{(t-1)}$	Potência no instante $t - 1$
$P_{(t)}$	Potência no instante t
$\bar{P}_t$	Valor médio da potência
P_{int}	Potência instalada
$P_{méd}$	Potência Média
$\hat{u}_{(t+k t_{NWP})}$	Previsão da velocidade de vento para o instante $t + k$ pelo <i>NWP</i> para o instante t
$\hat{\theta}_{(t+k t_{NWP})}$	Previsão da direcção de vento para o instante $t + k$ pelo <i>NWP</i> para o instante t
$e_{(t+k t)}$	Erro relativo à previsão para o instante $t + k$, efectuada no instante t

P_{t-1}	Potência no instante $t-1$;
P_t	Potência no instante t ;
V_{t-1}	Velocidade do vento no instante $t-1$;
V_t	Velocidade do vento no instante t ;
D_{t-1}	Direcção do vento no instante $t-1$;
D_t	Direcção do vento no instante t ;
P_{ant}	Valor da potência no instante anterior ao primeiro instante de previsão;
P	Valor da potência que surge da ferramenta simulação;
MW	Megawatt;
kW	Kilowatt;

Capítulo 1

Introdução

A presente dissertação foi desenvolvida no âmbito do Mestrado Integrado em Engenharia Electrotécnica e de Computadores, na Faculdade de Engenharia da Universidade do Porto (FEUP).

Neste trabalho é apresentado um novo conceito de previsão para a produção de energia eólica, tendo como objectivo explorar novas dimensões da informação produzida por modelos de previsão de produção eólica.

Sabe-se que a introdução da energia eólica conduz a incertezas adicionais na gestão dos sistemas de energia. Esta incerteza, no contexto da liberalização dos mercados de electricidade, introduz variabilidades no preço constituindo um desafio para os agentes de mercado. Além disso, a simples previsão pontual é insuficiente para a maioria das aplicações sendo necessária a modelização de incerteza, rampas, desvios de fase e outras formas de informação que requerem modelos e abordagens inovadoras nestas áreas de investigação. Assim, torna-se necessário desenvolver novas ferramentas de previsão que sejam capazes de retirar maior valor da informação e que apresentem indicadores mais adequados para aplicações específicas da previsão.

As previsões de energia eólica são tradicionalmente fornecidas na forma de um ponto de potência prevista. Este ponto corresponde ao valor esperado da previsão de potência para um determinado instante do horizonte temporal. Contudo, esta informação revela-se escassa para a maior parte das aplicações por excluir a incerteza e a forma da previsão na proximidade desse ponto.

Com o objectivo de compreender e combater as falhas dos actuais modelos de previsão nesta dissertação, apresenta-se um novo conceito de previsão que demonstra novas capacidades e desempenhos.

As novas dimensões de informação fornecidas pelo modelo tornam-se uma mais-valia para os seus utilizadores, sendo que estes podem tomar decisões com um maior nível de confiança.

Concretamente, este capítulo contempla uma abordagem ao problema, incluindo o seu contexto, assim como, apresenta as ideias fulcrais que serão defendidas na Dissertação.

1.1- Enquadramento

Actualmente existe um enorme investimento em recursos renováveis, principalmente devido aos factores ambientais que abalam o planeta.

A utilização das energias renováveis, não só permite desacelerar o crescimento das emissões de CO₂ para a atmosfera, como também permite uma maior independência da humanidade face aos combustíveis fósseis, ou seja, às energias não renováveis, como o petróleo e o carvão.

Porém, actualmente a principal preocupação visa diminuir a emissão de gases de efeito de estufa e assim melhorar o ambiente do planeta.

A aposta nas energias renováveis teve início após a criação do protocolo de Kyoto, que se iniciou em 1988, no Canadá, através da conferência “Toronto Conference on the Changing Atmosphere”. Em 1997 no Japão, deu-se por concluído (com a assinatura do protocolo por todos os países aderentes).

Após o surgimento deste protocolo, a Comunidade Europeia (CE) definiu um conjunto de metas a atingir por cada país, com o objectivo de diminuir as emissões de gases que provocam o efeito de estufa.

Em Portugal, surgiu em 2001 o programa E4 - *Eficiência Energética e Energias Endógenas* - que apresenta como objectivos garantir a segurança no abastecimento, a redução da factura energética e em simultâneo salvaguardar o ambiente, ou seja, cumprir com as metas definidas pela CE. Deste modo, o respectivo programa assenta em três grandes eixos:

- Diversificação do acesso às formas de energia disponíveis no mercado e aumento das garantias do serviço prestado pelas empresas da oferta energética [1];
- Promoção da melhoria da eficiência energética, contribuindo para a redução da intensidade energética do PIB, da factura energética externa e para a resposta que se impõe quanto às alterações climáticas, dando particular atenção às oportunidades e meios de optimização da eficiência do lado da procura [1];
- Promoção da valorização das energias endógenas, nomeadamente a hídrica, a eólica, a biomassa, a solar (térmica e fotovoltaica) e a energia das ondas, num compromisso fortemente dinâmico entre a viabilidade técnico-económicas e as condicionantes ambientais [1];

Com vista ao cumprimento dos objectivos, Portugal começa a definir as suas próprias metas e consequentemente inicia-se um grande investimento nas energias renováveis, mais propriamente na energia eólica.

A escolha recaiu sobre a energia eólica devido à disponibilidade do recurso existente, à remuneração bastante atractiva e também pela maturidade da tecnologia a utilizar.

De salientar que Portugal, em Março de 2009 apresentava 3 134 MW de potência eólica instalada, tendo um crescimento de 42,3% face ao mesmo período do ano anterior [2],[3]. Com o aumento da produção eólica em Portugal, surgem problemas que terão de ser resolvidos e que serão discutidos de seguida.

Este tipo de produção eléctrica está associado a um elevado grau de volatilidade e variabilidade, uma vez que, depende de uma fonte primária endógena muito variável, o Vento.

Assim esta variabilidade e volatilidade traduz-se em problemas de:

- Participação em Mercados de Electricidade - Numa lógica de mercado de electricidade, os promotores dos parques eólicos ou os comercializadores que os representem, poderão ter que apresentar propostas de produção discretizadas de hora a hora, com uma antecedência superior a 24 horas, no caso do mercado diário. Por outro lado, os mercados intradiários surgem com o objectivo de se proceder aos devidos ajustes de modo a permitir o equilíbrio entre a produção e a carga [4];
- Segurança de Abastecimento - Considerando a possibilidade de avarias das unidades produtoras, a variabilidade do recurso eólico e a necessidade de garantir a cobertura dos consumos por intermédio dos meios de produção disponíveis, há a necessidade de conhecer previamente uma estimativa acerca da produção eólica. De forma a identificar os volumes adequados de reservas operacionais que garantem os níveis de qualidade de serviço estipulados, os sistemas de previsão permitem uma maior eficiência no processo de contratação de serviços de reserva, em virtude de reduzirem a incerteza associada à produção esperada dos parques eólicos [4];
- Gestão dos Centros Produtores - No processo de despacho das centrais eólicas, havendo ou não mercado, é necessário considerar, para além das restrições da rede eléctrica, as estimativas de produção eléctrica e o seu grau de incerteza associado. Este processo, proporciona um melhor escalonamento das centrais eléctricas convencionais [4];
- Gestão dos Parques Eólicos - A gestão do parque eólico exige a definição de períodos de manutenção e poderá exigir o pré-despacho e o despacho dos aerogeradores com o objectivo de responder a solicitações dos operadores de sistema. Se o promotor possuir ferramentas que o informem acerca da produção prevista para um determinado

4 Introdução

período, poderá programar para os períodos com menor capacidade de produção do parque eólico as manutenções [4].

A elevada integração de unidades de geração eólica impõe que os sistemas de distribuição e transmissão de energia desenvolvam novos conceitos de monitorização, controlo e gestão dessas novas fontes de produção.

Assim, surgiram centros de despacho baseados numa arquitectura de controlo hierárquico [5], cujo seu modo de funcionamento pode ser visualizado na seguinte figura (Figura 1).




Figura 1 - Modo de Funcionamento do Centro de Despacho Hierárquico [6].

Estes centros de despacho necessitam de ter o conhecimento da evolução da produção eólica em cada parque ao longo das próximas horas. Tal facto implica a necessidade da existência de sistemas que permitam efectuar previsão da produção eólica.

O sistema de previsão é caracterizado pelo seu horizonte temporal, ou seja, pelo período para o qual o sistema fornece valores de previsão, como por exemplo, um horizonte de 24 horas.

Deste modo, o sistema de previsão vai ser diferenciado de acordo com o seu horizonte temporal, não existindo unanimidade para as fronteiras temporais, uma vez que, o horizonte é variável de acordo com o autor que o define.

De uma forma geral o sistema de previsão pode ser subdividido em 3 categorias principais:

- Muito curto prazo: São fornecidos valores de previsão para um intervalo de poucas horas, geralmente 3 a 6 horas.
- Curto prazo: São fornecidos valores de previsão para intervalos de 48 a 72 horas.

- Médio prazo: São fornecidos valores de previsão para intervalos de 7 dias.

É extremamente importante que estes sistemas de previsão apresentem um elevado grau de fiabilidade, bem como forneçam a maior quantidade de informação possível, pois só assim será possível minimizar os problemas que a injeção de potência eólica implica na rede.

1.2- Motivação

A grande variabilidade da fonte primária da energia eólica implica uma grande dificuldade na sua previsão. Assim sendo, qualquer sistema de previsão existente, apresenta falhas/erros que caracterizam o seu desempenho. Estas falhas podem ser oriundas de factores externos ao próprio sistema de previsão, desde erros de medição por parte do sistema SCADA, a erros de previsão das variáveis meteorológicas por parte dos modelos numéricos de previsão. Estas são as principais fontes de erro, uma vez que são estas variáveis que estão envolvidas directamente na previsão de potência eólica. No entanto, um outro problema destes sistemas é a falta de informação que estes produzem acerca da sua previsão. Este facto deve-se, actualmente os sistemas de previsão apenas fornecer uma previsão do tipo “*point forecasting*”, que consiste em fornecer o ponto de potência eólica prevista com maior probabilidade de ocorrência.

Como a inclusão da produção eólica no sistema eléctrico tende a aumentar, surge a necessidade de melhorar os sistemas de previsão actuais, ou seja, os novos sistemas de previsão não devem apenas fornecer uma previsão do tipo “*point forecasting*”, mas também, fornecer informação adicional capaz de enriquecer o processo de decisão dos agentes que utilizam esta informação.

As previsões do tipo “*point forecasting*” não fornecem informação de incerteza. A informação de incerteza permite ao agente de decisão avaliar riscos associados à magnitude, fase, rampas ou mesmo cenários de previsão.

Deste modo, um novo sistema de previsão deve ser capaz de, para cada instante de previsão, fornecer um determinado valor de potência e a incerteza associada a esse valor, para permitir aos utilizadores, desta informação, tomar decisões mais ponderadas quanto ao risco e com um maior nível de confiança.

Um outro factor a abordar será a previsão da evolução da potência, ou seja, previsão de rampas existentes entre o valor de produção anterior (P_{t-1}) e o valor da produção seguinte (P_t) para ser possível prever a severidade da variação na potência e facilitar o trabalho dos utilizadores. Saber de antemão, qual a severidade da tendência, e a probabilidade de ocorrência dessa tendência é uma mais-valia, que requer o desenvolvimento de uma nova geração de modelos de previsão.

Após possuir estas novas dimensões de informação, os novos sistemas de previsão poderão fornecer a possibilidade de simulação de cenários com diferentes probabilidades de ocorrência. Este facto permite mostrar ao utilizador, vários cenários com possibilidade de ocorrência diferentes.

A existência de novos sistemas de previsão mais robustos, com a capacidade de fornecer todo este conjunto de informação, torna possível aumentar a capacidade segura produzida pelas eólicas, sendo possível minimizar os problemas existentes actualmente devido à elevada introdução de potência eólica na rede.

1.3- Objectivos

Este trabalho de dissertação tem como objectivo principal desenvolver um novo sistema de previsão de potência eólica, baseado em técnicas de prospecção de dados aplicados ao histórico de produção do parque eólico.

O novo sistema de previsão será dotado de um conjunto de ferramentas que permitem fornecer uma maior diversidade e formas de informação ao seu utilizador. Concretamente, para obter a informação utilizam-se técnicas que permitem a extracção de subconjuntos de casos próximos usando métodos da família dos “k-vizinhos mais próximos”. Com este subconjunto de características similares é possível efectuar uma modelização estocástica da qual resulta toda a modelação da incerteza.

O sistema a desenvolver distingue-se dos actuais por fornecer informação adicional, ou seja, não fornecerá apenas um valor de previsão de potência, mas também um conjunto de informação que permitirá conhecer a incerteza e a forma da série de produção prevista.

Este trabalho científico apresenta os seguintes objectivos:

- Criar um novo sistema de previsão baseado em técnicas de prospecção de dados;
- O sistema deverá ser capaz de fornecer as incertezas existentes na previsão (Previsão de Incertezas);
- O sistema deverá ser capaz de fornecer a probabilidade de eventos de rampas (Previsão de Rampas);
- O sistema deverá fornecer a possibilidade de criação de cenários com diferentes probabilidades de ocorrência, sendo modelada as probabilidades de transição entre instantes de tempo adjacentes;

1.4- Estrutura da Dissertação

A presente dissertação está organizada em 5 capítulos. Sendo os capítulos 1 e 2 uma apresentação teórica do tema, tendo como objectivo facilitar a interpretação do trabalho desenvolvido. Os capítulos 3 e 4 apresentam a formulação e o teste ao modelo desenvolvido. O capítulo 5 apresenta todas as conclusões relevantes retiradas da elaboração desta tese de dissertação.

No capítulo 1 apresenta-se uma introdução ao trabalho, onde se apresentam os objectivos a alcançar, bem como, qual a motivação para o desenvolvimento deste trabalho.

No capítulo 2 apresenta-se o estado da arte da previsão de potência eólica. Será discutido o estado actual da implementação de recursos eólicos, metas a atingir na Europa e a importância da previsão eólica, apresentando alguns modelos existentes actualmente.

Para além disso, apresentar-se-ão as principais formas de avaliar os modelos existentes. Este facto é importante, uma vez que, o objectivo deste trabalho é a implementação de um novo sistema de previsão. Deste modo, torna-se indispensável efectuar o seu teste tendo por base os principais métodos de avaliação. Por último, será abordado todo o conjunto de informação existente sobre temas como a incerteza na previsão e os fenómenos de eventos de rampas, assim como, os principais sistemas de previsão actualmente disponíveis no mercado, apresentando as suas principais características.

No capítulo 3 será apresentada a formulação do modelo de previsão desenvolvido no âmbito deste trabalho. Assim, serão apresentadas todas as características que definem o modelo, bem como, serão descritas todas as etapas e pressupostos utilizados para validar o modelo. O modelo é composto por uma base, em que assentam um conjunto de ferramentas que permitem fornecer diversos tipos de informação. Neste capítulo, abordar-se-á todas as ferramentas de modo a explicar qual a sua função, características e utilidade.

No capítulo 4 serão apresentados os resultados obtidos para os testes efectuados ao modelo desenvolvido, testadas todas as ferramentas desenvolvidas e efectuar-se-á uma comparação com outros modelos.

Por último, no capítulo 5 serão apresentadas todas as conclusões retiradas ao longo do trabalho desenvolvido.

Capítulo 2

Estado da Arte

2.1- Introdução

Actualmente existe um grande investimento na produção de energia através de recursos renováveis. Este investimento deve-se principalmente às actuais preocupações ambientais. Na Europa, em países como a Alemanha, Espanha, Dinamarca, Portugal, entre outros, regista-se uma crescente penetração de produção eólica (entre os 5 e os 20%). Esta penetração tem vindo a aumentar cada vez mais ao longo dos últimos anos. A tendência é crescente, uma vez que, recentemente a European Wind Energy Association (EWEA) estabeleceu novas metas para a UE-15 de modo a que até 2010 exista uma potência instalada de 75GW e 180GW até 2020 [7],[8].

Analisando estes valores verifica-se que este aumento representa cerca de 25% da meta fixada em 2000 e cerca de 50% da meta fixada em 1997.

Segundo [9], a indústria da energia eólica continuará a liderar o mercado mundial. Analisando o último relatório desenvolvido pela EWEA [10] que examina em detalhe os efeitos da produção eólica sobre a electricidade, gases de estufa e sobre a economia da União Europeia (UE), pode-se verificar mais uma vez a importância que a energia eólica representa.

Não só os países da Europa têm demonstrado interesse na produção de energia recorrendo aos recursos eólicos, mas também os Estados Unidos da América (EUA), pois recentemente definiram metas e estratégias a atingir.

Tendo em consideração todos os indicadores referidos, pode-se concluir que num futuro próximo a produção de energia através de recursos eólicos vai desempenhar um papel extremamente importante na totalidade da produção de energia eléctrica, quer na Europa quer nos EUA.

Para que esta penetração de produção eólica seja possível, quer a nível de mercado de electricidade, quer a nível de gestão de redes é indispensável a existência de ferramentas capazes de efectuar a sua previsão.

Estas ferramentas têm evoluído ao longo do tempo, o que originou a obtenção de ferramentas mais precisas e com maior fiabilidade. Particularmente, estas são caracterizadas pelo horizonte temporal para o qual fornecem valores de previsão.

O horizonte temporal pode ser definido de acordo com a potência do sistema de produção e a quantidade de dados disponíveis, podendo ser dividido em três grandes secções:

- Previsões de Muito Curto Prazo - Estes sistemas operam para horizontes temporais de muito curto prazo, desde alguns segundos até 6 horas. Estão associados a situações de participação no mercado intradiário, de controlo dos aerogeradores, de definição da garantia de segurança de abastecimento por parte do operador da rede eléctrica e de gestão de unidades convencionais rápidas que participam nos serviços de sistema (muito usual em sistemas isolados, como por exemplo ilhas) [4];
- Previsões de Curto Prazo - Este tipo de previsões estão normalmente definidas através do intervalo de previsão entre os 30 minutos às 72 horas. Estas previsões são relevantes para a participação no mercado diário, embora o horizonte de previsão necessário seja definido pela exigência do operador de mercado sobre a antecedência das previsões [4];
- Previsões de Longo Prazo - Este tipo de previsões associam-se, normalmente ao apoio na gestão das centrais eléctricas convencionais e na programação de acções de manutenção nos parques eólicos. Também se podem desenvolver previsões de muito longo prazo com o intuito de apoiar o planeamento de expansão da rede eléctrica. O horizonte temporal destes sistemas varia desde as 72 horas até ao período de alguns anos [4].

No decorrer do trabalho irá ser abordado a previsão de curto prazo em que os horizontes podem variar de 30 minutos às 72 horas. Serão combinados modelos estatísticos e modelos físicos para se obter um melhor modelo de previsão.

A motivação para desenvolver este trabalho foi a falta de informação que actualmente os modelos de previsão a curto prazo fornecem. Os modelos actuais apenas fornecem um valor de previsão de potência e não fornecem informação sobre a fiabilidade desse mesmo valor.

2.2- Modelos Numéricos - Numerical Weather Prediction (NWP)

As previsões atmosféricas têm um vasto consumo de aplicação e utilizações, sendo a base explicadora do funcionamento de grande variedade de sistemas, porque quase todos os sistemas são influenciados pelas condições e variáveis meteorológicas.

Particularmente, a previsão das variáveis atmosféricas são de extrema importância para a previsão de produção eólica, uma vez que, é necessário conhecer o comportamento das condições atmosféricas para efectuar a previsão.

Deste modo, surgiram os modelos de previsão numérica (modelos NWP) que tem como objectivo, partindo de um conjunto de condições iniciais, fornecer informação sobre o comportamento da atmosfera para um determinado horizonte temporal.

Os modelos NWP têm sido utilizados desde 1950 após um trabalho desenvolvido por *Charney, Fjortoft e von Neumann* [11]. São modelos computacionais com capacidades para simularem o comportamento da atmosfera, através da utilização de um sistema complexo de equações matemáticas. Estas equações apresentam um carácter não linear, e por consequência torna-se impossível obter a sua solução exacta. Deste modo, resolver as respectivas equações implica a utilização de métodos numéricos.

Geralmente, os modelos de previsão numérica apresentam-se divididos em dois modelos:

- Global - Efectuam previsão para todo o planeta;
- Regional/Local - Efectuam previsão para zonas continentais;

É importante salientar que os modelos de previsão numérica são capazes de fornecer valores de previsão à escala continental, para um horizonte que varia de 3 a 72 horas. De âmbito mais alargado os modelos globais podem fornecer previsões com horizonte temporal de 7 dias.

