

Faculdade de Engenharia da Universidade do Porto



Metodologia Híbrida de Previsão de Preços de Eletricidade e Potência Eólica

Jorge Nuno Dias Lopes Gonçalves

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

Orientador: Prof. Doutor João Paulo da Silva Catalão
Co-orientador: Doutor Gerardo José Osório da Silva

junho de 2016

© Jorge Nuno Dias Lopes Gonçalves, 2016

Resumo

O advento da reestruturação do setor elétrico e a nova perspectiva das redes inteligentes, combinado com o aumento da variabilidade e incerteza associada aos preços de eletricidade no mercado e à crescente integração de fontes renováveis, tornam premente melhorar as ferramentas de previsão para os agentes de mercado e demais intervenientes para se lidar com a natureza não-estacionária e estocástica de tais séries temporais. As metodologias de otimização devem ser capazes de apoiar as decisões no ambiente competitivo com baixo erro de previsão e incerteza, com um tempo de computação e complexidade computacional aceitáveis. Abordagens híbridas e evolucionárias são boas candidatas para superar a maioria da preocupação anteriores, considerando a previsão de séries temporais. Neste sentido, esta dissertação propõe um novo modelo híbrido composto pela combinação de otimização diferencial evolutiva por enxame de partículas (DEEPSO), sistema de inferência neuro-difuso adaptativo (ANFIS) e a transformada de *wavelet* (WT) para a previsão, a curto prazo, da potência eólica e dos preços de eletricidade no mercado, testando o seu desempenho com estudos de casos reais publicados, comprovando a possibilidade de utilização numa ferramenta de previsão robusta.

Palavras-Chave

Previsão; Curto prazo; Séries temporais; Preços de eletricidade no mercado; Potência eólica; Sistema de inferência neuro-difuso adaptativo; Otimização por enxame de partículas evolucionário e diferencial; transformada de *wavelet*.

Abstract

Electricity sector restructuring and smart grids, combined with the increased variability and uncertainty associated with electricity market prices signals and growing renewable sources integration, require enhanced prediction tools for market players and different agents to face the non-stationarity and stochastic nature of such time series. Optimization methodologies must be capable of supporting decisions in a competitive environment with low prediction error and uncertainty, with acceptable computation time and modeling complexity. Hybrid and evolutionary approaches are good candidates to surpass most of previous concern considering time series prediction. In this sense, this thesis proposes a new hybrid model composed by the combination of differential evolutionary particle swarm optimization (DEEPSO), adaptive neuro-fuzzy inference system (ANFIS) and wavelet transform (WT) to predict, in the short-term, wind power and electricity market prices, testing its performance with real and published case studies, proving the possibilities to be used in a robust prediction tool.

Keywords

Forecasting; Short-term; Time series; Electricity market prices; Wind power; Adaptive neuro-fuzzy inference system; Differential evolutionary particle swarm optimization; Wavelet transform.

Agradecimentos

Quero agradecer ao meu orientador, Prof. Doutor João Paulo da Silva Catalão, por me ter proporcionado a possibilidade de trabalhar numa área que desejava, assim como pela motivação, empenho e apoio demonstrado ao longo de todo o processo, não só apenas nos últimos 5 meses, mas desde que soube que iríamos trabalhar juntos, ou seja, desde o início do ano letivo.

De seguida, quero agradecer a todos os meus colegas e amigos, os quais tiveram um papel essencial no desenrolar da minha vida académica, acompanhando-me nos bons e nos maus momentos, ajudando-me a atingir um objetivo tão importante e ambicionado por mim. Principalmente aqueles que vários trabalhos realizaram comigo e debatemos longas horas de dúvidas antes dos exames ou outras provas.

Também quero agradecer à grande e maravilhosa instituição que é a Faculdade de Engenharia da Universidade do Porto, assim como a todos os que dela fazem parte, desde todos os professores que me acompanharam e transmitiram um pouco do seu extenso conhecimento nesta caminhada de 6 anos que culminou nesta dissertação, até às minhas queridas amigas do bar que sempre me acarinharam e me motivaram.

Um especial agradecimento à minha família e namorada que sempre tiveram cuidado de me dar todas as condições necessárias para que eu pudesse realizar esta longa etapa com o sucesso pretendido, bem como apoiar-me e exigir o melhor de mim para que o objetivo fosse atingido.

Por fim, quero deixar um grande agradecimento ao meu co-orientador, Doutor Gerardo José Osório da Silva, pelo acompanhamento, dedicação, empenho, profissionalismo, e encorajamento, tudo essencial para que este trabalho fosse desenvolvido com rigor e qualidade. Ficarei eternamente grato pela ajuda e motivação dada, e dos inúmeros e longos contatos realizados, sem os quais nada disto seria possível. Bem-haja.

Índice

Resumo	iii
Abstract	v
Agradecimentos	vii
Lista de figuras	xi
Lista de tabelas	xiii
Acrónimos	xv
Capítulo 1	1
Introdução	1
1.1 - Enquadramento	1
1.2 - Motivação	14
1.3 - Organização da dissertação	15
Capítulo 2	16
Estado da Arte	16
2.1 - Classificação dos horizontes temporais	17
2.2 - Preços de eletricidade no mercado e ferramentas de previsão	17
2.3 - Potência eólica e ferramentas de previsão	21
Capítulo 3	28
Métodos Computacionais	28
3.1 - Redes neuronais	28
3.2 - Lógica difusa	34
3.3 - Sistema de inferência neuro-difuso adaptativo	37
3.4 - Otimização por enxame de partículas	40
3.5 - Otimização por enxame de partículas evolucionário	43

3.6 - Otimização diferencial evolutiva por enxame de partículas.....	45
3.7 - Transformada de wavelet	46
Capítulo 4	48
Metodologia híbrida proposta	48
4.1 - Descrição	48
4.2 - Medidas de erro	50
4.3 - Resultados dos preços de eletricidade no mercado	51
4.4 - Resultados da potência eólica.....	54
Capítulo 5	58
Conclusão	58
5.1 - Contribuições.....	58
5.2 - Trabalhos futuros	59
5.3 - Publicações	59
Referências	60

Lista de figuras

Figura 1.1 - Organização geral do MIBEL e operadores de mercado [5].	2
Figura 1.2 - Organização simplificada do SEN [7].	4
Figura 1.3 - Caracterização simplificada do mercado de eletricidade [8].	5
Figura 1.4 - Procedimento do mercado diário de eletricidade [8].	7
Figura 1.5 - Capacidade anual de potência instalada (MW) e quota renovável (%) nos EU28 [17].	9
Figura 1.6 - Capacidade total das novas instalações de energia eólica nos EU28 em GW [17].	9
Figura 1.7 - Capacidade instalada das diferentes energias renováveis em Portugal [18].	10
Figura 1.8 - Evolução anual da energia eólica instalada no SEN [21].	11
Figura 1.9 - Perfil de energia eólica com intermitência e volatilidade [8].	12
Figura 1.10 - Constituição de um sistema de despacho de potência eólica [24].	12
Figura 1.11 - Comparação da distribuição do <i>mix</i> produtivo em Portugal em 2014 e 2015 [25].	13
Figura 2.1 - Variabilidade e previsibilidade das diversas fontes renováveis [93].	22
Figura 2.2 - Diagrama geral de previsão de potência eólica a partir de modelos físicos [94].	23
Figura 2.3 - Taxonomia das principais metodologias de previsão [8].	27
Figura 3.1 - Constituição de um neurónio [121].	28
Figura 3.2 - Modelo não linear de um neurónio artificial [98].	29
Figura 3.3 - Exemplos de funções de ativação [122].	31
Figura 3.4 - Exemplo de um perceptrão multicamada [119].	32
Figura 3.5 - Estrutura genérica de um modelo de uma NN de três camadas [98].	32
Figura 3.6 - Arquitetura de uma máquina difusa assente em regras [122].	37
Figura 3.7 - Algumas das funções de pertença mais utilizadas [130].	38
Figura 3.8 - Arquitetura generalizada de um ANFIS de 5 camadas [45].	40

Figura 3.9 - Regra do movimento de partículas em PSO. [134].	42
Figura 3.10 - Fluxograma do algoritmo PSO [122].	42
Figura 3.11 - Regra do movimento de partículas no EPSO [8].	44
Figura 3.12 - Regra do movimento das partículas no DEEPSO [141].	45
Figura 3.13 - Modelo generalizado da decomposição WT em três níveis [8].	47
Figura 4.1 - Fluxograma da metodologia HWDA.	50
Figura 4.2 - Resultados dos preços de eletricidade no mercado para a semana de Inverno. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	52
Figura 4.3 - Resultados dos preços de eletricidade no mercado para a semana da Primavera. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	52
Figura 4.4 - Resultados dos preços de eletricidade no mercado para a semana de Verão. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	53
Figura 4.5 - Resultados dos preços de eletricidade no mercado para a semana de Outono. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	53
Figura 4.6 - Resultados da potência eólica para dia de Inverno. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	55
Figura 4.7 - Resultados da potência eólica para dia de Primavera. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	55
Figura 4.8 - Resultados da potência eólica para dia de Verão. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	56
Figura 4.9 - Resultados da potência eólica dia de Outono. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).	56

Lista de tabelas

Tabela 1.1 - Capacidade de energia eólica instalada e total nos EU28 [17].	8
Tabela 2.1 - Ferramentas de previsão da potência eólica mais utilizadas no globo [33].	23
Tabela 4.1 - Parâmetros do DEEPSO e do ANFIS utilizados.	49
Tabela 4.2 - Comparação do MAPE para preços de eletricidade no mercado.	54
Tabela 4.3 - Comparação da variância do erro semanal para os preços de eletricidade no mercado.....	54
Tabela 4.4 - Comparação do MAPE para a potência eólica.	57
Tabela 4.5 - Comparação da variância do erro diária para a potência eólica.	57
Tabela 4.6 - Comparação do NMAE para a potência eólica.....	57

Acrónimos

ANEM	Mercado de Eletricidade Nacional Australiano
ANFIS	Sistema de Inferência Neuro-difuso Adaptativo
ANN	Redes Neurais Adaptativas
APX	<i>Power Export Exchange Market of UK</i>
ARFIMA	<i>Auto Regressive Moving Average</i> fracionado
ARIMA	<i>Auto Regressive Moving Average</i>
AWNN	Sistema de Inferência Neuro-difuso Adaptativo, Transformada de Wavelet e NN
CLSSVM	<i>Chaotic Least Squares Support Vector Machine</i>
CNE	<i>Comisión Nacional de Energia</i>
CNEA	Algoritmo Neuro-evolucionário em Cascata
CNN	Redes Neurais em Cascata
COP	Conferência das Partes
CSLM	<i>Cuckoo Search Levenberg-Marquardt</i>
CUR	Comercializador de Último Recurso
CWT	Transformada de <i>Wavelet</i> Contínua
DEEPSO	Otimização Diferencial Evolutiva por Enxame de Partículas
DGEG	Direção Geral de Energia e Geologia
DWT	Transformada de <i>Wavelet</i> Discreta
EGARCH	<i>Exponential Generalized Autoregressive Conditional Heteroskedastic</i>
EPA	Otimização por Enxame de Partículas Evolucionário com ANFIS
EPSO	Otimização por Enxame de Partículas Evolucionário
ERSE	Entidade Reguladora dos Serviços Energéticos
EU28	28 Estados-Membro da União Europeia
FA	ARTMAP difuso
FF	Algoritmo <i>Firefly</i>
FFNN	<i>Feed-forward</i> NN
FV	Potência Fotovoltaica
GEE	Gases de Efeito Estufa
GW	Giga <i>Watt</i>
HEA	Informação Mútua, Transformada de Wavelet, ANFIS e EPSO
HNES	Sistema Híbrido Neuro-Evolucionário
HPA	Otimização por enxame de partículas e ANFIS
HPM	DEEPSO e ANFIS
HWDA	DEEPSO, ANFIS e Transformada de <i>Wavelet</i>
ISO	Operador Independente do Sistema
iSSO	<i>Improved Simplified Swarm Optimization</i>
IVM	<i>Informative Vector Machine</i>
KPCA	<i>Kernel Principal Component Analysis</i>

KF	Filtro de Kalman
MAPE	<i>Mean Absolute Percentage Error</i>
MC	Método da Centróide
MI	<i>Mutual Information</i>
MIBEL	Mercado Ibérico de Eletricidade
MLP	<i>Multi-layer Perceptron ANN</i>
MM	Método da Média dos Máximos
MO	Operador de Mercado
Mton	Mega tonelada
MW	Mega Watt
NMAE	<i>Normalized Mean Average Error</i>
NN	Redes Neurais
NNWT	NN e Transformada de <i>Wavelet</i>
NRM	<i>New Reference Model</i>
NWP	<i>Numerical Weather Prediction</i>
NYISO	Operador Independente do Sistema de Nova Iorque
OMEL	Operador do Mercado Interno Espanhol
OMIP	Operador do Mercado Interno Português
PJM	<i>Electricity Market for Pennsylvania New Jersey and Maryland</i>
PNAEE	Plano Nacional de Ação para a Eficiência Energética
PNAER	Plano Nacional de Ação para as Energias Renováveis
PRE	Produção em Regime Especial
PRO	Produção em Regime Ordinário
PSO	Otimização por Enxame de Partículas
RBF	<i>Radial Basis Function</i>
RDFA	<i>Recursive Dynamic Factor Analysis</i>
REN	Redes Energéticas Nacionais
RMP	Regra do Movimento da Partícula
RND	Rede Nacional de Distribuição
RNT	Rede Nacional de Transporte
RSU	Resíduos Sólidos Urbanos
RVM	<i>Relevance Vector Machine</i>
SCADA	Sistema de Supervisão e Aquisição de Dados
SSA	<i>Singular Spectrum Analysis</i>
SVM	<i>Support Vector Machine</i>
WGP	<i>Warped Gaussian Process</i>
WPA	Transformada de <i>Wavelet</i> , PSO e ANFIS
WT	Transformada de <i>Wavelet</i>

Capítulo 1

Introdução

Este capítulo descreve a estrutura do setor elétrico e o novo paradigma que surge devido às fontes de energias renováveis e a sua integração no referido setor, nomeadamente, a energia eólica, assim como a crescente necessidade na diminuição da dependência dos combustíveis fósseis, garantindo a sustentabilidade. Também são descritas as motivações que fundamentam o desenvolvimento do trabalho proposto, estabelecendo-se uma visão geral da organização da dissertação e a notação utilizada.

1.1 - Enquadramento

A eletricidade é uma forma de energia vital para a humanidade na atualidade e o seu usufruto, desde os dias em que a humanidade compreendeu as potencialidades proporcionadas pela adequada exploração da mesma, tem sido um fator determinante no crescimento da economia e da sociedade, uma vez que propulsiona os estímulos e o dinamismo necessário na criação de novas oportunidades de negócios e emprego. Historicamente, o setor elétrico a nível mundial, antes da década de oitenta do passado século, era caracterizado por uma estrutura verticalmente integrada (constituída pela geração, transmissão e distribuição), permitindo a expansão e crescimento natural como uma economia de escala onde a ideologia principal passava pela minimização dos custos de produção e, por isso, considerada como uma estrutura de monopólio natural. No entanto, nesse período de tempo tal filosofia começou a ser questionada com o aparecimento de novos produtores independentes, devido à imposição atribuída aos responsáveis pelo transporte e distribuição de eletricidade, na aquisição do potencial independente produzido [1].

Desde então e até à atualidade, o setor elétrico é caracterizado por uma constante e crescente reestruturação, permitindo a criação de mercados de eletricidade liberalizados com mecanismos de regulação havendo, no entanto, um ambiente competitivo entre os diferentes intervenientes. Posto isso, na atualidade, os consumidores têm a possibilidade de optar pelos diferentes fornecedores existentes no mercado elétrico, através das propostas oferecidas pelos mesmos [2].

O planeamento, gestão e exploração do Sistema Elétrico Nacional (SEN) são três conceitos importantes para as diferentes empresas de eletricidade, as quais devem de operar em conformidade com a liberalização global do setor elétrico, garantido que a operabilidade se processe com racionalidade, sustentabilidade e robustez na intercalação produtiva de eletricidade, ou *mix* produtivo, que constitui o SEN [3].

2 Introdução

Assim, os mecanismos e ferramentas que permitem a participação adequada no mercado de eletricidade devem incluir um número de fatores cujos objetivos estão intrinsecamente relacionados com a maximização do lucro através da otimização da utilização dos recursos do sistema elétrico, proporcionando estratégias adequadas de apoio e participação nos mercados de eletricidade liberalizados [4].

Em Portugal, a liberalização do setor elétrico foi possível no final da década de noventa do século passado com a Diretiva 1996/92/CE do Parlamento Europeu e do Conselho, na qual se estabeleceram regras para a criação de um mercado de eletricidade interno. Nessa diretiva também foi considerada a melhoria da eficiência do SEN para o aumento da competitividade económica. No processo evolutivo do SEN, no decorrer de 2003, foi publicada a Diretiva 2003/54/CE do Parlamento Europeu e do Conselho, que originou a liberalização do setor elétrico em toda a Península Ibérica, permitindo a criação do Mercado Ibérico de Eletricidade (MIBEL), no qual os preços praticados possuem um comportamento inconstante e volátil, determinados pelas ofertas de compra e venda de energia elétrica. Tal reestruturação teve um forte impacto na produção e transmissão de eletricidade.

A Figura 1.1 apresenta a organização geral do MIBEL, descrevendo os respectivos operadores de mercado [5]. Em julho de 2007, o MIBEL iniciou atividade com o esperado ambiente competitivo entre os agentes do mercado ibérico mediados pelo Operador de Mercado Interno Espanhol (OMEL), responsável pelo mercado de contratos futuros; e pelo Operador do Mercado Interno Português (OMIP), responsável pela gestão do mercado diário e intradiário.

Por sua vez, de modo a garantir a regularização dos operadores atrás descritos, existem duas agências reguladoras: a *Comisión Nacional de Energía* (CNE) relativa ao lado espanhol e a Entidade Reguladora dos Serviços Energéticos (ERSE) do lado português. Porém, somente em abril de 2010, através da Resolução do Conselho de Ministros n.º 29/2010, é que se estabeleceu um MIBEL harmonizado e onde foram definidos alguns mecanismos, tais como [6]:

- Definição dos operadores dominantes;
- Mecanismo harmonizado de garantia de potência;
- Definição de um mecanismo de interruptibilidade que harmonizou o sistema de serviço.

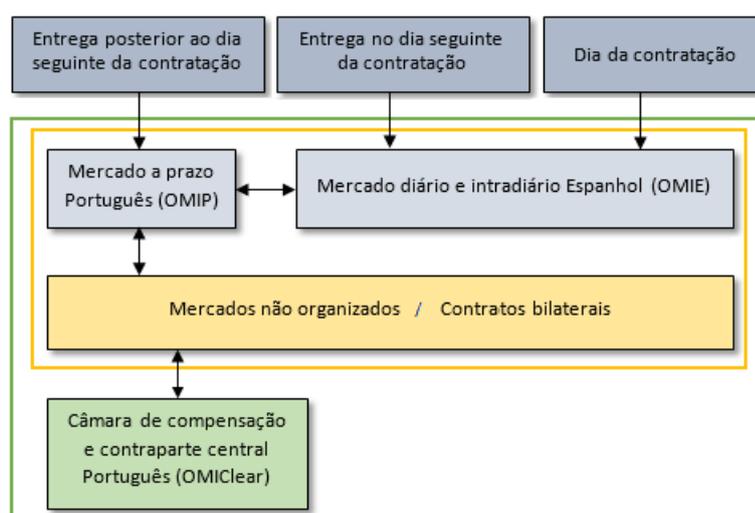


Figura 1.1 - Organização geral do MIBEL e operadores de mercado [5].

As várias medidas adotadas e definidas segundo o Decreto-Lei N.º 29/2006, permitem estabelecer um esquema simplificado do SEN [7] como é apresentado na Figura 1.2. No entanto, da Figura 1.1 torna-se importante destacar alguns aspetos que a seguir se descrevem:

- Produção:
 - Produção em Regime Ordinário (PRO) é realizada através de fontes tradicionais de energia, não renováveis e com recursos às grandes hídricas;
 - Produção em Regime Especial (PRE) é a realização da cogeração e aproveitamentos das fontes de energia renovável;
 - É otimizada seguindo uma lógica de mercado e não de uma produção centralizada;
 - No processo de produção, o Estado assegura as condições para o bom desempenho do mercado de eletricidade, garantindo o bom funcionamento e abastecimento de eletricidade, assim também deverá desempenhar o papel de monitorização permanente do setor elétrico. Também é responsável pela promoção, através de concurso público, das garantias necessárias relativas à capacidade de produção.
- Transporte:
 - Exploração realizada pela Rede Nacional de Transporte (RNT), através de uma única concessão em regime de serviço público, Redes Energéticas Nacionais (REN), cujas responsabilidades são:
 - Efetuar a gestão técnica global do sistema;
 - Assegurar a coordenação sistemática das instalações, produção e distribuição;
 - Garantir a continuidade de funcionamento, segurança no abastecimento e eficiência do sistema.
- Distribuição:
 - Exploração realizada pela Rede Nacional de Distribuição (RND), concessionada em regime de serviço público à EDP Distribuição encarregue de:
 - Assegurar a exploração, manutenção, condições de segurança, fiabilidade e qualidade de serviço;
 - Gerir os fluxos de eletricidade de modo a garantir a interoperabilidade entre as redes à que esteja ligada e com as instalações dos clientes.
- Comercialização:
 - Atividade livre, sujeita à atribuição de licenças onde se definem os direitos e deveres para que haja transparência do exercício. Nesta atividade é permitido aos comercializadores:
 - Comprar e vender eletricidade livremente, com acesso, mediante o pagamento de tarifas reguladas, à RNT e RND;
 - Proteger os consumidores, sendo portanto os Comercializadores de Último Recurso (CUR), em que se destaca a EDP Serviço Universal, cujas responsabilidades são:
 - Garantia do fornecimento em condições de qualidade e continuidade;
 - Proteção dos utilizadores relativamente às tarifas e preços praticados;
 - Cumprimento obrigatório de aquisição da eletricidade proveniente das PRE.

4 Introdução

- Regulação e Segurança do Abastecimento:
 - A ERSE regula as atividades de transporte, distribuição, comercialização de eletricidade de último recurso e operação logística da mudança de comercializador;
 - A segurança do abastecimento é monitorizada e garantida pela agência do Estado, a Direção Geral de Energia e Geologia (DGEG) [7].

Na atualidade, em consequência da liberalização do setor elétrico e do seu caráter competitivo inerente, é possível representar, de modo sucinto, a estrutura de comercialização de eletricidade descrita na Figura 1.3 onde sumariamente se descreve a existência de duas formas de realizar transações de eletricidade:

- O mercado de contratos bilaterais: onde se efetuam os acordos entre compradores e vendedores de eletricidade, em relação ao preço e quantidades a serem transacionados, o qual será, posteriormente, implementado pelo operador independente do sistema, ou *Independent System Operator (ISO)*, sendo também responsável pela garantia de qualidade do sistema de transmissão;
- O mercado *spot*: onde é realizada a compra e venda de eletricidade, executadas pelo operador de mercado, ou *Market Operator (MO)*, o qual determina a quantidade de eletricidade a ser produzida e o preço de mercado da mesma de acordo com as ofertas de compra e venda apresentadas pelos agentes envolvidos no processo.

Após a viabilidade técnica resultante dos acordos entre o ISO e o MO, relacionados com o programa técnico da produção de eletricidade, é necessário um serviço complementar para garantir a segurança, robustez e qualidade do fornecimento. Atualmente, a produção de eletricidade, existindo um mercado de eletricidade liberalizado e organizado, está associada a um mercado grossista, em que os produtores asseguram a colocação da sua geração ao dispor de outros agentes que, por sua vez, procuram comprar eletricidade por dois motivos principais: satisfação das exigências dos clientes e para consumo próprio da mesma. A atividade de comercialização está associada a um mercado retalhista, onde os agentes responsáveis competem para assegurar o fornecimento dos clientes finais.

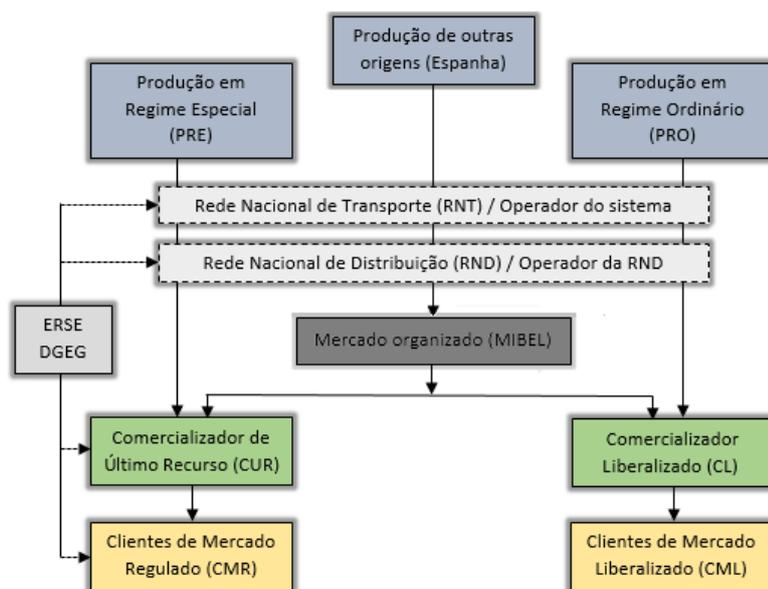


Figura 1.2 - Organização simplificada do SEN [7].

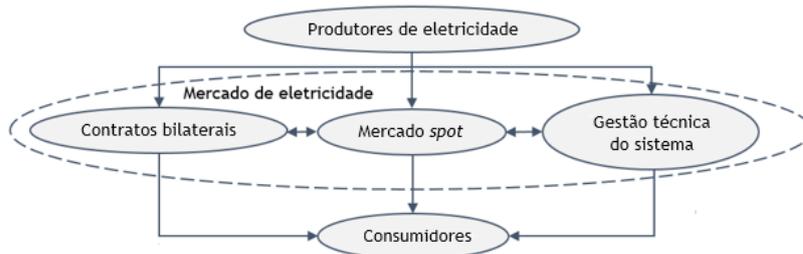


Figura 1.3 - Caracterização simplificada do mercado de eletricidade [8].

No ambiente liberalizado torna-se, então, obrigatório monitorizar a operação do mercado de energia elétrica pois é obrigatório seguir algumas características e comportamentos de outros mercados organizados, assim como os desenvolvimentos de outros cujas transações possam influenciar a determinação dos preços da eletricidade (por exemplo, mercados de energia fóssil, mercado das emissões de dióxido de carbono, mercados financeiros, entre outros). Por conseguinte, um mercado de eletricidade organizado é composto pela seguinte arquitetura [9], [10]:

- O mercado grossista, composto por diversos mercados, mecanismos legais ou regulamentares específicos, tais como:
 - O mercado diário que funciona através do cruzamento das ofertas de compra e venda por parte dos diversos agentes registados para atuar neste mercado, sendo que cada oferta indica o dia e a hora aos quais dizem respeito, um preço e quantidade de eletricidade correspondentes, sendo que a compra se processa no dia seguinte à negociação. Além disso, segue as suas próprias regras de funcionamento tal como é representado na Figura 1.4 [8];
 - O mercado intradiário, no qual a quantidade de eletricidade transacionada no mercado diário é corrigida. Este mercado é composto por seis sessões após as quais o preço da eletricidade é retificado com a correspondente transação de energia [10]:
 - Sessão 1: Estabelece os preços de eletricidade para as últimas 4 horas do dia de negociação e para as 24 horas do dia seguinte a esse;
 - Sessão 2: Estabelece os preços de eletricidade para as 24 horas do dia seguinte ao da negociação;
 - Sessão 3: Estabelece os preços de eletricidade para as 20 horas compreendidas entre a hora 5 e a hora 24 do dia seguinte ao da negociação;
 - Sessão 4: Estabelece os preços de eletricidade para as 17 horas compreendidas entre a hora 8 e a hora 24 do dia seguinte ao da negociação;
 - Sessão 5: Estabelece os preços de eletricidade para as 13 horas compreendidas entre a hora 12 e a hora 24 do dia seguinte ao da negociação;
 - Sessão 6: Estabelece os preços de eletricidade para as 9 horas compreendidas entre a hora 16 e a hora 24 do dia seguinte ao da negociação.
 - O mercado a prazo que oferece instrumentos de gestão de riscos para a compra e venda de eletricidade para períodos futuros (semana, mês, trimestre e ano) entre os diferentes agentes. Atualmente, o OMIP disponibiliza os seguintes instrumentos:
 - Contrato futuro - contrato padronizado de compra ou venda de eletricidade para um determinado horizonte temporal.