2.2.1- Modelos Globais

Os modelos atmosféricos de macro-escala são os que oferecem previsões meteorológicas de maior alcance (escala mundial). Estes modelos possuem uma resolução da ordem de 200 km e têm como objectivo identificar o comportamento geral da atmosfera sobre uma determinada zona. São modelos com capacidade de identificar fenómenos meteorológicos de larga escala.

De seguida, apresenta-se uma tabela (Tabela 1) na qual se encontra os principais modelos globais desenvolvidos.

Tabela 1 - Modelos de Previsão Numérica Globais.

<i>Designação</i>	<i>Desenvolvido por:</i>
GFS - <i>Global Forecast System</i>	<i>National Centre for Environmental Prediction</i>
GEM - <i>Global Environmental Multiscale Model</i>	<i>MSC - Meteorological Service of Canada</i>
IGCM - <i>Intermediate General Circulation Model</i>	<i>Department of Meteorology at the University of Reading</i>
UM - <i>Unified Model</i>	<i>UK Met Office</i>
GME	<i>German Weather Service</i>

As entidades descritas na segunda coluna da Tabela 1 detêm recursos computacionais de elevada capacidade de processamento, capazes de resolver as complexas equações várias vezes ao dia. Este facto permite fornecer previsões refrescadas em intervalos de 6 horas e 12 horas.

É importante referir que em Portugal para além do Instituto de Meteorologia existem várias instituições de investigação que recorrem a estas previsões globais que englobam o território nacional. O modelo mais utilizado é o GFS.

2.2.2- Modelos Regionais/Locais

Como já foi mencionado anteriormente, os modelos atmosféricos globais analisam a evolução da atmosfera em todo o planeta. No caso dos modelos atmosféricos locais, estes concentram-se em grandes áreas, como por exemplo, continentes.

Estes modelos apresentam uma resolução espacial de 2 km até cerca de 50 km e têm como objectivo analisar e identificar com detalhe, o comportamento da atmosfera sobre uma região específica. Deste modo, é possível identificar fenómenos meteorológicos de pequena escala.

De seguida, apresenta-se uma tabela (Tabela 2) com os principais modelos Regionais/Locais desenvolvidos.

Tabela 2 - Modelos de Previsão Numérica Locais/Regionais.

<i>Designação</i>	<i>Desenvolvido por:</i>
ALADIN - <i>Aire Limitée Adaptation dynamique Développement InterNational</i>	<i>Météo-France</i>
ARPS - <i>Advanced Regional Prediction System</i>	<i>University of Oklahoma</i>
MM5 - <i>Fifth Generation Penn State / NCAR Mesoscale Model MM5</i>	PSU/NCAR
WRF - <i>Weather Research and Forecasting Model</i>	NCEP
GEM-LAM - <i>Global Environmental Multiscale Limited Area Model</i>	MSC

Estes modelos são de extrema importância para a previsão eólica, uma vez que permitem estudar uma determinada zona geográfica com grande resolução espacial, como por exemplo, o estudo de um parque eólico.

É importante mencionar que os modelos NWP Regionais/Locais mais utilizados em Portugal são o MM5, WRF e o ALADIN.

2.3- Modelos de Referência

Esta secção tem como objectivo dar a conhecer os modelos existentes para a previsão de potência eólica que apresentam uma formulação mais simples e permitem fornecer uma base de comparação.

O modelo desenvolvido neste trabalho será avaliado tendo como base de comparação estes modelos de referência sendo, o objectivo verificar a validade do novo modelo. Este facto é importante, uma vez que, no caso dos modelos mais simples fornecerem melhores resultados, não será necessária a criação de modelos mais complexos e com desempenho inferior.

O modelo mais comum de previsão de potência eólica designa-se de “Persistência”. Este modelo de previsão assume que a velocidade e direcção do vento, bem como a potência futura, se comportam de modo análogo ao que se verificou no instante anterior à previsão.

Assim, este modelo é definido com base na seguinte expressão (Eq. 1):

$$\hat{p}_{t+k|t} = p_t \quad (\text{Eq. 1})$$

Analisando a expressão anteriormente descrita é possível verificar a simplicidade deste modelo. No entanto, como o vento (velocidade e direcção) é definido por alguma persistência, este método quando utilizado para horizontes temporais bastante curtos, geralmente 1 a 3 horas, é difícil de superar.

Um outro modelo de previsão de potência eólica que pode ser considerado como referência é proposto em [12], que resulta da combinação do modelo anterior (Persistência), com as médias das potências registadas. Existe ainda um peso associado que é uma função de correlação entre p_t e p_{t+k} .

Deste modo, o modelo é descrito segundo a seguinte expressão (Eq. 2):

$$\hat{p}_{t+k|t} = a_k \times p_t + (1 - a_k) \times \bar{p} \quad (\text{Eq. 2})$$

Onde, p_t é a última medida de potência, $\bar{p}$ é a média das potências medidas, dado por $\bar{p} = \frac{1}{N} \sum_{t=1}^N p_t$, a_k é o coeficiente de correlação entre p_t e p_{t+k} .

Uma das principais desvantagens deste método é que o coeficiente a_k tem que ser estimado utilizando para isso algumas considerações ou hipóteses, o que faz com que o modelo se altere ao longo do horizonte temporal da previsão.

2.4- Previsão de Potência Eólica baseada em Previsão Numérica

Actualmente, os modelos existentes para a previsão de potência eólica necessitam da existência da previsão de variáveis meteorológicas, como a velocidade e direcção do vento.

Existe mais do que uma única forma de efectuar a previsão de potência eólica. Deste modo, pode-se referir que as diferenças existentes entre os modelos de previsão devem-se à forma como as variáveis meteorológicas previstas são transformadas em valores de potência.

Concretamente, os modelos actuais que efectuem previsão de potência eólica podem ser divididos basicamente em dois grandes grupos.

O primeiro grupo é designado por “**Modelos Físicos**” que têm em consideração o fluxo do vento dentro e na periferia do parque eólico, sendo que para fornecer os valores de potência prevista utiliza as curvas de potência dos aerogeradores.

Quanto ao segundo grupo é designado de “**Modelos estatísticos**”. Estes modelos não consideram qualquer efeito físico, apenas relacionam através de modelos estatísticos, os valores históricos com as previsões das variáveis meteorológicas.

Importa referir que, actualmente já existem modelos que combinam os dois modelos descritos anteriormente, sendo o objectivo a combinação das vantagens de ambos, de modo a obter um modelo mais preciso e fiável.

2.4.1- Modelos Físicos

Os modelos físicos baseiam-se em leis físicas com o objectivo de alcançar as previsões pretendidas. Estas previsões têm como base a modelação do escoamento do fluido do ar, considerando a presença dos obstáculos existentes, a rugosidade do terreno, bem como, a orografia do terreno.

Em suma, os modelos físicos utilizam leis físicas para obter a melhor previsão possível do vento, antes de esta ser utilizada pelos modelos estatísticos. Deste modo é possível tornar menor a probabilidade de acontecimento de erros.

De um modo holístico, a informação necessária para os modelos físicos divide-se em dois grupos [13]:

- Informação dinâmica - Consiste basicamente nas previsões das variáveis meteorológicas.
- Informação estática - Informação sobre as características do parque e do terreno onde este está situado.

De seguida, apresenta-se um esquema com o objectivo de representar o modo de funcionamento deste tipo de modelos.




Figura 2 - Esquema do Modo de Funcionamento dos Modelos Físicos.

Analisando o esquema anterior (Figura 2) pode-se referir que os modelos físicos encontram-se estruturados em duas etapas: *downscaling* e conversão em potência eléctrica.

No primeiro processo *downscaling*, existe uma adaptação das previsões das variáveis NWP, ao local onde se situa o parque. Para tal, utilizam-se dois métodos micro ou meso-escala.




Figura 3 - Exemplo de um Processo de *Downscaling* [11].

Os modelos de meso-escala baseiam-se essencialmente no vento geostrófico para efectuar o processo de *downscaling*. Este processo é rápido, apresentando um grau de complexidade em termos de implementação baixo. Contudo, no que diz respeito ao seu desempenho, quando aplicado a terrenos complexos, este apresenta várias falhas.



Figura 4 - Diagrama do Modelo de Meso-Escala Físico [11].

No que concerne ao modelo de micro-escala, este utiliza modelos *Computacional Fluid Dynamics (CFD)*, com o objectivo de estimar o vento ao nível das turbinas. Este modelo caracteriza-se pelos bons desempenhos quando aplicado em terrenos complexos e pela modelação da turbulência. Contudo, para a sua implementação é necessário um grande investimento a nível computacional.

No segundo processo, conversão em potência eléctrica, utilizam-se modelos de curva de potência - *Power Curve Models*. Estes modelos têm como princípio de funcionamento transformar os valores de velocidade do vento em valores de potência eléctrica. Para tal, geralmente utilizam a curva de potência de cada aerogerador, que podem ser fornecidas pelos fabricantes ou então, podem ser estimadas com base nos valores históricos. A utilização das curvas fornecidas pelos fabricantes é uma abordagem simples, embora alguns estudos demonstrem ser vantajoso a estimação da curva de potência [14].

Por vezes, com o objectivo de melhorar os seus desempenhos, os modelos físicos incorporam os modelos estatísticos, *Model Output Statistics (MOS)*. Estes modelos adaptam as saídas dos modelos físicos com as medições efectuadas em tempo real, desta forma, torna-se possível atenuar a influência dos erros sistemáticos. A principal desvantagem deste modelo deve-se à necessidade de dados medidos (*online* e *offline*), sendo que estes devem apresentar um nível de elevada qualidade.

2.4.2- Modelos Estatísticos

Os modelos estatísticos têm como objectivo encontrar relações existentes entre os dados históricos de produção, variáveis explicativas e informações recolhidas em tempo real.

Esta abordagem, contrariamente aos modelos físicos, apenas utiliza um módulo para transformar a informação existente em previsão de potência eléctrica.

Na seguinte figura (Figura 5) descreve-se o modo de funcionamento dos modelos estatísticos:




Figura 5 - Modo de Funcionamento dos Modelos Estatísticos.

Geralmente, os modelos estatísticos utilizam modelos lineares e não lineares de diferentes tipos para efectuar a previsão. Alguns exemplos são designados de “caixa-preta”, nas quais estão incorporadas as redes neuronais (RN) entre outros sistemas.

Existem modelos em que a sua estrutura é definida com base no conhecimento das propriedades que definem a energia eólica (*Grey-Box models*). Também existem modelos que podem ser definidos analiticamente, como é o caso do “*Kernel Regression*” [13].

Os modelos estatísticos podem ser expressos pela seguinte equação:

$$\hat{p}_{(t+k|t)} = f\left(p_t, \hat{u}_{(t+k|t_{NWP})}, \hat{\theta}_{(t+k|t_{NWP})}, \hat{x}_{(t+k|t_{NWP})}\right) \quad (\text{Eq. 3})$$

Onde,

- $\hat{p}_{(t+k|t)}$ - Corresponde à previsão da potência para o instante $t+k$ efectuada no instante t ;
- p_t - É a potência produzida no instante t ;
- $\hat{u}_{(t+k|t_{NWP})}$ - É a previsão *NWP* da velocidade do vento para o instante $t+k$ efectuada no instante t_{NWP} ;
- $\hat{\theta}_{(t+k|t_{NWP})}$ - É a previsão *NWP* da direcção do vento para o instante $t+k$ efectuada no instante t_{NWP} ;
- $\hat{x}_{(t+k|t_{NWP})}$ - São outras variáveis previstas pelos modelos *NWP* para o instante $t+k$ efectuada no instante t_{NWP} .

É importante referir que para além destas variáveis ainda podem ser consideradas medidas em tempo real, como por exemplo, medidas meteorológicas.

Em suma, os modelos estatísticos apresentam-se normalmente compostos por uma parte que contempla os modelos autoregressivos e por uma parte que envolve a transformação das variáveis meteorológicas (*NWP*) em potência eléctrica.

É importante salientar que a componente autoregressiva é de elevada importância nas primeiras horas da previsão (6 a 10 horas), uma vez que esta tem em consideração a componente de persistência presente nas séries de vento.

Os modelos estatísticos apresentam como vantagem o facto de não necessitar de modelações físicas. Contudo, para o processo de estimação dos parâmetros é necessário possuir um vasto conjunto de dados históricos e medidas em tempo real.

2.4.3- Modelos Híbridos

Recentemente surgiram novas abordagens de modelos de previsão. Estes novos modelos baseiam-se na junção dos modelos físicos e dos modelos estatísticos [15]. Assim, surgem modelos que podem ser designados de modelos híbridos, cujo objectivo passa por combinar as vantagens de cada um dos modelos, de modo a obter valores de previsão com um maior nível de fiabilidade.

O modelo híbrido alia a elevada precisão das séries temporais na previsão para curtos horizontes de tempo, com a precisão dos modelos físicos para previsões em que os horizontes temporais variam entre as 6 e 72h.

Sendo um modelo híbrido, podem existir combinações de diferentes tipos:

- Combinação dos métodos físicos e estatísticos (modelo de previsão *Zephyr* [16]);
- Combinação dos modelos para curto prazo e médio prazo (*UMPREDICTION Project* [17]);

Existe também uma abordagem diferente que consiste na combinação de modelos estatísticos (*Sipreólico* [18]).

De seguida será apresentado um diagrama que tem como objectivo mostrar a estrutura do modelo híbrido (Figura 6).




Figura 6 - Estrutura dos Modelos Híbridos.

2.5- Avaliação dos Modelos de Previsão

Para se obter conhecimento sobre os modelos de previsão existentes torna-se necessário a existência de métodos que os permita avaliar.

Para avaliar o desempenho de um modelo de previsão podem utilizar-se variados indicadores estatísticos. Deste modo, surgem diversas formas de avaliação, não existindo um consenso, sobre qual a melhor forma a se utilizar. De uma forma simples, pode-se referir que o erro que um sistema de previsão comete para um determinado instante consiste na diferença entre o valor real e o valor previsto.

$$e_{t+k|t} = P_{t+k} - \hat{P}_{t+k|t} \quad (\text{Eq. 4})$$

Onde,

- P_{t+k} , é o valor medido no instante $t + k$;
- $\hat{P}_{t+k|t}$, é o valor previsto para o instante $t + k$, no instante t ;

Importa referir que o valor medido geralmente está sujeito a erros de medida por parte dos aparelhos. No entanto esse erro comparado com o erro da previsão é, geralmente, bastante inferior podendo ser desprezado.

Segundo *Madsen* em [19] é importante efectuar uma normalização do erro. Só assim é possível efectuar comparações de resultados obtidos entre parques, de uma forma independente. Esta normalização é conseguida dividindo o erro pela potência instalada (P_{inst}), como se pode visualizar na equação seguinte (Eq. 5):

$$e_{t+k|t} = \frac{1}{P_{inst}} (P_{t+k} - \hat{P}_{t+k|t}) \quad (\text{Eq. 5})$$

Existe ainda uma outra abordagem para efectuar a normalização do erro que consiste em dividir o erro pela potência média produzida pelo parque ao longo de um ano característico.

$$e_{t+k|t} = \frac{1}{P_{med}} (P_{t+k} - \hat{P}_{t+k|t}) \quad (\text{Eq. 6})$$

Onde,

- $P_{med} = \frac{1}{N} \sum_{t=1}^N P_t$

Qualquer previsão de erro pode ser decomposta em duas componentes:

- Erro sistemático μ_e ;
- Erro aleatório ξ_e ;

Idealmente, no caso de um modelo perfeito, o erro sistemático deveria assumir o valor zero e o erro aleatório deveria seguir uma sequência aleatória e independente de erros. Esta sequência aleatória poderá ser modelizada utilizando uma distribuição gaussiana com média zero. Assim resulta que o erro de um modelo é dado pela seguinte expressão (Eq. 7):

$$e = \mu_e + \xi_e \quad (\text{Eq. 7})$$

É necessário possuir ferramentas que permitam avaliar quer o erro sistemático quer o erro aleatório. O erro sistemático pode ser avaliado utilizando a análise do VIÉS (*BIAS*), dado pela seguinte expressão (Eq. 8):

$$BIAS_k = \frac{1}{N} \sum_{t=1}^N e_{t+k|t} \quad (\text{Eq. 8})$$

Quanto ao erro aleatório, este pode ser avaliado utilizando dois processos: *Mean Absolute Error (MAE)* e *Root Mean Square Error (RMSE)*.

O *Mean Absolute Error (MAE)* tem por base a seguinte expressão (Eq. 9):

$$MAE_k = \frac{1}{N} \sum_{t=1}^N |e_{t+k|t}| \quad (\text{Eq. 9})$$

Antes de introduzir o *Root Mean Square Error (RMSE)* é fundamental definir o *Mean Square Error (MSE)*:

$$MSE_k = \frac{1}{N - p} \sum_{t=1}^N e_{t+k|t}^2 \quad (\text{Eq. 10})$$

Onde p, para o conjunto de dados de teste toma o valor zero.

Deste modo, resulta o *RMSE* que é definido como:

$$RMSE_k = \sqrt{MSE} \quad (\text{Eq. 11})$$

$$RMSE_k = \sqrt{\frac{1}{N} \sum_{t=1}^N e_{(t+k|t)}^2} \quad (\text{Eq. 12})$$

É importante salientar que os erros sistemáticos afectam o *MAE* e o *RMSE*. Geralmente estes indicadores podem ser de difícil apreciação. Estes sofrem uma transformação de forma a ser possível uma melhor compreensão e utilização. Concretamente, a transformação que geralmente se utiliza é a passagem do erro para a forma de percentagem.

Contudo, para efectuar esta transformação é necessário atender a alguns critérios, que se apresentam de seguida.

➤ *Mean Absolute Percentage Error, MAPE*

$$MAPE = \frac{\frac{1}{N} \sum_{t=1}^N |e_{t+k|t}|}{P_{med}} \cdot 100 \quad (\text{Eq. 13})$$

➤ *Root Mean Square Percentage Error, RMSPE*

$$RMSPE = \frac{\sqrt{\frac{1}{N} \sum_{t=1}^N e_{t+k|t}^2}}{P_{med}} \cdot 100 \quad (\text{Eq. 14})$$

Refira-se que para estes indicadores também é possível efectuar a normalização que consiste apenas na troca da potência média (P_{med}) pela potência instalada (P_{inst}).

É importante referir que uma normalização deste género conduz a valores de erro inferiores. No entanto, pode-se registar alguma falhas quando se analisa o erro, uma vez que no caso de existir um sobre-equipamento, considera-se um valor de produção que geralmente nunca é atingido.

Assim sendo pode definir-se os erros *NMAPE* e *NRMSPE*:

➤ *Normalized Mean Absolute Percentage Error, NMAPE*

$$NMAPE = \frac{\frac{1}{N} \sum_{t=1}^N |e_{t+k|t}|}{P_{inst}} \cdot 100 \quad (\text{Eq. 15})$$

➤ *Normalized Root Mean Square Percentage Error, NRMSPE*

$$NRMSPE = \frac{\sqrt{\frac{1}{N} \sum_{t=1}^N e_{t+k|t}^2}}{P_{inst}} \cdot 100 \quad (\text{Eq. 16})$$

2.6- Comparação Entre Modelos de Previsão

Por vezes torna-se essencial efectuar a comparação entre diferentes modelos de previsão, contudo esta comparação nem sempre é fácil ou justa. Não é correcto afirmar que um modelo é melhor do que o outro, mas sim deve ter-se em conta que um modelo pode ser melhor do que o outro para uma determinada situação, mas não na globalidade.

O desempenho dos modelos de previsão de potência eólica não depende apenas da variância do erro de previsão, mas também do período de avaliação. Particularmente, alguns modelos podem apresentar um melhor desempenho quando existe uma disponibilidade baixa de energia eólica e para uma elevada disponibilidade, comportar-se de forma instável.

Assim, para comparar dois modelos é extremamente importante incorporar uma vasta variedade de medidas de erro.

Segundo *Madsen* em [19] quando se pretende efectuar a comparação de dois modelos de previsão, essa comparação deve ser realizada através de um modelo de melhoria (*improvement*) de cada um dos modelos face à Persistência. Para tal, deve recorrer-se a (Eq. 17):

$$\text{Imp}_{\text{Ref}, A}(k) = \frac{EC_k^{\text{Ref}} - EC_k^A}{EC_k^{\text{Ref}}} \quad (\text{Eq. 17})$$

Onde,

- EC - É considerado o critério de avaliação que pode ser qualquer uma das medidas de erro descritas no ponto 2.4;
- Ref - Representa o modelo da persistência;
- A - Representa o modelo que se pretende avaliar.

Uma outra forma de efectuar a comparação entre modelos é utilizando o coeficiente de determinação R^2 .

$$R_k^2 = \frac{MSE_k^{Ref} - MSE_k^A}{MSE_k^{Ref}} \quad (\text{Eq. 18})$$

Onde, MSE_k^{Ref} é o erro médio quadrático da média global dos modelos.