6 Introdução

Os produtores e compradores concordam uns com os outros o preço e quantidade de eletricidade transacionada para um determinado dia no futuro. Este apresenta liquidações diárias entre o preço de transação e a cotação de mercado (de futuro) de cada dia;

- Contrato *forward* - semelhante ao anterior mas, por sua vez, não possui liquidações diárias das margens durante o período de negociação, sendo a margem liquidada integralmente nos dias de entrega física ou financeira;
 - Contrato SWAP - contrato padronizado, onde um preço posicional variável é trocado por um preço fixo, ou vice-versa, dependendo do sentido da troca entre as partes intervenientes. Destina-se a gerir ou tomar um risco financeiro, não existindo entrega de qualquer produto subjacente, mas sim uma liquidação das margens correspondentes.
- Contrato bilateral, que pode ser dividido em:
- Mercado de contratação a prazo - onde são assegurados os compromissos futuros de produção e compra de eletricidade;
 - Mercado de contratação à vista - dividido em contratação diária e ajustes intradiários, em que os programas de compra e venda de eletricidade são estabelecidos para o dia seguinte à negociação;
 - Mercado de serviço do sistema - onde é efetuado o ajuste de equilíbrio entre a produção e o consumo de eletricidade em tempo real;
 - Mercado de contratação bilateral - onde as partes intervenientes contratam a compra e venda de eletricidade para todos os diferentes horizontes temporais.
- O mercado retalhista, onde qualquer cliente pode escolher livremente o seu fornecedor de eletricidade. Também é útil para garantir a concorrência entre os diferentes operadores de forma equilibrada, minimizando as assimetrias de informação entre consumidores e outros agentes de mercado.

Todavia, devido ao impacto da sociedade contemporânea no futuro do ambiente, o fator ambiental também deverá ser considerado no sistema elétrico. Exemplo disso poderá ser observado na ratificação do protocolo de Quioto, em 1999, reforçado pela conferência do clima em Copenhaga, em 2009, ou ainda pela Conferência das Partes (COP), realizada em Lima, Peru, em dezembro de 2014. Em todos os exemplos anteriores, relacionados com a proteção ambiental, os ativistas tentam avaliar, alertar e incentivar todas as nações para a criação de um conjunto de medidas e metas considerando a necessidade emergente da redução contínua das emissões de gases do efeito estufa (GEE), de forma a mitigar o aumento dos níveis médios da água do mar e do aquecimento global, sendo que o setor elétrico tem um importante papel a desempenhar nesse desafio [11].

Em Portugal, o desafio da atenuação dos GEE é enfrentado através de uma série de metas encorajadoras, como as propostas pela Diretiva 2001/77/CE do Parlamento Europeu e do Conselho de Ministros, publicada em setembro de 2001, onde se descrevem os incentivos e motivações para a produção de eletricidade através de fontes de energia renováveis, a fim de manter os padrões de equidade e sustentabilidade no conjunto electroprodutor na economia [12].

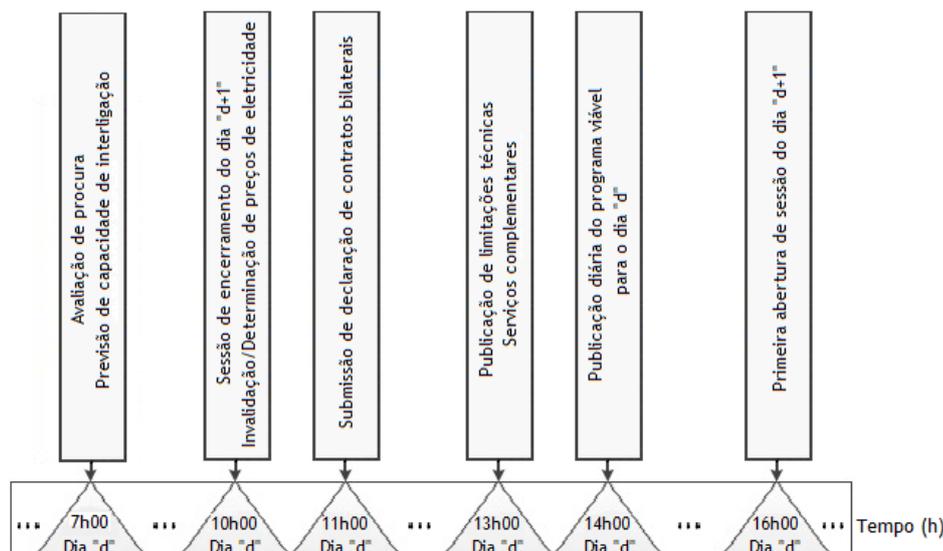


Figura 1.4 - Procedimento do mercado diário de eletricidade [8].

As metas citadas nessa diretiva incluem um crescimento substancial da quota da produção de eletricidade com origem em fontes renováveis, entre elas, a energia eólica, através do incentivo ao setor privado, permitindo, conseqüentemente, a descarbonização gradual do setor elétrico, como é defendido em [13].

A utilização do potencial renovável é socialmente aceite com plenitude devido ao caráter endógeno associado, pela contribuição de uma economia sustentável e pela redução substancial da dependência de outras fontes não endógenas. Além das vantagens atrás referidas, os custos de implementação e manutenção dos aproveitamentos renováveis têm vindo a diminuir com o decorrer do tempo, e, nesse contexto, o potencial eólico tem demonstrado maior rentabilidade, uma vez que é considerada uma tecnologia com maturidade e evolução adequada ao custo de implementação e rentabilidade ao longo da vida útil de utilização [14].

Com as vantagens comprovadas da utilização do potencial eólico e de outras fontes renováveis, apesar das inúmeras dificuldades enfrentadas pelos governos europeus devido às crises económicas, os esforços para continuar os programas de fomento à instalação de mais parques eólicos ou de melhoria dos existentes, bem como outros incentivos e reformas das leis de modo a suportar mais planos para descarbonizar o sistema elétrico europeu têm sido notórios [15].

Exemplo disso é a política adotada em 2007 pelo Conselho Europeu na qual define a obrigação vinculativa dos Estados-Membros da União Europeia em aumentar em 20% a quota de energias renováveis até 2020, tradicionalmente referido como o “Programa 20-20-20”, ou ainda com a revisão do mesmo plano, como descreve [16]. O “Programa “20-20-20” impõe os seguintes objetivos:

- Reduzir as emissões dos GEE em 20% relativamente aos valores registados em 1990;
- Aumentar a quantidade de energia renovável até cerca de 20% do consumo final de eletricidade;
- Diminuir em 20% o consumo total de energia primária através do aumento da eficiência energética.

8 Introdução

Em reflexo das estratégias adotadas pelos 28 Estados-Membros da União Europeia (EU28), no ano de 2015 foi instalada uma capacidade total de energia eólica de 12800 MW, verificando-se, portanto, um crescimento de 6,3% da capacidade de novas instalações face ao ano de 2014, representando, assim, 44,2% do total de novas instalações de energia obtida através de fontes renováveis em 2015. No entanto, as grandes variações observadas entre os diferentes países no aumento do potencial e aproveitamento renovável refletem a eficácia relativa dos quadros políticos e regulamentares, assim como a incerteza sobre as políticas energéticas para o futuro nos EU28 [17].

Na Tabela 1.1 é apresentada a capacidade total de energia eólica *onshore* instalada nos EU28. Facilmente se observa que países como a Alemanha, Polónia, França, Reino Unido, Suécia e Holanda se destacam pelo incremento notável no aproveitamento do recurso eólico. Um outro exemplo poderá ser observado na Figura 1.5 onde se mostra a capacidade total de energia entre 2000 e 2015, em Mega Watt (MW), e a respetiva quota de energia renovável nos EU28 que, no final de 2015, ascendia a um valor de 77%.

Com efeito, a energia eólica ultrapassou a hídrica posicionando-se como a terceira maior fonte de geração de energia nos UE28, com uma quota de 15,6% da capacidade total, sendo responsável por um terço de todas as novas instalações de energia desde 2000, enquanto os aproveitamentos convencionais prosseguem num processo de desmantelamento e diminuição da criação de novos aproveitamentos. Um outro exemplo, onde se apresenta a evolução das novas construções desenvolvidas no espaço europeu ao longo dos últimos 15 anos relativamente aos aproveitamentos eólicos em Giga Watt (GW) poderá ser observado na Figura 1.6 [17].

Tabela 1.1 - Capacidade de energia eólica instalada e total nos EU28 [17].

País	Capacidade instalada em 2014 (MW)	Capacidade total em 2014 (MW)	Capacidade instalada em 2015 (MW)	Capacidade total em 2015 (MW)
Alemanha	5242,5	39127,9	6013,4	44946,1
Áustria	405,0	2089,2	323,0	2411,5
Bélgica	293,5	1958,7	274,2	2228,7
Dinamarca	104,9	4881,7	216,8	5063,8
Espanha	27,5	23025,3	-	23025,3
Finlândia	184,3	626,7	379,4	1000,5
França	1042,1	9285,1	1073,1	10358,2
Grécia	113,9	1979,9	172,2	2151,7
Holanda	175,0	2865,0	586,0	3431,0
Irlanda	213,0	2262,3	224,0	2486,3
Itália	107,5	8662,8	295,0	8957,8
Polónia	444,3	3833,8	1266,2	5100,0
Portugal	222,0	4947,0	132,0	5079,0
Reino Unido	1923,4	12633,4	975,1	13602,5
Roménia	354,0	2952,9	23,0	2975,9
Suécia	1050,2	5424,8	614,5	6024,8
Restantes	134,4	2503,6	232,4	2736,0
Total EU28	12037,4	129060,1	12800,2	141578,8

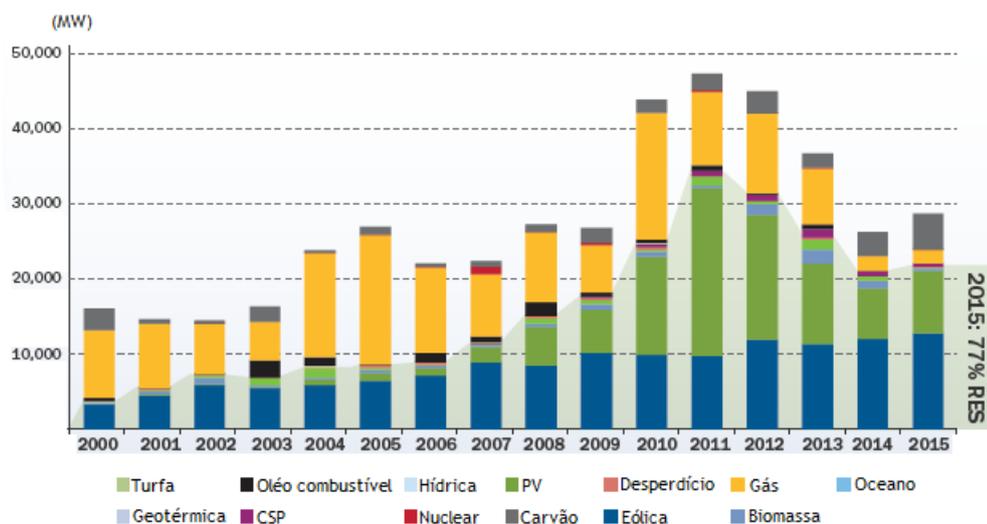


Figura 1.5 - Capacidade anual de potência instalada (MW) e quota renovável (%) nos EU28 [17].

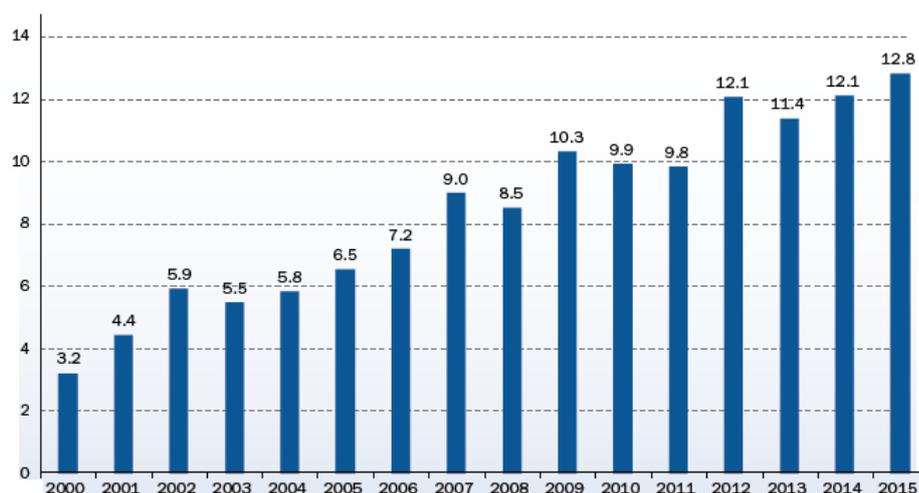


Figura 1.6 - Capacidade total das novas instalações de energia eólica nos EU28 em GW [17].

Em Portugal, o compromisso e as metas de proteção ambiental e descarbonização do setor elétrico não foram ignorados visto que as constantes exigências para enfrentar os novos desafios são confrontados com novas estratégias. Exemplo disso poderá ser observado na Resolução do Conselho de Ministros da UE n.º. 20/2013, que reforça a estratégia de Portugal para 2020, com vista à descarbonização sustentável e progressiva do setor elétrico, tanto através do Plano Nacional de Ação para a Eficiência Energética (PNAEE), como do Plano Nacional de Ação para as Energias Renováveis (PNAER).

Com efeito, a integração e introdução dos aproveitamentos renováveis no SEN alterou profundamente o comportamento dinâmico do *mix* de geração de eletricidade entre 2007 e 2016, como ilustrado na Figura 1.7, na qual se reflete a necessidade de estudos adequados para maximizar o uso do potencial renovável. Na mesma figura, também se encontra manifesta a importância das energias renováveis, as quais atingiram um total de 12301MW de capacidade instalada no final de março de 2016. De acordo com a metodologia apontada pela diretiva 2009/28/CE, na qual se estabelecem os objetivos a atingir em 2020, o peso da energia elétrica renovável no período entre abril de 2015 e março de 2016 foi de 51,1% [18].

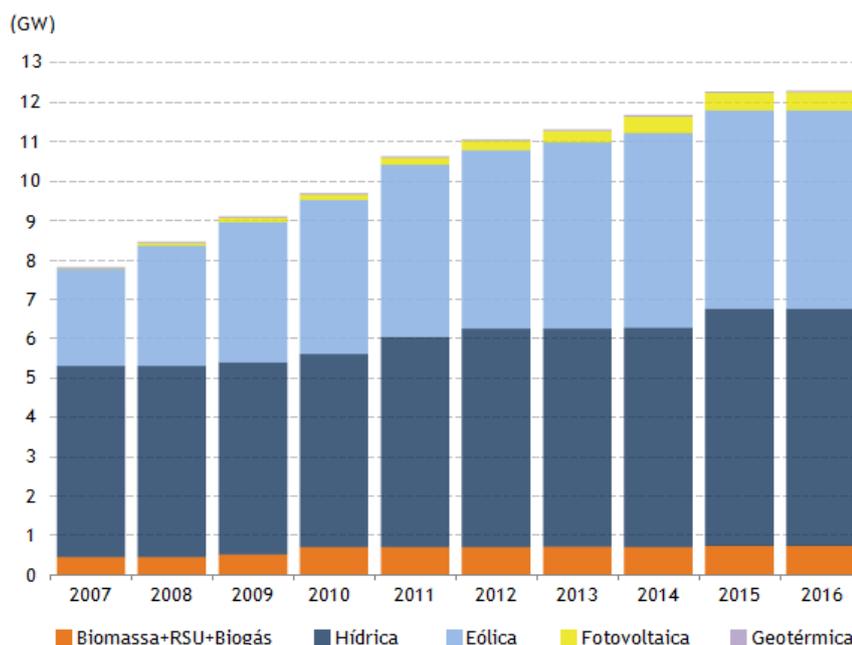


Figura 1.7 - Capacidade instalada das diferentes energias renováveis em Portugal [18].

Analisando os dados apresentados em [18] e [19] e refletidos na Figura 1.7 é possível verificar que, entre janeiro de 2007 e março de 2016, os aproveitamentos hídricos registaram um aumento de 4555MW para 6024MW, a geração térmica renovável (biomassa, resíduos sólidos urbanos (RSU), biogás e geotérmica) de 478MW para 769MW e a produção fotovoltaica (FV) de 15MW para 474MW. Ainda no período de tempo entre janeiro de 2007 e março de 2016, poderá verificar-se que a tecnologia com maior crescimento foi a eólica com 2,6GW, e todavia, observar que a fotovoltaica obteve melhorias significativas, uma vez que, de uma potência instalada residual em 2007 atingiu um valor de 474MW em 2016, o que é significativo. Nos resultados finais, o contributo das energias renováveis no consumo de energia primária, em 2014, foi de 25,9%, sendo que 19% desse valor foi oriundo dos aproveitamentos eólicos.

Pelo grande número de bibliografia disponível, facilmente se pode ter noção de que a potencial eólico é sustentado por uma maturidade tecnológica aceitável e também é economicamente viável em comparação com outras energias renováveis, contribuindo substancialmente para a descarbonização e redução dos GEE. No entanto, o potencial eólico aumenta, significativamente, os desafios no adequado controlo e gestão, assim como a concorrência natural existente nos mercados de eletricidade liberalizados, devido à natureza intermitente, volátil e não despachável que caracterizam esse recurso endógeno. Assim sendo, as estruturas elétricas apresentam maiores necessidades de possuir maior flexibilidade e adaptabilidade na presença destes recursos endógenos, em comparação com os aproveitamentos clássicos [20].

Apesar dos problemas associados aos aproveitamentos endógenos renováveis, o interesse e integração do potencial eólico em Portugal foi, em grande parte, devido às melhorias da tecnologia, à disponibilidade do recurso no país, assim como às remunerações atribuídas pelo Estado. Em resultado disso, em 2014, a potência consumida a partir da exploração eólica no SEN foi, à semelhança do ano transato, na ordem dos 24% como reportado em [21].

A título de exemplo, a Figura 1.8 demonstra a crescente implementação do recurso endógeno eólico em Portugal, verificando-se, no entanto, um decréscimo de novas instalações, principalmente, a partir de 2011, fruto dos cortes no financiamento proporcionado pelos EU28 e pelo Estado devido à crise económica instalada nesse ano. Ainda assim, em 2014, possuía uma potência total ligada de 4541MW.

Uma vez que o recurso eólico apresenta volatilidade e intermitência é necessário recorrer a várias tecnologias para que a produção de eletricidade ocorra de forma mais alargada e, assim, assegurar o fornecimento de energia de modo económico e seguro. Posto isto, é importante ressaltar os problemas a considerar [22]:

- Participação no mercado elétrico: Os agentes representantes dos parques eólicos apresentam as suas propostas de produção de eletricidade de um modo discreto, com um horizonte temporal antecedente igual ou superior a 24 horas.
- Segurança no abastecimento: Considera-se a possibilidade de avarias das unidades produtoras e a obrigatoriedade de cobrir a procura tendo por base o conhecimento estimado da geração eólica, obtido através de ferramentas de previsão.
- Gestão das centrais produtoras e parques eólicos: No processo de despacho é imperativo considerar não só as restrições da rede elétrica mas também as estimativas de produção de eletricidade e o grau de incerteza associado, realizando-se, assim, um bom escalonamento dos centros produtores convencionais, pelo que, nesse sentido, as ferramentas de previsão poderão auxiliar na planificação e manutenção dos parques eólicos nos períodos de menor capacidade de produção.

Acerca da intermitência e volatilidade do recurso eólico, torna-se necessário definir convenientemente ambos os termos. A intermitência é um acontecimento que inicia mas culmina abruptamente, a volatilidade encontra-se relacionada com a variação flutuante em torno duma linha de tendência como é referido em [23]. De forma a obter maior alusão ao anteriormente explicado, na Figura 1.9 apresenta-se um caso hipotético onde se observam os dois fenómenos em torno duma linha de tendência [8].

Devido a ambas as características atrás referidas, a expansão massiva do potencial eólico em substituição das centrais convencionais e poluentes implica o aumento da complexidade do sistema, assim como a necessidade de melhoria da monitorização, controlo e gestão do sistema electroprodutor e ainda deverão ser consideradas as restrições da rede e do próprio mercado elétrico.

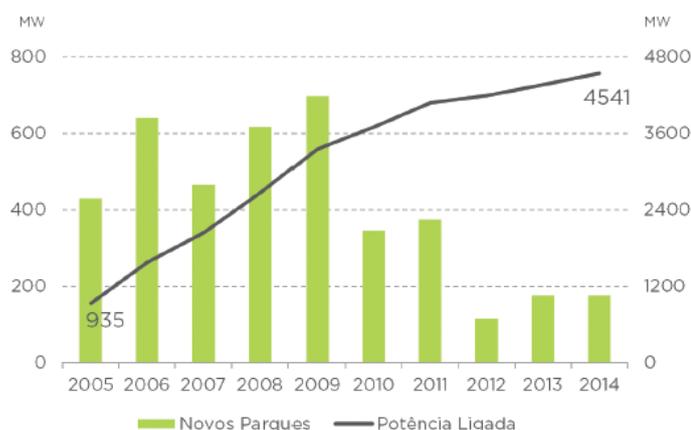


Figura 1.8 - Evolução anual da energia eólica instalada no SEN [21].

12 Introdução

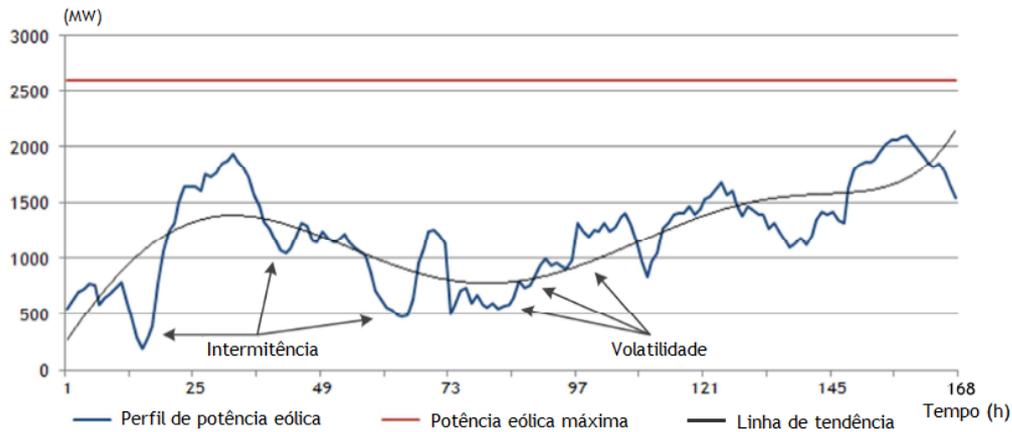


Figura 1.9 - Perfil de energia eólica com intermitência e volatilidade [8].

Um mecanismo para a adequada gestão do sistema eletroprodutor poderá ser observado na Figura 1.10, onde é feita a alusão da gestão da complexidade do *mix* de produção de eletricidade, realizada pelo centro de despacho, adotando uma arquitetura de controlo hierárquico e onde é realizado o diálogo entre os operadores das redes e o referido mercado. Assim, destaca-se o papel do centro de despacho da potência eólica onde se realiza o controlo dos parques eólicos 1 até N, sendo que estes são monitorizados e controlados pelos sistemas de monitorização, constituídos pelos k geradores [24].

Quanto à utilização no setor elétrico português das centrais convencionais de geração elétrica baseadas em energia fóssil, Portugal possui planos ambiciosos para a gradual desativação e desmantelamento das maiores centrais térmicas, principalmente de carvão, entre 2017 e 2030. No entanto, apesar da importância do gás natural para a robustez, garantia do *mix* produtivo e qualidade de serviço do setor elétrico, as dependências energéticas com a Argélia e Nigéria exigem uma melhoria das infraestruturas de armazenamento. Nesse contexto, existem também alguns planos para o reforço/substituição de 10% da energia gerada pelas centrais convencionais atrás mencionadas por centrais de biomassa e gás natural [25].

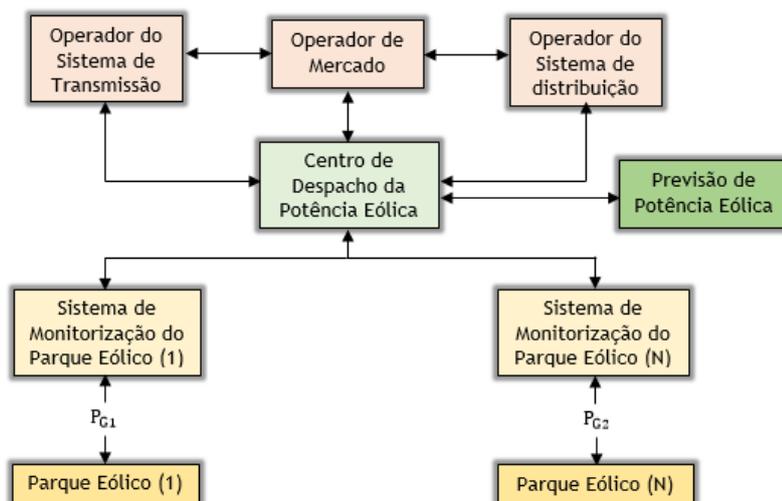


Figura 1.10 - Constituição de um sistema de despacho de potência eólica [24].

Da anterior análise reportada em [25], tais medidas são delineadas de modo a garantir o *mix* energético de produção elétrica, a robustez e qualidade de serviço, assim como também possibilitam a mitigação dos custos marginais da eletricidade, mantendo a competitividade face a outros mercados elétricos [10]. Além disso, a consideração pelo reforço das instalações hídricas existentes e da construção de novas centrais hídricas que sejam reversíveis, poderão auxiliar, substancialmente, em várias frentes e proporcionar a necessária flexibilidade e descarbonização do setor. Em contradição, alguns estudos indicam a tendência de uma redução da competitividade no mercado de eletricidade português nos próximos anos, principalmente por causa do aumento do custo marginal da eletricidade. Contudo, tal tendência poderá ser posta em causa já que é possível exportar o excedente produzido, através da bem-sucedida ligação elétrica entre Espanha e França, a qual permite um aumento do fluxo de eletricidade produzida na Península Ibérica.

No cálculo final, estima-se que as contribuições anteriormente referidas permitirão uma redução bastante significativa dos GEE para cerca de 8 Mega toneladas (Mton) nos próximos anos, em comparação com as atuais emissões que ascendem a cerca de 16Mton, no entanto, tal estudo/análise não se encontra no âmbito do presente trabalho [25].

A título de exemplo, a Figura 1.11 mostra a composição comparativa da produção de eletricidade em Portugal em 2014 e 2015. Destaque-se a importância da energia eólica como uma grande fatia de produção de eletricidade e o peso das unidades térmicas (incluindo biomassa, gás natural e RSU) [25].

Como já mencionado anteriormente, uma forma de atenuar alguns dos problemas relacionados com a integração de energia renovável para uma gestão correta e sustentável do sistema elétrico, envolve a integração de sistemas avançados de armazenamento de energia, pois possibilitam uma melhor gestão do sistema elétrico na presença de energias renováveis, incrementando a qualidade de gestão dos fluxos elétricos através da maximização do aproveitamento renovável evitando potenciais cortes na produção. Tal efeito permitiria uma melhoria significativa na gestão e operabilidade do sistema, o que se traduz numa redução dos custos operacionais, desde que se garantisse a correta gestão e dimensionamento desses sistemas, no entanto, a sua implementação na atualidade é ainda muito dispendiosa, e em alguns casos, ainda se encontra em fase experimental [26], [27].