Contudo, deve-se evitar utilizar este indicador como medida primária, uma vez que para elevados horizontes temporais, este valor pode surgir negativo. Assim, esta medida será errada, dado que o coeficiente de determinação R^2 deverá variar entre 0 (mau) e 1 (bom).

2.7- Incerteza nos Modelos de Previsão Eólica

Uma das necessidades que se impõem aos modelos actuais de previsão de potência eólica é a capacidade de fornecerem um conjunto de informação relativa aos valores de previsão que fornecem. Portanto, esta informação desempenhará um papel fundamental para a melhoria dos modelos de previsão, dado que, quem utiliza a informação deixará de receber um único valor de previsão e passará a receber um conjunto de dados. Sendo que estes dados são de extrema importância para apoiar as decisões de quem os utiliza.

2.7.1- Representação da Incerteza

Recentemente, com o objectivo de evoluir para modelos que não forneçam apenas um ponto de previsão, mas sim várias dimensões de informação têm sido desenvolvidos trabalhos/pesquisas cujo objectivo é associar uma determinada incerteza aos pontos de previsão de potência eólica.

Esta incerteza poderá ser representada na forma de previsão probabilística, índices de risco ou cenários associados às previsões de curto-prazo para previsão eólica.

2.7.1.1- Previsões Probabilísticas

De uma forma geral, as previsões probabilísticas consistem na estimação da incerteza para a energia eólica futura. Esta forma de previsão pode ser expressa através de medidas de probabilidade.

Actualmente existem ou encontram-se em desenvolvimento, vários modelos para a estimação das previsões probabilísticas, estudos sobre formas de caracterização das fontes de incerteza, bem como, métodos para estimar incerteza *online* [20],[21].

Para efectuar a previsão de potência para os parques eólicos são utilizadas variáveis aleatórias que podem ser expressas das seguintes formas:

- Funções densidade de probabilidade (*pdf*);
- Funções densidade de probabilidade acumulada (*cdf*);
- Função massa de probabilidade (*pmf*);
- Momentos de distribuição (média, variância, entre outros);
- Quantis e intervalos de previsão.

É importante referir que das diversas formas acima mencionadas, as funções densidade de probabilidade são genéricas. Deste modo, estas podem ser reduzidas a qualquer outra forma.

Actualmente a utilização de quantis é a forma mais comum para representar as previsões probabilísticas [22]. Para além disso, os quantis são também utilizados para a criação de intervalos, que fornecem uma gama de valores em que o valor esperado poderá ocorrer. De uma forma geral, estes intervalos designam-se por intervalos de previsão [23].

Em [24] é apresentada uma forma de representar a incerteza utilizando a função densidade de probabilidade (*pdf*).

2.7.1.2- Índices de Risco

O tema, previsão de incerteza associada à previsão eólica, revela-se bastante complexo, uma vez que a previsão da energia eólica vai depender de inúmeros factores, tais como: condições meteorológicas, nível de potência do parque, localização geográfica do parque, orografia do terreno, entre outros.

Uma das fontes que introduz erro na previsão de potência eólica é a previsão das variáveis meteorológicas, devido à sua grande instabilidade. Em caso de existirem condições atmosféricas muito instáveis, as variáveis NWP previstas vão apresentar valores elevados de erro e como consequência obter-se-á más previsões de potência eólica. Assim, pode-se concluir que por vezes os erros que um modelo de previsão eólica produz não dependem dele próprio, mas sim das variáveis de entrada desse modelo.

Deste modo, para além da previsão da incerteza e de pontos de previsão surgem os índices de risco, que recorrendo à sua utilização é possível fornecer o nível de precisão esperado para determinada previsão.

Na literatura são propostos dois índices de risco:

- *Meteo-Risk Index (MRI)* [25];
- *Normalized Prediction Risk Index (NPRI)* [26].

A previsão dos índices de risco consiste apenas num único valor, que tem como objectivo fornecer informações sobre a magnitude do erro esperado.

Uma das vantagens dos índices de risco é a sua fácil compreensão por parte dos seus utilizadores, o que por vezes não acontece com as previsões probabilísticas. No entanto, quando surgem problemas e existe a necessidade de tomar uma decisão, aos índices de risco será sempre necessário associar a incerteza na previsão eólica. Estes índices podem apoiar na questão da largura dos intervalos.

2.7.1.3- Cenários para a Previsão Eólica

Na literatura é possível encontrar alguns trabalhos que desenvolvem métodos de modo a permitir a criação de cenários na previsão eólica.

Pinson em [27] apresenta um método para a geração de cenários de potência eólica baseado na utilização da função densidade de probabilidade (*pdf*) e probabilidade acumulada (*cdf*). Este método consiste na conversão de um conjunto de variáveis aleatórias, que compõem as previsões probabilísticas, numa única variável aleatória gaussiana.

Para além disso, o mesmo autor em [28], utiliza os cenários para uma avaliação dinâmica da capacidade de carga, necessária para cada período de entrega de electricidade ao mercado. Estes cenários podem ser muito úteis para a resolução de problemas como o congestionamento.

2.7.2- Estimação da Incerteza

A forma mais utilizada para estimar a incerteza consiste na utilização da representação paramétrica ou na avaliação de um critério que apenas avalia o erro global da previsão.

Pinson em [23] analisa o desempenho de vários modelos de previsão em diferentes locais e verifica que a incerteza associada à previsão de potência eólica varia com o horizonte temporal e com diferentes níveis de potência.

Concretamente, existem diferentes factores que podem influenciar a previsão de incerteza da potência eólica:

- Previsões NWP [29], [30];
- A não linearidade da curva de potência;
- O processamento da amostragem;
- Tipo de terreno.

Assim a incerteza na previsão de potência eólica poderá ser estimada considerando três abordagens diferentes:

- Os valores de previsão NWP;
- Os pontos de previsões obtidos por um modelo de previsão eólico cujas entradas sejam as previsões NWP;
- O conjunto das previsões NWP.

Na primeira abordagem, a incerteza é calculada directamente a partir das previsões NWP, ou seja, este método converte os erros das previsões NWP (previsão da velocidade e direcção do vento) em incerteza [31],[29].

Bremnes em [32] apresenta uma comparação de três abordagens estatísticas:

- Regressão de Quantis Local;
- Modelização Gaussiana Local;
- Estimador *Nadaraya-Watson* [33].

A segunda abordagem consiste em efectuar uma previsão de incerteza baseada nos erros dos modelos de previsão. Este modelo de previsão de incertezas é aplicado após o modelo de previsão de potência eólica.

Um dos modelos utilizados para previsão de incerteza consiste em separar os erros dos modelos de previsão em classes, sendo a separação baseada nas variáveis explicativas do problema. Um exemplo de um modelo que tem por base estas considerações pode ser encontrado em [34]. Contudo, é notório referir que uma das desvantagens deste tipo de método é decidir qual o número de intervalos que se deve ter em consideração.

Pinson em [23] utiliza um modelo de inferência difusa para determinar a distribuição dos erros associados à previsão de potência eólica. Neste modelo, cada previsão contribui para a distribuição de probabilidades total de uma forma ponderada.

Um outro modelo baseado numa regressão linear de quantis é apresentado em [35].

Juban em [24] apresenta dois modelos não paramétricos para a previsão de incerteza da potência eólica: *Kernel Density Estimation* (KDE) e *Quantil Regression Forests* (QRF) [36].

No que diz respeito à última abordagem, esta consiste em utilizar modelos que tenham como entrada conjuntos de previsões NWP. O objectivo é usar as propriedades dos conjuntos de valores NWP de modo a obter a previsibilidade para determinadas situações de previsão.

Um estudo interessante sobre a influência das variáveis NWP no erro de previsão pode ser encontrado em [37] e em [38], no qual os autores apresentam os resultados de três anos de pesquisa sobre previsão de potência eólica utilizando conjuntos de previsões NWP.

2.8- Eventos de Rampa

A evolução dos sistemas de previsão de potência eólica tem como objectivo torná-los mais seguros e fiáveis. Para tal, actualmente, existe uma evolução no sentido de aumentar a quantidade de informação que é fornecida. Outra forma de melhorar os sistemas de previsão actuais consiste em identificar, analisar e corrigir os principais factores que influenciam o seu erro.

Um dos factores mais importante para o qual é necessário desenvolver sistemas de previsão pode ser designado de evento de rampa. Para os operadores da rede eléctrica, este facto pode mostrar-se um problema bastante complexo, sobretudo quando exista uma elevada penetração de potência eólica na rede. Este fenómeno verifica-se quando o nível de potência produzida flui de níveis muito elevados para níveis muito baixos ou vice-versa.

Sendo a energia eólica, actualmente, uma fonte de energia renovável muito explorada e com tendência para aumentar, será necessário encontrar formas de prever estes eventos de rampa, com o objectivo de minimizar os problemas que lhe estão associados.

Uma das questões iniciais que se coloca quando se aborda este assunto é: “Qual a definição de evento de rampa?”.

Eric Grimit em [39] defende que um evento de rampa na energia eólica é definido por três parâmetros: Tempo, Magnitude e Direcção. Neste trabalho o evento de rampa é definido como uma rampa que excede 10% da potência nominal por hora.

Uma outra definição para evento de rampa pode ser encontrada em [40], que define evento de rampa como sendo uma mudança superior a 50% da capacidade instalada num período de 2 horas ou menos.

Outro aspecto relevante que pode ser encontrado em [39] é a forma como se pode verificar se existe ou não um evento de rampa. Para tal, é utilizado um modelo de sim/não como é apresentado na figura seguinte (

Figura 7).

		Rampa Observada	
		<i>Sim</i>	<i>Não</i>
Previsão de Rampa	<i>Sim</i>	Acerta	Falha
	<i>Não</i>	Acerto	Falsa Previsão

Figura 7 - Forma de Identificar Eventos de Rampa [39].

Sendo o objectivo encontrar modelos capazes de prever o fenómeno de evento de rampa, torna-se necessário identificar e analisar as causas que estão na sua origem.

John W. Zack [40] apresenta os vários factores estudados que podem causar os eventos de rampa. Este tipo de evento, geralmente surge devido a fenómenos atmosféricos ou a processos de engenharia.

Um outro aspecto a ter em conta quando se analisa os eventos de rampa é a frequência de ocorrência. Em [40], após efectuado um estudo em 5 parques eólicos de *San Gorgonio Pass* (SG) na Califórnia, verificou-se que eventos de rampa com 50% da capacidade em períodos de 2 horas, apresentam uma probabilidade que varia entre os 0,1 e 4%. Para eventos com 75% da capacidade no mesmo intervalo de tempo, verificou-se uma probabilidade entre 0,1 e 0,5%.

Deste modo, pode-se concluir que este tipo de fenómeno é difícil de prever mas também é raro. Para além disso, importa salientar que estes valores podem variar com a localização geográfica onde decorre o estudo.

Dos vários estudos efectuados já é possível encontrar modelos capazes de fornecer previsões de eventos de rampa, mesmo que ainda sejam protótipos e se encontrem em fase de evolução.

Em [39] é apresentada uma possível metodologia, desenvolvida pela *3TIER*, para prever o evento de rampa. Este é um sistema totalmente probabilístico que tem em consideração a incerteza associada à previsão do vento e à potência eólica.




Figura 8 - Esquema do Modelo de Previsão de Eventos de Rampa [39].

De forma análoga, em [40] é apresentado um modelo de previsão de eventos de rampa desenvolvido pela *AWSTrueWind*, que é constituído por três etapas. Na primeira etapa é calculada a probabilidade de ocorrência de uma rampa acima de uma determinada amplitude, sendo a análise das probabilidades realizada na segunda etapa. Por fim, na última etapa as probabilidades de cada evento de rampa são combinadas e é estimada uma distribuição de probabilidades para um evento de rampa com uma amplitude específica.

Um outro modelo de previsão é proposto por *Jeremy Parkes* [41]. Este modelo utiliza como entradas conjuntos de previsões NWP, e usa para o seu tratamento processos estatísticos e algoritmos adaptativos.

2.9- Modelos de Previsão Operacionais no Mercado

Devido ao elevado investimento na produção de energia eléctrica através de recursos eólicos, foi sendo necessário desenvolver sistemas capazes de efectuar a sua previsão.

De seguida, serão apresentadas e discutidas algumas das características dos principais modelos de previsão de potência eólica existentes actualmente no mercado.

De referir que apenas serão abordados os modelos que já são capazes ou que utilizam módulos de fornecer informações sobre a previsão. No entanto, no final desta secção será construída uma tabela com o objectivo de revelar os modelos mais importantes existentes actualmente no mercado, bem como, as suas características principais.

2.9.1- *Previento*

O *Previento*¹ [42],[43] é um modelo físico desenvolvido na Universidade de *Oldenburg*, que utiliza como entradas as previsões NWP. É um modelo semelhante ao *Prediktor*, com diferenças a nível dos modelos de *downscaling* utilizados. Este sistema encontra-se dividido em vários sub-modelos, no entanto segundo *Monnich* [43] o sub-modelo com maior influência é o modelo utilizado para a estabilidade atmosférica. Importa salientar que, a utilização do *MOS* foi considerada muito útil.

Outro aspecto relevante refere-se à utilização da curva de potência, uma vez que, a curva dada pelo fabricante e a curva obtida através dos dados medidos no parque são bastante heterogéneas.

No que diz respeito ao principal factor que influencia o erro produzido pelo modelo, conclui-se que provém do próprio modelo NWP. Neste sistema de previsão está incorporado um modelo capaz de fornecer incertezas sobre as previsões de potência eólica e de velocidade do vento. Esta incerteza é fornecida com base nas condições atmosféricas [44].

A incerteza é modelada usando o facto de que a incerteza da potência eólica é proporcional ao declive da curva de potência e à precisão das previsões subjacentes à velocidade do vento. Assim sendo, os intervalos de confiança criados vão alterar os seus limites superiores e inferiores, de acordo com as condições atmosféricas. Um outro aspecto a ter em consideração

¹ <http://energymeteo.de/gb/leistung/>

é que a distribuição da incerteza associada à velocidade do vento é representada através de uma distribuição gaussiana. Por outro lado, a distribuição da incerteza associada à previsão de potência eólica é extremamente não-gaussiana. Actualmente este modelo encontra-se em funcionamento na Alemanha.

2.9.2- WPPT

O *Wind Power Prediction Tool*² foi desenvolvido pelo *Institute for Informatics and Mathematical Modelling* (IMM) na Universidade Técnica da Dinamarca (DTU).

Este sistema revela-se interessante, uma vez que, é capaz de fornecer previsões para um único parque eólico, para um grupo de parques eólicos, ou até mesmo para uma região [45].

O modo como o modelo efectua a previsão consiste em dividir o espaço em sub-regiões, em que cada sub-região representa um parque eólico. Assim, é realizada uma previsão para cada sub-região e posteriormente todas as previsões são re combinadas de forma a fornecer as previsões para toda uma área.

É importante referir que o modelo tem capacidade de auto-adaptação. Deste modo, o modelo adapta-se no caso de se verificarem mudanças, tais como:

- Evolução do número de turbinas e das suas características;
- Alterações do terreno;
- Mudanças no modelo NWP.

Outro aspecto relevante a considerar neste modelo é a existência de um módulo capaz de estimar a incerteza associada aos valores de previsão. Para fornecer a incerteza utiliza uma abordagem baseada nos pontos de previsões fornecidos por um modelo de previsão eólica, que considere como entrada as previsões NWP (abordagem discutida anteriormente).

Assim, este modelo é capaz de fornecer a estimação da incerteza para todo o horizonte temporal de previsão, utilizando para isso três métodos diferentes:

- Estimativa adaptativa da variância;
- Quantis de agregações [46];
- Regressões de quantis [35].

² http://www.enfor.eu/wind_power_prediction_tool_wppt.php

2.9.3- *Zephyr*

O modelo *Zephyr* resulta da combinação do *WPPT* com o *Prediktor* [47]. Esta combinação tem como objectivo combinar as funcionalidades dos dois modelos, de modo a obter um modelo com maior fiabilidade.

O modelo apresentado opera segundo duas filosofias: *online* e *offline*. Quando funciona no modo *online* é utilizado um modelo autoregressivo, enquanto no modo *offline* é utilizado o modelo estatístico de curva de potência. Com a combinação destas duas metodologias é possível obter uma previsão óptima para os diversos instantes do horizonte temporal.

À semelhança do modelo *WTTP*, o *Zephyr* tem a capacidade de previsão de incerteza, baseado no mesmo princípio de funcionamento.

2.9.4- *ARMINES Wind Power Prediction System (AWPPS)*³

Este sistema de previsão recorre a um modelo estatístico que tem por base redes neuronais *fuzzy*. Segundo *Kariniotakis* [48] a técnica utilizada apresenta melhores desempenhos do que as tradicionais redes neuronais. Este modelo encontra-se integrado no *MORE-CARE EMS software* e encontra-se operacional na Madeira [49].

Pinson em [50] apresenta um modelo de previsão de potência eólica que utiliza medições *online* do SCADA e as previsões NWP. O sistema de previsão proposto utiliza redes neuronais *fuzzy* para efectuar uma previsão para horizontes temporais de muito curto prazo e de curto prazo.

Para efectuar o controlo do processo de aprendizagem utiliza algoritmos de “*Simulated annealing*” e métodos de validação cruzada para finalizar o processo.

A principal contribuição deve-se à implementação de um método capaz de estimar intervalos de potência e da inclusão de índices de risco. O objectivo é substituir o processo clássico de tentativa e erro por um conjunto de configurações que, posteriormente, serão testadas por um algoritmo de optimização não linear. O algoritmo de optimização selecciona a informação relevante (velocidade do vento, direcção, entre outros), onde as variáveis de decisão representam o número de conjuntos *fuzzy* para um tipo específico de dados de entrada.

O modelo *ARMINES Wind Power Prediction System (AWPPS)* incorpora um módulo de previsão de incerteza baseado no modelo apresentado por *Pinson*.

³ <http://www-cenerg.cma.fr/prediction/>

2.9.5- Sipreólico

O modelo *Sipreólico* foi desenvolvido pela *Universidad Carlos III*, situada em Madrid. Este modelo surge devido à elevada integração de potência eólica no sistema eléctrico espanhol.

Para funcionar, o *Sipreólico* utiliza previsões meteorológicas do modelo HIRLAM fornecidas pelo instituto de meteorologia espanhol, bem como, informações horárias medidas pelo SCADA.

Posteriormente, são utilizados nove modelos estatísticos distintos para tratar a informação disponibilizada. Importa referir que os modelos são utilizados, de acordo com a informação disponível.

É necessário salientar que, em recentes investigações com o objectivo de melhorar o modelo, surgiu um processo capaz de efectuar a estimação de incertezas.

Sánchez [51] relata as primeiras tentativas efectuadas para desenvolver o processo de estimação de incertezas. A apresentação descreve um processo *online* capaz de estimar uma função densidade para as previsões de potência eólica. No entanto, este módulo ainda se encontra em fase de pesquisa.

2.9.6- WEPROG MSEPS

O modelo *WEPROG Multi-Scheme Ensemble Prediction System* (MSEPS) [52] surge de uma pesquisa iniciada por *Corinna Moehrlen* e *Jess Joergensen* em 2001.

Este modelo de previsão baseia-se, essencialmente, em dois módulos principais:

- Um sistema de previsão meteorológica para cada 6 horas;
- Um sistema de previsão de potência eólica que considera como entradas, medidas *online* e históricas do SCADA.

Uma das vantagens deste modelo é possuir um módulo que aborda e prevê a incerteza associada à previsão eólica. O módulo que este sistema incorpora, para fornecer incerteza na previsão de potência eólica, baseia-se na natureza não linear da curva de potência e nas incertezas associadas às condições atmosféricas.

2.9.7- SOWIE

O modelo de previsão *Simulation Model for the Operational Forecast of the Wind Energy Production in Europe* (SOWIE) foi desenvolvido pela *Eurowind GmbH*⁴.

⁴ <http://www.eurowind-gmbh.de/english/Leistungen/prognose.php>

Relativamente a este modelo não existe grande informação a nível científico. Pode-se encontrar alguma informação no estado da arte da energia eólica na Alemanha [53]. No entanto, sabe-se que é um modelo físico que efectua previsões quatro vezes ao dia, podendo ir até horizontes de 120 horas, que utiliza como entradas valores NWP provenientes da HIRLAM e do GFS.

Segundo o *website*⁵ o modelo *SOWIE* apresenta ferramentas capazes de fornecer a incerteza na previsão (representada por intervalos de confiança), no entanto, não existem detalhes sobre o processo de cálculo.