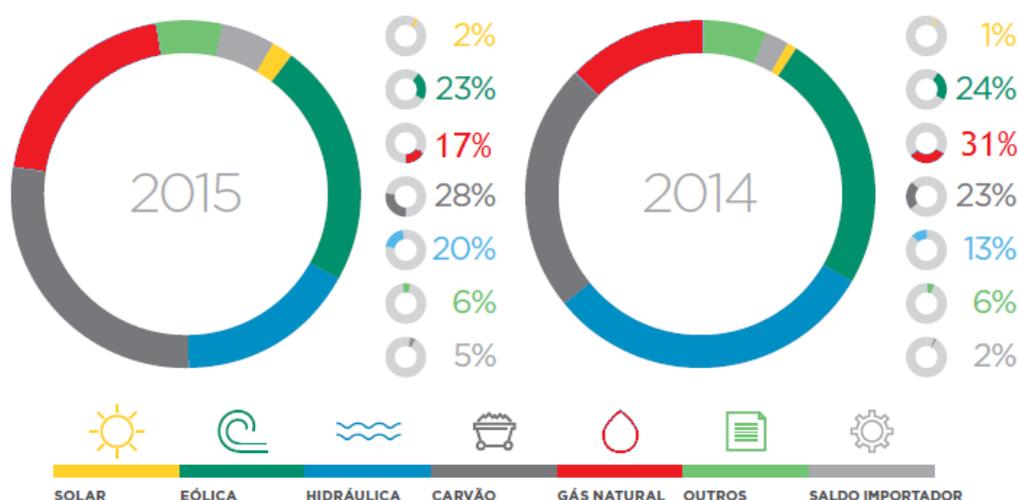


Figura 1.11 - Comparação da distribuição do *mix* produtivo em Portugal em 2014 e 2015 [25].

Uma outra forma, muito mais económica e versátil, é o desenvolvimento e melhoria das ferramentas de previsão para determinar o comportamento futuro do potencial eólico, por exemplo. Tal possibilita a criação de um conjunto de possibilidades ou uma estimação da possível geração eólica, que poderá ser considerado para o perfil dos preços de eletricidade no mercado, que também é influenciado por fatores ambientais, sociais e económicos, assim como pelo comportamento dos agentes de mercado em ambiente competitivo e concorrencial na hora das tomadas de decisões [28].

Pelos motivos atrás descritos, o objetivo deste trabalho passa pelo estudo do comportamento estocástico e volátil da previsão dos preços de eletricidade no mercado, assim como o estudo da volatilidade e a intermitência do perfil da potência eólica. A partir da análise da revisão da literatura realizada durante o trabalho de pesquisa, foram encontrados vários desafios que a indústria elétrica e a comunidade científica vêm tentando solucionar nos últimos anos, sendo esses:

- Redução da dependência de combustíveis fósseis e diminuição dos GEE;
- Desenvolvimento de ferramentas computacionais para apoio à decisão detentoras de maior proficiência e precisão;
- Harmonização entre a produção de energia convencional e renovável, ajudando a aumentar a flexibilidade global do sistema;
- Redução dos custos de geração de uma forma sustentável e fiável.

Torna-se, assim, importante, no âmbito da engenharia, a possibilidade de contribuir de forma inequívoca para a descarbonização e aumento da qualidade do setor elétrico, proporcionando mecanismos e ferramenta mais capazes de enfrentar os novos paradigmas que esse setor enfrenta, numa perspetiva inteligente e inovadora.

1.2 - Motivação

Como mencionado na seção anterior, a crise económica vivida em muitos países europeus e a crescente integração de energias renováveis nos sistemas convencionais elétricos, principalmente com origem eólica, faz com que a precisão da previsão da potência eólica e dos preços de eletricidade no mercado, devido aos processos que são desencadeados nos mercados liberalizados de eletricidade, possuam uma importância cada vez mais elevada.

As novas metodologias híbridas de previsão podem, potencialmente, evidenciar grandes níveis de apoio às decisões, permitindo ao produtor de eletricidade gerir os seus recursos com níveis de racionalidade mais elevados sem comprometer a segurança, robustez e fiabilidade da estrutura elétrica. Tais metodologias poderão, também, amenizar os problemas associados à incerteza inerente relativa à previsão dos preços de eletricidade e da potência eólica, ou até mesmo de outras fontes de incerteza, refletidas nos históricos das séries temporais.

Assim, pretende-se desenvolver uma nova metodologia capaz de prever os preços de eletricidade no mercado e a potência eólica recorrendo a ferramentas de inteligência computacional, tendo como dados de entrada apenas informação do conhecimento público, tal como os dados históricos dos preços da eletricidade e da produção eólica, acessíveis nas plataformas da OMEL e da REN, permitindo a avaliação correta e isenta das potencialidades da nova metodologia proposta.

Assim, no contexto da Engenharia Eletrotécnica, o desenvolvimento de ferramentas computacionais inovadoras e capazes de auxiliar o sistema elétrico nas diferentes etapas, bem como na adequada gestão do mesmo, é fundamental. Para o efeito foi realizado um estudo com várias ferramentas computacionais existentes e publicadas em momentos anteriores nas áreas da especialidade, de modo a melhorar a compreensão e o princípio de funcionamento das mesmas. De seguida, criar uma contribuição com a proposta de uma nova ferramenta de previsão, desenvolvida no âmbito deste trabalho relativamente à previsão de preços de eletricidade em mercado e de potência eólica.

No caso da primeira análise, o horizonte temporal considerado será de 168 horas amostradas em intervalos de 1 hora. No caso da previsão da potência eólica, o período a considerar será de 24 horas, correspondendo à previsão para um dia. Esta previsão será suportada por sucessivas atualizações de 3 em 3 horas com amostras em intervalos de 15 minutos. Em ambos os casos serão utilizados dados reais e realizada uma adequada comparação com metodologias anteriormente publicadas nas áreas da especialidade.

1.3 - Organização da dissertação

A presente dissertação está dividida em cinco capítulos sumariados de seguida para permitir uma compreensão rápida, bem como uma análise mais facilitada por parte do leitor. No capítulo 2 é exibido o estado da arte relativo aos avanços realizados pela comunidade científica nas propostas de novas ferramentas de previsão para os preços de eletricidade no mercado e da potência eólica e ainda algumas características de relevo nessas áreas de conhecimento. No capítulo 3 são abordadas as diversas ferramentas computacionais estudadas para a previsão de preços de eletricidade no mercado e de potência eólica. Com efeito, será realizada uma apreciação evolutiva desde as redes neuronais, *Neural Network* (NN), passando para as metodologias híbridas mais atuais que combinam diversas ferramentas, proporcionando um aumento do desempenho e qualidade dos resultados obtidos. No capítulo 4 é apresentada a metodologia híbrida de previsão proposta, assim como os respetivos resultados obtidos, estabelecendo uma comparação com resultados reportados na literatura especializada, nomeadamente em revistas internacionais de referência. Por fim, no capítulo 5 são expostas as principais conclusões relativas ao estudo desenvolvido, assim como a apresentação de propostas para trabalhos futuros e as contribuições científicas resultantes deste trabalho.

Ainda, a presente dissertação utiliza as mesmas notações que a literatura da comunidade científica, harmonizando os aspetos comuns em todas as secções conforme as possibilidades, e redigida segundo o novo acordo ortográfico de 1990, proclamado e atualmente aceite em todas as instituições portuguesas, conforme a resolução da Assembleia da República nº. 35/2008. As figuras e tabelas serão mencionadas em relação ao capítulo onde são inseridas e não apenas ordenadas sequencialmente, reiniciando-se a numeração quando um novo capítulo é iniciado. As referências que suportam os diferentes capítulos que compõem a presente dissertação estarão estruturadas e identificadas por [XX] e as equações por (XX). Os acrónimos utilizados encontram-se estruturados pela sintetização de nomes e informação técnica oriunda da língua portuguesa ou quando não for possível a tradução adequada, na língua anglo-saxónica, ambos aceites na comunidade técnica e científica.

Capítulo 2

Estado da arte

Nesta secção é descrita a evolução das ferramentas concebidas para a previsão de preços de eletricidade no mercado e da potência eólica num horizonte temporal de curto prazo. De salientar ainda que devido ao grande número de publicações nas diferentes áreas de estudo, o presente capítulo irá centrar-se na análise das ferramentas e metodologias com maior impacto nos últimos anos. No desenvolvimento dessas ferramentas é possível considerar diversos fatores que afetam a qualidade dos resultados obtidos [29]:

- Distúrbios aleatórios - são alterações comportamentais abruptas na indústria elétrica e no quotidiano social;
- Económicos - são influenciados pelo tipo de consumidor, fatores geográficos, entre outros;
- Meteorológicos - temperatura, índices de precipitação e de humidade, condições não favoráveis, tais como tempestades e, ainda, índices de vento e luminosidade;
- Temporais - são instigados pelos efeitos sazonais, dias da semana e feriados;
- Volatilidade e aleatoriedade dos preços de eletricidade no mercado, descrito na secção anterior, cujo comportamento é condicionado pelos seguintes fatores:
 - Comportamento dos diversos intervenientes no mercado de eletricidade com base na antevisão dos preços em questão e ainda o congestionamento da rede de transporte e/ou distribuição;
 - Flutuações e incerteza na produção de eletricidade provocados pelos aproveitamentos de origem renovável ou a incerteza do consumo de eletricidade;
 - Manipulação do comportamento do mercado de eletricidade por agentes dominantes;
 - Variação do custo de produção das energias primárias, tais como as resultantes da exploração dos combustíveis fósseis.
- Outros fatores, tais como os padrões de consumo em diferentes zonas, entre outros. Neste contexto é expectável, por exemplo, que uma zona rural apresente padrões de consumo de eletricidade bastante diferentes relativamente a uma zona urbana.

Nos últimos anos, os esforços realizados pela comunidade científica têm sido bastante significativos na apresentação de soluções mais fiáveis e viáveis que permitam atenuar os inúmeros problemas no sistema elétrico, refletindo-se na maior expansão das técnicas e abordagens de previsão, como mostrado por exemplo em [30] ou em [31].

Considerando o amplo estado da arte na área de previsão de preços de eletricidade no mercado e de potência eólica, torna-se necessário considerar alguns aspectos diferentes, tais como, a família onde a metodologia proposta se integra, o horizonte de tempo da mesma e, por fim, o campo da previsão [32].

2.1 - Classificação dos horizontes temporais

Analisando a literatura especializada, é possível observar que as ferramentas de previsão de preços de eletricidade no mercado e de potência eólica são desenvolvidas de modos diferentes pois pretendem responder a horizontes temporais também diferentes, portanto, essas previsões encontram-se divididas em três grandes grupos:

- Muito curto prazo, que realiza a previsão até 6 horas;
- Curto prazo, que realiza a previsão até 168 horas (1 semana);
- Longo prazo, que realiza a previsão até algumas semanas.

Em [33], é referido que os limites dos horizontes temporais não se encontram verdadeiramente definidos, uma vez que, nas diversas publicações apresentadas pela comunidade científica, alguns autores utilizam diferentes limites para os horizontes temporais. Contudo, esta questão passa pelas regras que são impostas nos respectivos mercados de eletricidade, já que essas variam entre os diferentes mercados, fazendo com que os horizontes temporais de previsão possam ser diferentes também.

2.2 - Preços de eletricidade no mercado e ferramentas de previsão

Os diferentes fatores que afetam a qualidade da previsão, descritos no início do presente capítulo, originam a necessidade de adaptação das técnicas de previsão que, no caso de horizonte temporal de curto prazo, baseiam-se em modelos estatísticos, tais como séries temporais, modelos econométricos e inteligência artificial. Assim, importa realçar [34]:

- Modelos estatísticos - realizam a previsão considerando as características estatísticas e intervalo de confiança dos preços de eletricidade no mercado, permitindo ainda a análise da volatilidade. Dentro deste grupo também se encontram:
 - Modelos estatísticos locais - responsáveis pela atenuação dos fatores meteorológicos, tais como o vento, a pluviosidade, a luminosidade, entre outros e fatores sociais como, por exemplo, a sazonalidade e eventos de grande escala.
- Séries temporais - realizam a previsão utilizando bases de dados de ocorrências passadas e presentes, bem como os erros associados à variável auxiliar a essa previsão, sendo que os modelos mais frequentes são os autorregressivos e os híbridos (combinação de metodologias/técnicas).
- Modelos econométricos - são regressivos, apresentam características dos modelos estatísticos e têm o intuito de relacionar variáveis de previsão através da utilização de variáveis endógenas, permitindo obter:
 - Evolução temporal com base no histórico;
 - Regressão das variáveis aplicadas às séries temporais;
 - Previsão de uma variável em função de outras variáveis.

Assim sendo, torna-se indispensável possuir ferramentas de apoio à decisão que apresentem elevada precisão de modo a assegurar os benefícios para todos os intervenientes no mercado, sendo que nessas ferramentas deverão constar os resultados das previsões dos preços de eletricidade no mercado e de potência eólica. Por exemplo, o interesse de um produtor de eletricidade é realizar as suas propostas de transação de eletricidade de modo a maximizar os seus lucros, enquanto o consumidor procura satisfazer as suas necessidades de eletricidade minimizando os custos. Dessa premissa, no mercado de eletricidade liberalizado, o sinal mais importante para todos os intervenientes no mercado é o preço [35].

Características como a volatilidade, sazonalidade, efeito calendário e o comportamento não-estacionário das séries de preços de eletricidade no mercado fazem com que a previsão rigorosa e próxima da realidade dos mesmos seja mais difícil do que para o caso das séries de procura [36].

Como citado anteriormente, a fiabilidade e robustez de uma ferramenta de previsão de preços de eletricidade no mercado num horizonte temporal de curto prazo é necessária, por um lado, para ajudar os produtores na elaboração das suas estratégias de oferta ao mercado de eletricidade maximizando os lucros [37] e [38], e por outro lado, ajudar os consumidores a protegerem-se contra os preços elevados, assim como para fins de planeamento [39] e [40].

Além disso, a previsão dos preços de eletricidade no mercado tem vindo a crescer de tal modo que se tornou numa das principais áreas de investigação como é referido [41]-[43], no entanto, as ferramentas ou técnicas correspondentes ainda não atingiram a maturidade desejada [44]. Assim sendo, essa previsão é, de facto, uma tarefa crucial para todos os intervenientes no mercado no apoio às suas tomadas de decisão [45], especialmente com o surgir mais evidente e necessário das redes inteligentes [46].

Nos últimos anos, foram descritas várias metodologias de previsão na literatura especializada, as quais podem ser categorizadas em dois grupos: as de computação pesada e de computação suave [47].

Relativamente às primeiras, é possível encontrar algumas metodologias como por exemplo, *auto regressive integrated moving average* (ARIMA) [48], ou as transformadas de *wavelet* (WT) combinadas com ARIMA [49], ou ainda modelos de função de transferência [50]. Uma vez que esta família de metodologias necessita geralmente de uma extensa quantidade de dados físicos e de uma modelação exata do sistema, a sua aplicação resulta numa elevada carga computacional, pelo que não serão analisadas no contexto do presente trabalho.

Posto isso, este trabalho irá demonstrar as técnicas de computação suave, que utilizam um processo de autoaprendizagem a partir de conjuntos históricos para identificar padrões futuros, as quais mostram maior versatilidade, facilidade de implementação, compreensão e proliferação na comunidade científica [51]. Como referido anteriormente, embora seja possível encontrar variadíssimas publicações na comunidade científica na área de previsão de preços de eletricidade no mercado desde a liberalização do setor elétrico, apenas serão apresentadas algumas técnicas desenvolvidas a partir de 2009.

Em 2009, em [52] uma técnica híbrida baseada na combinação de *mutual information* (MI), técnica de relaxação de dados e redes neuronais (NN) em cascata (CNN), foi proposta para previsão dos preços de eletricidade nos mercados espanhol e PJM (PJM é uma organização de transmissão regional nos EUA que coordena o todo o processo elétrico e de mercado em todos os treze estados entre Pensilvânia e Nova Jersey), para as 168 horas seguintes, recorrendo aos dados históricos dos anos 2002 e 2006, respetivamente.

Para os mesmos mercados, em [53] foi relatada uma ferramenta composta pelo algoritmo neuro-evolucionário em cascata (CNEA). Em [54] foi reportado um modelo híbrido sustentado na ferramenta de relaxamento modificado e CNN com análises de correlação para previsão dos preços de eletricidade nos mercados de eletricidade espanhol e australiano, *Australian National Electricity Market* (ANEM). Em [55] foi exposta uma técnica assente num modelo misto de NN iterativa e MI para previsão de preços de eletricidade no mercado espanhol e no *New York Independent System Operator* (NYISO).

Em [56] foi publicada uma técnica apoiada em NN com base radial auto-adaptativa com inferência difusa para previsão de preços de eletricidade das 24 horas seguintes aplicada no mercado ANEM, considerando dados históricos de 2006. Em [57] foi apresentada uma técnica fundada na análise sensível combinada com NN para igual previsão e no mesmo horizonte temporal considerado em [56], considerando ainda a análise do mercado PJM com dados históricos de 2006.

Em 2010, em [58] foi apresentada uma técnica híbrida apoiada em NN com algoritmos evolucionários para previsão de preços de eletricidade nos mercados espanhol e PJM para as 168 horas seguintes, considerando os dados históricos de 2002 e 2006, respetivamente, sendo denominado por *hybrid neuro evolutionary system* (HNES). Em [59] foi reportada uma técnica baseada na combinação de ARIMA com NN para previsão de preços de eletricidade no mercado ANEM para as 168 horas seguintes, considerando os dados históricos de 2006. Em [60] foi relatada uma combinação de NN e WT para previsão de preços de eletricidade a curto prazo em mercados liberalizados.

Em [61] foi proposta uma ferramenta assente no modelo recursivo combinado com NN para previsão de preços de eletricidade no mercado PJM para as 24 horas seguintes, considerando os dados históricos de 2006. Em [62] foi exposta uma técnica alicerçada em NN com um algoritmo aperfeiçoado baseado na função de rede de base radial para a previsão de preços de eletricidade no mercado PJM para as 24 e 168 horas seguintes. Ainda da análise dos mercados anteriormente descritos, em [63] foi descrito um modelo híbrido e em [64] uma técnica de relaxamento modificado, apresentando resultados relevantes.

Em 2011, em [38] foi proposta uma metodologia híbrida combinando WT, otimização por enxame de partículas, *particle swarm optimization* (PSO), e algoritmo difuso para previsão dos preços de eletricidade no mercado espanhol para as 168 horas seguintes, considerando os dados históricos de 2002. No mesmo mercado e para o mesmo horizonte de tempo de previsão, em [65], foi reportada outra metodologia híbrida, associando a otimização por enxame de partículas evolucionário, *evolutionary particle swarm optimization* (EPSO), ao sistema de inferência neuro-difuso adaptativo, *adaptive neuro-fuzzy inference system* (ANFIS). Em [66] foi publicada uma técnica aplicando um algoritmo de previsão com base no padrão de similaridade das sequências para previsão de preços de eletricidade nos mercados liberalizados normalmente utilizados na comunidade científica para comparar e testar as técnicas propostas.

Em 2012, em [67] foi exposta uma ferramenta intitulada de máquina de aprendizagem extrema para previsão de preços de eletricidade no mercado ANEM para as 168 horas seguintes, considerando os dados históricos de 2006 e 2007. Em [68] foi proposta uma técnica que combina MI com NN decompostos em duas etapas, para previsão de preços de eletricidade no mercado espanhol e PJM com os dados históricos de 2002 e 2006, respetivamente, e ambos para as 168 horas seguintes.

Em [69] foi publicada uma metodologia híbrida constituída por WT, sistema de inferência e NN para previsão de preços de eletricidade no mercado de Ontário para as 24 e 168 horas seguintes, considerando os dados históricos de 2010. Em [70] foi anunciada outra metodologia híbrida, composta por PSO e ANFIS para previsão de preços de eletricidade no mercado espanhol para as 168 horas seguintes, considerando os dados históricos de 2002.

Em [71] foi apresentada uma ferramenta baseada na combinação de *Grey model* e PSO para previsão de preços de eletricidade nos mercados da Califórnia, de Ontário e do *Nord Pool* para as 24 horas seguintes, considerando os dados históricos de 2000 a 2003, 2006 e 2007, respetivamente. Em [72] foi apresentado um estudo completo de modelos de previsão híbridos aplicados no sistema elétrico, bem como o desempenho de dois métodos híbridos propostos para previsão de preços de eletricidade de carga base para o dia seguinte no mercado APX (*Power Export Exchange*) da Grã-Bretanha.

Em 2013, em [36] foi publicada uma técnica híbrida baseada na cointegração de painéis e filtro de partículas para a previsão de preços de eletricidade no mercado PJM para as 168 horas seguintes, considerando dados históricos de 2008. Em [73] foi proposta a combinação de WT com *chaotic least squares support vector machine* (CLSSVM), e com o modelo exponencial *generalized autoregressive conditional heteroskedastic* (EGARCH), concebido como (WT+CLSSVM+EGARCH) para previsão dos preços de eletricidade nos mercados de Espanha e PJM para as 24 horas seguintes. Em [74] foi concebido o método singular *spectrum analysis* (SSA) para previsão de preços de eletricidade nos mercados de Espanha e ANEM para as 24 horas seguintes.

Em [51] foi reportada uma técnica recorrendo à WT, algoritmo *firefly* (FF), bem como à teoria do mapeamento da ressonância adaptativa difusa, Fuzzy ARTMAP (FA), conjugando-se numa estrutura (WT+FF+FA) para previsão de preços de eletricidade nos mercados PJM e de Ontário, Canadá, para as 24 horas seguintes. Em [75] foi apresentada uma metodologia *Kernel principal component analysis* (KPCA), combinada com *informative vector machine* (IVM), originando a estrutura (KPCA+IVM) dividida em duas fases: primeiro, a KPCA é utilizada para extrair as características das entradas e obter os componentes do princípio de Kernel para a construção do espaço faseado da série histórica de entradas; de seguida, a IVM é empregue para previsão de preços de eletricidade no mercado, considerando dados históricos.

Em [76] foi exposto um modelo NN recorrente utilizando a metodologia de Elman para previsão dos preços de eletricidade no mercado espanhol para as 168 horas seguintes, considerando os dados históricos, e apresentando os resultados obtidos com um passo de 1 hora. De modo a demonstrar a sua eficiência, o mesmo foi aplicado no mercado de eletricidade de Nova Iorque com os dados históricos de 2010. Em [77] foi sugerida a combinação do *recursive dynamic factor analysis* (RDFA), com o filtro de Kalman (KF), originando a ferramenta (RDFA+KF), a qual se combina num modelo multifacetado para previsão de preços de eletricidade nos mercados de Nova Inglaterra e ANEM

Em 2014, em [78] foi apresentado um modelo híbrido resultante da combinação das ferramentas MI, WT, EPSO e ANFIS para previsão de preços de eletricidade nos mercados espanhol e PJM, considerando os dados históricos de 2002 e 2006 no caso do primeiro mercado e os dados de 2006 no segundo mercado em análise. O horizonte temporal considerado foi compreendido, entre 24 e 168 horas com passo de 1 hora, sem a utilização de dados exógenos. Em [79] foi proposto um modelo híbrido que explora ARIMA fracionado (ARFIMA) combinado com *feed-forward* NN para previsão de preços de eletricidade no mercado *Nord Pool*.

Em 2015, em [80] foi proposto um modelo de previsão de preços *spot* para um horizonte temporal de curto prazo, considerando-se uma metodologia genética treinada através do algoritmo *Cuckoo Search Levenberg-Marquardt* (CSLM), combinada com *feed-forward NN* (CSLM-FFNN). A metodologia teve em consideração a geração de energia e a carga do sistema elétrico como conjuntos de entrada, de modo a facilitar o uso eficiente dos recursos de transmissão e geração de energia por parte dos participantes diretos no mercado, sendo testado no mercado espanhol e *Nord Pool*, recorrendo aos dados históricos de 2002 e 2009, respetivamente.

Em [81] foi reportado um modelo híbrido para previsão dos preços de eletricidade no mercado de Nova Inglaterra com um passo de 1 hora, considerando todos os dados históricos de 2001. Esse modelo foi implementado em duas etapas: na primeira etapa, foi adotado um conjunto de *relevance vector machines* (RVM) para uma previsão individual; e na segunda etapa, as previsões anteriores foram agregadas para criar um conjunto de regressão linear. Posteriormente, a previsão final foi obtida recorrendo à utilização de um algoritmo microgenético.

2.3 - Potência eólica e ferramentas de previsão

Nos últimos anos, a integração da potência eólica no sistema elétrico nos EU28 tem assistido a um crescimento mais rápido quando comparado com as unidades elétricas convencionais, tais como as centrais térmicas ou hídricas. Em [82] foi anunciado que o recurso eólico deveria ser previsto a curto prazo para alcançar melhores resultados, devido à menor influência da incerteza associada ao recurso que influencia a qualidade dos resultados finais da previsão. Posto isso, a integração de potência eólica em sistemas elétricos convencionais introduz maior variabilidade, volatilidade e incerteza na adequada operação e gestão do sistema [83], [84].

Tal como acontece para a previsão dos preços de eletricidade no mercado, na previsão da potência eólica não existe um consenso na comunidade científica relativamente aos limites temporais a serem adotados para a previsão da potência eólica, devido aos meios de aplicação e mercados onde podem ser inseridos ou utilizados. No entanto, por uma questão de harmonização, os horizontes temporais adotados seguem na sua maioria os descritos nas seções anteriores [85]. Com efeito, as ferramentas de previsão da potência eólica representam um campo de pesquisa muito importante para os operadores do sistema, já que permitem a redução das flutuações de eletricidade e auxiliam na otimização dos aproveitamentos eólicos instalados, permitindo a mitigação dos GEE [86]. O desenvolvimento de métodos computacionais com capacidade de simular o comportamento da atmosfera ajudou à compreensão e criação dos modelos de persistência. Assim sendo, é possível categorizar os modelos de previsão em dois grupos, como descreve [87]:

- Modelos físicos - são modelos computacionais que precisam de uma extensa série de especificações físicas, nos quais as suas entradas também são variáveis físicas, tais como a orografia, a pressão e a temperatura, apresentando vantagens na previsão de longo prazo [88]. Estes podem recorrer a modelos estatísticos para melhorar as suas performances, contudo, as variáveis em que se baseiam as previsões são, por sua vez, dependentes de outras variáveis, tais como as características do gerador, os coeficientes de controlo das turbinas, entre outras [89].

- Modelos estatísticos - são modelos computacionais que tentam estabelecer relações inerentes dentro dos dados registados, podendo apresentar vantagens nas previsões de curto prazo [90], [91]. Estes utilizam métodos baseados em NN, entre outras ferramentas, e possuem a vantagem de prescindir de modelos físicos, reduzindo os tempos computacionais, não prescindindo, contudo, de uma cuidada estimação dos parâmetros, os quais estão interligados a um vasto conjunto de dados históricos [89].

As ferramentas de previsão a curto prazo são realmente úteis no apoio às decisões nos mercados *spot*, diário e intradiário para os diferentes intervenientes, com maior incidência nos produtores eólicos e para o ISO, ajudando a gerir o equilíbrio entre a carga e a procura, bem como auxilia na flexibilidade e robustez do sistema elétrico [92]. Tal como referido em [93], a energia eólica possui mais incerteza e volatilidade comparativamente a outras fontes renováveis, como mostrado na Figura 2.1.

Os dados físicos podem ser divididos em modelos específicos ou modelos de potência que utilizam esses dados, e podem, também, ser combinados com ferramentas estatísticas de previsão, tal como é demonstrado na Figura 2.2, que apresenta um diagrama de blocos geral dos modelos físicos utilizados na previsão de potência eólica [94].

Em [33] é afirmado que os modelos físicos apenas utilizam considerações físicas para alcançar as melhores estimativas da velocidade do vento num local específico e, eventualmente, numa segunda fase, um modelo estatístico pode ser empregado para minimizar os erros restantes. Desta forma, o modelo de persistência provou ser útil para estabelecer uma primeira aproximação para previsão da potência eólica num horizonte temporal de curto prazo, servindo também como referência comparativa para ferramentas alternativas [94].

Geralmente, as ferramentas estatísticas são baseadas em técnicas autorregressivas, ou seja, ARIMA [95], ou no *new reference model* (NRM) [96], os quais também são modelos de séries temporais que podem fornecer uma primeira aproximação valiosa, e inclusivé, são capazes de superar os modelos baseados em dados provenientes do *numerical weather prediction* (NWP), para um horizonte temporal de curto prazo.

Nos últimos anos, os modelos de computação suave tornaram-se muito difundidos e aceites na comunidade científica, principalmente devido à reduzida carga computacional exigida, resultante de um processo de autoaprendizagem do conjunto histórico, para identificar padrões futuros. A Tabela 2.1 apresenta as ferramentas de previsão mais difundidas e utilizadas para a previsão de curto prazo, bem como o seu modelo de classificação de acordo com o que é descrito em [33].

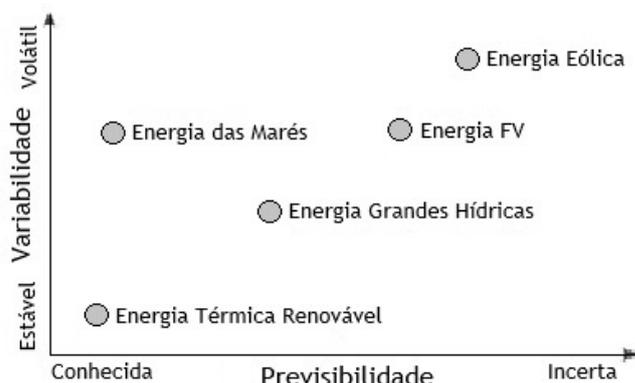


Figura 2.1 - Variabilidade e previsibilidade das diversas fontes renováveis [93].

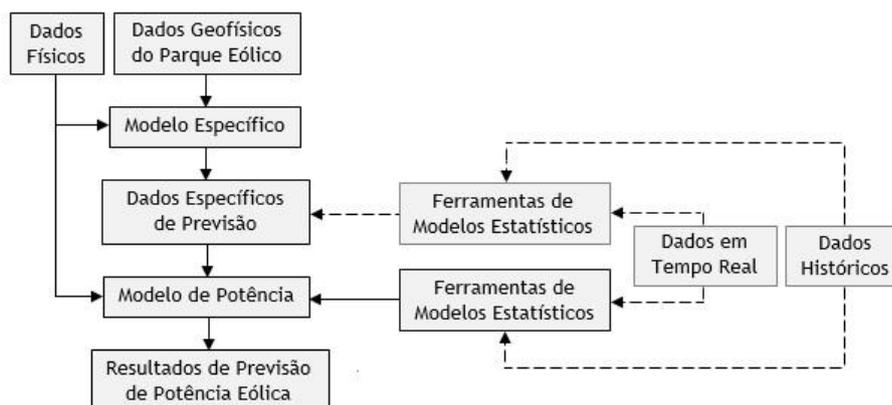


Figura 2.2 - Diagrama geral de previsão de potência eólica a partir de modelos físicos [94].

Tabela 2.1 - Ferramentas de previsão da potência eólica mais utilizadas no globo [33].

Ferramenta de previsão	Modelo
AWPPS (More-Core)	Estatístico, NF
AWPT	Estatístico, NN
Prediktor	Físico
Previento	Físico
RAL (More-Core)	Estatístico
Sipreólico	Estatístico
WPPT	Estatístico

Tal como acontece na previsão dos preços de eletricidade no mercado, o estado da arte no campo da previsão da potência eólica tornou-se extenso e diversificado e, por isso, a revisão da literatura aqui apresentada irá focar-se em relatar, as ferramentas encontradas na comunidade científica consideradas mais relevantes e que sejam relacionadas com técnicas de computação suave aplicadas à previsão de potência eólica para um horizonte temporal de curto ou muito curto prazo a partir de 2009.

Em 2009, em [97] foi apresentada uma ferramenta combinando *feed forward* NN com teorias da entropia e correntropia para previsão de potência eólica em dois parques eólicos em Portugal para as 72 horas subsequentes. Esse estudo foi testado em estruturas *online* e *offline*, considerando dados de 2005 e 2006, de modo a obter uma reduzida distribuição do erro.

Em [95] foi relatada uma técnica baseada num modelo ARIMA fracionado para previsão da potência eólica dividida em duas fases: na primeira, realiza-se a previsão da velocidade do vento para as 24 e 48 horas seguintes; e na segunda fase, utilizando os resultados obtidos na fase anterior, os dados são combinados com as características mecânicas das unidades eólicas determinando-se, assim, a potência eólica. O horizonte temporal considerado foi de 24 e 48 horas e foram utilizados os dados recolhidos de quatro parques eólicos no Dakota do Norte, EUA, estabelecendo-se uma comparação dos resultados finais com um modelo de persistência.

Em [98] foi reportada uma abordagem baseada numa NN artificial (ANN) para previsão de potência eólica em Portugal para as 24 horas seguintes com um passo de 15 minutos e discretos em intervalos de 3 horas, considerando apenas dados históricos de 2007 e 2008, sendo comparado com os modelos de persistência e ARIMA.

Em 2010, em [99] foi apresentada uma ferramenta de previsão para o horizonte temporal de muito curto prazo, combinando um método exponencial de mitigação e mineração dos dados, ou *data mining*. Os dados recolhidos foram combinados com os dados provenientes dos sistemas de supervisão e aquisição de dados, ou *supervisory control and data acquisition* (SCADA), e com dados meteorológicos, físicos e mecânicos das unidades eólicas. A previsão foi realizada com passos temporais diferentes e para as 168 horas seguintes dividido em três modelos: o modelo 1 realiza a previsão dos coeficientes da função gerada pelas unidades eólicas; o modelo 2 utiliza dados mecânicos pelas unidades eólicas e a velocidade do vento para a previsão da saída de potência eólica; o modelo 3 usa parâmetros do *data mining* combinados com os modelos descritos para a previsão de potência eólica. Por fim, os resultados obtidos foram comparados com outros sistemas, tais como NN e *support vector machine* (SVM).

Em 2011, em [100] foi reportada uma ferramenta utilizando um algoritmo de evolução diferencial com um novo operador de cruzamento e um mecanismo de seleção para treinar as Ridgelet NN combinadas com WT para as 24 horas seguintes sem a utilização de variáveis exógenas. Os casos de estudo basearam-se em dados históricos de potência eólica de um parque eólico localizado na Irlanda relativos a 2010, e para a previsão da velocidade do vento e da potência eólica em Espanha com dados históricos de 2010, respetivamente.

Em [87] foi proposta uma ferramenta constituída por componentes de seleção característicos que filtram a irrelevância e redundância dos dados históricos utilizados, sendo a saída desses utilizada num mecanismo baseado numa estrutura CNN com PSO melhorado para previsão de potência eólica em dois parques eólicos, um localizado em Alberta, Canadá, e outro em Oklahoma, EUA. Em [101] foi exposta uma abordagem híbrida combinando WT e NN (NNWT) para previsão de potência eólica, em Portugal, em parques eólicos com telemetria ligada à REN para as 3 horas seguintes com um passo de 15 minutos, considerando apenas dados históricos fornecidos pelo SCADA entre 2006 e 2007.

Em [102] foi publicada uma ferramenta baseada na técnica ANFIS para previsão de potência eólica em parques eólicos portugueses ligados ao SCADA para as 3 horas seguintes com um passo de 15 minutos, considerando apenas dados históricos entre 2006 e 2007, sendo comparado, com as metodologias de ARIMA e a ferramenta NN. Em [103] foi reportada uma metodologia híbrida combinando WT, PSO e ANFIS (WPA) para previsão de potência eólica em parques eólicos com telemetria ligada à REN para as 3 horas seguintes, com um passo de 15 minutos, considerando dados históricos apenas, sem recorrer às variáveis exógenas.

Em [104] foi relatada uma ferramenta híbrida baseada em PSO e ANFIS (HPA) para previsão de potência eólica, em Portugal, para as 24 horas seguintes, com um passo de 15 minutos, considerando apenas dados históricos e sem recorrer às variáveis exógenas. Em [105] foi apresentado um método híbrido assente na combinação dos algoritmos EPSO e ANFIS para previsão da potência eólica, em Portugal, para as 24 horas seguintes, com um passo 15 minutos sem a utilização de variáveis exógenas ou meteorológicas, sendo comparado com outras ferramentas de previsão tais como ARIMA, NN e *data mining*.

Em 2012, em [88] foi reportada uma técnica alicerçada na aplicação de um algoritmo de otimização evolucionário para a especificação automática da NN e a procura do vizinho mais próximo, utilizado para a previsão da potência eólica a curto prazo em diversos parques eólicos situados na Alemanha, utilizando dados meteorológicos combinados com dados históricos compreendidos entre 2004 e 2007 com um passo de 1 hora. Os resultados dessa previsão foram comparados com outros dois algoritmos baseados no PSO e evolução diferencial.

Em [83] foi publicado um modelo com um regime de comutação baseado em inteligência artificial para previsão de potência eólica, especificamente, os acontecimentos extremos associados com a incerteza dos dados NWP. O algoritmo NN utilizado foi fundamentado com a teoria da ressonância e métodos probabilísticos, sendo testado para dois casos distintos: um parque eólico na Dinamarca, considerando dados históricos de 2000 a 2002; e um parque eólico em Creta, na Grécia, considerando dados históricos de 2006 a 2008. Ainda utilizando os mesmos dados históricos referentes a esses dois parques eólicos, em [106] foi relatado um modelo probabilístico para a previsão da potência eólica, o qual recorre a pontos de previsão e dados de incerteza a partir de modelos determinísticos. Os resultados reportados tiveram em conta a qualidade dos dados NWP, da previsão da potência eólica diária e da estabilidade meteorológica, nomeadamente, a velocidade e direção do vento. Esta abordagem usou, também, uma combinação de múltiplas NN combinadas com o algoritmo PSO para a previsão de potência eólica para as 60 horas seguintes.

Em [107] foi abordado o problema no que concerne à grande penetração de novos parques eólicos na estrutura elétrica, revendo as suas vantagens e desvantagens, bem como os avanços das ferramentas de previsão de potência eólica. Nesse trabalho, também foi proposto um algoritmo NN para a previsão da potência ativa e reativa na rede elétrica, com um passo de 1 hora, para as 24 até 48 horas seguintes, baseando-se no caso de estudo de um parque eólico localizado na Alemanha. Em [108] foi exposto um método baseado em três modelos de WT e SVM para previsão da potência eólica de um parque eólico localizado no Texas, EUA, para as 3 horas seguintes, testando-os com um passo de 1 hora. O modelo 1 é uma combinação das características geradas pelas unidades eólicas e os princípios da WT. O modelo 2 combina as mesmas características com a substituição do *radial basis function* (RBF). Por último, o modelo 3 é a resultante da combinação de ambos os modelos anteriores e a sua saída é a previsão de potência eólica.

Em [109] foi proposta uma ferramenta de previsão da velocidade do vento e da potência eólica para um parque eólico em Denver, EUA, para as 30 horas seguintes e sem utilizar variáveis meteorológicas, procedendo-se através de duas fases distintas: na primeira utilizou uma combinação de WT e NN para a previsão da velocidade do vento; na segunda fase utilizou a uma *feed-forward* NN para criar um mapeamento não-linear entre a velocidade do vento e os resultados de potência eólica.

Em 2013, em [110] foi apresentado um estudo de comparação entre diversos modelos híbridos e convencionais, tais como a persistência, NN e NN difusas para prever o comportamento da velocidade do vento recorrendo a diferentes séries de velocidade do vento, divididas em três casos de estudos com diferentes passos temporais relativamente a um parque eólico chinês localizado na província de Qinghai. Em [111] foi reportado um estudo das características estatísticas de valores provenientes do NWP, no qual um simulador avançado de ARIMA foi desenhado para ajustar os valores do NWP para previsão da potência eólica num horizonte temporal de curto prazo, demonstrando que esses ajustes dos dados de NWP originam resultados mais precisos.

Em 2014, em [112] foi exposto um modelo híbrido composto por *multi-layer perceptron artificial* NN (MLP) e um modelo *improved simplified swarm optimization* (iSSO), para previsão da potência eólica no parque eólico mais importante de Taiwan, o Mai Liao, considerando os dados históricos recolhidos num período de cinco anos, compreendidos entre setembro de 2002 e agosto de 2007, respetivamente.

Em [113] foi publicado um modelo híbrido determinista para previsão da potência eólica utilizando uma combinação de WT com uma rede FA, otimizada através do algoritmo FF, ou seja, um modelo (WT+FA+FF), sendo o erro dos resultados obtidos minimizados através da utilização de SVM, (WT+FA+FF+SVM). Além disso, no mesmo trabalho foi relatada uma técnica probabilística para a previsão da potência eólica recorrendo a um método de regressão de quantificação, o qual avalia o desempenho dos resultados determinados através do modelo híbrido anterior. Para tal, são utilizados dados históricos de um parque eólico em Cedar Creek, Colorado, EUA.

Em [114] foi reportado um outro modelo probabilístico para a previsão da potência eólica, baseado nos modelos de seleção *online* e no *warped Gaussian process* (WGP), tendo sido testado com os dados reais recolhidos dos parques eólicos, tanto individuais como agregados. Em [115] foi apresentada uma visão geral das ferramentas de previsão da potência eólica publicadas nos últimos anos utilizando metodologias probabilísticas.

Em 2015, em [116] foi relatado um modelo híbrido que combina MI, WT, EPSO e ANFIS para previsão da potência eólica a curto prazo em parques eólicos ligados ao operador do sistema de transmissão português, a REN, considerando intervalos de 3 horas com um passo de 15 minutos, realizando a previsão para as próximas 24 horas.

Em [117] foi reportada uma metodologia de previsão da potência eólica combinando um modelo de pré-processamento, *back-propagation* NN e um algoritmo genético contando com dados históricos para realizar previsões para as próximas 24 horas com um passo de 30 minutos. Os resultados obtidos através da afinação do modelo proposto foram alvos de comparação com os de diferentes modelos NN, conseguindo provar a superioridade do modelo híbrido proposto.

Em [118] foi proposta uma metodologia WNN considerando os neurónios da camada escondida e construídos com base em WT de Morlet multidimensionais, treinados através de um algoritmo de seleção também genético e adaptado para a previsão da potência eólica, considerando os dados horários reais da geração da potência eólica do sistema em Alberta, Canadá, divididos em conjuntos de 6 horas para um horizonte de 168 horas de previsão.

Pode-se depreender da análise anterior que a maioria das metodologias de previsão a curto prazo propostas pela comunidade científica encontram-se enquadradas quer em modelos estatísticos, como é o caso das séries temporais, da inteligência artificial como é o caso das NN e algoritmos genéticos, entre outros. Também se pode realçar o facto de que os sistemas ditos inteligentes para a previsão são utilizados tanto na previsão dos preços de eletricidade no mercado como na previsão da potência eólica.

Um dos motivos na escolha destes modelos na hora de criar uma ferramenta de previsão prende-se com o facto de que estes modelos são mais eficientes a nível computacional e recorrem, na sua grande maioria, a uma quantidade inferior de parâmetros para desempenhar a previsão, pelo que a sua implementação, como demonstrada na grande quantidade de publicações encontrada em revistas internacionais de renome, é benéfica. Em suma, e a título de exemplo, na Figura 2.3 é apresentada uma taxonomia com as principais metodologias desenvolvidas até a atualidade no campo da previsão [8].

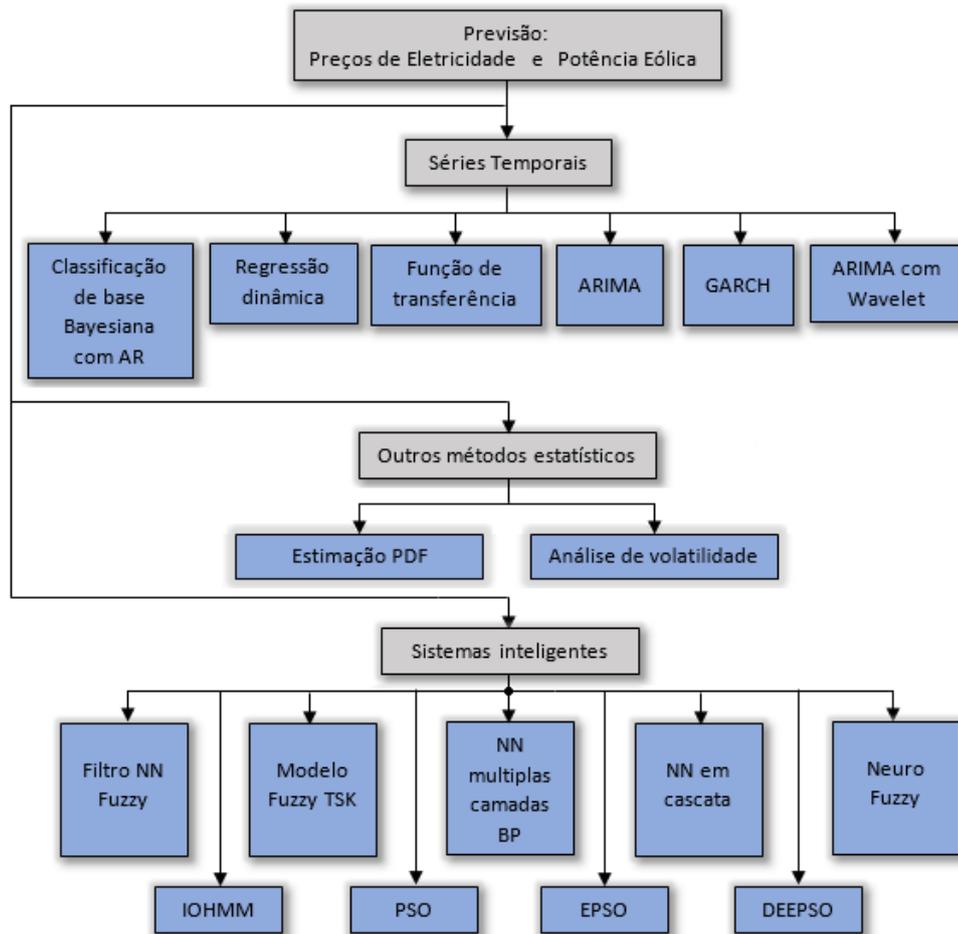


Figura 2.3 - Taxonomia das principais metodologias de previsão [8].

Capítulo 3

Métodos Computacionais

Nesta secção são descritos os métodos computacionais aplicados no estudo desta dissertação, nomeadamente as redes neuronais, a lógica difusa, os sistemas neuro-difusos, a otimização por exame de partículas, entre outras metodologias híbridas.

3.1 - Redes neuronais

As NN artificiais são métodos computacionais que se baseiam em algoritmos matemáticos desenvolvidos para simular e assemelhar o funcionamento do cérebro humano, ou seja, as NN são estruturas montadas para possuir um comportamento inteligente, nomeadamente, aprender novas tarefas, errar, fazer generalizações e descobertas, permitindo assim ter a capacidade de aprender através da experiência [119]. Os neurónios são responsáveis pela realização das principais funções do cérebro humano estimando-se que existam perto de 10^{11} neurónios, os quais são constituídos por três componentes: o corpo celular, as dendrites e o axónio, como é apresentado na Figura 3.1. A transmissão de informação nos neurónios é realizada através de pequenos impulsos eletroquímicos que são recebidos através das dendrites que conduzem a mesma para o corpo celular que, posteriormente, transportam a informação para o axónio, seguindo para o próximo neurónio através da conexão entre as ramificações do axónio e as dendrites do novo neurónio, designando-se o processo por sinapse e formando uma rede de neurónios [120]. As NN baseiam-se na estrutura do cérebro humano, realizando diversas tarefas em tempo útil para um volume elevado de dados, apresentando diversas vantagens, das quais [119] e [122]:

- Aprendizagem - são fornecidos os dados à entrada do sistema que, por sua vez, dará uma resposta na saída;
- Auto-organização - criam a sua própria representação da informação contida no seu interior;

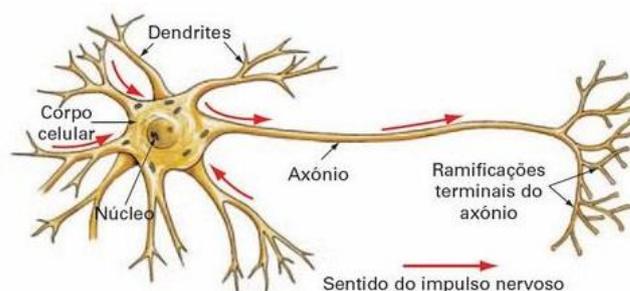


Figura 3.1 - Constituição de um neurónio [121].

- Flexibilidade - podem adaptar-se à medida que novos dados são introduzidos;
- Não linearidade - permitem uma modelação não linear, importante no mecanismo físico subjacente responsável pela geração de sinal de entrada;
- Tolerância a falhas - armazenam informação de forma redundante, mesmo que esteja parcialmente danificada, ou que a própria informação de entrada seja incompleta, conseguindo dar uma resposta aceitável;
- Trabalho em tempo real - são estruturas paralelas logo permitem realizar tarefas complexas num espaço temporal curto.

Na utilização de NN para previsão estão envolvidos dois processos que devem ser realizados sob supervisão do utilizador: o treino e a aprendizagem. No primeiro processo, o utilizador é responsável por verificar a existência de um conjunto de treino obtido através de dados históricos válidos, contendo as entradas e correspondentes saídas, de modo a obter o sucesso pretendido do procedimento em causa.

No processo de aprendizagem as NN aprendem a partir do conjunto de treino constituído pelos pares entrada/saída, realizando um ajuste dos pesos e das polarizações em cada iteração, de modo a minimizar a medida de erro, a qual é definida pelo utilizador e relaciona a saída da previsão e a saída real. O procedimento iterativo termina assim que é atingido o critério de paragem pré-definido pelo utilizador [98].

Analogamente aos neurónios humanos, as NN são constituídas por uma ou mais camadas interligadas por um grande número de conexões, designando-se por perceptrão. Neste processo, a cada ligação associa-se um valor numérico, ou seja, um peso que caracteriza a força de uma determinada ligação entre dois neurónios, já que desta forma permite a representação do conhecimento armazenado nessa ligação, sendo a aprendizagem da NN realizada através do processo de adaptação dos seus pesos sinápticos [119].

Na Figura 3.2 é apresentado um modelo não linear de uma NN, no qual é recebido um vetor x_i de dimensão m correspondente a um valor real y . O valor atribuído a y depende do vetor dos pesos $[w_0 w_1 \dots w_m]$ e da função de ativação escolhida, $F(\cdot)$.

A estrutura possui ainda uma entrada específica, x_0 , designada por viés, que permite deslocar a função de ativação e, caso esse viés seja negativo, a soma das entradas tem que ser superior a esse valor para que o neurónio produza um valor positivo na saída [98]. Posto isto, os valores presentes nas entradas do neurónio são:

$$s = \sum_{i=1}^m w_i x_i + w_0 \quad (3.1)$$

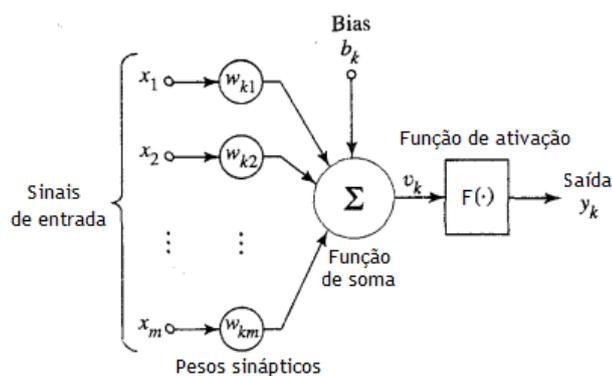


Figura 3.2 - Modelo não linear de um neurónio artificial [98].

O resultado obtido através da equação (3.1) é sujeito à função de ativação, a qual, tradicionalmente, é uma função não linear e da qual é originada a saída do neurónio. Tal procedimento corresponde ao modelo perceptrão que, de modo genérico, é:

$$y = F\left(\sum_{i=1}^m w_i x_i + w_o\right) \quad (3.2)$$

Assim, torna-se importante destacar as formas de funções de ativação mais utilizadas em NN, as quais são apresentadas, graficamente, na Figura 3.3 [119]:

- Função linear:

$$F(s) = \beta * s \quad (3.3)$$

- Função degrau unitário:

$$F(s) = \begin{cases} \beta_2, & s \geq 0 \\ \beta_1, & s < 0 \end{cases} \quad (3.4)$$

onde β_1 pode assumir o valor 0 ou -1.

- Função rampa unitária:

$$F(s) = \begin{cases} \beta, & s \geq \beta \\ s, & |s| < \beta \\ -\beta, & s \leq -\beta \end{cases} \quad (3.5)$$

- Função sigmóide:

$$F(s) = \frac{1}{1 + e^{-\lambda s}} \quad (3.6)$$

- Função tangente hiperbólica:

$$F(s) = \frac{e^{\lambda s} - e^{-\lambda s}}{e^{\lambda s} + e^{-\lambda s}} \quad (3.7)$$

No caso de previsões de séries temporais são mais adequadas as funções de ativação da tangente hiperbólica para a camada escondida e a função linear para a camada de saída. As funções de ativação são, tipicamente, monótonas e crescentes, no entanto, a função de ativação linear é uma exceção, possuindo as propriedades seguintes:

- $F(-\infty) = -1 \vee F(-\infty) = 0$;
- $F(+\infty) = 1$.

Assim, torna-se necessário implementar um sistema multicamada, isto é, um perceptrão multicamada, no qual a interligação das entradas com a camada de saída terá, por sua vez, uma ou mais camadas de neurónios intermédias, designando-se por camada escondida. A criação do perceptrão multicamada permite uma ampliação do universo de soluções possíveis no qual estes sistemas operam, ou seja, poderão ser utilizados para a resolução de problemas que não são linearmente separáveis [120].

Na Figura 3.4 é apresentado o esquema de um sistema de perceptrão multicamada [119]. Seguindo o exemplo de perceptrão multicamada apresentado nessa figura, na entrada da NN encontra-se o vetor x .

Tal vetor à entrada da NN é dado por:

$$x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (3.8)$$

Na mesma entrada, estão associadas as matrizes dos pesos das ligações:

$$w_{0,1} = \begin{bmatrix} w_{0,1}^1 \\ w_{0,1}^2 \end{bmatrix}, \quad w_{1,1} = \begin{bmatrix} w_{1,1}^{1,1} & w_{1,1}^{1,2} \\ w_{1,1}^{2,1} & w_{1,1}^{2,2} \end{bmatrix} \quad (3.9)$$

Os dados à entrada da NN são combinados com os pesos das suas ligações, algebricamente significa a combinação das expressões (3.8) e (3.9), resultando na saída da camada escondida:

$$S_1 = \begin{bmatrix} w_{1,1}^{1,1} & w_{1,1}^{1,2} \\ w_{1,1}^{2,1} & w_{1,1}^{2,2} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} w_{0,1}^1 \\ w_{0,1}^2 \end{bmatrix} \Leftrightarrow S_1 = \begin{bmatrix} S_1^1 \\ S_1^2 \end{bmatrix} \quad (3.10)$$

No caso mais usual para a previsão, a função de ativação à saída da camada escondida é tangente hiperbólica, ou seja:

$$y_1 = \text{tansig} \left(\begin{bmatrix} S_1^1 \\ S_1^2 \end{bmatrix} \right) \Leftrightarrow y_1 = \begin{bmatrix} y_1^1 \\ y_1^2 \end{bmatrix} \quad (3.11)$$

De seguida, os resultados obtidos a partir da expressão (3.11) são transmitidos para a camada de saída, originando uma matriz correspondente aos pesos sinápticos de cada ligação:

$$w_{0,2} = [w_{0,2}^1], \quad w_{2,1} = [w_{2,1}^{1,1} \ w_{2,1}^{1,2}] \quad (3.12)$$

A combinação das expressões (3.11) e (3.12) resulta na equação da saída da camada de saída. Assim, os dados de entrada da camada de saída são combinados com as matrizes dos pesos sinápticos das suas ligações, resultando em:

$$S_2 = [w_{2,1}^{1,1} \ w_{2,1}^{1,2}] \cdot \begin{bmatrix} y_1^1 \\ y_1^2 \end{bmatrix} + [w_{0,2}^1] \Leftrightarrow S_2 = [S_2^1] \quad (3.13)$$

Por último, à saída da camada de saída é aplicada a função de ativação que, tradicionalmente é linear, tal como se verifica na estrutura em questão, determinando o resultado final do perceptrão multicamada:

$$y_2 = \text{linear}([S_2^1]) \quad (3.14)$$

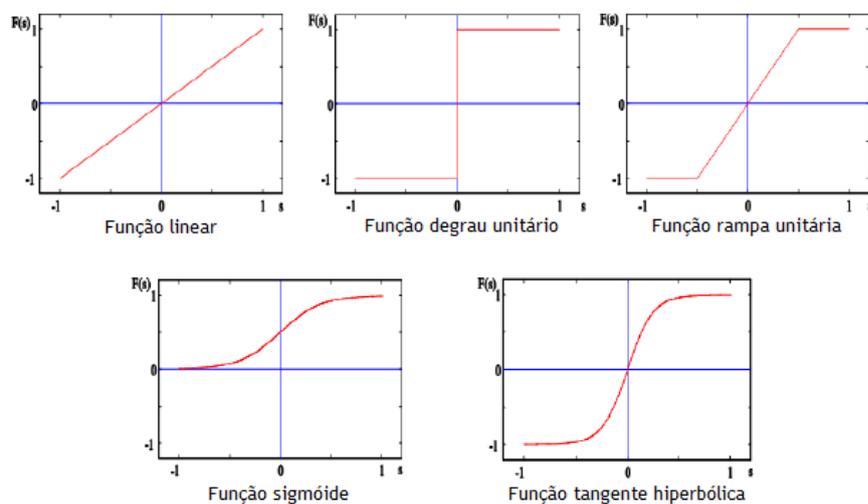


Figura 3.3 - Exemplos de funções de ativação [122].