2.9.8- Quadro Resumo

Anteriormente foi abordado um conjunto de modelos existentes de previsão de potência eólica, onde se referiu algumas das suas características principais.

De seguida, será apresentada uma tabela resumo (Tabela 3) que evidencia as características principais de alguns dos modelos do mercado, de modo sintetizado.

Tabela 3 - Alguns dos Principais Modelos no Mercado.

Modelo	Promotor	Tipo	Referências
<i>Prediktor</i>	<i>Risø, Denmark</i>	Físico	[54],[55],[56], [57],[58],[59]
<i>Previento</i>	<i>University Oldenburg/EMSYS, Germany</i>	Híbrido	[42],[43]
<i>LocalPred/RegioPred</i>	<i>CENER, Spain</i>	Híbrido	[60]
<i>WPPT</i>	<i>IMM.DTU/ENFOR, Denmark</i>	Estatístico	[45]
<i>Zephyr</i>	<i>Risø e IMM.DTU, Denmark</i>	Híbrido	[47]
<i>Cassandra</i>	<i>University of Castilla-La Mancha/Gamesa, Spain</i>	Físico	[61]
<i>AWPPS</i>	<i>ARMINES, France</i>	Estatístico	[48],[49]
<i>WPMS</i>	<i>ISSET, Germany</i>	Estatístico	[62],[63]
<i>WEPROG</i>	<i>WEPROG, Germany</i>	Híbrido	[52]
<i>Sipreólico</i>	<i>University Carlos III</i>	Estatístico	[18]

⁵ Data de visualização: 17 de Maio de 2009.

	<i>of Madrid, Spain</i>		
<i>GH Forecaster</i>	<i>Garrard Hassan, UK</i>	Estatístico	[64],[65]
<i>SOWIE</i>	<i>EuroWind GmbH, Germany</i>	Físico	[53]
<i>EPREV</i>	<i>INESC Porto/ INE- GI/CEsA/CGUL, Por- tugal</i>	Estatístico	[6]
<i>AleaWind</i>	<i>AleaSoft, Spain</i>	Estatístico	[66]
<i>Scirocco</i>	<i>Aeolis Forecasting services, Netherlands</i>	Híbrido	
<i>MeteoLógica</i>	<i>MeteoLógica, Spain</i>	Físico	
<i>WEFS</i>	<i>AMI Environmente Inc, USA</i>	Híbrido	
<i>eWind</i>	<i>TrueWind, USA</i>	Híbrido	[67]
<i>WindLogics</i>	<i>Xcel Energy Northem States Power and WindLogics Inc, USA</i>	Estatístico	[68]
<i>PowerSight</i>	<i>3TIER, USA</i>	Estatístico	

2.10- Conclusões

Actualmente é imposto um desafio aos modelos de previsão de potência eólica, com o objectivo de tornar os modelos existentes mais fiáveis. Deste modo, será possível evitar os impactos que a produção eólica implica nas redes de distribuição e transporte de energia, bem como, permitirá melhorar a forma de efectuar a gestão dos parques eólicos.

Os modelos são conduzidos a evoluir no sentido de fornecerem um maior conjunto de informação sobre a previsão que efectuam. No que concerne à sua caracterização, podem ser caracterizados segundo o seu horizonte temporal de previsão: modelos de **muito curto prazo**, **curto prazo** e **longo prazo** e são vulgarmente divididos em 3 grupos: **modelos físicos**, **modelos estatísticos** e **modelos híbridos** que resultam da junção dos dois anteriores.

Quando se pretende desenvolver novas ferramentas para efectuar a previsão é essencial considerar modelos de referência que permitam efectuar uma comparação. Particularmente, no caso da previsão de potência eólica o modelo mais utilizado para efectuar essa comparação é designado de **Persistência**.

Um outro pormenor a considerar é a avaliação do desempenho dos modelos de previsão de potência eólica. No entanto, nem sempre é tarefa fácil devido a factores como: depen-

dência da localização do parque eólico, variabilidade do recurso do vento no período em análise, magnitude de agregação geográfica da produção e discretização do horizonte temporal. Efectivamente, existem um conjunto de indicadores que podem ser utilizados mas, é necessário ter atenção na escolha do indicador, pois uma selecção inadequada pode conduzir a erros.

Também surge a necessidade de efectuar comparação entre modelos existentes, assim geralmente recorre-se ao conceito de *improvement*. Este indicador permite efectuar uma avaliação do desempenho relativamente a um modelo referência, geralmente a Persistência.

Estudos recentes sobre os modelos de previsão eólica têm como objectivo analisar a incerteza que se encontra associada à previsão. Destes estudos, surgem formas de representar e estimar a incerteza. Particularmente, este indicador será uma informação extremamente importante para quem utiliza os valores de previsão eólica, uma vez que, será possível tomar decisões com um maior nível de confiança. Para além disso, com o conhecimento da incerteza é possível quantificar a fiabilidade dos valores que se estão a utilizar.

Outro factor que influencia a fiabilidade de sistemas de previsão eólica é o evento de rampa. Efectivamente, existem estudos que analisam os factores que provocam esse tipo de evento, bem como, actualmente há modelos para a sua previsão. É importante referir que estes estudos concluíram que os eventos de rampa são raros e que dependem da localização geográfica do parque.

No mercado actual já existem modelos de previsão eólica que incorporam módulos com a possibilidade de fornecerem incerteza. Estes modelos não são apenas modelos computacionais, ou seja, existe uma base de conhecimento construída de uma forma estruturada de acordo com cada parque eólico.

Capítulo 3

Prospecção de Similaridade Histórica⁶ - PROSIH

3.1- Introdução

O objectivo da presente dissertação é desenvolver um novo modelo de previsão de potência de base eólica com ferramentas capazes de assegurar uma elevada fiabilidade.

Sabe-se que actualmente os modelos na generalidade apenas fornecem um ponto de previsão, ou seja, o ponto que corresponde ao valor esperado da potência. No entanto, essa informação revela-se escassa e surge a necessidade de desenvolver métodos que permitam fornecer um conjunto de informação sobre os valores de previsão fornecidos.

Neste capítulo, será apresentado o modelo PROSIH desenvolvido no decorrer deste trabalho. O Modelo PROSIH incorpora um conjunto de ferramentas que permitem fornecer informação adicional. Assim, o modelo não só fornece os valores esperados de previsão de potência, mas também fornece a previsão de incerteza, a previsão de eventos de rampa, bem como, permite ao seu utilizador a simulação de cenários com diferentes probabilidades de ocorrência.

A energia eólica por vezes é penalizada devido à falta de informação que existe sobre a sua variabilidade, assim, a informação gerada pelo modelo PROSIH vai permitir aos seus utilizadores tomar decisões com maior nível de confiança, reduzindo os impactos negativos da volatilidade do recurso.

⁶ A motivação para esta designação teve origem no conceito de prospecção de dados (*Data mining*). No conceito apresentado os dados pro-precionados são padrões de dados históricos com similaridade ao caso de previsão em análise.

3.2- Fundamento

As séries de dados referentes às variáveis NWP de velocidade e direcção do vento são sempre modelos autoregressivos, quase sempre de primeira ordem.

Concretamente, como forma de evidenciar tais ilações apresentam-se os gráficos ACF e PACF da variável em análise (Figura 9 e Figura 10).

- Análise da velocidade do vento




Figura 9 - Gráfico ACF.




Figura 10 - Gráfico PACF.

Pela análise dos gráficos anteriormente apresentados, conclui-se que efectivamente se trata de um modelo autoregressivo de primeira ordem, dado que o gráfico ACF ostenta decaimento exponencial e o PACF indica a ordem do modelo.

- **Análise da direcção do vento**




Figura 11 - Gráfico ACF.




Figura 12 - Gráfico PACF.

De forma análoga, os gráficos anteriores (Figura 11 e Figura 12) apresentam, também, que a direcção do vento se rege por um modelo autoregressivo de primeira ordem.

Posto isto, é possível concluir que quando se efectua previsão de potência de base eólica (considerando estas variáveis com entrada) para o instante t a informação situa-se na sua maior parte no instante $t-1$. Deste modo, é possível afirmar que, a informação encontra-se nas transições existentes entre os instantes $t-1$ e t ($t-1;t$).

Assim sendo, caso as séries de dados das variáveis meteorológicas não sigam modelos autoregressivos de primeira ordem, ou seja, no caso em que existe informação no instante $t-k$ é necessário modelizar a transição $(t-k;...;t-1;t)$. Esta transição deve ser modelizada, uma vez que, toda a informação relevante se encontra presente na mesma.

Contudo, e como na generalidade as séries de velocidade e direcção do vento regem-se por um modelo autoregressivo de primeira ordem, para desenvolver o modelo PROSIH supõem-se que toda a informação necessária se encontra na transição do instante $t-1$ para t .

3.3- Base de Conhecimento do Modelo PROSIH

A base de conhecimento do modelo PROSIH encontra-se no histórico de dados de um determinado parque ou aerogerador.

Este histórico deverá ser constituído pelos seguintes dados:

- P_{t-1} - Potência no instante $t-1$;
- P_t - Potência no instante t ;
- V_{t-1} - Velocidade do vento no instante $t-1$;
- V_t - Velocidade do vento no instante t ;
- D_{t-1} - Direcção do vento no instante $t-1$;
- D_t - Direcção do vento no instante t ;

Novamente, destaca-se o facto de ser necessário este conjunto de dados, uma vez que, a informação necessária para efectuar a previsão encontra-se nas transições existentes entre $t-1$ e t ($t-1;t$).

Um outro pormenor a mencionar é que os dados de velocidade e direcção do vento são dados previstos, ou seja, previsões NWP, enquanto os dados de potência são reais, adquiridos pelo sistema SCADA.

Para além disso é importante considerar que a uma transição de variáveis NWP encontra-se associada uma transição de potência, formando assim uma *n-upla de transição*.

Tabela 4 - Representação de uma n-upla de Transição.

Transições NWP				Transições de Potência (SCADA)	
V_{t-1}	V_t	D_{t-1}	D_t	P_{t-1}	P_t

Assim sendo, pode-se concluir que a base de conhecimento do modelo PROSIH é constituída por um conjunto de n -uplas de transição. Sendo que, no histórico de dados existem a casos representados pelas n -uplas de transição e que representam o espaço de ocorrências explicadas pela base de conhecimento.

3.4- Base do Modelo PROSIH

O modelo PROSIH tem como objectivo efectuar previsão de potência de base eólica e em simultâneo fornecer um conjunto de informação sobre essa previsão.

Para tal, este modelo efectua uma prospecção à base de conhecimento do modelo com o objectivo de encontrar casos similares aos que se pretendem prever, ou seja, tendo um conjunto de transições de variáveis NWP como entrada, o modelo de prospecção procura transições equivalentes na base de conhecimento, de modo a efectuar a previsão.

Deste modo, para que o modelo desenvolvido funcione é imprescindível desenvolver uma técnica que efectue uma prospecção, para encontrar os casos pretendidos na base de conhecimento do modelo, e que ao mesmo tempo atribua um peso mais elevado aos casos mais similares e um menor peso aos casos mais distantes no espaço de similaridade. Este mecanismo será designado de mecanismo de prospecção de similaridade histórica.

Após aplicado o mecanismo de prospecção irão surgir um conjunto de transições de potência ($P_{t-1}; P_t$). Assim, será possível a criação de uma matriz, que contemplará as probabilidades de transição de potência para uma determinada transição de variáveis NWP. Esta matriz poderá ser representada através de uma função de probabilidade conjunta, que fornece a probabilidade de ocorrência de uma dada transição de potência.

3.4.1- Mecanismo de Prospecção de Similaridade Histórica

O mecanismo de prospecção referido anteriormente tem como função efectuar uma selecção dos casos similares ao que se pretende prever, presentes na base de conhecimento do modelo.

Deste modo, dado um conjunto de entradas o mecanismo de prospecção irá atribuir diferentes pesos aos valores presentes na base de conhecimento do modelo, de forma a seleccionar apenas a informação relevante.

Após analisar algumas técnicas para efectuar a prospecção de similaridade decidiu-se utilizar uma modelização gaussiana local, que é definida pela seguinte equação (Eq. 19):

$$f(x; \mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} e^{\left(\frac{(x-\mu)^2}{2\sigma^2}\right)} \quad x \in \mathbb{R} \quad (\text{Eq. 19})$$

Onde,

- x - É a variável a prospeccionar;
- μ - É o valor central onde é feita a prospecção para a variável em análise;
- σ - É o valor do desvio padrão que define a largura do intervalo de prospecção;

Graficamente, a gaussiana local apresenta-se do seguinte modo:




Figura 13 - Representação Gráfica da Gaussiana Local.

Analisando a figura anterior (Figura 13) justifica-se a escolha por esta modelização, uma vez que, a gaussiana local permite definir qual o valor central pretendido (média - μ). Também é possível visualizar que a modelização escolhida tem a capacidade de distribuir os pesos, de acordo com a proximidade à média como era pretendido, ou seja, a função atribui maior peso quando próximo do valor central e menor peso quando distante do valor central.

Importa referir que, é necessário definir uma gaussiana local para cada variável de entrada do modelo. Assim, considerando um vector de entradas $[E]$ com n entradas é necessário definir um vector de funções de prospecção $[F]$ com n funções, ou seja:

$$\bullet \quad [E] = \begin{bmatrix} E_1 \\ E_2 \\ \dots \\ E_n \end{bmatrix} \rightarrow [F] = \begin{bmatrix} f_1 \\ f_2 \\ \dots \\ f_n \end{bmatrix};$$

$$\text{Em que, } f_n = \frac{1}{\sigma_n\sqrt{2\pi}} e^{\left(\frac{(x-E_n)^2}{2\sigma_n^2}\right)};$$

Graficamente surgem n funções todas centradas em torno da sua variável média (μ) como se pode visualizar na Figura 14:




Figura 14 - Conjunto de Gaussianas Locais para cada Variável de Entrada.

O objectivo é encontrar na base de conhecimento do modelo n-uplas de transição. Deste modo, e como existem n variáveis de entrada o mecanismo de prospecção de similaridade histórica é definido como:

$$FH_a = f_{1a} \times f_{2a} \times \dots \times f_{na} \quad (\text{Eq. 20})$$

Onde,

- a - Corresponde ao índice do caso em análise, que pode variar entre 0 e o número máximo de dados presentes na base de conhecimento;

O mecanismo de prospecção associa a cada transição entre P_{t-1} e P_t , presente na base de conhecimento do modelo, um determinado valor de acordo com similaridade existente entre as transições NWP de entrada, para qual se pretende efectuar uma previsão, e as transições NWP que se encontram na base de conhecimento do modelo.

3.4.1.1- Análise do Parâmetro Sigma - σ

Após apresentada a influência do parâmetro média (μ) da gaussiana local, de seguida apresenta-se a análise do parâmetro sigma (σ). Este parâmetro define a largura dos intervalos de prospecção, onde a sua influência na forma da gaussiana local é apresentada na Figura 15.




Figura 15 - Influência da Variável Sigma (σ).

Após inspecção da figura anterior verifica-se que quanto maior é o parâmetro sigma maior é o número de valores que são considerados quando se efectua a prospecção. Este facto é importante, uma vez que, este parâmetro define a quantidade de valores com relevância, que são seleccionados quando é aplicado o mecanismo de prospecção.

Assim, para definir os valores de sigma a serem utilizados pelas funções de prospecção, deve-se ter em consideração a incerteza/erro associada a cada uma das variáveis de entrada do modelo.

Importa referir que as variáveis de entrada são previsões NWP. Uma possível forma de definir o parâmetro sigma é realizar uma análise de erro entre as variáveis previstas NWP e os valores que foram medidos pelo SCADA.

$$ERRO_i = Valor\ Previsto_i - Valor\ Real_i \quad (Eq. 21)$$

Posto isto, o valor do sigma pode ser definido como sendo o desvio padrão do erro.

$$\sigma = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (ERRO_i - \overline{ERRO})^2} \quad (Eq. 22)$$

Contudo, quando se analisa a variável velocidade do vento, a metodologia anterior pode revelar-se como não sendo a melhor, para definir o parâmetro sigma.

Este facto pode ser explicado quando se analisa a curva de potência de um aerogerador.




Figura 16 - Curva de Potência de um Aerogerador.

Analisando a figura anterior (Figura 16) é possível concluir que na zona de crescimento da curva (zona 1) uma pequena variação na velocidade do vento ΔV implica uma grande variação na potência ΔP . Este efeito é apresentado na figura seguinte (Figura 17).




Figura 17 - Relação entre ΔV e ΔP .

Deste modo, um sigma elevado, quando se analisa velocidades na ordem dos 10 *m/s*, implica o aparecimento de um grande conjunto de valores de potência que podem variar de 0 até à potência máxima. É importante referir que a velocidade de 10 *m/s* apenas serve de exemplo, uma vez que, as curvas dos aerogeradores variam de acordo com o aerogerador.

Assim sendo, o sigma para a variável velocidade do vento não deve ser muito elevado, ou seja, a função de prospecção apenas deverá dar importância a valores com velocidades que distem da média aproximadamente 1 *m/s* (*Valor obtido devido a tentativa e erro durante o processo de construção do modelo*).

Caso o parâmetro sigma seja elevado, o modelo não consegue diferenciar os valores que realmente interessam na zona de subida da curva de potência, uma vez que todos eles são seleccionados independentemente do valor da velocidade do vento.

Quanto à variável direcção do vento, o desvio padrão do erro referido anteriormente, é uma boa técnica, uma vez que a curva que relaciona a direcção do vento com a potência não implica grandes dificuldades.

3.4.2- Matriz de Probabilidades (MP)

Após aplicar o mecanismo de prospecção é necessário criar uma matriz de probabilidades, que integra as probabilidades de transição entre P_{t-1} e P_t (transições de potência).

Criado e aplicado o mecanismo de prospecção, fica definido um valor que se encontra associado a cada transição de potência, presente na base de conhecimento do modelo. Este valor define a probabilidade de ocorrência de cada transição de potência, para uma determinada transição das variáveis NWP.

Importa referir que é extremamente complexo criar uma matriz em que constem todas as transições presentes na base de conhecimento, uma vez que, existem inúmeras transições diferentes. No entanto, os valores de potência podem ser agrupados em intervalos de potência, visto que todos os valores de potência presentes na base de conhecimento do modelo variam entre a potência mínima e a potência máxima.

Deste modo, será representada a probabilidade de transições entre intervalos de potência. Assim sendo, é necessário definir o número de intervalos com o objectivo de agrupar o conjunto de valores de potência.

Outro aspecto a ter em consideração é o número de intervalos a escolher, dado que influencia posteriormente na previsão de potência eólica. Concretamente, os valores de potência que existem na base de conhecimento do modelo vão ser representados por um único valor, geralmente o valor médio das potências presentes em cada intervalo. Assim torna-se necessário escolher um número de intervalos coerente (ex: para um aerogerador de 2MW utilizar intervalos de 100kW) de forma a, obter-se um compromisso entre a previsão desejada e um número de casos suficientemente representativos.

De seguida é necessário definir dois vectores, $[PA]$ que representa a variável P_{t-1} e $[P]$ que representa a variável P_t .

Importa referir que estes vectores contêm a média dos valores de potência presentes em cada intervalo.

$$\bullet \quad [PA] = \begin{bmatrix} I_{y1} \\ I_{y2} \\ \dots \\ I_{yn} \end{bmatrix}$$

- $[P] = \begin{bmatrix} I_{x1} \\ I_{x2} \\ \dots \\ I_{xn} \end{bmatrix}$

- $[PA] = [P]$

Onde:

- n - Define o número de intervalos;
- $I_{yn} = I_{xn} = \frac{(a_n + b_n)}{2}$ - É um intervalo de potência do tipo $[a_n ; b_n]$ sendo a_n e b_n valores de potência compreendidos em 0 e a potência máxima.

Geralmente, o número de intervalos, bem como os próprios intervalos são iguais para os dois vectores, sendo que os valores de P_{t-1} e P_t são muito próximos.

Após a escolha do número de intervalos (n) é possível definir a dimensão da matriz de probabilidade, ou seja, a matriz de probabilidade apresenta uma dimensão $n \times n$.

Posteriormente deve proceder-se à sua construção, em que é necessário percorrer todas as transições de potência presentes na base de conhecimento do modelo, ou seja todos os casos, através da utilização de (Eq. 23):

$$MP(i, j) = MP(i, j) + FH_a \quad (\text{Eq. 23})$$

Onde:

- i - Define as linhas da matriz sendo dado por: $i = (\text{int}) \frac{P_{t-1}}{L}$;
- j - Define as colunas da matriz e é expresso por: $j = (\text{int}) \frac{P_t}{L}$
- L - Define a largura do intervalo sendo dado por: $L = \frac{P_{inst}}{n^\circ \text{ Intervalos}}$
- a - Corresponde ao índice da transição em análise.