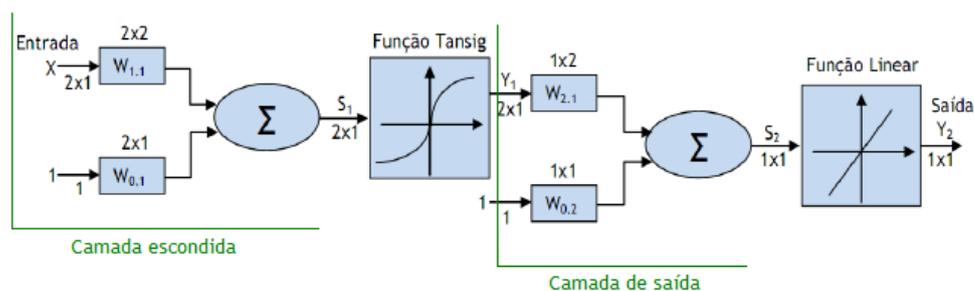


Figura 3.4 - Exemplo de um perceptron multicamada [119].

A aplicação de um número excessivo de neurónios na camada escondida fará com que o sistema crie um *overfitting*, ou afinação excessiva. Tal processo tem como consequência a memorização dos padrões de treino ao invés de se obter as características gerais que permitem a generalização ou o reconhecimento dos padrões não observados durante o treino.

No caso oposto, ou seja, se o número de neurónios na camada escondida for demasiado reduzido, o sistema irá desencadear um *underfitting*, ou afinação deficiente, ou seja, os resultados não serão os desejados, divergindo durante o treino [120]. Torna-se, então, importante a determinação do tamanho mais apropriado das NN, de modo a obter um desempenho satisfatório e uma capacidade adequada de generalização, a qual é imposta pelos fatores:

- Tamanho e eficiência dos dados de treino;
- Arquitetura da rede e número de neurónios a usar na camada escondida;
- Complexidade do problema a resolver.

Assim, o dimensionamento da camada escondida pode ser dado por uma expressão dependente do número de entradas [123].

$$N_{escondidos} = 2 \times N_{entradas} + 1 \quad (3.15)$$

onde:

- $N_{escondidos}$ é o número de neurónios que constituem a camada escondida;
- $N_{entradas}$ é o número de entradas da NN.

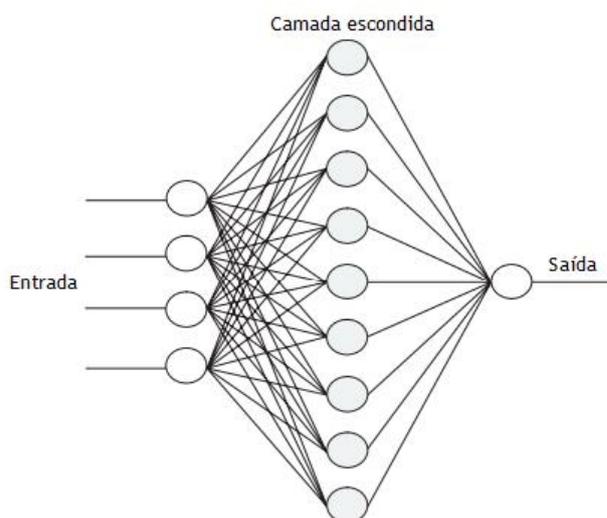


Figura 3.5 - Estrutura genérica de um modelo de uma NN de três camadas [98].

Na Figura 3.5 apresenta-se uma estrutura de uma NN de três camadas [123], onde se representa a entrada, uma camada escondida e um conjunto de saída, sendo outra representação possível de um perceptrão multicamada, desta feita, de modo genérico.

Para a utilização das NN na previsão podem ser empregues diversos algoritmos de aprendizagem com diferentes níveis de complexidade e, conseqüentemente, eficiência da sua execução, sendo que também deve ser considerado o horizonte temporal pretendido para a previsão na escolha do algoritmo mais adequado.

Um algoritmo que se destaca entre os mais utilizados é o algoritmo da retropropagação do erro, o qual é baseado no conceito de que os dados recolhidos pela camada de entrada são propagados até a camada de saída, podendo ser dividido em três pontos fulcrais [120]:

- A saída do sistema, ou seja, o resultado previsto é comparado com o resultado real de modo a avaliar o erro, o qual é retropropagado ao longo das várias camadas;
- Cada unidade da camada escondida recebe apenas uma fração do erro, que é proporcional à contribuição relativa dessa unidade na elaboração da saída real;
- Os pesos e polarizações são atualizados progressivamente de modo a que a soma do quadrado dos erros seja minimizada, a qual pode ser obtida através da utilização do método do gradiente.

Contudo, apesar da simplicidade do algoritmo anteriormente mencionado, esse exige um tempo de computação significativo e não garante a convergência para o mínimo global. Assim, com efeito o método de Levenberg-Marquardt é o mais utilizado, sendo 10 a 100 vezes mais rápido que o algoritmo da retropropagação do erro, garantindo uma melhor convergência de resultados [123]. Este algoritmo é um processo iterativo com o objetivo de minimizar uma função Ω , seguindo a equação de atualização:

$$\Delta y = -[\nabla^2 \Omega(y)]^{-1} \nabla \Omega(y) \quad (3.16)$$

onde:

- $\nabla^2 \Omega$ corresponde à matriz Hessiana, H ;
- $\nabla \Omega$ corresponde ao vetor do gradiente g .

Assumindo que a função Ω determina a soma do quadrado dos erros, tem-se:

$$\Omega(y) = \sum_{k=1}^K e_k^2(y) \quad (3.17)$$

Considerando o vetor dos erros, e_k , então a matriz Jacobiana, J , será:

$$J(y) = \begin{pmatrix} \frac{\partial e_1(y)}{\partial y_1} & \frac{\partial e_1(y)}{\partial y_2} & \dots & \frac{\partial e_1(y)}{\partial y_k} \\ \frac{\partial e_2(y)}{\partial y_1} & \frac{\partial e_2(y)}{\partial y_2} & \dots & \frac{\partial e_2(y)}{\partial y_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_K(y)}{\partial y_1} & \frac{\partial e_K(y)}{\partial y_2} & \dots & \frac{\partial e_K(y)}{\partial y_k} \end{pmatrix} \quad (3.18)$$

Sendo possível obter-se:

$$\nabla \Omega(y) = 2J^T(y)e(y) \quad (3.19)$$

$$\nabla^2 \Omega(y) = 2J^T(y)J(y) + 2S(y) \quad (3.20)$$

Dado que a matriz S é definida por:

$$S(y) = \sum_{k=1}^K e_k(y) \nabla^2 e_k(y) \quad (3.21)$$

Assim, desprezando as segundas derivadas dos erros, isto é, considerando $S \approx 0$, a matriz Hessiana é, desta feita:

$$\nabla^2 \Omega(y) = 2J^T(y)J(y) \quad (3.22)$$

De seguida, substitui-se as equações (3.22) e (3.19) na expressão (3.16), de modo a obter a equação de atualização do método de Gauss-Newton:

$$\Delta y = -[J^T(y)J(y)]^{-1} J^t(y) e(y) \quad (3.23)$$

A vantagem do método de Gauss-Newton comparativamente com o método de Newton reside no facto de serem desprezadas as segundas derivadas do vetor dos erros, as quais podem ser difíceis de determinar. Além disso, o método de Newton não possibilita que a matriz $J^T(y)J(y)$ seja invertível, sendo que tal pode ser ultrapassado através do método de Levenberg-Marquardt, o qual apresenta uma substituição da expressão (3.23) [120]:

$$\Delta y = -[J^T(y)J(y) + \zeta I]^{-1} J^t(y) e(y) \quad (3.24)$$

3.2 - Lógica difusa

A lógica difusa, ou *fuzzy logic* no anglo-saxónico, foi criada por Lotfi Zadeh e apresentada em 1965 como uma metodologia para encontrar um equilíbrio entre a imprecisão e incerteza da informação do dia-a-dia, ou seja, responder aos dados não precisos aos quais a teoria das probabilidades não conseguia dar resposta, fazendo com que o espaço de resposta seja superior comparativamente à lógica binária [124]. A título de exemplo, a lógica difusa determina o quão escuro é um determinado objeto, ao invés de referir apenas que é escuro ou claro, sendo possível quantificar o nível da tonalidade através da atribuição de um conjunto de parâmetros.

A utilização da ferramenta de lógica difusa ocorre na indústria, no controlo de processos complexos de automação, por exemplo, assim como na construção de sistemas híbridos para a previsão. Essa ferramenta é baseada num controlador lógico condicional, o qual funciona de modo a lidar com dados de ordem ordinária que são utilizados na linguagem do quotidiano. O conjunto dos possíveis resultados são interpretados por um aglomerado de termos linguísticos e de regras que determinam o resultado do problema de forma definida, sendo que um dos modos de definir esses termos e regras é através da combinação da lógica difusa com as NN, o que torna num sistema híbrido.

Matematicamente, seja A o universo do discurso do conjunto definido por uma função de pertinência que se encontra no domínio Ω , formada pela função que associa cada elemento x de Ω , ou seja, pelo conjunto $\mu_A: \Omega \rightarrow [0,1]$, no qual cada elemento x de Ω faz a associação ao grau de certeza da função de pertinência $\mu_A(x)$ do conjunto A .

Posto isto, a função de pertinência $\mu_A(x)$ pode ser descrita pelo grau de compatibilidade entre o discurso do universo definido por A e o elemento x seguindo determinadas propriedades e restrições [124], [125]:

- $\mu_A(x) = 1$, então x é totalmente compatível com A ;
- $0 < \mu_A(x) < 1$, o sistema é parcialmente compatível com A com grau de pertinência definido $\mu_A(x)$;
- $\mu_A(x) = 0$, então x não é compatível com A ;
- $CD_\Omega \rightarrow [0,1]$, é o contradomínio da função;
- Cada valor de $x \in A$ deve corresponder unicamente a um valor da função de pertinência $\mu_A(x)$.

A lógica binária apresenta uma função de compatibilidade com uma diferença notável em comparação com a lógica difusa [125]:

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{caso contrário} \end{cases} \quad (3.25)$$

Posto isto, estão reunidas as condições necessárias para definir o domínio de operação do conjunto difuso, isto é, domínio contínuo ou discreto. Assim, é importante realçar que a notação desses domínios é diferente, sendo que os operadores de somatório e integral não devem ser interpretados como operadores algébricos, mas sim como a distinção do domínio em estudo [125]:

- Domínio contínuo:

$$A = \int_{\Omega} \frac{\mu_A(x)}{x} \quad (3.26)$$

- Domínio discreto:

$$A = \sum_{i=1}^n \frac{\mu_A(x_i)}{x_i} \quad (3.27)$$

Além disso, o tratamento e interpretação entre conjuntos, isto é, dado um conjunto A e um conjunto B pertencentes um universo Ω , tais conjuntos difusos necessitam de ter em consideração o seguinte [124], [125]:

- É obrigatório estarem contidos e sujeitos à condição $A, B \in \Omega$.
- São iguais entre si, só e só se é satisfeita a condição:

$$\mu_A(x) = \mu_B(x), \quad \forall x \in \Omega \quad (3.28)$$

- A é um sub-conjunto de B , só e só se:

$$\mu_A(x) \leq \mu_B(x), \quad \forall x \in \Omega \quad (3.29)$$

- Sendo que tal representa a pertença de subconjuntos difusos, podendo igualmente ser descrito por: $A \subseteq B$.
- \bar{A} diz-se complemento de A quando:

$$\forall x \in \Omega, \mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (3.30)$$

- A e B são intersetados quando:

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\}, \quad \forall x \in \Omega \quad (3.31)$$

- A e B são unidos quando:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\}, \quad \forall x \in \Omega \quad (3.32)$$

Algumas das principais propriedades da lógica difusa são [125]:

- Normalização - um conjunto A é normalizado quando contém um elemento com grau de pertença igual a 1:

$$\exists x \in \Omega: \mu_A(x) = 1 \rightarrow \text{Normalização}(A) = \frac{\mu_A(x)}{\text{Altura}(x)} \quad (3.33)$$

- Altura - definida pelo supremo da função de pertença de A :

$$\text{Altura}(A) = \sup \mu_A(x), \quad x \in \Omega \quad (3.34)$$

- Suporte - verifica-se quando o conjunto da função de pertença de A é maior que zero:

$$\text{Suporte}(A) = \{x \in \Omega: \mu_A(x) > 0\} \quad (3.35)$$

- Núcleo - representado por todos os elementos do domínio Ω que pertençam ao conjunto A , cujo grau de pertença seja unitário:

$$\text{Núcleo}(A) = \{x \in \Omega: \mu_A(x) = 1\} \quad (3.36)$$

- Corte- α - conjunto de elementos de A cuja função de pertença é maior ou igual a $\alpha \in [0,1]$:

$$\text{corte} - \alpha(A) = \{x \in \Omega: \mu_A(x) \geq \alpha\} \quad (3.37)$$

- Unimodal - conjunto A em que a sua função de pertença possui apenas um máximo.

No entanto, importa destacar que, dados três conjuntos difusos A , B e C , estes podem apresentar outras propriedades de relação entre eles [125]:

- Comutatividade: $A \cap B = B \cap A$ e $A \cup B = B \cup A$;
- Associatividade: $A \cap (B \cap C) = C \cap (A \cap B)$ e $A \cup (B \cup C) = C \cup (B \cup A)$;
- Distributividade: $A \cap (B \cup C) = (A \cap B) \cup (A \cap C)$ e $A \cup (B \cap C) = (A \cup B) \cap (A \cup C)$;
- Transitoriedade: $A \subseteq B, B \subseteq C \rightarrow A \subseteq C$;
- Idempotência: $A \cup A = A$.

Na prática, a aplicação da lógica difusa corresponde a um conjunto de regras, do tipo “se-então” o qual apenas é válido caso as condições impostas também sejam válidas. No entanto, a questão será determinar o melhor resultado de um aglomerado de resultados obtidos através da condição em questão. Assim, é necessário utilizar uma metodologia que possibilite determinar a regra ou conjunto de regras a aplicar de modo a determinar a melhor solução do problema. Os problemas são expressos em funções de pertinência e a ação é determinada pela inferência difusa, consoante os dados disponíveis, sendo o programador, tradicionalmente, o responsável pela definição das regras [125].

3.3 - Sistema de inferência neuro-difuso adaptativo

O sistema de inferência neuro-difuso adaptativo (ANFIS) é uma metodologia híbrida, visto que combina as NN com algoritmos difusos, apresentados anteriormente. Essa combinação é possível devido aos baixos requisitos computacionais de ambas arquiteturas quando bem estruturadas, as quais podem ser úteis para lidar com uma grande quantidade de dados, aliadas com a boa resposta do algoritmo difuso. A capacidade de autoaprendizagem das NN é combinada com o algoritmo difuso para autorregular os seus parâmetros, sendo particularmente interessante para aplicações industriais devido [42], [126]:

- Facilidade de aplicação de algoritmos de aprendizagem provenientes de técnicas desenvolvidas de NN;
- Integração e promoção do conhecimento implícito e explícito da lógica difusa;
- Possibilidade de extração de conhecimento em regras, a partir de conjuntos de dados suportados pela lógica difusa.

De um modo geral, um sistema difuso é composto por quatro componentes: fuzificador, regras, máquina de inferência e desfuzificador. O fuzificador é responsável por converter uma variável de entrada de valor numérico numa representação difusa, onde funções de pertinência atribuem o grau de pertinência da variável relativamente a um determinado atributo. As regras, do tipo “se-então”, podem ser derivadas de dados numéricos ou da linguística inteligente.

A máquina de inferência, no caso em estudo, relaciona as entradas difusas com o conjunto de saídas. Por último, o desfuzificador interpreta o conjunto com linguagem difusa e converte o resultado num valor [45]. Na Figura 3.6 é apresentado um exemplo genérico de uma máquina difusa baseada em regras, tal como acima descrito.

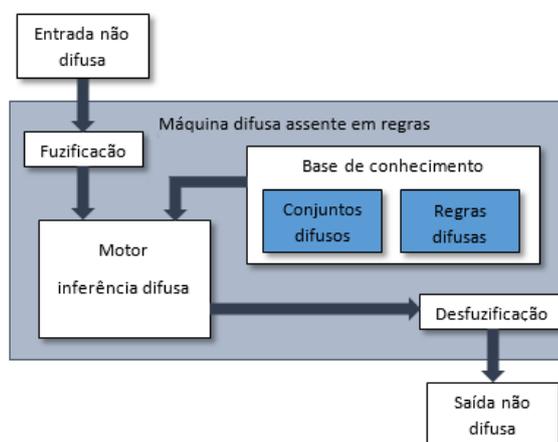


Figura 3.6 - Arquitetura de uma máquina difusa assente em regras [122].

Assim, da Figura 3.6 importa realçar [127]:

- O espaço difuso de entrada é constituído pelos antecedentes das regras difusas;
- A fuzificação é responsável pela representação difusa dos dados de entradas escalares, aplicando valores da função de pertença associados aos conjuntos difusos;
- O motor de inferência difusa processa os dados recebidos após a fuzificação com as regras difusas, determinando os resultados à saída de cada uma das regras difusas.
- A desfuzificação é responsável pela representação não difusa dos dados de saídas escalares, aplicando valores associados às regras difusas impostas pelos conjuntos difusos. O espaço difuso de saída constituída pelos consequentes das mesmas regras. A desfuzificação pode ser processada utilizando várias metodologias, destacando-se [128]:
 - Método bissetor da área - determina o valor que define a área da função de pertença em duas regiões de áreas iguais.
 - Método do primeiro máximo - determina o valor correspondente ao primeiro máximo da função de pertença.
 - Método da média dos máximos (MM) - define o valor médio de todos os máximos atingidos pela função de pertença:

$$MM = \sum_{i=1}^m \frac{x_i}{m} \quad (3.38)$$

- Método da centróide (MC) - dado pela área abaixo da função de pertença cuja abcissa da centróide é definida pela saída do controlador:

$$MC = \begin{cases} \frac{\sum_x \mu_A(x) \cdot x}{\sum_x \mu_A(x)}, & \text{se } x \text{ é discreto} \\ \frac{\int_x \mu_A(x) \cdot x \, dx}{\int_x \mu_A(x) \, dx}, & \text{se } x \text{ é contínuo} \end{cases} \quad (3.39)$$

Na Figura 3.7 são apresentadas as funções de pertença, tradicionalmente, utilizadas na resolução de problemas recorrendo a lógica difusa, sendo que, em [129] provou-se que as triangulares demonstram uma boa eficiência computacional, contudo, dependem de onde a mesma é aplicada.

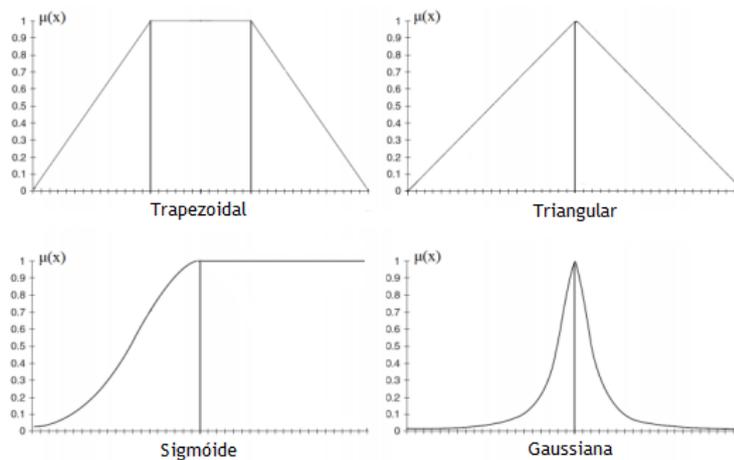


Figura 3.7 - Algumas das funções de pertença mais utilizadas [130].

Neste trabalho, a arquitetura ANFIS foi desenhada contendo o processo de fuzificação, regras, dados de normalização, desfuzificação e reconstrução do sinal pelas respectivas cinco camadas, a qual é designada na comunidade científica por rede multicamada *feed-forward*, apresentada de um modo geral na Figura 3.8 [131]. O utilizador deve permitir que o sistema opere em modo de autoaprendizagem, de modo a que as regras que moldam a solução do problema sejam definidas dinamicamente e, como tal, as regras de inferência sejam atualizadas visando obter assim melhores resultados. As cinco camadas presentes na Figura 3.8 têm um propósito específico [45]:

- Camada 1 - todos os nós i são adaptativos com função nó L_{1i} :

$$L1_i = \mu A_i(x), \quad i = 1,2 \quad (3.39)$$

Ou

$$L1_i = \mu B_{i-2}(y), \quad i = 3,4 \quad (3.40)$$

onde x ou y é a entrada do nó i_m e A_i ou B_{i-2} é um rótulo linguístico associado a esse nó. As funções de pertença em A ou B são definidas como triangulares no caso em estudo, as quais são funções contínuas e diferenciáveis por partes:

$$\mu A_i(x) = \frac{1}{1 + \left| \frac{x - r_i}{p_i} \right|^{2q_i}} \quad (3.41)$$

onde $\{p_i, q_i, r_i\}$ são parâmetros que determinam a função triangular.

- Camada 2 - todos os nós de saída representam a força de disparo da regra w_i , em que cada nó é representado por Π , ou seja, a saída é o produto de todos os sinais de entrada:

$$L2_i = w_i = \mu A_i(x) \mu B_i(y), \quad i = 1,2 \quad (3.42)$$

- Camada 3 - cada nó N calcula a proporção da força das regras de disparo i_m com a soma de todas as regras de força de disparo:

$$L3_i = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2 \quad (3.43)$$

- Camada 4 - todos os nós calculam a contribuição da regra i_m para a saída global:

$$L4_i = \bar{w}_i z_i = \bar{w}_i (a_i x + b_i y + c_i), \quad i = 1,2 \quad (3.44)$$

onde \bar{w}_i é a saída da camada 3 e $\{a_i, b_i, c_i\}$ são os parâmetros consequentes.

- Camada 5 - nó de saída da ferramenta ANFIS, onde o somatório Σ é realizado:

$$L5_i = \sum_i \bar{w}_i z_i = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (3.45)$$

Além do que foi referido, a máquina de inferência difusa utilizada neste trabalho baseia-se no algoritmo proposto por Takagi-Sugeno, o qual apresenta um resultado da saída determinístico, ou seja, resulta num número interpretável, empregando a regra dos mínimos quadrados e o método da descida do gradiente em *back-propagation* [70], [107], [132].

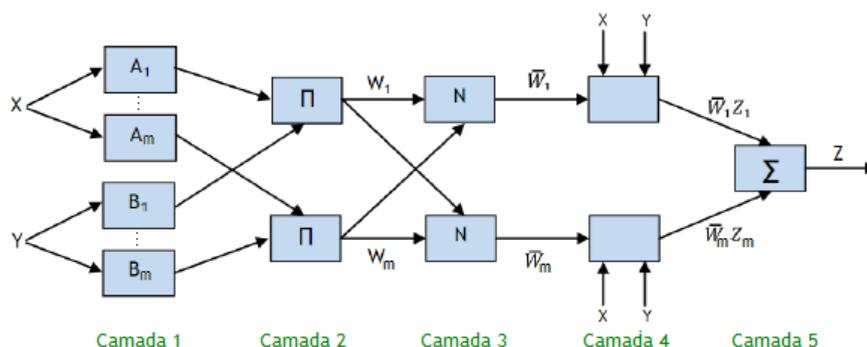


Figura 3.8 - Arquitetura generalizada de um ANFIS de 5 camadas [45].

3.4 - Otimização por enxame de partículas

A otimização por enxame de partículas (PSO) foi uma ferramenta desenvolvida por James Kennedy e Russell Eberhart em 1995 para a resolução de problemas de otimização com variáveis contínuas, sendo inspirada no comportamento e dinâmica das sociedades de alguns animais, peixes e alguns insetos que trabalham em equipa, apresentando capacidade de partilha de informação. Considerando tais sociedades de animais como partículas, as quais se movem aleatoriamente num espaço de pesquisa, é possível iniciar o sistema com uma população de soluções aleatórias de modo a procurar as soluções ótimas através da atualização das novas gerações. Para o efeito, o processo decorre mediante a partilha de informação entre o enxame, no qual a memória, a inércia e a cooperação entre as partículas determinam a solução ótima do problema.

O PSO é então uma técnica de otimização computacional inteligente não influenciável pelo tamanho ou não linearidade do problema, conseguindo convergir para uma solução ótima. As possíveis soluções das partículas do enxame percorrem o espaço do problema seguindo a melhor partícula atual [106]. Comparativamente com os algoritmos genéticos, o PSO apresenta as seguintes virtudes [133]:

- Vantagens:
 - É indiferente à mudança de escala das variáveis;
 - É de fácil implementação, uma vez que apresenta poucos parâmetros definidos e ajustados pelo utilizador;
 - Não requer cálculos de derivadas;
 - É adequado para encontrar mínimos globais.
- Desvantagem:
 - É inflexível no ajuste fino de parâmetros.

Considerando um espaço de dimensão D , cada partícula i apresenta-se como uma possível solução ótima de um determinado problema [133]:

- Vetor de posição:

$$X_i = [x_{i1}, x_{i2}, \dots, x_{iD}] \quad (3.46)$$

- Vetor de velocidade:

$$V_i = [v_{i1}, v_{i2}, \dots, v_{iD}] \quad (3.47)$$

- Vetor que contém a melhor posição ocupada pela partícula até ao momento:

$$b_i = [b_{i1}, b_{i2}, \dots, b_{iD}] \quad (3.48)$$

- Vetor de salvaguarda da melhor posição ocupada pelo conjunto total de partículas:

$$b_G = [b_{g1}, b_{g2}, \dots, b_{gD}] \quad (3.49)$$

- Assim, quando uma partícula se desloca no hiperespaço, a sua velocidade, V_i , e posição, X_i , determinam-se do seguinte modo:

$$V_i^{novo} = Dec(t)W_{i0}V_i + rand_1W_{i1}(b_i - X_i) + rand_2W_{i2}(b_G - X_i) \quad (3.50)$$

$$X_i^{novo} = X_i + V_i^{novo} \quad (3.51)$$

Da expressão (3.50), realçam-se alguns aspetos [134]:

- O parâmetro $Dec(t)$ é uma função temporal decrescente, sendo responsável pela redução progressiva do peso inercial;
- O termo W_{i0} possui um valor inicial não superior a 1,4 o qual vai diminuindo a medida que a inércia também vai diminuindo;
- Os termos $rand_1$ e $rand_2$ são valores aleatórios compreendidos entre 0 e 1;
- Os termos W_{i1} e W_{i2} são constantes de valor positivo igual ou menor que 2;
- O termo $Dec(t)W_{i0}V_i$ representa a inércia da partícula em seguir o movimento anteriormente descrito;
- O termo $rand_1W_{i1}(b_i - X_i)$ ilustra a memória da partícula que a atrai para o melhor ponto encontrado durante a trajetória que essa segue;
- O termo $rand_2W_{i2}(b_G - X_i)$ retrata a cooperação, conduzindo o conjunto de partículas para o melhor ponto então encontrado pelo enxame em si.

Por sua vez, da expressão (3.51) permite que a nova posição da partícula resulte da adição da nova velocidade adquirida com a sua posição anteriormente adotada, sendo representada vetorialmente na Figura 3.9, na qual se ilustra a influência da inércia, da memória e da cooperação na definição do caminho e a nova posição da partícula.

A técnica PSO utiliza o conceito de aptidão, sendo o ajuste da velocidade através da informação partilhada de outras posições comparável com o sucedido nos algoritmos genéticos, ocorrendo, desse modo, o processo de mutação, uma vez que os elementos da memória e cooperação são modificados em cada iteração [133]. Na Figura 3.10 é ilustrado o algoritmo representativo mais utilizado do PSO.

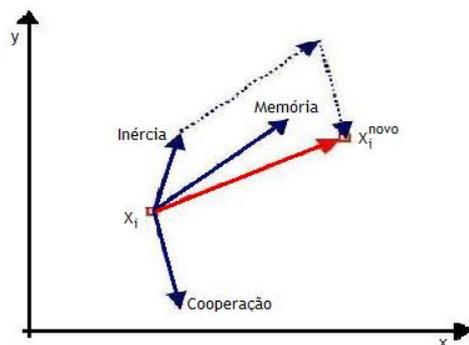


Figura 3.9 - Regra do movimento de partículas em PSO. [134].

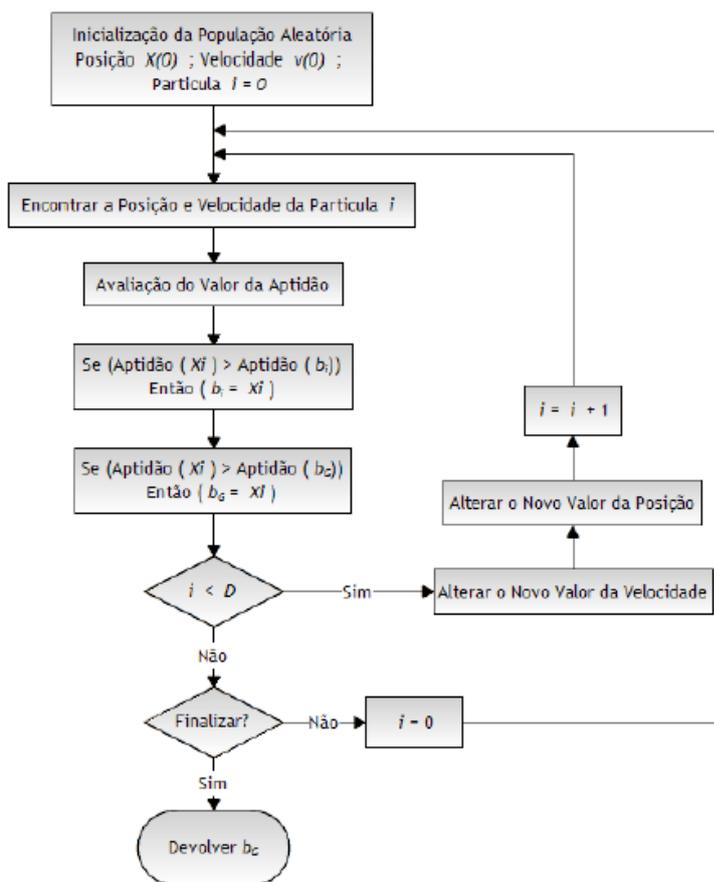


Figura 3.10 - Fluxograma do algoritmo PSO [122].

Da Figura 3.10 importa explicitar alguns detalhes relativamente aos diversos passos:

1. Iniciar o enxame considerando uma posição aleatória do espaço do problema para cada partícula;
2. Avaliar a aptidão de cada partícula;
3. Em cada partícula deve ser comparado o valor de aptidão da posição atual, X_i , com o valor de aptidão de melhor posição, b_i , que, caso seja superior ao valor da posição atual, então deve substituir o mesmo;
4. Identificar o melhor valor de aptidão de cada partícula, o qual a sua função é identificada como b_g ;
5. Atualizar os valores de velocidade e posição de cada partícula;

6. Repetem-se os passos 2 a 5 enquanto a condição de paragem não for atingida, isto é, atingir o número de iterações ou o melhor valor ser encontrado.

No decorrer do trabalho realizado verificou-se ainda que as constantes W_{i1} e W_{i2} deverão ser valor constante igual a 2 e a atualização da constante inicial de inércia W_{i0} [132] é atualizada utilizando:

$$W_{i0} = w_{max} - \frac{w_{max} - w_{min}}{Itr_{max}} Itr \quad (3.52)$$

onde $w_{m\acute{a}x}$ e $w_{m\acute{i}n}$ são os pesos máximo e mínimos iniciais da inércia, respetivamente, $Itr_{m\acute{a}x}$ é o número máximo de iterações e Itr corresponde à iteração em curso.

3.5 - Otimização por enxame de partículas evolucionário

A ferramenta da variante meta-heurística designada por otimização por enxame de partículas evolucionário, (EPSO), é um algoritmo cujas regras e conceitos de otimização estão contidos em estratégias evolucionárias e propriedades de auto-adaptação [135], sendo usual apelidar de “geração” os dados com soluções alternativas e “indivíduos” os dados das partículas. Cada partícula é descrita por um parâmetro do objeto (o valor das variáveis que descrevem a solução) e por parâmetros estratégicos (os coeficientes de mutação de cada variável, ângulo de correlação das variáveis de mutação ou semelhantes) [136]. Do algoritmo EPSO, destaca-se [137]:

- Cada partícula é replicada;
- O parâmetro estratégico de cada partícula é transformado por um processo evolucionário;
- O parâmetro do objeto de cada partícula se modifica numa nova partícula gerada por parâmetros estratégicos, novamente, através de um processo evolucionário;
- As partículas mudadas novas geram, por sua vez, novas partículas;
- Num universo constituído por partículas ancestrais e partículas descendentes, o melhor ajuste deverá conduzir à geração de uma nova população de partículas. As partículas mais fortes sobreviverão no processo evolucionário ajudando a fornecer o resultado ótimo.

O processo de seleção tem uma série de variantes, podendo ser controlado por um processo estocástico, puramente determinístico, envolvendo elitismo, entre outros [136]. A formulação do EPSO é composta por parâmetros objeto que representam a posição, X , e por parâmetros estratégicos correspondentes aos pesos, w . Numa determinada iteração, uma partícula é a série do objeto e do parâmetro estratégico $\{X, W\}$, cujo esquema é [137] ,[138]:

- Multiplicação - cada partícula é multiplicada r vezes;
- Mutação - cada partícula contém um peso, w , mutado;
- Reprodução - cada partícula gera um conjunto de partículas de acordo com a regra do movimento da partícula (RMP);
- Avaliação - cada conjunto de partículas é avaliado pelo seu peso, w ;
- Seleção - através de processos estocásticos, nos quais a melhor partícula sobrevive para criar um novo conjunto.

Assim, a regra do movimento do algoritmo EPSO apresenta-se como [139]:

$$X_i^{novo} = X_i + V_i^{novo} \quad (3.53)$$

$$V_i^{novo} = w_{i0}^* V_i + w_{i1}^* (b_i - X_i) + w_{i2}^* (b_g^* - X_i) \quad (3.54)$$

Como se pode observar, as expressões (3.53) e (3.54) são semelhantes às do algoritmo PSO, apresentado na seção anterior, onde a regra do movimento mantém as condições de inércia, de memória e de cooperação, tal como apresentado na Figura 3.11. No entanto, a diferença está relacionada com os pesos w_{ik}^* , os quais sofrem mutação:

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (3.55)$$

onde $N(0,1)$ é uma variável aleatória Gaussiana de média 0 e variância 1 e o melhor valor global, b_g^* , é definido por:

$$b_g^* = b_g + \tau' N(0,1) \quad (3.56)$$

A lógica subjacente a esta modificação prende-se com o seguinte: caso o melhor global seja o ótimo global, é irrelevante para as expressões (3.53) e (3.54), no entanto, caso o ótimo ainda não tenha sido encontrado, mas possa estar na vizinhança, não se aponta o atual exatamente como melhor global, especialmente quando a procura é focada numa determinada região.

O parâmetro de aprendizagem, τ , e o parâmetro de aprendizagem mutado, τ' , encontram-se a aprender parâmetros, fixos ou tratados também dos parâmetros estratégicos, como tal, sofrem mutação. O EPSO apresenta, de um modo geral, melhores características de convergência do que o PSO devido ao facto de beneficiar do processo da seleção evolutiva natural onde os elementos mais fortes e com melhores capacidades de adaptação no meio que os rodeia sobrevivem [135].

Assim, comparativamente ao PSO anteriormente apresentado, os conceitos evolucionários que sustentam o EPSO podem fazer uma diferença real em termos de propriedades de convergência, sendo auto-adaptativo, mais robusto e menos sensível à inicialização de parâmetros.

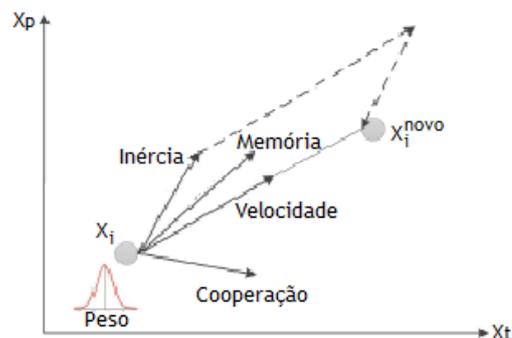


Figura 3.11 - Regra do movimento de partículas no EPSO [8].

3.6 - Otimização diferencial evolutiva por enxame de partículas

O algoritmo de otimização diferencial evolutiva por enxame de partículas (DEEPSO) é uma combinação híbrida de sucesso a partir do modelo EPSO. No algoritmo DEEPSO os pesos possuem características auto-adaptativas que são combinadas com programação evolucionária, originando operadores auto-adaptativos [139], com um algoritmo evolucionário e diferencial, o qual fornece uma nova solução da partícula atual do enxame através da adição de uma diferença de fração entre dois outros pontos experimentados do enxame avaliado [140]. Assim, a formulação do algoritmo DEEPSO é semelhante à do EPSO na sua sequência de desenvolvimento [141], no entanto, a regra do movimento das suas partículas é diferente:

$$V_i^{novo} = w_{i0}^* V_i + w_{i1}^* (X_{r1}^i - X_{r2}^i) + P w_{i2}^* (b_g^* - X_i) \quad (3.57)$$

Por sua vez, os pesos, w_{ik}^* , sofrem mutação de igual modo ao apresentado anteriormente para o EPSO (expressão (3.55)). No entanto, a posição global, b_g^* , fornecida pelo novo peso w_g recolhida a partir de uma matriz diagonal determina-se de modo diferente:

$$b_g^* = b_g (1 + w_g N(0,1)) \quad (3.58)$$

Da expressão (3.57) os elementos X_{r1}^i devem ser qualquer par de partículas diferentes já testadas que, no caso de ser pretendida uma minimização, devem ser ordenadas da seguinte forma:

$$f(X_{r1}^i) < f(X_{r2}^i) \quad (3.59)$$

Os elementos X_{r1}^i e X_{r2}^i garantem que uma tração apropriada é realizada, considerando pontos macro-gradientes numa direção descendente, dependendo da comparação estruturada da expressão (3.57). Neste sentido, a componente X_{r2}^i é assumida como $X_{r2}^i = X_i$ e o componente X_{r1}^i é amostrado a partir do conjunto dos melhores antepassados do enxame de n partículas, ou seja, $S_{bA} = \{b_1, b_2, \dots, b_n\}$, como é descrito em [141]. Além disso, relativamente aos métodos anteriormente descritos, nomeadamente o PSO e o EPSO, o DEEPSO possui um fator de comunicação P , o qual é uma matriz binária diagonal em que os seus elementos têm valor 1 caso a probabilidade seja p e 0 caso seja $(1 - p)$. A ideia universal por trás do movimento DEEPSO é ilustrada na Figura 3.12.

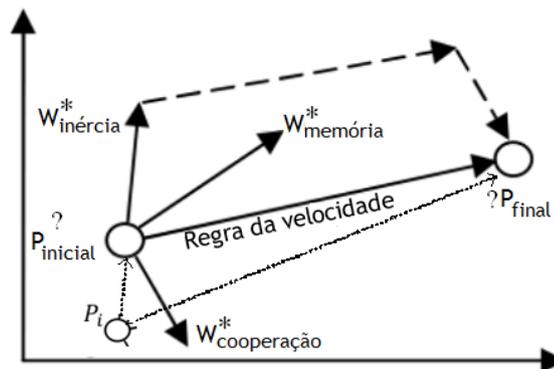


Figura 3.12 - Regra do movimento das partículas no DEEPSO [141].

3.7 - Transformada de *wavelet*

Hoje em dia, a aplicação da técnica da transformada de *wavelet* (WT) em ferramentas de previsão é de extrema importância devido à necessidade de superar as limitações de séries temporais não-estacionárias, tais como os preços de eletricidade no mercado ou potência eólica. A WT é um método matemático aplicado em diferentes campos da engenharia, o que permite a realização de uma análise de séries temporais no seu estado natural. Desta forma, a WT é utilizada, normalmente, no pré-processamento para compreensão dos dados não-estacionários ou de tempo variado, possuindo sensibilidade para as irregularidades dos dados de entrada [142], ou seja, é capaz de mostrar os diferentes aspectos que constituem os dados sem perder o conteúdo do sinal real [143].

A WT possui a capacidade de reduzir o ruído dos dados de entrada sem degradação visível dos mesmos, efeito de suavização. É importante realçar que os dados de séries temporais associados com variáveis aleatórias consistem em observações ordenadas em tempo e registadas no mesmo período com igual passo de tempo. Os dados de séries temporais são estacionários quando a média e a variância são constantes e, muitas vezes, são considerados, hipoteticamente, para impor estacionaridade em dados de séries temporais para a sua análise, ou seja, a série temporal desenvolve aleatoriedade ao longo do tempo em torno de uma média constante, refletindo um comportamento estável [144].

O processamento analítico que permite a representação das séries temporais no domínio da frequência e tempo é atingido através de WT contínua (CWT) e WT discreta (DWT). O CWT_{ab} do sinal associado $p(t_{wt})$ de uma função *wavelet*-mãe ψ_{ab} é definido [143]:

$$CWT_{ab} = \int_{-\infty}^{+\infty} p(t_{wt})\psi_{ab}(t_{wt}) dt_{wt} \quad (3.60)$$

onde o parâmetro escalar a é responsável pelo controlo da propagação da WT e o parâmetro de translação b determina a posição da janela, uma vez que se move pelos dados. A *wavelet*-mãe, $\psi_{ab}(t_{wt})$, é calculada usando a função $w(t_{wt})$:

$$\psi_{ab}(t_{wt}) = \frac{1}{\sqrt{a_{wt}}} w\left(\frac{t_{wt} - b_{wt}}{a_{wt}}\right) \quad (3.61)$$

Desta forma, a função CWT é por substituição da expressão (3.61) na expressão (3.62):

$$CWT_{ab} = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} p(t_{wt}) w\left(\frac{t_{wt} - b_{wt}}{a}\right) dt_{wt} \quad (3.62)$$

No entanto, visto que a CWT é determinada no domínio temporal e multiplicada por uma função WT escalonada e deslocada, $\psi_{ab}(t_{wt})$, o processo origina um número de séries de coeficiente de WT escalonados em frequência e tempo [145], o que na prática não é útil, uma vez que requer um elevado número de escalas e traduções que consomem uma grande capacidade computacional [143].

Para superar o anterior problema e resolver problemas no domínio discreto as DWT proporcionam, de forma eficiente, a descrição relativamente à CWT para decompor a série temporal em estudo, a qual é apresentada de seguida.

$$DWT(m_{wt}, n_{wt}) = 2^{-(m_{wt}/2)} \sum_{t=0}^H p(t_{wt}) \varphi\left(\frac{t_{wt} - n_{wt} 2^{m_{wt}}}{2^{m_{wt}}}\right) \quad (3.63)$$

onde H representa o comprimento $p(t_{wt})$ e os parâmetros de escala e de tradução são alterados para variáveis inteiras: $a_{wt} = 2^{m_{wt}}$ e $b_{wt} = n_{wt} 2^{m_{wt}}$, respetivamente, com um passo de tempo t_{wt} .

Um modo eficiente de utilizar a DWT é através de uma análise multi-resolução desenvolvida por Mallat, recorrendo a uma *wavelet*-pai com uma *wavelet*-mãe complementar, onde a primeira determina os componentes das séries de baixa frequência, enquanto a segunda estabelece os elementos das séries de alta frequência [146]. Além disso, neste trabalho e seguindo a descrição referida em [45], [106] os Daubechies de quarta ordem, *db4*, foram considerados na função *wavelet*-mãe. Essa escolha deve-se ao facto de que as *db4* dispõem de propriedades assimétricas e contínuas, onde a um nível de ordem superior irá criar uma oscilação de nível superior, o que é desejável na previsão [143], [146]. Para o efeito, os coeficientes de aproximação, A_n , e detalhe D_n , são:

$$A_n = \sum_n DWT(m_{wt}, n_{wt}) \varphi_{mn}(t) \quad (3.64)$$

$$D_n = \sum_n DWT(m_{wt}, n_{wt}) \psi_{mn}(t) \quad (3.65)$$

onde $\varphi_{mn}(t_{wt})$ é a *wavelet*-pai, $\psi_{mn}(t_{wt})$ é a *wavelet*-mãe e $DWT(m_{wt}, n_{wt})$ são os coeficientes obtidos a partir da expressão (3.63) [144].

Além disso, o algoritmo DWT utilizado neste trabalho é baseado em quatro filtros divididos em dois grupos: a decomposição em filtros passa-baixo e passa-alto e a reconstrução em filtros passa-baixo e passa-alto. As aproximações e detalhes dos conjuntos originais podem ser obtidas com recurso ao algoritmo de Mallat, tal como referido em [143] ou em [106]. A Figura 3.13 apresenta um modelo generalizado da decomposição de três níveis das WT.

De um modo geral, as aproximações são capazes de reter a informação global dos conjuntos originais, isto é, a representação das componentes de baixa frequência e a descrição das componentes de alta frequência. Os detalhes são capazes de explicar a diferença entre as aproximações sucessivas. A partir da Figura 3.13 é possível observar que o conjunto original é decomposto em duas subséries: A_n e D_n , designadas de subséries de aproximação e de detalhe, respetivamente. A partir deste ponto, A_n é decomposta, novamente, num segundo nível e repetida num terceiro nível. Esse procedimento dará origem as duas subséries anteriormente referidas: uma de aproximação (A_1, A_2 e A_3); outra de detalhe: (D_1, D_2 e D_3).

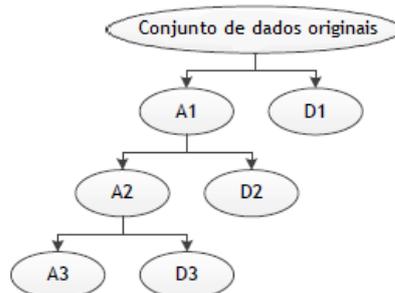


Figura 3.13 - Modelo generalizado da decomposição WT em três níveis [8].

Capítulo 4

Metodologia híbrida proposta

Nesta secção, apresenta-se a metodologia híbrida desenvolvida, a qual combina três técnicas, nomeadamente, as WT, o DEEPSO e o ANFIS, sendo denominada por HWDA, a qual foi aplicada na previsão dos preços de eletricidade no mercado e da potência eólica para um horizonte temporal a curto prazo. Além disso, estabelece-se uma comparação pormenorizada com outras metodologias publicadas previamente na literatura científica da especialidade, de modo a demonstrar a proficiência da metodologia proposta na previsão com comprovada redução da carga computacional e ensaiada considerando casos de estudo reais.

4.1 - Descrição

Como anteriormente referido, a metodologia HWDA é aplicada para a previsão dos preços de eletricidade no mercado e da potência eólica a curto prazo. A WT é empregue para decompor os conjuntos de séries de dados em novos conjuntos com um comportamento melhor (devido ao efeito de suavização inerente). Os valores desses novos conjuntos são utilizados para a previsão dos preços de eletricidade no mercado ou da potência eólica através do ANFIS.

O DEEPSO permite aumentar o desempenho do ANFIS através do ajuste das suas funções de pertinência de modo a reduzir o erro de previsão. Comparativamente ao EPSO, o conceito de evolução diferencial por detrás do DEEPSO pode fazer a diferença em termos de propriedades de convergência, sendo mais robusto e complementando-se com o ANFIS devido às características adaptativas. Por fim, a inversa da WT é utilizada para reconstruir o sinal, obtendo-se assim, os resultados finais de previsão dos preços de eletricidade no mercado ou da potência eólica. Assim, a estrutura da metodologia HWDA pode ser descrita através de um fluxograma detalhado e ilustrado na Figura 4.1, onde se pode descrever os seguintes passos:

- Passo 1 - Iniciar o método HWDA com uma matriz de dados históricos de preços de eletricidade no mercado ou da potência eólica, considerando a escala de tempo respeitante a cada tipo de previsão;
- Passo 2 - Considerar um determinado conjunto de dados da matriz do passo anterior são entradas da WT (tarefa realizada por tentativa em erro);
- Passo 3 - O resultado obtido do Passo 2 irão ser os dados de entrada da rede ANFIS;
- Passo 4 - Otimizar os parâmetros das funções de pertinência do ANFIS recorrendo ao DEEPSO. A Tabela 4.1 apresenta os parâmetros considerados para o ANFIS e para o DEEPSO;

As regras de inferência do ANFIS são determinadas automaticamente pela ferramenta, permitindo alcançar o melhor desempenho, não sendo possível de outra forma, devido à natureza dos dados, os quais requerem um grande número de regras de inferência;

- Passo 5 - Enquanto não são atingidos os resultados melhores ou a convergência da previsão:
 - Passo 5.1 - No caso da previsão dos preços de eletricidade no mercado, repete-se o Passo 4;
 - Passo 5.2 - No caso da previsão da potência eólica, regressa-se ao Passo 2, refrescando os dados históricos. Quando são atingidos os melhores resultados ou a convergência, os dados de potência eólica estão, finalmente, previstos para as próximas 3 horas até que se completem as 24 horas totais de previsão desejada;
- Passo 6 - Aplicar a inversa da WT aos resultados obtidos do Passo 5, obtendo-se os resultados finais de previsão dos preços de eletricidade no mercado ou da potência eólica;
- Passo 7 - Determinar os erros da previsão realizada com diferentes critérios, os quais permitirão validar a ferramenta HWDA.

Inicialmente foi desenvolvida uma metodologia híbrida combinando apenas as metodologias DEEPSO e ANFIS, a qual foi atribuída a sigla HPM e que seguiu os passos anteriormente citados. No entanto, uma vez que ainda não foi incluída a WT, os passos 2 e 6 não foram executados. Os resultados obtidos através dessa metodologia serão posteriormente apresentados junto com os da metodologia HWDA, para efeitos comparativos das valências da utilização das WT na metodologia de previsão proposta.

Tabela 4.1 - Parâmetros do DEEPSO e do ANFIS utilizados.

	Parâmetros	Tipo ou tamanho
DEEPSO	Probabilidade de comunicação	0,10
	Peso de inércia final	0,01 - 0,15
	Peso de inércia inicial	0,50 - 0,90
	Tamanho da população inicial	100
	Velocidade inicial	0,50 - 2,00
	Processo de aprendizagem inicial	1,00 - 2,00
	Processo de partilha	2,00
	Parâmetro de aprendizagem	1
	Valor máximo da nova posição	Vetor dos valores máximos de entrada de dados
	Valor mínimo da nova posição	Vetor dos valores mínimos de entrada de dados
	Iterações necessárias	100 - 1000
ANFIS	Número de funções de pertinência	2 - 15
	Número de estágios	2 - 50
	Tipo de função de pertinência	Triangular ou trapezoidal

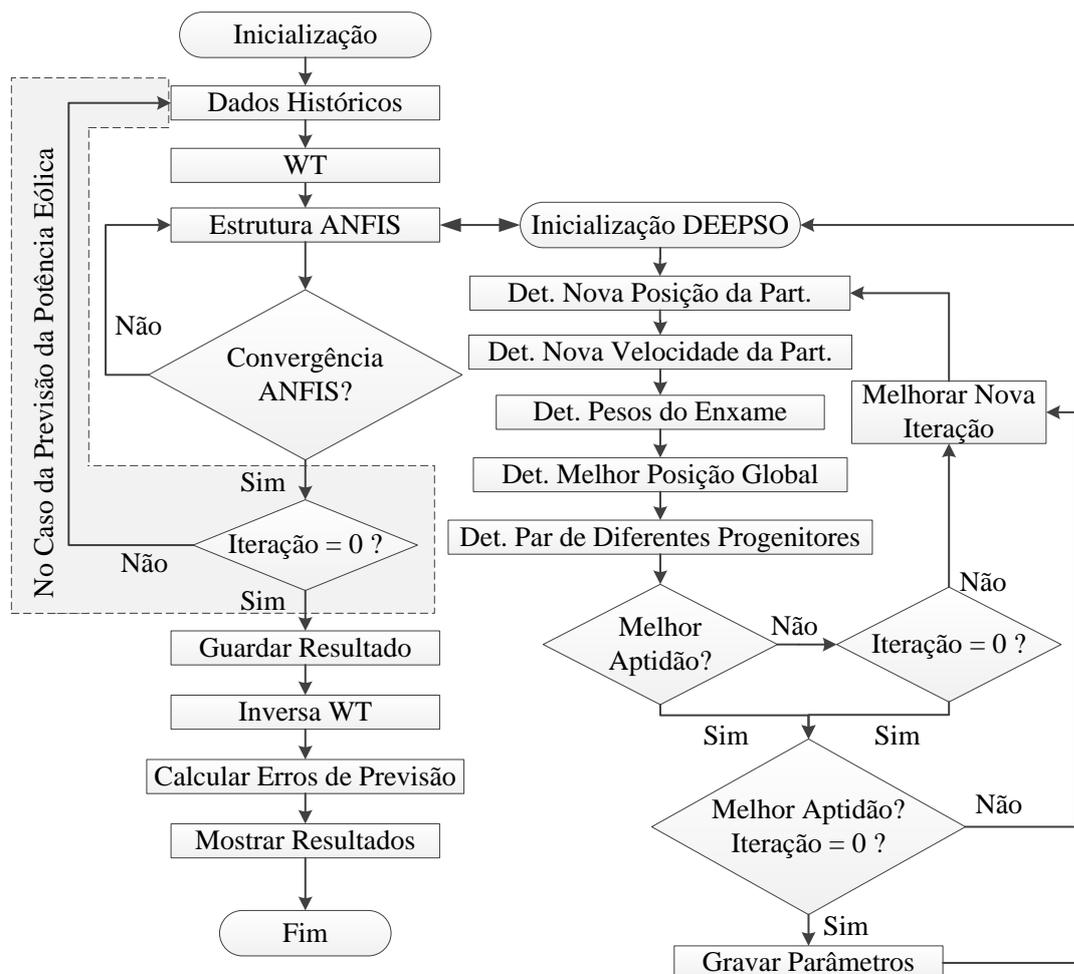


Figura 4.1 - Fluxograma da metodologia HWDA.