Após preencher a matriz de probabilidades é necessário efectuar a sua normalização entre 0 e 1, uma vez que, se considera que a matriz contém todo o espaço de acontecimentos. Deste modo, a matriz de probabilidades é representada por uma distribuição de probabilidade conjunta $f(x, y)$, que apresenta as seguintes características:

- seja $D = \{(I_{xi}, I_{yj}) : P(X = I_{xi}, Y = I_{yj}) > 0\}$;
- $P[(X, Y) \in D] = 1$;
- $f(x, y) \geq 0, (x, y) \in \mathbb{R}^2$;
- $\sum_{I_{xi} I_{yj}} f(I_{xi}, I_{yj}) = 1$;
- $P[(x, y) \in B] = \sum_{(I_{xi} I_{yj}) \in B} f(I_{xi}, I_{yj}) \quad B \subset \mathbb{R}^2$.

Então, a função de distribuição pode exprimir-se em termos da respectiva função de probabilidade:

$$F(x, y) = P(X \leq x, Y \leq y) = \sum_{I_{xi} \leq x; I_{yj} \leq y} f(I_{xi}, I_{yj}) \quad (\text{Eq. 24})$$

Desta forma, a matriz de probabilidades pode ser representada do seguinte modo (Figura 18):

$f(x, y)$		x			
		I_{x1}	I_{x2}	...	I_{xn}
y	I_{y1}	...	...	...	...
	I_{y2}	...	...	...	...
	...	...	...	...	...
	I_{yn}	...	...	...	...

Figura 18 - Representação da Matriz de Probabilidades para n Intervalos.

A variável x representa o conjunto de intervalos de potência em que foi dividida a série de valores de P_t , e a variável y representa o conjunto de intervalos em que foi dividida a série de valores de P_{t-1} .

Assim, representar uma transição de potência por $(P_{t-1}; P_t)$, ou $(y; x)$ é equivalente.

Importa referir que a distribuição de probabilidades conjunta tem associado o conceito de probabilidades marginais, ou seja:

Seja $D = \{(I_{xi}, I_{yj}) : i, j = 1, 2, \dots\}$, as funções probabilidade marginais são definidas por:

$$\begin{aligned} f_{m1}(I_{xi}) &= P(X = I_{xi}) = P(X = I_{xi}, Y = I_{y1}) + P(X = I_{xi}, Y = I_{y2}) + \dots \\ &= \sum_j f(I_{xi}, I_{yj}), \quad j = 1, 2, \dots \end{aligned} \quad (\text{Eq. 25})$$

$$\begin{aligned} f_{m2}(I_{yj}) &= P(Y = I_{yj}) = P(X = I_{x1}, Y = I_{yj}) + P(X = I_{x2}, Y = I_{yj}) + \dots \\ &= \sum_i f(I_{xi}, I_{yj}), \quad i = 1, 2, \dots \end{aligned} \quad (\text{Eq. 26})$$

3.4.3- Formulação do Problema em Estudo

Após apresentar a formulação do modelo desenvolvido, de um modo geral, de seguida será apresentada a formulação para o problema em estudo.

Com o intuito de tornar mais simples e intuitiva a compreensão da formulação procedeu-se à sua subdivisão em etapas.

1. Etapa - Definir as Variáveis

As variáveis em estudo são as apresentadas na secção 3.3, ou seja:

- P_{t-1} - Potência no instante $t-1$;
- P_t - Potência no instante t ;
- V_{t-1} - Velocidade do vento no instante $t-1$;
- V_t - Velocidade do vento no instante t ;
- D_{t-1} - Direcção do vento no instante $t-1$;
- D_t - Direcção do vento no instante t ;

Estas variáveis constituem a base de conhecimento do modelo. Relativamente às variáveis de entrada do modelo são transições NWP, ou seja:



2. Etapa - Definir o Vector Entrada

Importa salientar que no caso em análise apenas é considerada uma entrada, ou seja apenas se efectua a previsão para um conjunto de transições NWP. No entanto, no trabalho desenvolvido o modelo efectua previsão para 48 transições NWP, que corresponde a realizar previsão para intervalos de 30 minutos.

Em todo o caso, o processo para qualquer entrada é equivalente, daí se utilizar como exemplo apenas uma entrada.

$$[E] = \begin{bmatrix} V_{t-1} \\ V_t \\ D_{t-1} \\ D_t \end{bmatrix}$$

3. Etapa - Definir o Vector de Funções

Sendo o vector de entrada definido por quatro elementos, o vector das funções de prospecção terá de apresentar quatro gaussianas locais, ou seja, uma função de prospecção para cada elemento.

Um outro aspecto a ter em consideração é a definição do valor de sigma associado a cada elemento da entrada. Deste modo, para os elementos V_{t-1} e V_t considera-se σ_V e para os elementos D_{t-1} e D_t , σ_D .

$$F = \begin{bmatrix} f_1 \\ f_2 \\ f_3 \\ f_4 \end{bmatrix}$$

Onde,

	$t - 1$		t
Velocidade	$f_1(x; V_{t-1}, \sigma_V) = \frac{1}{\sigma_V \sqrt{2\pi}} e^{\left(\frac{(x-V_{t-1})^2}{2\sigma_V^2}\right)}$		$f_2(x; V_t, \sigma_V) = \frac{1}{\sigma_V \sqrt{2\pi}} e^{\left(\frac{(x-V_t)^2}{2\sigma_V^2}\right)}$
Direcção	$f_3(x; D_{t-1}, \sigma_D) = \frac{1}{\sigma_D \sqrt{2\pi}} e^{\left(\frac{(x-D_{t-1})^2}{2\sigma_D^2}\right)}$		$f_4(x; D_t, \sigma_D) = \frac{1}{\sigma_D \sqrt{2\pi}} e^{\left(\frac{(x-D_t)^2}{2\sigma_D^2}\right)}$

4. Etapa - Definir o Mecanismo de Prospecção de Similaridade Histórica

Após definidas todas as gaussianas locais do vector de funções de prospecção, o mecanismo de prospecção resulta da seguinte expressão:

$$FH_a = f_{1a} \times f_{2a} \times f_{3a} \times f_{4a}$$

5. Etapa - Definir o Número de Intervalos

Como foi explicado anteriormente, para criar a matriz de probabilidades é necessário definir o número de intervalos para se agrupar os valores de potência. Este facto é importante, uma vez que, como existe um elevado conjunto de transições de potência diferentes tornava-se bastante complicado criar uma matriz em que se apresentem todas as transições possíveis. Com este método, é possível agregar as diferentes transições de potência num conjunto de intervalos, tornando a abordagem do problema mais simples.

No caso em estudo, optou-se por escolher 20 intervalos de potência.

$$n = 20;$$

Assim sendo, define-se automaticamente a largura do intervalo, ou seja:

$$L = \frac{P_{inst}}{n^\circ \text{ Intervalos}} = \frac{P_{inst}}{20}$$

Os vectores que representam os intervalos de potência associados a P_{t-1} e P_t apresentam-se respectivamente.

$$\bullet \quad [PA] = \begin{bmatrix} I_{y1} \\ I_{y2} \\ \dots \\ I_{y20} \end{bmatrix} \quad \bullet \quad [P] = \begin{bmatrix} I_{x1} \\ I_{x2} \\ \dots \\ I_{x20} \end{bmatrix}$$

6. Etapa - Construir a Matriz de Probabilidades (MP)

Dado que se optou pela escolha de 20 intervalos de potência, então a dimensão da matriz MP é 20×20 .

De seguida, sabendo que $MP(i, j) = MP(i, j) + FH_a$ é possível preencher a matriz. Posteriormente a próxima etapa visa efectuar a normalização da matriz, para permitir que esta seja representada por uma distribuição de probabilidade conjunta $f(x, y)$.

$f(x, y)$		x			
		I_{x1}	I_{x2}	...	I_{x20}
y	I_{y1}	$P(I_{y1}, I_{x1})$	$P(I_{y1}, I_{x2})$	...	$P(I_{y1}, I_{x20})$
	I_{y2}	$P(I_{y2}, I_{x1})$	$P(I_{y2}, I_{x2})$	...	$P(I_{y2}, I_{x20})$
	...	...	...	...	...
	I_{y20}	$P(I_{y20}, I_{x1})$	$P(I_{y20}, I_{x2})$	...	$P(I_{y20}, I_{x20})$

Figura 19 - Representação da Função $f(x, y)$.

3.5- Ferramentas do Modelo PROSIH

Anteriormente apenas foi referido a base do modelo PROSIH que consiste na transformação de um conjunto de transições NWP de entrada, numa distribuição de probabilidade conjunta $f(x, y)$ que representa a probabilidade de ocorrência das diferentes transições de potência.

No entanto, analisando esta distribuição de probabilidades pode-se fornecer várias dimensões de informação ao utilizador.

Deste modo, foi definido um conjunto de ferramentas, que têm por base as distribuições de probabilidade conjunta criadas, que permitem fornecer um vasto conjunto de informação.

Assim associadas ao modelo PROSIH existem as seguintes ferramentas:

- Previsão de um Ponto de Potência;
- Previsão de Incerteza;
- Previsão de Eventos de Rampa;
- Simulação.

De seguida serão abordadas todas estas ferramentas desenvolvidas, explicando a sua formulação e descrevendo a sua importância.

3.5.1- Previsão de um Ponto de Potência

Esta ferramenta permite fornecer o valor esperado da potência para um determinado instante de tempo, tal como é comum nos modelos de previsão de potência de base eólica existentes. Assim sendo, esta ferramenta tendo como entrada uma determinada transição NWP fornece o valor esperado da potência.

É importante referir que, para cada transição de entrada NWP o modelo PROSIH cria uma função de distribuição de probabilidades conjunta que representa a probabilidade de ocorrência das transições de potência. Deste modo, supondo que se está a efectuar previsão para intervalos de tempo consecutivos, no caso em análise de 30 em 30 minutos, para realizar a previsão para um determinado instante deve-se analisar as transições anteriores e posteriores.

Para efectuar a previsão de um ponto de potência é necessário recorrer à utilização de duas funções de distribuição de probabilidade conjunta, em que a primeira representará a transição anterior $f_1(x, y)$ e a segunda a transição posterior $f_2(x, y)$. Especificamente, serão utilizadas as funções de probabilidade marginal associadas a cada função.

Assim considerando:

- $f_{m1}(I_{xi}) = P(X = I_{xi})$ é a função marginal associada a $f_1(x, y)$;
- $f_{m2}(I_{yj}) = P(Y = I_{yj})$ é a função marginal associada a $f_2(x, y)$;

Tendo em consideração as funções definidas anteriormente é possível definir um vector de funções marginais associadas a $f_1(x, y)$ e a $f_2(x, y)$, ou seja, $[M1]$ e $[M2]$ respectivamente.

$$[M1] = \begin{bmatrix} f_{m1}(I_{x1}) \\ f_{m1}(I_{x2}) \\ \dots \\ f_{m1}(I_{xn}) \end{bmatrix} \quad (\text{Eq. 27})$$

$$[M2] = \begin{bmatrix} f_{m2}(I_{y1}) \\ f_{m2}(I_{y2}) \\ \dots \\ f_{m2}(I_{yn}) \end{bmatrix} \quad (\text{Eq. 28})$$

Posto isto, e considerando que o vector que representa as potências dos intervalos ($[P] = [PA]$ referido anteriormente) se mantém constante ao longo da previsão, a forma para efectuar a previsão de um ponto de potência apresenta-se na equação seguinte (Eq. 29):

$$\text{Previsão} = \frac{[M1] \times [P]^T + [M2] \times [P]^T}{2} \quad (\text{Eq. 29})$$

Importa referir que a metodologia apresentada anteriormente não é a única solução que permite fornecer um ponto de previsão de potência esperada. Numa secção seguinte (3.5.4) será abordada uma outra ferramenta que também permite efectuar previsão de um ponto de potência de base eólica.

3.5.2- Previsão de Incerteza - u

Uma das vantagens do modelo PROSIH desenvolvido nesta dissertação é a sua capacidade de fornecer a incerteza que está associada ao ponto de previsão de potência esperada.

Deste modo, o modelo não fornece apenas um ponto de previsão de potência, mas também fornece a incerteza que está associada a esse ponto. Assim, quando o utilizador desta informação analisar os pontos de previsão de potência esperada, consegue verificar a sua viabilidade. Tal facto permitirá ao utilizador a tomada de decisões com um maior nível de confiança.

Com esta ferramenta, para um determinado instante de tempo, o utilizador terá informação sobre os intervalos de potência em que a o valor real da potência poderá surgir. Para além dos intervalos, também é fornecida a correspondente probabilidade.

Como mencionado anteriormente na secção que aborda a previsão de um ponto de potência, para o cálculo da incerteza também é necessário ter em consideração duas funções de distribuição de probabilidade conjunta, uma que representa a transição anterior $f_1(x, y)$ e outra que representa a transição posterior $f_2(x, y)$. Este facto é importante, uma vez que, nesta situação também interessa analisar as transições de potência anteriores e posteriores.

Assim sendo, o processo é idêntico ao anterior (secção 3.5.1), ou seja, para efectuar a previsão da incerteza recorre-se ao conceito de função de probabilidade marginal para modelizar a incerteza associada à transição anterior e posterior.

Sendo:

- $f_{m1}(I_{xi}) = P(X = I_{xi})$ é a função marginal associada a $f_1(x, y)$;
- $f_{m2}(I_{yj}) = P(Y = I_{yj})$ é a função marginal associada a $f_2(x, y)$;

A função $f_{m1}(I_{xi})$ representa a incerteza associada à transição anterior, enquanto a função $f_{m2}(I_{yj})$ representa a incerteza associada à transição posterior.

Posto isto, a incerteza associada ao ponto de previsão de potência de base eólica é definido através da seguinte equação (Eq. 30).

$$[u] = \begin{bmatrix} f_{m1}(I_{x1}) \times f_{m2}(I_{y1}) \\ f_{m1}(I_{x2}) \times f_{m2}(I_{y2}) \\ \dots \\ f_{m1}(I_{xn}) \times f_{m2}(I_{yn}) \end{bmatrix} \quad (\text{Eq. 30})$$

Importa referir que o vector de incerteza definido anteriormente (Eq. 30) devolve a probabilidade da ocorrência de cada intervalo. No entanto, é necessário efectuar uma normalização do vector entre 0 e 1, uma vez que se assume que este espaço de acontecimentos é o espaço global.

Com o vector normalizado fica definida a probabilidade associada a cada intervalo que varia entre 0 e 100%.

3.5.3- Previsão de Eventos de Rampa

Como já foi descrito no estado da arte (Capítulo 2), uma das características mais importantes a prever são os eventos de rampa associados à potência eólica.

Assim, torna-se relevante efectuar a previsão destes eventos de variabilidade. Deste modo, é possível dar a conhecer ao utilizador a probabilidade de ocorrência deste fenómeno, e assim permitir que este tome as devidas precauções.

O modelo desenvolvido no presente trabalho, modelo PROSIH, tem a capacidade de fornecer informação sobre a probabilidade de eventos de rampa. De seguida, apresenta-se a formulação da sua metodologia de cálculo.

A partir do modelo PROSIH resulta uma função de distribuição de probabilidade conjunta $f(x, y)$ que representa a probabilidade de transição entre intervalos de potência, que pode ser representada do seguinte modo:

$f(x, y)$		x			
		I_{x1}	I_{x2}	...	I_{xn}
y	I_{y1}	$P(I_{y1}, I_{x1})$	$P(I_{y1}, I_{x2})$	...	$P(I_{y1}, I_{xn})$
	I_{y2}	$P(I_{y2}, I_{x1})$	$P(I_{y2}, I_{x2})$	...	$P(I_{y2}, I_{xn})$
	...	...	...	...	...
	I_{yn}	$P(I_{yn}, I_{x1})$	$P(I_{yn}, I_{x2})$	...	$P(I_{yn}, I_{xn})$

	Rampa Mínima
	Rampas Negativas
	Rampas Positivas
	Rampa Máxima Positiva e Negativa

Figura 20 - Função de Distribuição de Probabilidade Conjunta $f(x, y)$.

A figura apresentada anteriormente (Figura 20) surge a título de exemplo sobre a forma como se identificam as rampas utilizando a representação da função $f(x, y)$.

Os eventos de rampa ficam definidos de acordo com a transição entre intervalos de potência. Especificamente, um evento de rampa mínima surge quando se verifica uma transição de potência $(y; x)$, em que os intervalos de potência associados a y e a x são iguais, enquanto os eventos de rampa máxima verificam-se quando existe uma transição do intervalo de potência mínima para o intervalo de potência máxima. Deste modo, surgem dois tipos de rampa máxima:

- Negativa - Surge com o maior intervalo de y e o menor intervalo de x ;
- Positiva - Surge com o menor intervalo de y e o maior intervalo de x ;

Um evento de rampa positiva caracteriza-se por existir uma transição $(y; x)$ em que o intervalo associado a y é inferior ao intervalo associado a x .

No que diz respeito a um evento de rampa negativa, este caracteriza-se por existir uma transição $(y; x)$ em que o intervalo associado a y é superior ao intervalo associado a x .

É notório referir que não existe apenas um evento de rampa positiva ou negativa. Dependendo do número de intervalos definidos pelo utilizador do modelo, podem existir um conjunto de eventos de rampa, que podem ser caracterizados através da atribuição de um nível, caracterizado pela variável a . Esta variável varia entre 2 e $n - 1$.

Assim, podem existir dois tipos de rampas com nível a :

- *Rampa positiva* - Quando existe uma transição em que o intervalo de y é inferior ao intervalo de x ;
- *Rampa Negativa* - Quando existe uma transição em que o intervalo de y é superior ao intervalo de x ;

Um outro pormenor a considerar é a exclusão dos intervalos que fornecem valores de rampa mínima (nível 1) e rampa máxima (nível n).

Dado que, a um determinado nível do evento de rampa se encontra associado uma determinada potência, a amplitude de potência que define um determinado nível pode ser encontrada utilizando a seguinte expressão (Eq. 31).

$$P_{nível\ a} = I_x - I_y \quad (\text{Eq. 31})$$

Da equação anterior (Eq. 31) resulta a amplitude do nível do evento de rampa, bem como, a sua direcção que permite classificá-la como positiva ou negativa.

A figura seguinte (Figura 21) ilustra os diversos níveis possíveis para os diferentes eventos de rampa.

$f(x, y)$		x				
		I_{x1}	I_{x2}	...	I_{xn-1}	I_{xn}
y	I_{y1}	Nível 1	Nível 2	...	Nível $n - 1$	Nível n
	I_{y2}	Nível 2	Nível 1	...		Nível $n - 1$
	...	...	...	...	...	...
	I_{yn-1}	Nível $n - 1$		...	Nível 1	Nível 2
	I_{yn}	Nível n	Nível $n - 1$	...	Nível 2	Nível 1

Figura 21 - Ilustração da Distribuição dos Diferentes Níveis que Caracterizam os Eventos de Rampa.

Em termos numéricos as equações que caracterizam os eventos de rampa são as seguintes:

- Probabilidade de Rampa Mínima

$$\sum_{i,j} f(I_{xi}, I_{yj}) = P(X = I_{x1}, Y = I_{y1}) + P(X = I_{x2}, Y = I_{y2}) + \dots + P(X = I_{xn}, Y = I_{yn}) \quad (\text{Eq. 32})$$

- Probabilidade de Rampas Positivas

$$\begin{aligned} \sum_{i,j} f(I_{x(i=a)}, I_{yj}) &= \\ &= P(X = I_{xa}, Y = I_{y1}) + P(X = I_{x(a+1)}, Y = I_{y2}) + \dots + P(X = I_{xn}, Y = I_{y(n-(a-1))}) \end{aligned} \quad (\text{Eq. 33})$$

É importante referir que a expressão anterior (Eq. 33) é variável consoante o nível da rampa que se pretende calcular.

- Probabilidade de Rampas Negativas

$$\begin{aligned} \sum_{i,j} f(I_{xi}, I_{y(j=a)}) &= \\ &= P(X = I_{x1}, Y = I_{ya}) + P(X = I_{x2}, Y = I_{y(a+1)}) + \dots + P(X = I_{x(n-(a-1))}, Y = I_{yn}) \end{aligned} \quad (\text{Eq. 34})$$

As considerações utilizadas para as rampas positivas aplicam-se, para o caso específico das rampas negativas.