4.2 - Medidas de erro

De modo a comparar a metodologia proposta com outras metodologias previamente reportadas e validadas na comunidade científica da especialidade, aplicadas quer para previsão dos preços de eletricidade no mercado, quer para a previsão da potência eólica a curto prazo, é necessário recorrer a diversos critérios de quantificação do erro obtido nas previsões. Um dos critérios mais utilizados para o efeito é o *mean absolute percentage error* (MAPE), o qual quantifica o quão desviada se encontra a previsão dos valores reais e é descrito como [78], [116]:

$$MAPE = \frac{100}{N} \sum_{n=1}^N \frac{|\hat{p}_n - p_n|}{\bar{p}} \quad (4.1)$$

$$\bar{p} = \frac{1}{N} \sum_{n=1}^N p_n \quad (4.2)$$

onde \hat{p}_n se refere aos dados previstos na hora n , p_n são os dados reais na hora n , \bar{p} é o valor médio no horizonte temporal de previsão e N se refere à dimensão dos pontos observados.

Seguindo o mesmo conceito do critério anterior, a incerteza da metodologia HWDA é avaliada através da variância do erro, a qual quanto menor o resultado obtido, se traduz numa maior exatidão da metodologia proposta, e se descreve:

$$\sigma_{e,n}^2 = \frac{1}{N} \sum_{n=1}^N \left(\frac{|\hat{p}_n - p_n|}{\bar{p}} - e_n \right)^2 \quad (4.3)$$

$$e_n = \frac{1}{N} \sum_{n=1}^N \frac{|\hat{p}_n - p_n|}{\bar{p}} \quad (4.4)$$

Além disso, no caso da previsão da potência eólica, também é utilizado o critério *normalized mean absolute error* (NMAE), o qual é determinado por [116]:

$$NMAE = \frac{100}{N} \sum_{n=1}^N \frac{|\hat{p}_n - p_n|}{P_{instalada}} \quad (4.5)$$

onde $P_{instalada} = 2700\text{MW}$, considerando a informação obtida em [8], [25].

4.3 - Resultados dos preços de eletricidade no mercado

A metodologia HWDA foi implementada para a previsão dos preços de eletricidade no mercado espanhol para as 168 horas seguintes com um passo de 1 hora, considerando os dados históricos das 6 semanas precedentes, os quais são relativos ao ano de 2002 e representam as diversas estações do ano, tal como descrito em [78]. Além disso, para uma comparação justa e isenta, apenas foram utilizados para a previsão os dados históricos relativos ao período em causa, ou seja, não foram considerados dados exógenos, como a carga, demanda, entre outros.

As Figuras 4.2 - 4.5 apresentam os resultados obtidos relativamente às semanas de Inverno, Primavera, Verão e Outono, respetivamente. Observando os mesmos, verifica-se como o modelo HWDA possibilita a boa previsão do comportamento dos perfis dos preços de eletricidade no mercado em todas as semanas em estudado. Importa realçar a boa capacidade de previsão dos preços de pico, *price spikes*, principalmente no caso do Inverno embora a metodologia não tenha sido desenhada com esse intuito. No entanto, é possível observar que para o caso da semana de Verão, a mesma previsão de tal característica já não é tão bem conseguida.

Além disso, as Tabelas 4.2 e 4.3 apresentam uma comparação entre a metodologia HWDA com outras metodologias que utilizaram o mesmo caso de estudo, e histórico de dados em causa, reportadas e validadas na literatura especializada, utilizando os critérios MAPE e variância do erro, respetivamente, onde se poderá observar em detalhe a evolução da diminuição do erro ao longo das novas propostas que têm vindo a ser propostas ao longo dos anos.

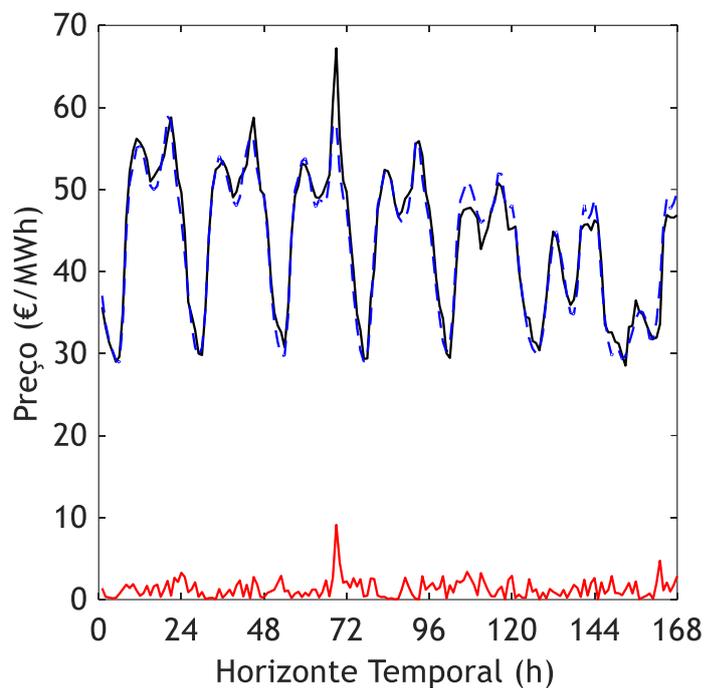


Figura 4.2 - Resultados dos preços de eletricidade no mercado para a semana de Inverno. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

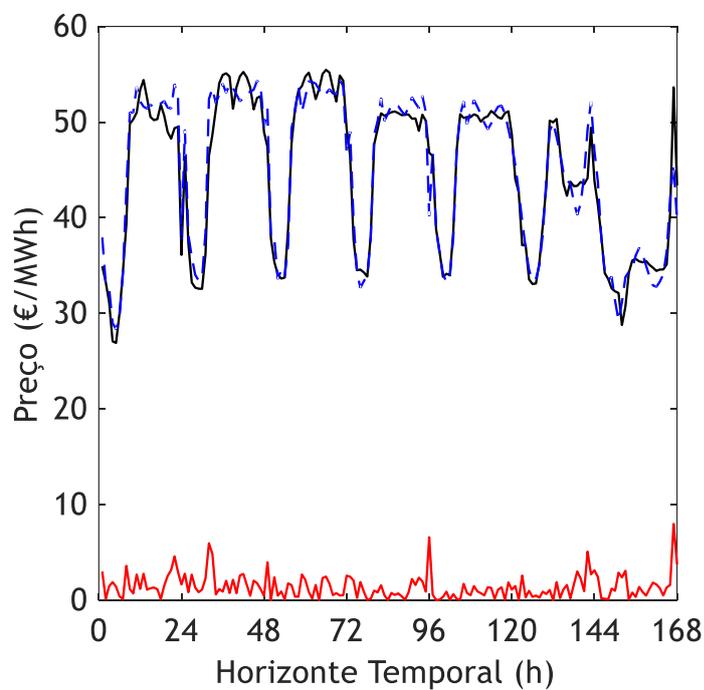


Figura 4.3 - Resultados dos preços de eletricidade no mercado para a semana da Primavera. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

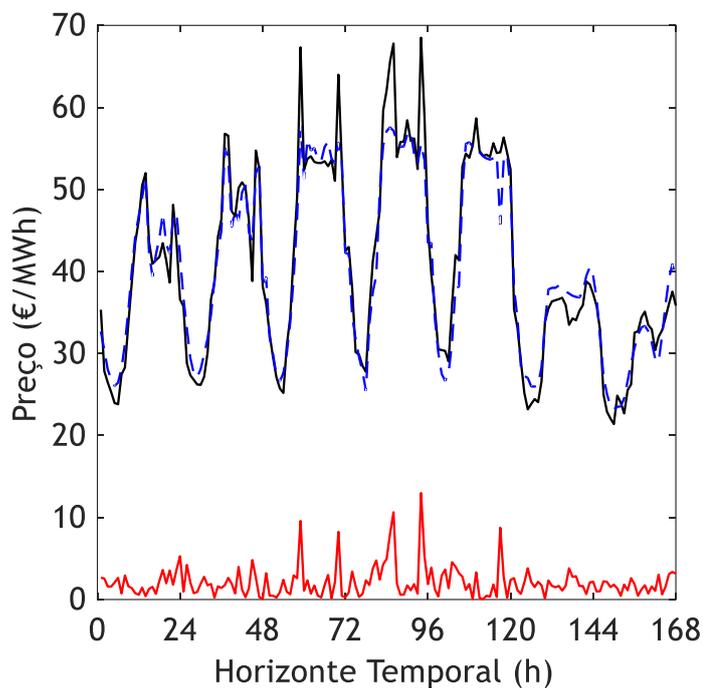


Figura 4.4 - Resultados dos preços de eletricidade no mercado para a semana de Verão. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

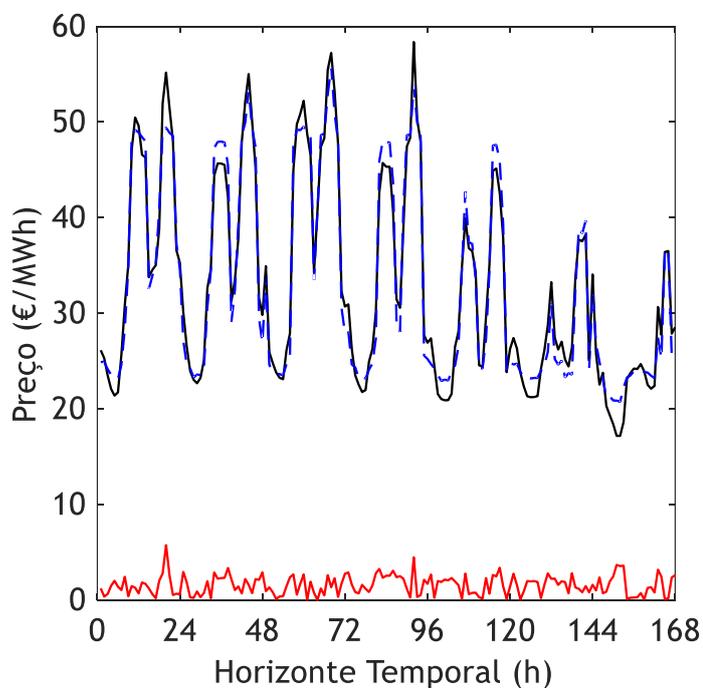


Figura 4.5 - Resultados dos preços de eletricidade no mercado para a semana de Outono. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

Tabela 4.2 - Comparação do MAPE para preços de eletricidade no mercado.

Metodologia	Inverno	Primavera	Verão	Outono	Média
FNN [78]	4,62	5,30	9,84	10,32	7,52
HIS [78]	6,06	7,07	7,47	7,30	6,97
AWNN [78]	3,43	4,67	9,64	9,29	6,75
NNWT [78]	3,61	4,22	9,50	9,28	6,65
CNEA [78]	4,88	4,65	5,79	5,96	5,32
EPA [65]	3,59	4,10	6,39	6,40	5,12
HPM	3,55	3,70	6,16	6,28	4,92
HEA [78]	3,04	3,33	5,38	4,97	4,18
HWDA	3,00	3,16	5,23	4,76	4,04

Tabela 4.3 - Comparação da variância do erro semanal para os preços de eletricidade no mercado.

Metodologia	Inverno	Primavera	Verão	Outono	Média
FNN [78]	0,0018	0,0019	0,0092	0,0088	0,0054
HIS [78]	0,0012	0,0031	0,0074	0,0075	0,0048
AWNN [78]	0,0009	0,0017	0,0074	0,0049	0,0037
NNWT [78]	0,0034	0,0049	0,0029	0,0031	0,0036
CNEA [78]	0,0036	0,0027	0,0043	0,0039	0,0036
EPA [65]	0,0012	0,0016	0,0048	0,0032	0,0027
HPM	0,0008	0,0013	0,0037	0,0017	0,0019
HEA [78]	0,0008	0,0011	0,0026	0,0014	0,0015
HWDA	0,0007	0,0008	0,0022	0,0010	0,0012

4.4 - Resultados da potência eólica

A metodologia de previsão HWDA foi também aplicada para realização da previsão da potência eólica para as 3 horas seguintes com um passo de 15 minutos até completar as 24 horas seguintes, isto é, previsão a curto prazo. Para tal, utilizaram-se os dados históricos da potência eólica instalada em Portugal, entre 2007 e 2008, e ligada ao sistema de telemetria da REN, relativos às diversas estações do ano, conforme descrito em [116]. Tal como no estudo da secção precedente, de modo a permitir uma comparação justa e isenta, não foram considerados dados exógenos, como o perfil de vento, NWP, entre outros.

As Figuras 4.6 - 4.9 apresentam os resultados obtidos relativamente aos dias de Inverno, Primavera, Verão e Outono, respetivamente. Analisando os mesmos, observa-se como a metodologia HWDA permite uma boa previsão, principalmente quando se observa as alterações súbitas dos perfis de potência eólica, isto é, a metodologia consegue suportar o comportamento volátil e incerto característico do potencial eólico ao longo dos dias em análise. Importa realçar a boa previsão realizada pela metodologia para o fenómeno de rampas, tal como se verifica no dia de Primavera e Outono, principalmente, possuindo esses tantos subidas como descidas.

As Tabelas 4.4 - 4.6 apresentam uma comparação entre a metodologia HWDA com outras metodologias previamente publicadas na literatura especializada relativamente aos critérios MAPE, variância do erro e NMAE, respetivamente.

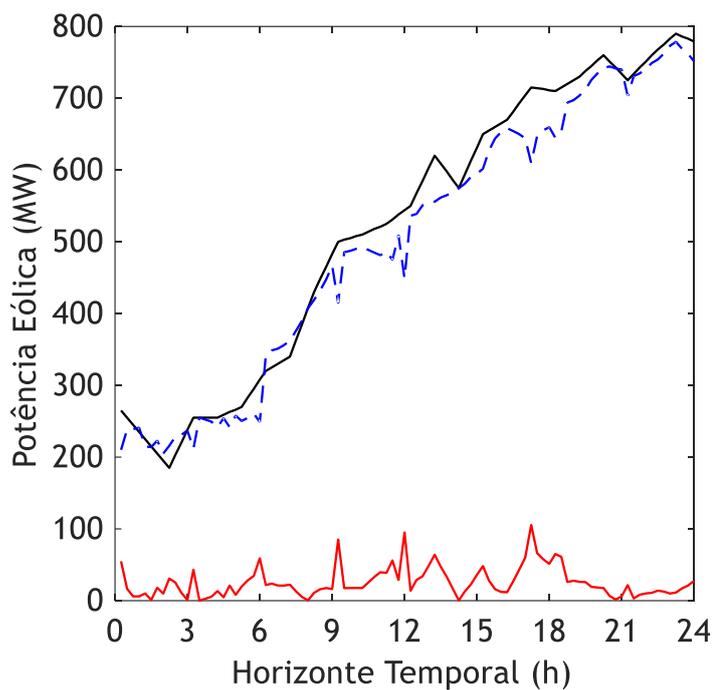


Figura 4.6 - Resultados da potência eólica para dia de Inverno. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

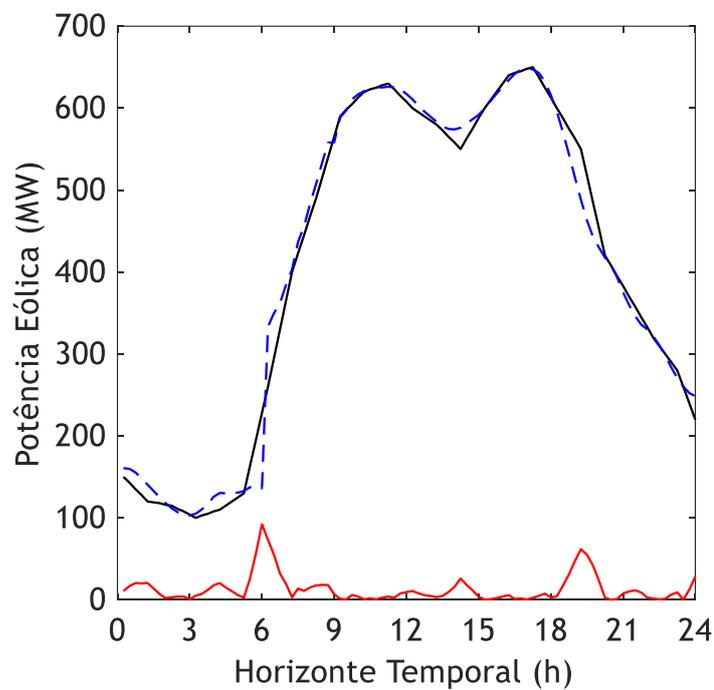


Figura 4.7 - Resultados da potência eólica para dia de Primavera. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

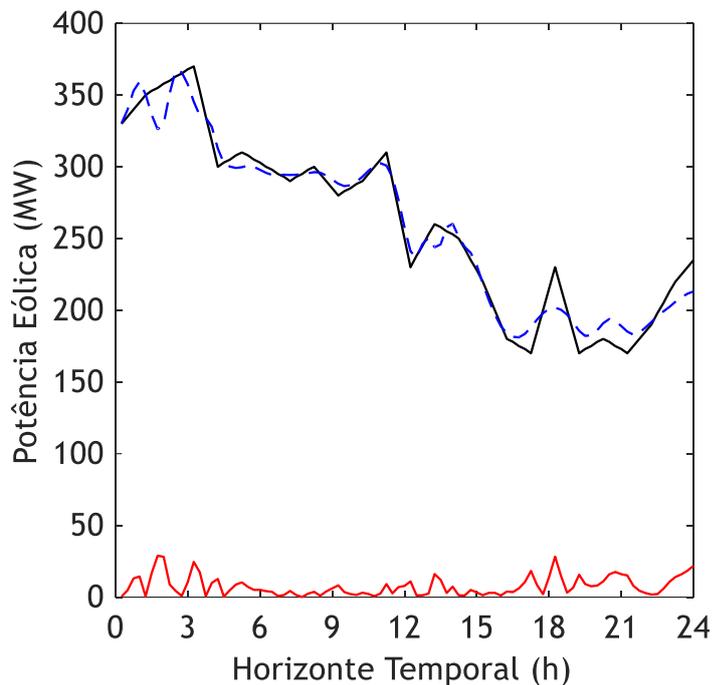


Figura 4.8 - Resultados da potência eólica para dia de Verão. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

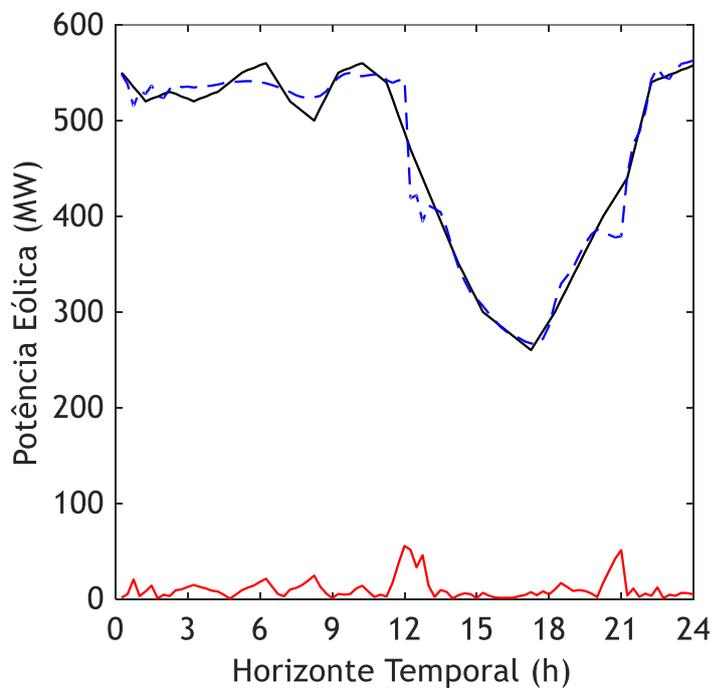


Figura 4.9 - Resultados da potência eólica dia de Outono. Valores reais (preto), previstos (azul) e erro absoluto (vermelho).

Tabela 4.4 - Comparação do MAPE para a potência eólica.

Metodologia	Inverno	Primavera	Verão	Outono	Média
NN [116]	9,51	9,92	6,34	3,26	7,26
NF [116]	8,85	8,96	5,63	3,11	6,64
WNF [116]	8,34	7,71	4,81	3,08	5,99
WPA [116]	6,47	6,08	4,31	3,07	4,98
HPM	5,35	5,72	4,08	2,58	4,43
HEA [116]	5,74	3,49	3,13	2,62	3,75
HWDA	5,08	3,19	2,96	2,27	3,37

Tabela 4.5 - Comparação da variância do erro diária para a potência eólica.

Metodologia	Inverno	Primavera	Verão	Outono	Média
NN [116]	0,0044	0,0106	0,0043	0,0010	0,0051
NF [116]	0,0041	0,0086	0,0038	0,0008	0,0043
WNF [116]	0,0046	0,0051	0,0021	0,0011	0,0032
WPA [116]	0,0021	0,0035	0,0016	0,0011	0,0021
HPM	0,0026	0,0030	0,0013	0,0007	0,0019
HEA [116]	0,0019	0,0015	0,0010	0,0008	0,0013
HWDA	0,0017	0,0016	0,0007	0,0006	0,0012

Tabela 4.6 - Comparação do NMAE para a potência eólica.

Metodologia	Inverno	Primavera	Verão	Outono	Média
NN [116]	5,22	3,72	2,35	2,15	3,36
NF [116]	4,86	3,36	2,09	2,05	3,09
WNF [116]	4,58	2,89	1,78	2,03	2,82
WPA [116]	3,56	2,28	1,60	2,02	2,37
HPM	5,22	3,72	2,35	2,15	3,36
HEA [116]	2,73	1,48	0,74	1,10	1,51
HWDA	0,94	0,49	0,28	0,39	0,53

Capítulo 5

Conclusão

5.1 - Contribuições

Neste trabalho foi criada uma nova metodologia híbrida, apelidada de HWDA, para a previsão dos preços de eletricidade no mercado e da potência eólica, no horizonte temporal de curto prazo. A referida metodologia resulta da combinação inovadora da WT, a qual proporciona um efeito de suavização dos dados de entrada, com o ANFIS, o qual promove uma arquitetura adaptativa, e com o DEEPSO, o qual fornece uma otimização através dum processo evolutivo e diferencial.

De modo a estabelecer uma avaliação comparativa justa e isenta das potencialidades da metodologia proposta, foram considerados iguais casos de estudo, dias/semanas, aos utilizados em outras metodologias propostas, validadas e publicadas na bibliografia da especialidade, para testar a proficiência da nova metodologia, sem a utilização de variáveis exógenas.

A aplicação da metodologia HWDA demonstrou ser precisa e eficaz, ajudando a diminuir a incerteza associada aos preços de eletricidade no mercado e à potência eólica. Os resultados obtidos mostraram claramente a superioridade da metodologia proposta, como é verificável através da análise dos três critérios utilizados para comparação (MAPE, variância do erro e NMAE), devidamente comparados nas tabelas descritas na secção anterior nos diferentes casos de estudos analisados.

Com efeito, no caso dos preços de eletricidade no mercado, o HWDA apresentou um MAPE de 4,04%, representando uma melhoria de 3,35% em relação ao valor médio reportado pela metodologia HEA. No caso da variância do erro semanal o valor médio obtido foi de 0,0012 que representa uma melhoria de 20,00% face ao valor médio obtido pela metodologia HEA, o que é significativo.

No caso da potência eólica, o HWDA apresentou um MAPE de 3,37%, representando uma melhoria de 10,13% face ao MAPE médio reportado na metodologia HEA e uma variância diária do erro de 0.0012, representando uma melhoria de 7,69% face aos valores reportados pela metodologia HEA.

O tempo computacional da metodologia proposta foi inferior a 2 minutos, em média, e em todos os casos estudados, e após afinamento da metodologia, utilizando um computador pessoal padrão dotado de um sistema CPU Intel Core i7-3537U, 2GHz e 4 GB de RAM, recorrendo a MATLAB®2016a operando em ambiente Windows 10.

5.2 - Trabalhos futuros

Pela experiência conseguida neste trabalho proposto, no futuro será interessante a possível análise da metodologia incluindo variáveis exógenas, uma vez que estas poderão fornecer informação que permitirá reduzir as incertezas associadas aos preços de eletricidade no mercado e à potência eólica, como alguma da bibliografia citada neste trabalho também defende.

Uma outra possibilidade passará pelo estudo de um sistema que se consiga adaptar a metodologia aqui proposta, e que realize num ambiente de pré-processamento dos dados de entrada, a seleção dos melhores dados de entrada, permitindo aumentar a robustez da metodologia, a rapidez de uma resposta para a tomada de decisão em tempo útil, e ainda na seleção dos melhores históricos, visto que, a qualidade e integridade dos dados históricos influencia o desempenho de qualquer metodologia de previsão.

Por último, uma outra possibilidade poderá passar pelo desenvolvimento de uma técnica de DEEPSO com um algoritmo que desempenhe o processo de otimização e convergência de forma ainda mais célere.

5.3 - Publicações

Da sequência deste trabalho foi possível realizar duas publicações com arbitragem internacional, que a seguir se descrevem:

- [J1] J. N. D. L. Gonçalves, G. J. Osório, J. P. S. Catalão, *et al.*, “DEEPSO to Predict Wind Power and Electricity Market Prices Series in Short-Term,” *Proc. 51st International Universities’ Power Engineering Conference*, Coimbra, Portugal, 6 - 9 Set. 2016, (**aceite**).
- [J2] J. N. D. L. Gonçalves, G. J. Osório, J. P. S. Catalão, *et al.*, “Enhanced Forecasting Approach for Electricity Market Prices and Wind Power Data Series in Short-Term,” *Energies – Open Access Energy Research, Engineering and Policy Journal*, Jun. 2016, (**em revisão**).

Referências

- [1] Santana J. J. E, e Resende M. J., “Reflectir Energia”, *Edições ETEP-LIVRIMPOR*, Portugal, 2006.
- [2] Shahidehpour M., Yamin H., Li Z., “Market operations in electric power systems: forecasting, scheduling and risk”, *Wiley*, New York, 2002.
- [3] Ferreira L. A. F. M., Anderson T., Imparato C. F., *et al.*, “Short-term resource scheduling in multi-area hydrothermal power systems”, *Int. J. Electr. Power Energy Syst.*, vol. 11, pp. 200-212, 1989.
- [4] Weron R., “Electricity price forecasting: A review of the state-of-the-art with a look into the future”, *Int. J. Forecast.*, vol. 30, pp. 1030-1081, 2014.
- [5] Pedras R., “Mercado Ibérico de Electricidade - A Regulação do MIBEL e Perspectivas de Evolução”, *Seminário APOCEEP*, 2006.
- [6] “Mercado Ibérico de Electricidade (MIBEL)”, Acedido [10/06/2016], em: <http://www.mibel.com/index.php?lang=pt>.
- [7] Castro R., “Uma Introdução às Energias Renováveis: Eólica, Fotovoltaica e Mini-Hídrica”, *IST Press*, Ed. 1, 2011.
- [8] Osório G. J., Matias J. C. O., Catalão J. P. S., “Forecasting tools and probabilistic scheduling approach incorporating renewables uncertainty for the insular power systems industry”, *Tese de Doutoramento*, Universidade da Beira Interior, Covilhã, Portugal, 2015.
- [9] “Operador del Mercado Eléctrico Español (OMEL)”, Acedido [10/06/2016], em: <http://www.omelholding.es/pt/omel-holding-pt>.
- [10] “Entidade Reguladora dos Serviços Energéticos (ERSE)”, Acedido [10/06/2016], em: <http://www.erse.pt/pt/Paginas/home.aspx>.
- [11] “Framework Convention on Climate Changing”, Acedido [10/06/2016], em: http://unfccc.int/meetings/lima_dec_2014/meeting/8141.php.
- [12] “Governo de Portugal, Diretiva 2001/77/CE”, Acedido [10/06/2016], em: <http://www.portugal.gov.pt/pt.aspx>.