- Probabilidade de Rampa Máxima

$$f(I_{xn}, I_{y1}) = P(X = I_{xn}, Y = I_{y1})$$

ou

$$f(I_{x1}, I_{yn}) = P(X = I_{x1}, Y = I_{yn})$$
(Eq. 35)

Utilizando a metodologia anteriormente apresentada, é possível definir a amplitude de um evento de rampa, a sua direcção, bem como, a sua probabilidade de ocorrência. Assim, após o cálculo de todos os eventos de rampa possíveis para uma transição de variáveis de entrada NWP, pode-se analisar qual a probabilidade de evolução da potência, ou seja, é possível prever se a produção eólica se vai manter no mesmo nível de potência, se vai baixar ou se vai aumentar.

Esta informação permite mais uma vez analisar a viabilidade dos pontos de potência previstos. Logo, vai permitir ao utilizador desta informação tomar decisões com um maior nível de confiança.

No entanto, convém salientar que a metodologia apresentada anteriormente não é a única solução possível para se efectuar a previsão de eventos de rampa. Em seguida, em 3.5.4 quando se abordar as técnicas de simulação, será abordada outra forma de identificar eventos de rampa.

3.5.4- Simulação

Esta ferramenta permite efectuar simulação de cenários, ou seja, realizar uma previsão de vários valores de potência para uma determinada transição de variáveis NWP de entrada. A simulação é baseada na incerteza que está associada a cada ponto de previsão de potência fornecido pelo modelo PROSIH.

A informação produzida por outras ferramentas como a previsão de incertezas e de eventos de rampa, em diversas situações, não é de fácil compreensão. Tal facto, torna necessário que o seu utilizador apresente alguma sensibilidade. Contudo, com a ferramenta de simulação, o facto de existir a necessidade de sensibilidade fica reduzido, ou seja, representando os resultados provenientes da simulação sob a forma gráfica, torna-se mais fácil analisar a informação.

Com esta ferramenta será possível efectuar previsões de pontos de potência esperada, analisar a incerteza, bem como, verificar os níveis de rampas que devem surgir ao longo do horizonte temporal da previsão. Refira-se que, esta ferramenta fornece vários pontos de potência esperada para um determinado instante de tempo do horizonte temporal, sendo que todos eles apresentam uma probabilidade de ocorrência diferente.

Para efectuar a simulação para todo o horizonte temporal de previsão é necessário percorrer todas as funções de distribuição de probabilidade conjunta que surgem quando se aplica o modelo PROSIH.

Seja:

- $f_1(x, y)$ - Função de probabilidade conjunta definida para o instante de previsão t ;
- $f_2(x, y)$ - Função de probabilidade conjunta para o instante de previsão seguinte $t+1$;
- x - Representa a variável P_t associada a uma transição de variáveis NWP;
- y - Representa a variável P_{t-1} associada a uma transição de variáveis NWP.

Com base nos pressupostos anteriores, é possível apresentar a metodologia que está na base da simulação.

É importante referir que para efectuar a simulação é necessário conhecer o valor de potência no instante anterior ao que se está a analisar - P_{t-1} . Assim, após conhecido o valor de P_{t-1} , ou seja, o y é possível definir o intervalo de potência em que este se insere. Logo, o intervalo I_y fica definido - I_{yA} .

Posteriormente é possível definir um vector que contém as probabilidades de transição necessárias para efectuar a simulação, ou seja:

$$[S] = \begin{bmatrix} f_1(I_{x1}, I_{yA}) \\ f_1(I_{x2}, I_{yA}) \\ \dots \\ f_1(I_{xn}, I_{yA}) \end{bmatrix} \quad (\text{Eq. 36})$$

Considera-se que a função $g(x)$ representa o vector $[S]$ e que $G(x)$ é a sua função acumulada. Então, graficamente $g(x)$ e $G(x)$ apresentam-se da seguinte forma (Figura 22 e Figura 23):




Figura 22 - Função $g(x)$.




Figura 23 - Função $G(x)$.

Importa salientar que os gráficos apresentados anteriormente apenas se encontram a título de exemplo, ou seja, não é necessário que estes apresentem sempre a mesma forma. No entanto, a forma de $G(x)$ será muito semelhante e apresentará valores entre 0 e 1, uma vez que, o vector $[S]$ deverá ser normalizado entre 0 e 1.

As funções anteriores surgem devido ao conhecimento do valor de potência P_{t-1} . Logo, o passo seguinte consiste em encontrar o intervalo com maior probabilidade de ocorrência, em que se encontra o valor de potência P_t .

Assim, para obter o intervalo utiliza-se a função inversa de $G(x)$, ou seja, $G^{-1}(x)$, em que x é um valor aleatório entre 0 e 1, obtido através de uma distribuição uniforme.

Portanto, o ponto de potência previsto para P_t consiste no valor do intervalo escolhido pela função $G^{-1}(x)$.

No caso em estudo as funções em análise são funções discretas em que a variável x representa intervalos de potência. Este facto pode ser visualizado nas seguintes figuras (Figura 24 e Figura 25).




Figura 24 - Função Discreta $g(x)$.




Figura 25 - Função Discreta $G(x)$.

Este processo repete-se durante todo o horizonte temporal de acordo com o número de simulações, que define o número de valores de potência que são simulados para cada instante de tempo do horizonte temporal.

Outro aspecto a considerar é que o valor de potência previsto P_t para o instante t , quando se analisa a função $f_1(x, y)$, vai ser o valor de P_{t-1} quando se analisa a função $f_2(x, y)$ e assim sucessivamente.

O esquema seguinte (Figura 26) visa demonstrar o modo de funcionamento do processo de simulação entre dois instantes de tempo consecutivos, ou seja, quando se analisa $f_1(x, y)$ e $f_2(x, y)$.




Figura 26 - Exemplo do Princípio de Funcionamento da Simulação.

É importante referir que o esquema repete-se durante todo o horizonte temporal. Sendo que, no final da simulação existe um conjunto de pontos de potência, de acordo com o número de simulações, para cada instante de tempo do horizonte temporal.

Após realizada a simulação é possível obter um conjunto de informação, ou seja, previsão de um ponto de potência, incertezas, eventos de rampa, bem como, probabilidades dos cenários simulados.

No que diz respeito à previsão de um ponto de potência, este pode ser obtido efectuando a média dos vários conjuntos de pontos de potência que existem para cada instante de tempo.

Quanto à incerteza, a ferramenta de simulação permite obter uma distribuição de probabilidades discreta, equivalente à que surge após a aplicação da ferramenta que permite a previsão de incerteza apresentada anteriormente. Contudo, é necessário referir que esta distribuição irá estar dependente do número de simulações que são definidas pelo utilizador. Assim, deve-se ter em consideração o número de simulações utilizado, pois quanto maior o número de simulações maior precisão apresentará a distribuição da incerteza que resulta da simulação.

Tendo em consideração os dados que resultam da simulação e analisando as transições entre os instantes de tempo $t - 1$ e t , é possível obter uma distribuição de probabilidades discreta equivalente ao que se obtém quando se aplica a ferramenta que permite a previsão de eventos de rampa. Analogamente ao que acontece com a distribuição de incerteza também nesta situação a distribuição é dependente do número de simulações.

Expressando graficamente toda a informação produzida pela simulação, é possível analisar/compreender toda a informação de uma forma simplificada. Posteriormente apresenta-se um possível resultado que poderá ser encontrado após efectuar uma simulação (Figura 27).




Figura 27 - Exemplo do Resultado Final de uma Simulação.

Importa salientar, que a curva mais espessa representa as médias da potência prevista para cada intervalo de tempo da previsão, ou seja, a previsão de um ponto de potência de base eólica.

Também é possível verificar a tendência que existe nas transições entre $t - 1$ e t , ou seja, a evolução dos eventos de rampa.

Quanto à incerteza esta pode ser analisada tendo em conta a dispersão de pontos de potência simulados para cada instante do horizonte temporal. Deste modo, quanto mais dispersos se encontrarem os pontos de potência, maior é a incerteza existente.

Um outro indicador fornecido pela ferramenta de simulação é a probabilidade de ocorrência de cenários, sendo um facto importante, quando se analisam diferentes cenários. Esta probabilidade é obtida através do produto entre as diferentes probabilidades que surgem para cada instante de tempo do horizonte temporal, de um determinado cenário.

A probabilidade associada a cada instante de tempo é obtida da função densidade de probabilidade conjunta que resulta do modelo PROSIH para um determinado instante de tempo do horizonte temporal. No final, considerando que o número de cenários é o conjunto total de acontecimentos possíveis deve-se efectuar uma normalização entre 0 e 1.

Em conclusão, a metodologia utilizada para fornecer a simulação é apresentada de seguida.

Seja:

- A_i a probabilidade de uma determinada potência ocorrer para o instante i

Então, a probabilidade de um determinado cenário é dada por:

$$P_{Cenário} = \prod_{i=1}^n A_i \quad (\text{Eq. 37})$$

Onde,

- n é o horizonte temporal da previsão;

No final do processo de simulação obtêm-se um $P_{Cenário}$ para cada cenário pertencente à simulação.

3.6- Síntese

Os actuais modelos de previsão de potência de base eólica apenas fornecem um ponto de previsão de potência. Por vezes, esta informação revela-se escassa, fazendo com que a energia eólica sofra penalizações a nível de mercados de electricidade e também a nível da gestão dos centros produtores.

Sendo o objectivo reduzir as penalizações sofridas pela energia eólica urge a necessidade de desenvolver novos sistemas de previsão capazes de fornecer a informação adequada.

O modelo PROSIH, desenvolvido no presente trabalho, apesar de fornecer o ponto de previsão de potência esperado, fornece um conjunto de informação associada aos pontos de

previsão. Concretamente, este apresenta capacidades que lhe permitem efectuar a previsão de incerteza, previsão de eventos de rampa e simulação de cenários.

A constituição do modelo PROSIH, integra uma base de conhecimento onde se encontram as informações históricas do parque ou aerogerador, e para efectuar a previsão considera como variáveis de entrada as transições de variáveis NWP (direcção e velocidade do vento).

Para que o modelo PROSIH funcione é necessário proceder à criação de um mecanismo de prospecção de similaridade histórica que selecciona os casos relevantes presentes na base de conhecimento do modelo. Após aplicação do mecanismo de prospecção é possível definir uma função de distribuição de probabilidades conjunta que representa transições de intervalos de potência.

Assim, a constituição do modelo PROSIH pode ser representado pelo esquema seguinte (Figura 28).




Figura 28 - Constituição do Modelo PROSIH.

É notório referir que, associado ao modelo PROSIH encontram-se um conjunto de ferramentas que permitem tratar a informação presente nas distribuições de probabilidades conjuntas.

A ferramenta de previsão de um ponto de potência eólica, utiliza as funções de distribuição de probabilidades conjunta que representam as transições de potência anteriores e posteriores ao instante para que se pretende efectuar a previsão. Com esta ferramenta é possível fornecer o valor da potência esperada para um determinado instante do horizonte temporal.

A ferramenta de previsão de incerteza fornece a incerteza associada a cada ponto de previsão obtido pela ferramenta anterior. Esta ferramenta revela-se de grande importância, uma

vez que, permite verificar a validade dos pontos de previsão, permitindo assim melhorar a tomada de decisão. Na sua aplicação, são fornecidos todos os intervalos de potência, em que o valor real de potência poderá surgir.

Os eventos de rampa são considerados como os fenómenos mais importantes para o qual é necessário desenvolver sistemas de previsão. Assim, torna-se necessário efectuar a sua previsão, de modo a melhorar os sistemas de previsão. Com a previsão dos eventos de rampa é possível analisar as tendências da potência eólica ao longo do horizonte temporal de previsão, sendo que a informação produzida por esta ferramenta permite tomar decisões com um maior nível de confiança.

É importante referir que no presente trabalho não se define o evento de rampa, ou seja, qualquer evento de rampa é considerado, ficando a cargo do utilizador da informação definir o evento de rampa que pretende considerar.

Um dos problemas em fornecer um vasto conjunto de informação pode ser a sua interpretação/compreensão. Deste modo, para analisar esta informação pode ser necessário adquirir um determinado nível de sensibilidade. Particularmente, com o objectivo de minimizar este problema foi desenvolvida a ferramenta que permite efectuar a simulação de cenários.

Utilizando a ferramenta de simulação é possível analisar a incerteza existente na previsão, os eventos de rampa ao longo do horizonte temporal, obter um ponto de previsão de potência eólica para cada instante de tempo, bem como, fornecer a probabilidade de cada cenário produzido. O aglomerado de toda esta informação numa apresentação gráfica, torna-se mais simples a sua compreensão. Em conclusão, a ferramenta de simulação permite apresentar um conjunto de possibilidades que podem ocorrer durante um determinado horizonte temporal.

A arquitectura geral do modelo de previsão desenvolvido no presente trabalho pode ser observada na Figura 29.




Figura 29 - Esquema de Funcionamento do Modelo de Previsão Desenvolvido na dissertação.

O modelo desenvolvido fornece uma grande quantidade de informação ao seu utilizador, permitindo melhorar o desempenho dos modelos de previsão de potência de base eólica e apoiar na sua tomada de decisões. Assim, existindo um maior nível de confiança nas decisões, as penalizações existentes sobre a energia eólica devido à volatilidade do recurso primário vão ser minimizadas.

Capítulo 4

Teste do Modelo

4.1- Introdução

Após desenvolver o modelo de previsão de potência eólica torna-se necessário efectuar o seu teste. Este facto é importante, uma vez que, irá permitir validar o modelo desenvolvido e ao mesmo tempo efectuar uma comparação com outros sistemas de previsão de potência de base eólica.

Nesta secção apresenta-se o teste a todas as ferramentas desenvolvidas e apresentadas anteriormente.

Para efectuar o teste utilizaram-se um conjunto de dados medidos e previstos, durante o período de um ano, para um aerogerador de um parque eólico.

A previsão efectuada é para um horizonte temporal de um dia, com intervalos de 30 em 30 minutos, ou seja, 48 pontos de previsão.

Com o intuito de efectuar uma comparação com outros sistemas de previsão, utiliza-se o modelo da Persistência e um modelo baseado em redes neuronais. Importa referir que as condições de teste dos modelos são equivalentes.

Esta comparação apenas pode ser realizada quando se analisa pontos de previsão de potência eólica, uma vez que, os outros modelos não conseguem fornecer a restante informação que o modelo desenvolvido fornece - Incerteza, Eventos de Rampa e Simulação de cenários.

4.2- Teste à Previsão de um Ponto de Potência

Para realizar o teste à ferramenta que permite efectuar a previsão do ponto de potência esperado, efectuaram-se previsões para os dados de teste, para trinta dias ao longo de um ano, com um horizonte temporal de 24 horas. Este conjunto de teste tem como objectivo analisar o erro devolvido pelos vários modelos (Modelo PROSIH, Rede Neuronal e Persistência) ao longo do horizonte temporal de previsão. Para avaliar o desempenho utiliza-se o indicador de erro *NMAPE* (Eq. 15).

Após efectuar o conjunto de previsões para os 30 dias em análise, com os diferentes modelos, obteve-se a seguinte distribuição dos erros ao longo dos diferentes intervalos de tempo.




Figura 30 - Comparação entre os erros (NMAPE) dos diferentes modelos para o horizonte temporal de previsão.

Analisando o gráfico anterior (Figura 30) é possível verificar que tanto a Rede Neuronal como o Modelo PROSIH apresentam uma distribuição do erro, aproximadamente, constante ao longo do horizonte temporal.

A Persistência apresenta bons resultados nos primeiros instantes (até t+4 que no caso em análise representa duas horas), mas, ao longo do horizonte temporal de previsão o erro tem tendência a aumentar. Assim pode-se concluir que o modelo PROSIH apresenta uma melhoria em relação ao modelo da Persistência.

Contudo, pela análise do gráfico não é explícito a melhoria em relação ao modelo da Rede Neuronal. Deste modo, efectuou-se uma média dos erros ao longo do horizonte temporal, de modo a tornar possível a comparação do modelo PROSIH com o modelo da Rede Neuronal. Os resultados obtidos apresentam-se na Tabela 5.

Tabela 5 - Média dos Erros dos diferentes Modelos ao longo do Horizonte Temporal de Previsão.

Tipo de Modelo	Modelo PROSIH	Rede Neuronal	Persistência
Erro NMAPE	8,69%	9,31%	28,95%

Por inspecção da tabela anterior é possível verificar que apesar dos erros do modelo PROSIH e do modelo de Rede Neuronal se apresentarem próximos, ao longo do horizonte de previsão, o modelo PROSIH apresenta em média erros menores. Assim, pode-se concluir que o modelo PROSIH apresenta um melhor desempenho ao longo do horizonte temporal de previsão.

É importante referir quais as características do modelo de Rede Neuronal utilizado. Concretamente, este modelo é constituído por uma rede neuronal com duas entradas (Velocidade e Direcção do Vento Previstas, ou seja variáveis NWP), com 5 neurónios na camada intermédia e com uma saída (Potência).

O número de neurónios foi escolhido com base na seguinte expressão [69] (Eq. 38).

$$N^{\circ}Neuronios = 2 \times N^{\circ}entradas + 1 \quad (\text{Eq. 38})$$

Para efectuar o treino da rede neuronal foi utilizada a mesma informação histórica que se utiliza no modelo PROSIH. A rede neuronal é do tipo *feedforward* em que o seu método de treino é por *backpropagation*. A função de activação dos neurónios é *Tan-Sigmoid Transfer Function* (*tansig(n)*).

A estrutura da rede neuronal é apresentada na figura seguinte (Figura 31).




Figura 31 - Estrutura da Rede Neuronal utilizada.

4.2.1- Análise do Erro na Previsão de um Ponto de Potência

Durante os testes efectuados para realizar a comparação entre modelos observou-se, alguns pormenores importantes que influenciam no erro produzido pelo modelo PROSIH.

Quando se seleccionou os dados de teste, efectuou-se uma escolha de forma a abordar todas as situações que podem acontecer, ou seja, situações de potência elevada, potência baixa e acréscimos e decréscimos de potência ao longo do horizonte temporal.

De seguida, apresentam-se duas das situações para a qual se efectuou a previsão.




Figura 32 - Comparação da Potência Real com a Prevista pelo Modelo PROSIH.

Analisando a figura anterior (Figura 32) é possível verificar que a previsão fornecida pelo modelo PROSIH apresenta várias falhas, quer no início do horizonte temporal de previsão, quer no final.

De modo a encontrar possíveis factores que causam influência nos erros, de seguida procede-se à análise das variáveis de entrada: Velocidade e Direcção do vento, obtidas por previsão NWP.




Figura 33 - Relação entre a Velocidade do Vento Prevista e a Velocidade Real.




Figura 34 - Relação entre a Direcção do Vento Prevista e a Direcção Real.

Analisando as figuras anteriores (Figura 33 e Figura 34) verifica-se que a previsão da velocidade do vento apresenta erros, ou seja, a previsão não segue o valor real. Quanto à direcção não deverá apresentar grandes problemas, uma vez que, o previsto segue o real.

Após observação atenta da previsão de potência (Figura 32) e da previsão de velocidade do vento (Figura 33) verifica-se que nos instantes em que a previsão do vento acompanha o real, o modelo PROSIH apresenta bons resultados. Em contrapartida, quando a previsão do vento falha o modelo PROSIH também falha.

Assim, pode-se concluir que um dos factores que influencia a previsão de um ponto de potência de base eólica por parte do modelo PROSIH é o erro associado ao modelo de previsão das variáveis NWP de entrada.

De seguida, apresenta-se um exemplo em que a previsão das variáveis NWP acompanha o valor real, como forma de comprovar que o modelo PROSIH fornece valores de potência que acompanham o real.




Figura 35 - Comparação da Potência Real com a Prevista pelo Modelo PROSIH.




Figura 36 - Relação entre a Velocidade do Vento Prevista e a Velocidade Real.




Figura 37 - Relação entre a Direcção do Vento Prevista e a Direcção Real.

Analizando as figuras anteriores (Figura 35, Figura 36 e Figura 37) verifica-se que, quando as previsões das variáveis de entrada do modelo acompanham o valor real, o modelo PROSIH fornece bons resultados de previsão.

No entanto, é importante referir que este factor não será a única fonte de erros que poderá influenciar os valores de previsão através do modelo PROSIH. Outros erros que podem provocar falhas podem ser erros de medição por parte do sistema SCADA, bem como erros associados ao próprio modelo.

Contudo, pode-se referir que a ferramenta do modelo PROSIH que permite efectuar previsão de um ponto de potência comporta-se de forma aceitável.

4.3- Teste à Previsão de Incerteza

Quando se pretende efectuar o teste à ferramenta que permite obter a previsão de incerteza, surgem dificuldades. Estas dificuldades devem-se, essencialmente, à não existência de métricas que se adaptem perfeitamente à ferramenta em análise. Assim, para efectuar o teste a esta ferramenta optou-se por adaptar um teste de hipóteses para proporções ao caso em análise, conforme se procede à sua explicação de seguida.