- [13] Gil H. A., Joos G., “Generalized estimation of average displaced emissions by wind generation”, *IEEE Trans. Power Syst.*, vol. 22, pp. 1035-1043, 2007.
- [14] Yang M., Nguyen F., De T’Serclaes P. B., “Wind farm investment risks under uncertain CDM benefit in China”, *Energy Policy*, vol. 38, pp. 1436-1447, 2010.
- [15] “Our Future Energy”, The Danish Government, Denmark, 2011.
- [16] “Roteiro das Energias Renováveis”, Acedido [10/06/2016], em: http://europa.eu/legislation_summaries/energy/renewable_energy/l27065_pt.
- [17] “Europe's Premier Wind Energy Event”, Acedido [12/06/2016], em: <https://windeurope.org/wp-content/uploads/files/about-wind/statistics/EWEA-Annual-Statistics-2015.pdf>.
- [18] “Direcção Geral de Energia e Geologia (DGEG)”, Acedido [13/06/2016], em: <http://www.dgeg.pt/>.
- [19] “Adapting renewable energy policies to dynamic market conditions”, *IRENA - International Renewable Energy Agency*, Abu Dhabi, 2014.
- [20] “Environmental impacts of wind-energy projects”, *National Academies Press*, USA, 2007.
- [21] “Portal da REN - Potência Eólica, História”, Acedido [24/05/2016], em: <http://www.centrodeinformacao.ren.pt/PT/publicacoes/EnergiaEolica/>.
- [22] Saraiva J. P. T., Da Silva J. L. P. P., De Leão M. T. P., “Mercados de Electricidade - Regulação e Tarifação de Uso das Redes”, *FEUP edições*, 2002.
- [23] Dica C., Dica C. -I., Vasiliu D., et al., “Wind Power Short-Term Forecasting System”, em *Proc. 2009 IEEE Power Tech. Conf.*, Bucareste, Roménia, 2009.
- [24] Rodrigues A., Peças-Lopes J. A., Miranda D. E., et al., “EPREV - A Wind Power Forecasting Tool for Portugal”, *Apresentado na EWEC2007*, Milão, Itália, 2007.
- [25] “Redes Energéticas Nacionais (REN)”, Acedido [13/06/2016], em: <http://www.ren.pt/>.
- [26] Dufo-López R., Bernal-Agustín J. L., Monteiro C., “New methodology for the optimization of the management of wind farms, including energy storage”, *Appl. Mechanics Materials*, vol. 330, pp. 183-187, 2013.
- [27] Rodrigues E. M. G., Osório G. J., Godina R., et al., “Modelling e sizing of NaS (sodium sulfur) battery energy storage system for extending wind power performance in Crete island”, *Energy*, vol. 90, pp. 1606-1617, 2015.
- [28] Li L., Wang J., “Sustainable energy development scenario forecasting and energy saving policy analysis of China”, *Renew. Sust. Energy Rev.*, vol. 58, pp. 718-724, 2016.
- [29] Fereidoon P. S., Wolfgang P., “Electricity market reform: An international perspective”, *Elsevier Global Energy Policy and Economics Series*, 2006.
- [30] Chang W. Y., “A Literature Review of Wind Forecasting Methods,” *J. Power Energy Eng.*, vol. 2, pp. 161-168, 2014.

- [31] Shankar N. C., Frank. A. F., “Impact of climate change on electricity systems and markets - A review of models and forecasts,” *Sust. Energy Tech. Assess.*, vol. 5 pp. 62-74, 2014.
- [32] Rakesh D. C., Sailaja M. K., Sydulu M., “A Detailed Literature Review on Wind Forecasting,” *Proc. International Conf. Power, Energy and Control - ICPEC*, Tamilnadu, India, pp. 630-634, 2013.
- [33] Monteiro C., Bessa R., Miranda V., *et al.*, “Wind Power Forecasting: State-of-the-Art 2009”, *Decision and Information Sciences Division*, Argonne National Laboratory, Argonne, Illinois, 2009.
- [34] Coimbra J. P. L., “Previsão Curto Prazo de Preços no Mercado de Electricidade”, *Versão Provisória de Dissertação*, Faculdade de Engenharia da Universidade do Porto, Porto, 2010.
- [35] Niknam T., Sharifinia S., Azizipanah-Abarghooee R., “A new enhanced batinspired algorithm for finding linear supply function equilibrium of GENCOs in the competitive electricity market,” *Energy Convers. Manag.*, vol. 76, pp. 1015-1028, 2013.
- [36] Li X. R., Yu C. W., Ren S. Y., *et al.*, “Day-ahead electricity price forecasting based on panel cointegration e particle filter,” *Electron. Power Syst. Res.*, vol. 95, pp. 66-76, 2013.
- [37] González V., Contreras J., Bunn P. W., “Forecasting power prices using a hybrid fundamental-econometric model,” *IEEE Trans. Power Syst.*, vol. 27, pp. 363-372, 2012.
- [38] Dong Y., Wang J., Jiang H., Wu J., “Short-term electricity price forecast based on the improved hybrid model,” *Energy Convers. Manag.*, vol. 52, pp. 2987-2995, 2011.
- [39] Pindoriya N. M., Singh S. N., Singh S. K., “An adaptive wavelet neural network-based energy price forecasting, in electricity market,” *IEEE Trans. Power Syst.*, vol. 23, pp. 1423-1432, 2008.
- [40] Amjady N., Vahidinasab V., “Security-constrained self-scheduling of generation companies in day-ahead electricity markets considering financial risk,” *Energy Convers. Manag.*, vol. 65, pp. 164-172, 2013.
- [41] Lin W. -M., Gow H. -J., Tsai M. -T., “Electricity price forecasting using enhanced probability neural network,” *Energy Convers. Manag.*, vol. 51, pp. 2707-2714, 2010.
- [42] Catalão, J. P. S., Pousinho, H. M. I., Mendes, V. M. F., “Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach,” *Energy Convers. Manag.*, vol. 52, pp. 1061-1065, 2011.
- [43] Shayeghi H., Ghasemi A., “Day-ahead electricity prices forecasting by a modified CGSA technique and hybrid WT in LSSVM based scheme,” *Energy Convers. Manag.*, vol. 74, pp. 482-491, 2013.
- [44] Aggarwal S. K., Saini L. M., Kumar A., “Electricity price forecasting in deregulated markets: review and evaluation,” *Int. J. Power Energy Syst.*, vol. 31, pp. 13-22, 2009].
- [45] Catalão J. P. S., Pousinho H. M. I., Mendes V. M. F., “Hybrid wavelet-PSO-ANFIS approach for short-term electricity prices forecasting,” *IEEE Trans. Power Syst.*, vol. 26, pp. 137-144, 2011.

- [46] Marzband M., Sumper A., Domínguez-García J. L., Gumarra-Ferret R., “Experimental validation of a real time energy management system for microgrids in islanded mode using a local day-ahead electricity market and MINLP,” *Energy Convers. Manag.*, vol. 76, pp. 314-322, 2013.
- [47] Shafie-khah M., Moghaddam M. P., Sheikh-El-Eslami M. K., “Price forecasting of day-ahead electricity markets using a hybrid forecast method,” *Energy Convers. Manag.*, vol. 52, pp. 2165-2169, 2011.
- [48] Contreras J., Espínola, R., Nogales F. J., Conejo A. J., “ARIMA models to predict next day electricity prices,” *IEEE Trans. Power Syst.*, vol. 18, pp. 1014-1020, 2003.
- [49] Conejo A. J., Plazas M. A., Espínola R., Molina A. B., “Day-ahead electricity price forecasting using wavelet transform and ARIMA models,” *IEEE Trans. Power Syst.*, vol. 20, pp. 1035-1042, 2005.
- [50] Nogales F. J., Conejo A. J., “Electricity price forecasting through transfer function models,” *J. Oper. Res.*, vol. 2006, pp. 350-356, 2006.
- [51] Mandal P., A. Haque U, Meng J., *et al.*, “A Novel Hybrid Approach Using Wavelet, Firefly Algorithm, and Fuzzy ARTMAP for Day-Ahead Electricity Price Forecasting,” *IEEE Trans. Power Syst.*, vol. 28, no. 2, pp. 1041-1051, 2013.
- [52] Amjady N., Daraeepour A., “Design of input vector for day-ahead price forecasting of electricity markets,” *Expert. Syst. Appl.*, vol. 2009, pp. 12281-12294, 2009.
- [53] Amjady N., Keynia F., “Day-Ahead price forecasting of electricity markets by mutual information technique and cascaded neuro-evolutionary algorithm,” *IEEE Trans. Power Syst.*, vol. 24, pp. 306-318, 2009.
- [54] Amjady N., Keynia F., “Day-ahead price forecasting of electricity markets by a new feature selection algorithm and cascaded neural network technique,” *Energy Conv. Manag.*, vol. 50, pp. 2976-2982, 2009.
- [55] Amjady N., Daraeepour A., “Mixed price and load forecasting of electricity markets by a new iterative prediction method,” *Elect. Power Syst. Res.*, vol. 79, pp. 1329-1336, 2009.
- [56] Meng K., Dong Z. Y., Wong K. P., “Self-adaptive radial basis function neural network for short-term electricity price forecasting,” *IET Gene. Trans. Dist.*, vol. 3, pp. 325-335, 2009.
- [57] Meng K., Dong Z. Y., Wong K. P., “Self-adaptive radial basis function neural network for short-term electricity price forecasting,” *IET Gene. Trans. Dist.*, vol. 3, pp. 325-335, 2009.
- [58] Amjady N., Keynia F., “Application of a new hybrid neuro-evolutionary system for a day-ahead price forecasting of electricity markets,” *App. Soft. Comp.*, vol. 10, pp. 784-792, 2010.
- [59] Areekul P., Senjyu T., Toyama H., Yona A., “A hybrid ARIMA and neural network model for short-term price forecasting in deregulated market,” *IEEE Trans. Power Syst.*, vol. 25, pp. 524-530, 2010.

- [60] Areekul P., Senjyu T., Toyama H., Yona A., "A hybrid ARIMA and neural network model for short-term price forecasting in deregulated market," *IEEE Trans. Power Syst.*, vol. 25, pp. 524-530, 2010.
- [61] Mandal P., Srivastava A. K., Park J. -W., "A new recursive neural network algorithm to forecast electricity price for PJM day-ahead market," *Int. J. Energy Rese.*, vol. 24, pp. 507-522, 2010.
- [62] Lin W. -M., Gow H. -J., Tsai M. -T., "An enhanced radial basis function network for short-term electricity price forecasting," *Appl. Energy*, vol. 87, pp. 3226-3234, 2010.
- [63] Wu L., Shahidehpour M., "A hybrid model for day-ahead price forecasting," *IEEE Trans. Power Syst.*, vol. 25, pp. 1519-1530, 2010.
- [64] Amjady N., Daraeepour A., Keynia, F., "Day-ahead electricity price forecasting by modified relief algorithm and hybrid neural network," *IET Gener. Transm. Distrib.*, vol. 4, pp. 432-444, 2010.
- [65] Catalão J. P. S., Osório G. J., Pousinho H. M. I., "Application of an intelligent system based on EPSO and ANFIS to price forecasting," *Proc. 16th Int. Conf. Int. Syst. Appl. Power Syst. - ISAP 2011*, Greece, 2011.
- [66] Martinez-Alvarez F., Troncoso A., Riquelme J. C., Aguilar-Ruiz J.S., "Energy time series forecasting based on pattern sequence similarity," *IEEE Trans. Knowl. Data Eng.*, vol. 23, pp. 1230-1243, 2011.
- [67] Chen X., Dong Z. Y., Meng K., Xu Y., Wong K. P., Ngan H. W., "Electricity price forecasting with extreme learning machine and bootstrapping," *IEEE Trans. Power Syst.*, vol. 27, pp. 2055-2062, 2012.
- [68] Keynia F., "A new feature selection algorithm and composite neural network for electricity price forecasting," *Eng. Appl. Arti. Intel.*, vol. 25, pp. 1687-1697, 2012.
- [69] Mandal P., Haque A. U., Meng J., Martínez R., Srivastava A. K., "A hybrid intelligent algorithm for short-term energy price forecasting in the Ontario market," *Proc. IEEE Power Energy Soci. Gene. Meet.*, 2012.
- [70] Pousinho H. M. I., Mendes V. M. F., Catalão J. P. S., "Short-term electricity prices forecasting in a competitive market by a hybrid PSO-ANFIS approach," *Int. J. Elect. Power Energy Syst.*, vol. 39, pp. 29-35, 2012.
- [71] Mingli L., Feng Z., "A proposed grey model for short-term electricity price forecasting in competitive power markets," *Int. J. Elect. Power Energy Syst.*, vol. 43, pp. 531-538, 2012.
- [72] González V., Contreras J., Bunn D. W., "Forecasting Power Prices Using a Hybrid Fundamental Econometric Model," *IEEE Trans. Power Syst.*, vol. 27, pp. 363-372, 2012.
- [73] Zhang J., Tan Z., "Day-ahead electricity price forecasting using WT, CLSSVM and EGARCH model," *Electron. Power Energy Syst.*, vol. 45, pp. 362-368, 2013.
- [74] Miranian A., Abdollahzade M., Hassani H., "Day-ahead electricity price analysis and forecasting by singular spectrum analysis," *IET Gener. Transm. Distrib.*, vol. 7, pp. 337-346, 2013.

- [75] Elattar E., Shebin E. -K., "Day-ahead price forecasting of electricity markets based on local informative vector machine," *IET Gener. Transm. Distrib.*, vol. 7, pp. 1063-1071, 2013.
- [76] Anbazhagan S., Kumarappan N., "Day-Ahead Deregulated Electricity Market Price Forecasting Using Recurrent Neural Network," *IEEE Syst. J.*, vol. 7, pp. 866-872, 2013.
- [77] Wu H. C., Chan S., Tsui K. M., Hou Y., "A new recursive dynamic factor analysis for point and interval forecast of electricity price," *IEEE Trans. Power Syst.*, vol. 28, pp. 2352-2365, 2013.
- [78] Osório G. J., Matias J. C. O., Catalão J. P. S., "Electricity Prices Forecasting by a Hybrid Evolutionary-Adaptive Methodology," *Energy Conv. Manag.*, vol. 80, pp. 363-373, 2014.
- [79] Chaâbanehttp N., "A hybrid ARFIMA and neural network model for electricity price prediction," *Elect. Power Energy Syst.*, vol. 55, pp. 187-194, 2014.
- [80] Kim M. K., "Short-Term Price Forecasting of Nordic Power Market by Combination Levenberg-Marquardt and Cuckoo Search Algorithms," *IET Gen. Transm. Distrib.*, vol. 9, pp. 1553-1563, 2015.
- [81] Alamaniotis M., Bargiotas D., Bourbakis N. G., Tsoulalas L. H., "Genetic Optimal Regression of Relevance Vector Machines for Electricity Pricing Signal Forecasting in Smart Grids," *IEEE Trans. Smart Grid*, vol. 6, pp. 2997-3005, 2015.
- [82] Wu Y.-K., Hong J.-S., "A literature review of wind forecasting technology in the world," in Proc. IEEE Power Tech. Conf., Switzerland, 2007.
- [83] Sideratos G., Hatziargyriou N.D., "Wind power forecasting focused on extreme power system events," *IEEE Trans. Sustain. Energy*, vol. 3, pp. 445-454, 2012.
- [84] Botterud A., Zhi Z., Bessa R.J., *et al.*, "Wind power trading under uncertainty in LMP markets," *IEEE Trans. Power Syst.*, vol. 27, pp. 894-903, 2012.
- [85] Wang X., Guo P., Huang X., "A review of wind power forecasting models," *Energy Proc.*, vol. 12, pp. 770-778, 2011.
- [86] Costa A., Crespo A., Navarro J., *et al.*, "A review of the young history of wind power short-term prediction," *Renew. Sustain. Energy Rev.*, vol. 12, pp. 1725-1744, 2008.
- [87] Amjady N., Keynia F., Zareipour H., "Wind power prediction by a new forecast engine composed of modified hybrid neural network and enhanced particle swarm optimization," *IEEE Trans. Sustain. Energy*, vol. 2, pp. 265-276, 2011.
- [88] Togelou A., Sideratos G., Hatziargyriou N., "Wind power forecasting in the absence of historical data," *IEEE Trans. Sustain. Energy*, vol. 3, pp. 416-421, 2012.
- [89] Sousa J. N. M. S., "Previsão da Produção Eléctrica em Parques Eólicos", *Dissertação*, Faculdade de Engenharia da Universidade do Porto, Porto, 2007.
- [90] Prasad R. D., Bansal R. C., Sauturaga M., "Some of the design and methodology considerations in wind resource assessment," *IET Renew. Power Gener.*, vol. 2009, pp. 53-64, 2009.

- [91] Ma L., Luan S. Y., Jiang C. W., Liu H. L., Zhang Y., "A review on the forecasting of wind speed and generated power," *Renew. Sustain. Energy Rev.*, vol. 2009, pp. 915-920, 2009.
- [92] El-Fouly T. H. M., El-Saadany E. F., Salama M. M. A., "One day ahead prediction of wind speed and direction," *IEEE Trans. Energy Convers.*, vol. 23, pp. 191-201, 2008.
- [93] "The effects of integrating wind power on transmission system planning, reliability, and operations: Report on phase 2," *WindAction*, New York, USA, 2005.
- [94] Kariniotakis G., Pinson P., Siebert N., Giebel R., "The state of the art in short-term prediction of wind power from an offshore perspective," *Proc. of 2004 Sea. Tech. Week*, France, 2004.
- [95] Kavassery R., Seetharaman K., "Day-ahead wind speed forecasting using f-ARIMA models," *Renew. Energy*, vol. 34, pp. 1388-1393, 2009.
- [96] Nielsen T., Joensen A., Madsen H., *et al.*, "A new reference for wind power forecasting," *Wind Energy*, vol. 1, pp. 29-34, 1998.
- [97] Bessa R.J., Miranda V., Gama J., "Entropy and correntropy against minimum square error in offline and online three-day ahead wind power forecasting," *IEEE Trans. Power Syst.*, vol. 24, pp. 1657-1666, 2009.
- [98] Catalão J. P. S., Pousinho H. M. I., Mendes V. M. F., "An artificial neural network approach for short-term wind power forecasting in Portugal," *Eng. Intell. Syst. Electr. Eng. Commun.*, vol. 17, pp. 5-11, 2009.
- [99] Kusiak A., Zhang Z., "Short-horizon prediction of wind power: a data-driven approach," *IEEE Trans. Energy Conv.*, vol. 25, pp. 11112-11122, 2010.
- [100] Amjady N., Keynia F., Zareipour H., "Short-term wind power forecasting using ridgelet neural network," *Elec. Power Syst. Res.*, vol. 81, pp. 2099-2107, 2011.
- [101] Catalão J. P. S., Pousinho H. M. I., Mendes V. M. F., "Short-term wind power forecasting in Portugal by neural network and wavelet transform," *Renew. Energy*, vol. 34, pp. 1245-1251, 2011.
- [102] Pousinho H. M. I., Mendes V. M. F., Catalão J. P. S., "Application of adaptive neuro-fuzzy inference for wind power short-term forecasting," *IEEJ Trans. Elect. Electr. Eng.*, vol. 6, pp. 571-576, 2011.
- [103] Catalão J.P.S., Pousinho H.M.I., Mendes V.M.F., "Hybrid Wavelet-PSO-ANFIS approach for short-term wind power forecasting in Portugal," *IEEE Trans. Sustain. Energy*, vol. 2011, pp. 50-59, 2011.
- [104] Pousinho H.M.I., Mendes V.M.F., Catalão J.P.S., "A hybrid PSO-ANFIS approach for short-term wind power prediction in Portugal," *Ener. Conv. Manag.*, vol. 52, pp. 397-402, 2011.
- [105] Catalão J.P.S., Osório G.J., Pousinho H.M.I., "Short-term wind power forecasting using a hybrid evolutionary intelligent approach," *16th Int. Conf. Int. Syst. Appl. to Power Syst.*, Greece, 2011.
- [106] Sideratos G., Hatzigargyriou N.D., "Probabilistic wind power forecasting using radial basis function neural network," *IEEE Trans. Pow. Syst.*, vol. 27, pp. 1788-1796, 2012.

- [107] Venayagamoorthy G., Rohrig K., Erlich I., “Short-term wind power forecasting and intelligent predictive control based on data analytics,” *IEEE Power Ener. Manag.*, vol. 10, pp. 71-78, 2012.
- [108] Liu Y., Shi J., Yang Y., Lee W. -J., “Shot-term wind-power prediction based on wavelet transform-support vector machine and statistic-characteristics analysis,” *IEEE. Trans. Indus. Appl.*, vol. 48, pp. 1136-1141, 2012.
- [109] Bhaskar K., Singh S., “AWNN-assisted wind power forecasting using feed forward neural network,” *IEEE Trans. Sustain. Energy*, vol. 3, pp. 306-315, 2012.
- [110] Hui L., Hong-qi T., Di-fu P., Yan-fei L., “Forecasting Models for Wind Speed Using Wavelet, Wavelet Packet, Time Series and Artificial Neural Networks,” *Appl. Energy*, vol. 107, pp. 191-208, 2013.
- [111] Guannan Q. Jie M.. Dawei H., “Short-term wind power forecasting based on numerical weather prediction adjustment,” *11th IEEE International Conference on Industrial Informatics - INDIN2013*, pp. 453-457, Bochum, Germany, 2013.
- [112] Wi-Chang Y., Yuan-Ming Y., Po-Chun C., Yun-Chin K., Chung V., “Forecasting Wind Power in the Mai Liao Wind Farm Based on the Multi-Layer Perceptron Artificial Neural Network Model with Improved Simplified Swarm Optimization,” *Elect. Power Energy Syst.*, vol. 55, pp. 741-748, 2014.
- [113] Haque A. U., Nehrir M. H., Mandal P., “A hybrid intelligent model for deterministic and quantile regression approach for probabilistic wind power forecasting,” *IEEE Trans. Power Syst.*, vol. 29, pp. 1663-1672, 2014.
- [114] Kou P., Liang D., Gao F., Gao L., “Probabilistic wind power forecasting with online model selection and warped Gaussian process,” *Energy Conv. Manag.*, vol. 84, pp. 649-663, 2014.
- [115] Zhang Y., Wang J., Wang X., “Review on probabilistic forecasting of wind power generation,” *Renew. Sust. Energy Rev.*, vol. 32, pp. 255-270, 2014.
- [116] Osório G. J., Matias J. C. O., Catalão J. P. S., “Short-Term Wind Power Forecasting Using Adaptive Neuro-Fuzzy Inference System Combined with Evolutionary Particle Swarm Optimization, Wavelet Transform and Mutual Information,” *Renew. Energy*, vol. 75, pp. 301-307, 2015.
- [117] Xiao L., Wang J., Yang X., Xiao L., “A Hybrid Model Based on Data Preprocessing for Electrical Power Forecasting,” *Elect. Power Energy Syst.*, vol. 64, pp. 311-327, 2015.
- [118] Chitsaz H., Amjady N., Zareipour H., “Wind Power Forecast Using Wavelet Neural Network Trained by Improved Clonal Selection Algorithm,” *Energy Conv. Manag.*, vol. 89, pp. 588-598, 2015.
- [119] Haykin S., “Neural Networks - A Comprehensive Foundation,” *Pearson Hall*, 2º Edition, 2005.
- [120] Barreto J. M., “Introdução às Redes Neurais Artificiais”, *UFSC - Departamento de Informática e Estatística*, Florianópolis, Brasil, 2002.

- [121] “Tecido Cerebral Humano,” Acedido [16/06/2016] em <http://ajudaescolar.weebly.com/tecido-nervoso.html>
- [122] Osório G. J., Catalão J. P. S., “Nova metodologia híbrida para a previsão dos preços da energia eléctrica e da potência eólica a curto prazo,” *Dissertação de Mestrado*, Universidade da Beira Interior, Covilhã, Portugal, 2015.
- [123] Medeiros J. S., “Banco de Dados Geográficos e redes Neuronais Artificiais: Tecnologias de Apoio à Gestão do Território,” *Tese de Doutoramento*, Universidade de São Paulo, Brasil, 1999.
- [124] Sandri S., Correa C., “Lógica Nebulosa”, *INPE*, São José dos Campos, Brasil, 1999.
- [125] Bonissone P. P., “Adaptive Neural Fuzzy Inference Systems (ANFIS): Analysis and Applications”, *Piero P. Bonissone*, 2002.
- [126] Yun Z., Quan Z., Caixin S., Shaolan L., Yuming L., Yang S., “RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment,” *IEEE Trans. Power Syst.*, vol. 23, pp. 853-858, 2008.
- [127] Miranda V., Cerqueira C., Monteiro C., “Training a FIS with EPSO under an entropy criterion for wind power prediction,” *Proc. Inter. Conf. Proba. Meth. Appl. Power Systems*, 2006.
- [128] Koivo H., “ANFIS (Adaptive Neuro-Fuzzy Inference System),” *Heikki Koivo*, 2000.
- [129] Roy S. S., “Design of adaptive neuro-fuzzy inference system for predicting surface roughness in turning operation,” *J. Scient. Indust. Rese.*, vol. 64, pp. 653-659, 2005.
- [130] Pegoraro E. J. M., “Neuro-Fuzzy Software for Intelligent Control and Education,” *Versão Provisória de Dissertação*, Faculdade de Engenharia da Universidade do Porto, Porto, 2009.
- [131] Jang J.-S. R., “ANFIS: Adaptive-network-based fuzzy inference system,” *IEEE Trans. Syst. Manag. Cybern.*, vol. 23, pp. 665-685, 1993.
- [132] Ying H., “General Takagi-Sugeno Fuzzy Systems with Simplified Linear Rule Consequent Are Universal Controllers, Model and Filters,” *Elsevier Infor. Scien.*, vol. 108, pp. 91-107, 1997.
- [133] Lacerda E. G. M., “a otimização nuvem de partículas (particle swarm),” *Departamento de Engenharia e Automação UFRN*, Brasil, 2007.
- [134] Del Valle Y., Venayagamoorthy G. K., Mohagheghi S., *et al.*, “Particle Swarm Optimization: Basic Concepts, Variants and Applications in Power Systems,” *IEEE Trans. Evolut. Compt.*, vol. 12, pp. 171-195, 2008.
- [135] Miranda V., Oo N. W., “New experiments with EPSO-Evolutionary particle swarm optimization,” *Proc. IEEE Swarm Intel. Sympo.*, Indiana, USA, 2006.
- [136] Chen M., Wu C., Fleming P., “An evolutionary particle swarm algorithm for multi-objective optimization,” *Proc. 7th World Congr. Intel. Contr. Auto.- WCICA2008*, Chongqing, China, 2008.

- [137] Abdelhalim M. B., Salama A. E., Habib S. E. D., "Hardware software partitioning using particle swarm optimization technique," *Proc. 6th Int. workshop on system-on-chip for real-time appl.*, Cairo, Egypt, 2007.
- [138] Cerqueira C. A. A., "Relatório - Estudo de Variantes de Optimização por Enxames de Partículas (EPSO) e o seu Comportamento num Problema Real de Previsão de Potência de um Parque Eólico", *INESCPORTO*, 2005.
- [139] Miranda V., Carvalho L. M. , Rosa M. A., *et al.*, "Improving power system reliability calculation efficiency with EPSO variants," *IEEE Trans. Power Syst.*, vol. 24, pp. 1772-1779., 2009.
- [140] Miranda V., and Alves R., "Differential Evolutionary Particle Swarm Optimization (DEEPSO): A Successful Hybrid," *Proc. 11th IEEE Brazilian Congress on Computational Intelligence - BRICS2013*, Recife, Brazil, pp. 368-374, 2013.
- [141] "Differential Evolutionary Particle Swarm Optimization - DEEPSO". Acedido [10/02/2016], em: <http://epso.inescporto.pt/deepso/deepso-basics>.
- [142] Eynard J., Grieu S., Polit M., "Wavelet-based multi-resolution analysis and artificial neural networks, for forecasting temperature and thermal power consumption," *Eng. App. Art. Intell.*, vol. 24, pp. 501-516, 2011.
- [143] Amjady N., Keynia F., "Short-term loads forecasting of power systems by combining wavelet transform and neuro-evolutionary algorithm," *Energy*, vol. 34, pp. 46-57, 2009.
- [144] Conejo A. J., Contreras J., Espínola R., Plazas M. A., "Forecasting electricity prices for a day-ahead pool-based electric energy market," *Int. J. Forecast.*, vol. 21, pp. 435-462, 2005.
- [145] Noori R., Abdoli M. A., Farokhnia A., Abbasi M., "Results uncertainty of solid waste generation forecasting by hybrid of wavelet transform-ANFIS and wavelet transform-neural network," *Exp. Syst. Appl.*, vol. 36, pp. 9991-9999, 2009.
- [146] Chen Y., Luh P. B., Guan C., *et al.*, "Short-term load forecasting: similar days-based wavelet neural network," *IEEE Trans. Power Syst.*, vol. 25, pp. 322-330, 2010.