Para cada instante do horizonte temporal de previsão, o modelo PROSIH apesar de fornecer o valor de potência esperada, fornece informação sobre a incerteza que está associada a esse valor, sob forma de uma distribuição de probabilidades discreta. Assim, é possível analisar em que intervalos de potência existe a probabilidade de o valor de potência real surgir. Em termos de análise gráfica a distribuição de probabilidades associada à incerteza é apresentada de seguida (Figura 38).




Figura 38 - Representação gráfica da Incerteza associada a um determinado Instante de Previsão.

Após inspecção da figura anterior (Figura 38) é possível verificar que o ponto de potência real poderá surgir em vários intervalos. É notório referir que esta ferramenta fornece a probabilidade com que a potência real pode surgir num determinado intervalo de potência.

Assim e com o objectivo de testar a ferramenta de previsão de incerteza, considerar-se-á situações em que a potência real surge nos intervalos de potência com maior probabilidade.

O teste de hipóteses para proporções consiste em identificar se uma determinada amostra se enquadra numa determinada população, daí ser justificável o porquê da sua escolha para este teste, uma vez que, o objectivo do teste à ferramenta de previsão de incerteza é verificar se o valor real de potência se enquadra na distribuição de incerteza.

Deste modo, torna-se necessário definir a zona para a qual se aceita e a zona para a qual se rejeita o teste. Para definir estas zonas é necessário efectuar uma transformação à distribuição de probabilidades discreta associada à incerteza. Esta transformação consiste em ordenar, de forma descendente, a distribuição de probabilidades, ou seja, ordenar dos intervalos com maior probabilidade para os de menor probabilidade.

Aplicada a transformação à distribuição de probabilidades discreta obtém-se os resultados apresentados na Figura 39.




Figura 39 - Distribuição da Incerteza, ordenada decrescentemente, por Probabilidade.

É importante salientar que o gráfico anterior (Figura 39) surge apenas a título de exemplo, uma vez que, para cada instante do horizonte temporal de previsão, existe uma distribuição de probabilidades diferente.

Deste modo e definindo o valor da probabilidade para o qual se aceita e rejeita o teste é possível definir duas zonas, ou seja, a **zona de aceitação** e a **zona de rejeição**.

Seja $A = \{I_1, \dots, I_n\}$, o conjunto de intervalos que definem a distribuição de probabilidade discreta associada à incerteza:

- A zona de aceitação é constituída pelos intervalos cuja soma de probabilidades é menor ou igual à probabilidade para qual se aceita o modelo.

$$V = \{x: x \text{ é um número inteiro tal que } 0 < x < n\}$$

- A zona de rejeição é constituída pelos intervalos restantes, ou seja é um conjunto complementar do conjunto de aceitação.

$$F = \{x: x \text{ é um número inteiro tal que } 0 < x < n\}$$

É importante referir que não existe intersecção entre os conjuntos V e F , ou seja, $V \cap F = \{\}$.

Assim sendo é possível definir duas hipóteses:

- H_1 : A potência real surge no conjunto de Aceitação ($P_{real} \in V$);
- H_0 : A potência real surge no conjunto de Rejeição ($P_{real} \in F \Leftrightarrow P_{real} \notin V$);

De seguida, existe a necessidade de verificar em que intervalo surge a potência real, de forma a identificar qual a hipótese a escolher.

É fundamental mencionar que para todos os instantes do horizonte temporal de previsão os conjuntos de aceitação e rejeição alteram-se, uma vez que, a distribuição da incerteza também se altera.

Para efectuar o teste, no caso em análise, foi determinado que o conjunto de aceitação seria definido para uma probabilidade de 90%. Assim, o conjunto de aceitação será constituído por todos os intervalos cuja soma de probabilidades seja 90%, enquanto o conjunto de rejeição será constituído pelos restantes intervalos.

Deste modo, utilizou-se os mesmos dados de teste (trinta dias ao longo de um ano com horizonte de previsão de 48 meias-horas) utilizados na secção anterior (4.2) para efectuar o teste à ferramenta de previsão de um ponto de potência de base eólica. Sendo que, para cada instante do horizonte temporal se verificou qual a hipótese escolhida.

Posteriormente, apresenta-se um gráfico (Figura 40) que mostra a relação entre o número de vezes que cada hipótese foi escolhida ao longo de todos os testes.




Figura 40 - Hipótese H0 versus Hipótese H1.

Da análise do gráfico anterior (Figura 40) verifica-se que ao longo de todos os instantes do horizonte temporal a hipótese 1 (aceitar o modelo de incerteza) foi escolhida 78,7% das vezes.

Contudo, considerando que o valor determinado anteriormente para definir a zona de aceitação é de 90%, seria de esperar que no global a hipótese 1 rondasse os 90%. Tal facto, não se verifica, o que leva a concluir que o modelo de previsão de incerteza apresenta falhas.

É importante referir que quando se tem como objectivo efectuar previsão de potência de base eólica, tendo por base o histórico de dados das variáveis NWP de velocidade e direcção do vento e da potência medida em tempo real pelo sistema SCADA, geralmente analisa-se o histórico de modo a encontrar possíveis erros que possam posteriormente influenciar na previsão.

Os erros que geralmente se pretende eliminar são erros de medição. Assim será possível obter melhores resultados na previsão de um ponto de potência de base eólica. Contudo, estes erros que se pretende eliminar podem ocorrer na realidade, deste modo, ao efectuar a sua eliminação o histórico de dados perde informação.

Quando se analisa a ferramenta de previsão de incerteza que tem por objectivo modelizar todas as situações que têm possibilidade de ocorrência, utilizar o histórico de dados tratado pode ser prejudicial. Deste modo, com um histórico tratado a incerteza perderá informação, ou seja, na previsão de incerteza não serão modelizados todos os casos possíveis, uma vez que existem situações que foram eliminadas.

Assim sendo, como a base de conhecimento do modelo PROSIH utilizada para efectuar a previsão de incerteza no caso em estudo é uma base de conhecimento tratada, é justificável que existam os valores apresentados anteriormente, ou seja, o número de vezes que a hipótese 1 é escolhida ao longo de todos os testes apresenta um valor inferior ao que seria de esperar.

4.4- Teste à Previsão de Eventos de Rampa

Como referido anteriormente (secção 4.3) para testar a ferramenta de previsão de eventos de rampa não existem métricas que se adaptem perfeitamente. De forma análoga, ao teste efectuado à ferramenta de previsão de incerteza utilizou-se uma adaptação ao teste de hipóteses de proporções.

Antes de apresentar a metodologia utilizada para efectuar o teste à ferramenta de previsão de eventos de rampa, é essencial definir o que se considera como evento de rampa. Particularmente, no caso em estudo, define-se de evento de rampa, subidas ou descidas que apresentem uma amplitude de potência superior a 20% da potência máxima, num intervalo de trinta minutos. Assim, para cada instante do horizonte de previsão, esta ferramenta fornece a probabilidade de ocorrência dos vários tipos de rampas, conforme apresenta a Figura 41.




Figura 41 - Previsão de Eventos de Rampa representada graficamente.

É importante mencionar que, no eixo do x são apresentados valores de rampa em relação à potência máxima, ou seja, percentagens de potência máxima.

De seguida é fundamental definir quando é que se considera que a ferramenta prevê a existência de um evento de rampa, pois é necessário definir a percentagem para a qual se considera que existe ou não previsão de evento de rampa. Somente, desta forma, é possível testar se o modelo prevê correctamente a existência ou não de evento de rampa através da comparação com a rampa que acontece na realidade.

Deste modo, é possível definir duas hipóteses:

- H_1 : O Modelo de Previsão Acerta;
- H_0 : O Modelo de Previsão Falha;

Em que escolhe-se a opção com base na tabela seguinte:

Tabela 6 - Tabela que permite a escolha da hipótese.

		Rampa Real	
		Sim	Não
Rampa Prevista	Sim	H_1	H_0
	Não	H_0	H_1

Define-se que o modelo prevê evento de rampa quando, a soma das probabilidades superiores a 20% e inferiores a -20% da potência máxima, é igual ou superior a 90%. Deste modo, quando existir uma soma superior a 90% considera-se que o modelo prevê um evento de rampa para um determinado instante do horizonte temporal. Seguidamente, apenas é necessário verificar se acontece ou não evento de rampa na realidade, e assim escolher qual a hipótese que se deve considerar.

Importa referir que no caso de a soma não verificar os 90% o modelo prevê que não existe evento de rampa.

Considerando que a previsão de um evento de rampa surge para uma percentagem igual ou superior a 90% é de esperar que, na globalidade dos testes a ferramenta de previsão apresente uma percentagem de acertos próxima dos 90%.

Após aplicação dos testes utilizados nas secções anteriores (4.2 e 4.3) e analisando os resultados, obteve-se a seguinte relação.




Figura 42 - Hipótese H0 versus Hipótese H1.


Analisando o gráfico anterior (Figura 42) pode-se concluir que a ferramenta de previsão em 97,2% dos casos analisados acerta na previsão de eventos de rampa.

Assim sendo, esta ferramenta é uma mais-valia, uma vez que, vai permitir ao utilizador da informação saber de antemão, se existe ou não probabilidade de ocorrência de evento de rampa e assim tomar as devidas precauções.

Sabendo que os eventos de rampa podem ser de dois tipos, rampas positivas e rampas negativas, decidiu-se verificar em que situações o modelo falha com maior frequência, ou seja, verificar se é na previsão de rampa positiva ou rampa negativa que o modelo comete erros.

Particularmente, optou-se pela subdivisão do modelo de previsão e analisar separadamente, a previsão de rampas positivas e rampas negativas. Os resultados obtidos da análise apresentam-se na Tabela 7.

Tabela 7 - Resultados obtidos para as Previsões dos diferentes Eventos de Rampa.



Analisando a tabela anterior (Tabela 7) é possível verificar que o modelo de previsão de eventos de rampa apresenta uma maior percentagem de falhas quando está a prever rampas positivas. Contudo, é importante referir que a diferença é pouco significativa, conforme se pode visualizar na análise da Figura 43.




Figura 43 - Influência do tipo de Rampas no modelo de Previsão de Eventos de Rampa.

Examinando a figura anterior (Figura 43) é possível verificar que em 55% dos casos o modelo de previsão de eventos de rampa falha quando está a prever eventos de rampa positiva. Assim, pode-se concluir que o modelo apresenta maior número de falhas quando está a prever eventos de rampa positiva.

4.5- Teste à Simulação

Com a ferramenta de simulação de cenários é possível obter um conjunto de informação sobre a previsão de base eólica. Deste modo, pode-se afirmar que a ferramenta de simulação está subdividida em várias ferramentas.

De seguida, apresenta-se o teste a todas as ferramentas que compõem a simulação.

4.5.1- Previsão de um Ponto de Potência

Uma das capacidades da simulação de cenários é a possibilidade de fornecer um ponto de previsão de potência. Sabe-se que a simulação fornece vários pontos para o mesmo instante de tempo do horizonte temporal. Assim, o ponto de previsão é obtido através da média dos diferentes valores de potência que são simulados para um determinado instante de tempo.

É importante salientar que a ferramenta de simulação para cada ponto de potência simulado utiliza um modelo de fusão, ou seja, utiliza uma fusão com o modelo da Persistência.

O modelo de fusão segue a seguinte equação (Eq. 39).

$$P_{ant} \times \left(e^{\left(-0,44346 * \left(\frac{x+1}{2} \right) \right)} \right) + P \times \left(1 - e^{\left(-0,44346 * \left(\frac{x+1}{2} \right) \right)} \right) \quad (\text{Eq. 39})$$

Onde,

- P_{ant} - É o valor da potência no instante anterior ao primeiro instante de previsão;
- P - É o valor da potência que surge da ferramenta simulação;
- x - É o instante de previsão, que varia entre 0 e o instante máximo de previsão (no caso em estudo 47).

Considerando $f(x) = e^{\left(-0,44346 * \left(\frac{x+1}{2} \right) \right)}$, de seguida pode-se analisar o peso de cada um dos modelos, ao longo do horizonte temporal de previsão.




Figura 44 - Influência dos diferentes modelos ao longo do Horizonte Temporal de Previsão.

Através da observação do gráfico anterior (Figura 44) é possível verificar que o modelo de fusão tem como objectivo utilizar o modelo da Persistência nos instantes iniciais e o modelo da simulação nos restantes. Assim, é possível aproveitar os bons desempenhos do modelo da Persistência nos instantes iniciais.

Seguidamente, efectuou-se uma análise do erro do modelo apresentado, ao longo dos diferentes intervalos de previsão e estabeleceu-se uma comparação com o modelo da Persistência. Os resultados são apresentados de seguida (Figura 45).




Figura 45 - Comparação entre os erros (NMAPE) dos diferentes modelos para o Horizonte Temporal de Previsão.

Atendendo aos resultados apresentados anteriormente (Figura 45) é possível verificar que o modelo de fusão entre o modelo da simulação e da Persistência, apresenta um melhor desempenho face ao modelo da Persistência.

Era expectável que o modelo de fusão nos instantes iniciais apresenta-se um comportamento idêntico ao modelo da Persistência, apesar do modelo da Persistência continuar com melhor desempenho. Quanto ao erro do modelo de fusão este é aproximadamente constante ao longo do horizonte temporal, enquanto que, no modelo da Persistência o erro aumenta consideravelmente, com o horizonte temporal.

No entanto, para verificar a validade do modelo proveniente da simulação apresentada anteriormente, decidiu-se criar mais dois modelos de fusão:

- Fusão entre a Persistência e o modelo de previsão de um ponto potência (secção 4.2);
- Fusão entre a Persistência e o modelo baseado em redes neuronais apresentado na secção 4.2;

De forma a obter uma melhor compreensão decidiu-se atribuir nomes a estes modelos, ou seja:

- Fusão 1 - Modelo de fusão entre a Persistência e o modelo da simulação;
- Fusão 2 - Modelo de fusão entre a Persistência e o modelo de previsão de um ponto de potência;
- Fusão 3 - Modelo de fusão entre a Persistência e o modelo baseado em redes neuronais.

De seguida, efectuou-se o teste a todos os modelos de fusão com o objectivo de verificar o seu comportamento ao longo do horizonte temporal de previsão.




Figura 46 - Comparação dos erros (NMAPE) entre os diferentes Modelos de Fusão.

Os resultados presentes no gráfico anterior (Figura 46) evidenciam que o comportamento dos modelos é muito semelhante ao longo do horizonte temporal de previsão. Contudo, e com o objectivo de classificar os modelos realizou-se uma média dos erros para cada modelo ao longo do horizonte de previsão.

Tabela 8 - Comparação da média dos erros (NMAPE) dos diferentes Modelos, ao longo do Horizonte Temporal de Previsão.

Tipo de Modelo	Fusão 1	Fusão 2	Fusão 3
Erro NMAPE	9,68%	8,45%	9,03%

Pela análise dos erros NMAPE é possível verificar que o modelo de Fusão 1 apresenta o erro médio mais elevado, sendo o modelo Fusão 2 aquele que apresenta o menor erro médio. Contudo, importa referir que o modelo de Fusão 1 está dependente do número de simulações, uma vez que, o valor deste modelo resulta de uma média de valores simulados para a potência prevista.

4.5.2- Previsão da Incerteza

A simulação também permite fornecer uma distribuição de probabilidades associada à incerteza. Assim é essencial verificar se a simulação está a comportar-se de acordo com a ferramenta de previsão de incerteza.


Sendo o objectivo testar se a ferramenta de simulação fornece uma previsão de incerteza, de acordo com a ferramenta de previsão, decidiu-se efectuar uma comparação entre as duas ferramentas.


Assim para efectuar uma comparação, extraíram-se alguns pontos aleatórios do conjunto de dados de teste, de modo a avaliar se as distribuições de probabilidades fornecidas pelas duas ferramentas são equivalentes.


É importante mencionar, que logo à partida existe uma diferença no número de pontos que cada ferramenta tem em consideração. Sendo que a ferramenta da simulação está dependente do número de simulações definido pelo utilizador.

De seguida, é apresentada uma tabela que contém as distribuições de probabilidades associadas à incerteza, fornecidas pelas duas ferramentas.

Tabela 9 - Comparação entre a Ferramenta de Simulação (Previsão de Incertezas) e a Ferramenta de Previsão de Incertezas.







Pela análise dos gráficos presentes na tabela anterior (Tabela 9) constata-se que com a ferramenta de simulação também é possível fornecer a previsão de incerteza com um elevado nível de confiança.

No entanto, é notório referir que a incerteza fornecida pela ferramenta de simulação não apresenta o grau de detalhe da ferramenta de previsão de incerteza. Tal facto, deve-se ao número de simulações que são consideradas. Contudo, a distribuição de probabilidades discreta fornecida por ambas as ferramentas é equivalente, deste modo esta ferramenta pode ser validada.


Um outro pormenor importante a salientar é que, no caso em análise foram consideradas 100 simulações para cada instante de tempo do horizonte temporal.









4.5.3- Previsão de Eventos de Rampa


A ferramenta de simulação também permite fornecer a previsão de eventos de rampa. Esta previsão é baseada no número de simulações que existe para cada ponto do horizonte temporal da previsão. Assim uma forma de testar a simulação quanto à previsão de eventos de rampa é estabelecer uma comparação entre a distribuição de probabilidades que surgem, quer da ferramenta de simulação, quer da ferramenta de previsão de eventos de rampa.

De forma análoga ao efectuado na secção anterior (secção 4.5.3) considerou-se um conjunto de pontos aleatórios dos dados de teste, com o objectivo de proporcionar uma comparação. Os resultados da análise dos pontos extraídos apresentam-se na Tabela 10.

Tabela 10 - Comparação entre a Ferramenta de Simulação (Previsão de Eventos de Rampa) e a Ferramenta de Previsão de Eventos de Rampa.







Após análise dos resultados presentes na tabela anterior (Tabela 10) verifica-se que a distribuição de probabilidades fornecidas pelas diferentes ferramentas é equivalente. No entanto, a ferramenta de simulação apresenta menor detalhe, originado pelo número de simulações utilizadas.

Contudo, conclui-se que a previsão dos eventos de rampa é possível utilizando qualquer uma das ferramentas. Como a ferramenta de simulação apresenta resultados idênticos aos fornecidos pela ferramenta de previsão de eventos de rampa (ferramenta testada anteriormente na secção 4.4), pode-se concluir que esta ferramenta comporta-se como seria de esperar, podendo assim ser validada.

4.6- Conclusões

O teste de uma ferramenta é extremamente importante, uma vez que, permite validar ou não, essa mesma ferramenta. Assim anteriormente, efectuou-se o teste a todas as ferramentas desenvolvidas com o objectivo de verificar a sua viabilidade.

No decorrer dos diversos testes, surgiram algumas dificuldades motivadas pela falta de métricas que se adaptem perfeitamente às ferramentas em análise. Este facto surge devido à ausência de ferramentas semelhantes às que foram desenvolvidas nesta dissertação. Contudo, e com o objectivo de testar todas as ferramentas procedeu-se à adaptação de alguns testes.

Um dos objectivos do presente capítulo era testar e comparar as ferramentas com outras já existentes. Contudo, este facto apenas foi possível com a ferramenta que permite efectuar a previsão de um ponto de potência eólica. Para as restantes ferramentas não foi possível efectuar a comparação, uma vez que, não existem ferramentas que permitam efectuar o mesmo tipo de previsão.

Da análise dos resultados dos testes efectuados, verificou-se que em geral todas as ferramentas se encontram dentro do esperado. No entanto, é importante referir que a ferramenta que permite a previsão de incerteza apresenta um desempenho abaixo do expectável, talvez, devido ao tratamento dos dados que constituem a base de conhecimento do modelo.

Como conclusão geral, pode-se afirmar que o modelo PROSIH, desenvolvido no decorrer do trabalho superou os testes propostos, podendo assim ser validado.

Capítulo 5

Conclusões

5.1- Conclusões Gerais

Actualmente existe um elevado investimento na produção de energia através de recursos renováveis. Deste modo, surgiu um elevado investimento na energia eólica, quer na Europa, quer nos Estados Unidos da América. Essencialmente, recorre-se à produção de energia eléctrica através de recursos eólicos devido à maturidade da sua tecnologia e dos recursos disponíveis.

Contudo, a introdução da energia eólica na rede implica problemas que surgem devido à variabilidade e volatilidade do seu recurso primário - O Vento.

Com o objectivo de minimizar os problemas impostos por este tipo de recurso, bem como, minimizar as penalizações que lhe são impostas, surge a necessidade de efectuar a sua previsão. Esta previsão tende a evoluir cada vez mais, com o intuito de melhorar a sua precisão e fornecer novas dimensões de informação.

Os modelos de previsão existentes distinguem-se de acordo com o horizonte temporal de previsão: **muito curto prazo, curto prazo e longo prazo**. Estes podem ser divididos em 3 grupos: **modelos físicos, modelos estatísticos e modelos híbridos** que resultam da junção dos anteriores.

Especificamente, o modelo desenvolvido nesta dissertação insere-se no grupo dos modelos estatísticos com horizonte temporal de curto prazo.

Nos dias de hoje, uma das desvantagens dos modelos de previsão eólica é que apenas fornecem um ponto de previsão de potência. Sendo o objectivo melhorar os sistemas de previsão, muitas das vezes esta informação revela-se escassa fazendo, com que a energia eólica sofra penalizações a nível de mercados de electricidade e também a nível da gestão dos centros produtores. Assim, o principal motivo para a realização deste trabalho foi a escassez de informação que os modelos fornecem. Deste modo, desenvolveu-se um sistema de previsão

com a possibilidade de fornecer os tradicionais pontos de potência eólica, assim como, um conjunto de informação que permitirá melhorar a tomada de decisão e minimizar as penalizações.

Concretamente, o sistema desenvolvido é designado de modelo PROSIH, que tem por base o histórico de dados de um determinado aerogerador ou parque eólico. Para realizar a previsão, o modelo desenvolvido considera a informação que existe nas transições entre os instantes tempo $t - 1$ e t das seguintes variáveis:

- Variáveis NWP - Direcção e velocidade do vento;
- Potência medida pelo sistema SCADA;

Com base nesta informação é possível fornecer a incerteza presente na previsão, bem como, prever a probabilidade de eventos de rampa.

No que concerne à previsão de incerteza esta informação é uma mais-valia para o seu utilizador, uma vez que, permite não só o conhecimento antecipado do valor esperado de potência, mas também saber até que ponto esse valor previsto é fiável.

Os eventos de rampa em sistemas com elevada integração de potência eólica podem causar inúmeros problemas. Deste modo, torna-se necessário desenvolver ferramentas que permitam efectuar a sua previsão. Assim, o modelo desenvolvido nesta dissertação (modelo PROSIH) apresenta uma ferramenta com capacidade de prever este tipo de eventos, fazendo com que os problemas que lhe estão associados sejam minimizados.

Após facultar toda esta informação ao utilizador, é possível que este tome decisões com maior grau de fiabilidade. Contudo, um dos problemas em fornecer um vasto conjunto de informação pode ser a sua interpretação/compreensão. Tal facto, implica que o utilizador que pretenda analisar um elevado conjunto de informação, adquira um determinado nível de sensibilidade.

É importante referir que o modelo apresenta outra ferramenta - Simulação. Esta ferramenta permite a simulação de diversos cenários com várias probabilidades de ocorrência. Desta ferramenta, é possível obter todo o conjunto de informação abordado anteriormente.

Uma das vantagens da simulação é que, quando se representam os seus resultados sob a forma gráfica é possível analisar toda a informação de uma forma simplificada.

Para validar o modelo desenvolvido procedeu-se à realização de testes. Particularmente, efectuaram-se testes a todas as ferramentas desenvolvidas, sendo também estas ferramentas comparadas com outros modelos de previsão. É relevante salientar que, unicamente foi possível efectuar comparação quando se testou a ferramenta de previsão de um ponto de potência. Quanto às restantes ferramentas não foi possível efectuar a sua comparação, uma vez que, os modelos utilizados para efectuar a comparação não permitem fornecer a informação pretendida.

Da análise dos resultados obtidos pode-se concluir que em geral todas as ferramentas desenvolvidas apresentaram um bom desempenho. É de salientar que apenas a ferramenta de

previsão de incertezas apresentou uma variância inferior ao esperado. Contudo, este facto deve-se ao pré-processamento de dados do histórico, sendo filtrados e retirados da base de conhecimento casos extremos.

Um aspecto a ter em consideração é o histórico de dados do modelo, uma vez que, para funcionar com um elevado nível de confiança é necessário apresentar um histórico de dados significativo.

Pode-se referir que, modelos capazes de fornecer um conjunto de informação em vez de um ponto de potência tornam os modelos mais fiáveis e robustos. Assim sendo, é possível minimizar as penalizações sofridas pela energia eólica devido à volatilidade do seu recurso primário. Deste modo, com a evolução dos sistemas de previsão, a introdução da energia eólica na rede eléctrica pode ser considerada uma solução e não um problema.

5.2- Conclusões Finais

Em suma, o modelo de previsão desenvolvido apresenta capacidades inovadoras, tais como:

- Capacidade de modelização estocástica de casos;
- Capacidade de modelização de transições entre instantes de tempo, para além de valores pontuais;
- Não necessita de treino.

As capacidades do modelo PROSIH permitem simular incertezas no próprio conjunto de casos, efectuar directamente a previsão de eventos de rampa, bem como, realizar simulações, em que não se simula a incerteza associada a cada ponto de potência, mas sim a incerteza presente nas transições entre pontos de potência.

O modelo desenvolvido apresenta-se como uma nova forma de inferência de conhecimento, apresentando melhores resultados (*outsample*) que os modelos tradicionais. Este modelo tem a capacidade de fornecer várias dimensões de informação (Incerteza, Eventos de Rampa, Previsão de um Ponto de Potência), o que até ao momento não é muito habitual.

Outro aspecto a salientar é que aparentemente parece um modelo pesado a nível de cálculo. No entanto, este facto não se verifica devido ao baixo número de variáveis que tem em consideração, conseguindo efectuar previsões em tempos muito inferiores ao que é necessário para funcionar em tempo real.

Uma das vantagens do modelo apresentado nesta dissertação é a capacidade de se actualizar a base de conhecimento do modelo. Este facto é importante, uma vez que, quanto melhor a base de conhecimento, melhor será o desempenho do modelo.

5.3- Trabalhos Futuros

Um dos sistemas de previsão do modelo PROSIH a melhorar é a previsão de incerteza, uma vez que, revelou resultados inferiores ao que seria de esperar. Uma possível solução para esta situação consiste em construir um modelo que apresente mais do que uma base histórica. Este facto irá permitir, que quando se efectua previsão de incerteza todas as situações sejam modelizadas, pois a base histórica utilizada não seria tratada.

Um outro sistema a desenvolver seria um modelo de estimação de estados. O modelo de previsão fornece valores de previsão para as situações em que o parque se encontra a funcionar no seu estado normal. Contudo, existem situações em que o parque não se encontra no estado normal, assim um modelo capaz de modelizar o estado actual do parque poderia melhorar significativamente os modelos de previsão.

Um dos principais factores de erro nos modelos de previsão são as variáveis meteorológicas previstas, seria importante encontrar modelos que permitam efectuar a modelização do erro.

Em conclusão, na opinião do autor da presente dissertação, todos os aspectos referidos anteriormente seriam importantes para a evolução dos sistemas de previsão de potência eólica. O objectivo é tornar os modelos mais fiáveis e assim permitir a redução das penalizações sofridas pela energia eólica.

Referências

- [1] "Programa E4 - Eficiência Energética e Energias Endógenas", Ministério da Economia, Setembro. 2001.
- [2] "Renováveis: Estatísticas e tecnologia Rápidas", Direcção Geral de Energia e Geologia, Março 2009.
- [3] "Renováveis: Estatísticas e tecnologia Rápidas", Direcção Geral de Energia e Geologia, Março 2008.
- [4] João Nuno Monteiro da Silva e Sousa, "Previsão da Produção Eléctrica em Parques Eólicos," Porto: FEUP, 2007.
- [5] Rui Castro Ana Estaqueiro, Pedro Flores, João Ricardo, Medeiros Pinto, Reis Rodrigues e Peças Lopes, "How to prepare a power systems for 15% wind wnwegy penetration: the Portuguese case study," *Wind Energy*, vol. 11, pp. 75-84, 2008.
- [6] J. A. Peças Lopes A. Rodrigues, P. Miranda, L. Palma, C. Monteiro, R. Bessa, J. Sousa, C. Rodrigues, J. Matos, "EPREV - A Wind Power Forecasting Tool for Portugal," in *Proceeding of the European Wind Energy Conference EWEC'07*, Milan, Italy, 2007.
- [7] "Wind Power Targets for Europe: 75,000 MW by 2010", European Wind Energy Association, Outubro. 2003.
- [8] "Making 180 GW a reality by 2020", European Wind Energy Association, Outubro. 2007.
- [9] "Strategic Research Agenda Market Deployment Strategy: from 2008 to 2030", European Wind Energy Technology Platform, Julho. 2008.
- [10] "Pure Power: Wind Energy Scenarios up to 2030", The European Wind Energy Association, Março. 2008.
- [11] R. Fortoft J. Charney, and J. von Neumann, "Numerical integration of the barotropic vorticity equation," *Tellus*, vol. 2, pp. 237-254 1950.
- [12] A. Joensen T. Nielsen, H. Madsen, L. Landberg, and G. Giebel, "A new reference for Wind Power Forecasting," *Wind Energy*, vol. 1, pp. 29-34, 1999.
- [13] and R. Brownsword Gregor Giebel G. Kariniotakis, "State of the Art on Short-term Wind Power Prediction," *ANEMOS Deliverable Report D1.1*, 2003.
- [14] I. Marti D. Cabezon, M.J. San Isidro, and I. Perez., "Comparison of Methods for Power Curve Modelling," in *Proceedings of the Global WindPower 2004 Conference*, Chicago, Illinois, USA, 2004.
- [15] A. Crespo A. Costa, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa, "A review on the young history of the wind power short-term prediction," *Renewable and Sustainable Energy*, vol. 12, pp. 1725-1744, 2008.

- [16] H. Madsen T.S. Nielsen, H.Aa. Nielsen, L. Landberg, and G. Giebel, "Zephyr - The Prediction Models," in *Proceeding of the European Wind Energy Conference EWE'01*, Copenhagen, Julho 2001, pp. 868-871.
- [17] A. Crespo A. Costa, E. Feitosa, J. Navarro, P. Jiménez, and E. García, "Mathematical and physical Wind Power Forecasting models: a proposal for the UPM PREDICTION project," in *Proceedings of the second joint action symposium on wind forecasting techniques*, Lyngby, 2004.
- [18] Ismael Sanchez, "Short-term prediction of wind energy production," *International Journal of Forecasting*, vol. 22, pp. 43-56, 2006.
- [19] G. Kariniotakis H. Madsen, H. A. Nielsen, T. Nielsen, and P. Pinson, "A Protocol for Standardizing the Performance Evaluation of Short-Term Wind Power Prediction Models," ANEMOS deliverable 2.3, 2004.
- [20] L. Fugon J. Juban, and G. Kariniotakis, "Uncertainty Estimation of Wind Power Forecasts," in *Proceeding of the European Wind Energy Conference EWE'08*, Brussels, Belgium, 2008.
- [21] H. Aa. Nielsen P. Pinson, H. Madsen, M. Lange, and G. Kariniotakis, "Methods for the estimation of the uncertainty of wind power forecasts," Anemos project deliverable report D3.1b, Março, 2007.
- [22] John B. Bremnes, "Probabilistic wind power forecasts using local quantile regression," *Wind Energy*, vol. 7, pp. 45-54, 2004.
- [23] P. Pinson, "Estimation of the uncertainty in wind power forecasting," Paris, France: Ecole des Mines de Paris, 2006.
- [24] L. Fugon and George Kariniotakis J. Juban "Probabilistic short-term wind power forecasting based on kernel density estimators," in *Proceeding of the European Wind Energy Conference EWE'07*, Milão, 2007.
- [25] P. Pinson and G. Kariniotakis, "On-line assessment of prediction risk for wind power production forecasts," *Wind Energy*, vol. 7, pp. 119-132, 2004.
- [26] H.Aa. Nielsen P. Pinson, H. Madsen, and G. Kariniotakis, "Skill forecasting from ensemble predictions of wind power," *Applied Energy*, 2009.
- [27] G. Papaefthymiou P. Pinson, B. Klockl, H.Aa. Nielsen, and H. Madsen "From probabilistic forecasts to statistical scenarios of short-term wind power production," *Wind Energy*, vol. 12, pp. 51-62, 2009.
- [28] G. Papaefthymiou P. Pinson, B. Klockl, and J. Verboomen, "Dynamic sizing of energy storage for hedging wind power forecast uncertainty," in *Proceedings of the IEEE Power Engineering Society General Meeting 2009*, , Calgary, Canada, 2009.
- [29] M. Lange, "On the uncertainty of wind power predictions - Analysis of the forecast accuracy and statistical distribution of errors," *Transactions of the ASME, Journal of Solar Energy Engineering*, vol. 2, pp. 174-194, 2005.
- [30] C. Morhlen, "Uncertainty in wind energy forecasting," Ireland: University College Cork, 2004.
- [31] M. Lange, "Analysis of the uncertainty of wind power predictions," Carl von Ossietzky Oldenburg University, 2003.
- [32] John B. Bremnes, "A comparison of a few statistical models for making quantile wind power forecasts," *Wind Energy*, vol. 9, pp. 3-11, 2006.
- [33] R.C. Wolff P. Hall, Q. Yao, "Methods for estimating a conditional distribution function," *Journal of the American Statistical Association*, vol. 94, pp. 154-163, 1999.
- [34] J.A. Dominguez-Navarro H. Bludszweit, and A. Llombart, "Statistical Analysis of Wind Power Forecast Error," *IEEE Transactions on Power Systems*, vol. 23, pp. 983-991, 2008.
- [35] H. Madsen H. A. Nielsen, and T. S. Nielsen, "Using quantile regression to extend an existing Wind Power Forecasting system with probabilistic forecasts," *Wind Energy*, vol. 9, pp. 95-108, 2006.
- [36] Nicolai Meinshausen, "Quantile Regression Forests," *Journal of Machine Learning Research*, vol. 7, pp. 983-999, 2006.
- [37] H. Madsen H. A. Nielsen, T.S. Nielsen, J. Badger, G. Giebel, L. Landberg, K. Sattler, and H. Feddersen, "Wind Power Ensemble Forecasting Using Wind Speed and Direction Ensembles from ECMWF or NCEP," Denmark Project PSO, Technical Report, 2005.

- [38] J. Badger G. Giebel, L. Landberg, H. A. Nielsen, T. S. Nielsen, H. Madsen, K. Sattler, H. Feddersen, H. Vedel, J. Tøfting, L. Kruse, and L. Voulund, "Wind Power Prediction using Ensembles," Technical Report, Risø National Laboratory, Roskilde, Denmark, 2005.
- [39] Eric Gritmit, "A Prototype Day-Ahead Forecast System for Rapid Wind Ramp Events ", Presentation for CanWEA 2007, 2007.
- [40] John W. Zack, "Optimization of Wind Power Production Forecast Performance During Critical Periods for Grid Management ", *Poster presentation WINDPOWER 2007, Los Angeles, CA*, 2007.
- [41] Jonathan Collins Jeremy Parkes, Craig Collier, Andrew Tindal, "TEMPORAL FORECAST UNCERTAINTY FOR RAMP EVENTS."
- [42] M. Lange U. Focken, and H.P. Waldl, "Previento - A Wind Power Prediction System with an Innovative Upscaling Algorithm," in *Proceeding of the European Wind Energy Conference EWEC'01 System with an Innovative Upscaling Algorithm*, Copenhagen, Denmark, 2001, pp. 826-829.
- [43] K. Mönnich, "Vorhersage der Leistungsabgabe netzeinspeisender Windkraftanlagen zur Unterstützung der Kraftwerkseinsatzplanung," Carl von Ossietzky Universität Oldenburg, 2000.
- [44] U. Focken M. Lange, and D. Heinemann, "Previento - Regional Wind Power Prediction with Risk Control," in *Proceedings of the World Wind Energy Conference*, Berlin, 2002.
- [45] H.A. Nielsen H. Madsen, and T.S. Nielsen "A tool for predicting the wind power production of off-shore wind plants," in *Proceedings of the Copenhagen Offshore Wind Conference & Exhibition, Danish Wind Industry Association*, Copenhagen, 2005.
- [46] T.S. Nielsen H.A. Nielsen, H. Madsen, G. Giebel, J. Badger, L. Landberg, K. Sattler, L. Voulund, and J. Tofting, "From wind ensembles to probabilistic information about future wind power production - results from an actual application," in *Proceedings of International Conference on Probabilistic Methods Applied to Power Systems*, 2006.
- [47] L. Landberg G. Giebel, T.S. Nielsen, and H. Madsen, "The Zephyr Project - The Next Generation Prediction System," in *Poster Presentation on the Global Windpower Conference and Exhibition*, Paris, France, 2002.
- [48] G. Kariniotakis, "The ARMINES Wind Power Prediction System," 2004.
- [49] D. Mayer G. Kariniotakis, J.A. Halliday, A.G. Dutton, A.D. Irving, R.A. Brownsword, P.S. Dokopoulos, and M.C. Alexiadis, "Load, Wind and Hydro Power Forecasting Functions of the More-Care EMS System," in *Proceedings of the 3rd MED POWER conference 2002*, Athens, Greece, 2002.
- [50] P. Pinson and G. Kariniotakis, "Wind Power Forecasting using fuzzy neural networks enhanced with on-line prediction risk assessment," in *Proceedings of the IEEE Power Tech Conference*, Bologna, 2003, pp. 23-26.
- [51] I. Sánchez, "Adaptive density estimation of wind power predictions," in *Proceedings of the International Symposium on Forecasting ISF2008*, Nice, France, 2008.
- [52] J. Möhrle S. Lang, J. Jørgensen, B. O. Gallachóir, and E. McKeogh, "Aggregate forecasting of wind generation on the Irish grid using a multi-scheme ensemble prediction system," in *Proceedings, Renewable Energy in Maritime Island Climates, 2nd Conference*, Dublin, Ireland, 2006.
- [53] M. Lange and U. Focken, "State-of-the-art in wind power prediction in Germany and international developments," in *Proceedings of the Second Workshop of International Feed-In Cooperation*, Berlin, 2005.
- [54] L. Landberg, "Short-term Prediction of Local Wind Conditions," Roskilde, Denmark Risø National Laboratory, 1994.
- [55] I. Troen and E.L. Petersen, "European Wind Atlas," Published for the EU Commission DGXII by Risø National Laboratory, Denmark, 1998.
- [56] L. Landberg R. Watson, R. Costello, D. McCoy, and P. O'Donnell, "Evaluation of the Prediktor Wind Power Forecasting System in Ireland," in *Proceeding of the European Wind Energy Conference EWEC'01*, Copenhagen, Denmark, 2001, pp. 703-706.
- [57] L. Landberg G. Giebel, K. Mönnich, and H. P. Waldl, "Relative Performance of different Numerical Weather Prediction Models for Short Term Prediction of Wind Energy,"

- in *Proceeding of the European Wind Energy Conference EWEC'99*, pp. 1078-1081, Nice, France, 1999.
- [58] "California Wind Energy Forecasting System Development and Testing, Phase 1: Initial Testing", EPRI Final report, January 2003.
- [59] "California Wind Energy Forecasting System Development and Testing Phase 2: 12-Month Testing and Evaluation", EPRI Final report, 2003.
- [60] Ignácio Martí, "Wind Forecasting Activities," in *Proceedings of the First IEA Joint Action Symposium on Wind Forecasting Techniques*, Norrköping, Sweden, 2002.
- [61] C. Gallardo M. A. Gartner, C. Tejada, N. Martínez, S. Calabria, and B. Fernández, "The Casandra Project: results of wind power 72 h range daily operational forecasting in Spain," in *Proceedings of European Wind Energy Conference*, 2003.
- [62] M. C. Ensslin Durstewitz, B. Hahn, and M. Hoppe-Kilpper, "Annual Evaluation of the Scientific Measurement and Evaluation Programme (WMEP)," Kassel, 2001.
- [63] K. Rohrig B. Ernst, H. Regber, and P. Schorn, "Managing 3000 MW Wind Power in a Transmission System Operation Center," Copenhagen, Denmark, 2001.
- [64] G. Gow, "Forecasting Short-Term Wind Farm Production," Technical report, Garrad Hassan and Partners Ltd, Bristol, 2003.
- [65] J. Parkes and A. Tindal, "Forecasting short term wind farm production in complex terrain " in *Proceeding of the European Wind Energy Conference EWEC'04*, London, U.K., 2004.
- [66] "Previsión producción eólica", AleaSoft, Madrid, marzo. 2006.
- [67] M.C. Brower J.W. Zack, and B.H. Bailey, "Validating of the Forewind Model in Wind Forecasting Applications," Talk on the EUWEC Special Topic Conference Wind Power for the 21st Century, Kassel, Germany, 2000.
- [68] "Renewable Energy Research and Development Project ", Final Report, 2008.
- [69] R. de Figueiredo, "Implications and applications of Kolmogorov's superposition theorem," *Automatic Control, IEEE Transactions on*, vol. 25, pp. 1227-1231, 1980.