



**UNIVERSIDADE DA BEIRA INTERIOR**  
**Faculdade de Engenharia**

# **Nova Metodologia Híbrida Para a Previsão dos Preços da Energia Eléctrica e da Potência Eólica a Curto Prazo**

**Gerardo José Osório da Silva**

Dissertação para obtenção do Grau de Mestre em  
**Engenharia Electrotécnica e de Computadores - Automação e  
Electrónica**  
(2º ciclo de estudos)

Orientador: Prof. Doutor João Paulo da Silva Catalão

**Covilhã, Junho de 2011**



# Dedicatória

Aos meus queridos, estimados e saudosos pais, António e Lúcia, cujos valores morais e éticos me inculcaram no meu percurso de vida, tornaram-me na pessoa que sou hoje, já que nos seus simples e modestos modos de aconselhamento e de ver as coisas que os rodeiam, me orientaram e ajudaram a colocar-me no lugar onde hoje estou. Também a todos aqueles que me inculcaram com a sua sabedoria e ensinamentos já que foram os alicerces da minha educação científica.



# Agradecimentos

Ao Professor Doutor João Paulo da Silva Catalão, pela oportunidade concedida para a realização deste trabalho, agradeço ainda toda a motivação, apoio, disponibilidade e companheirismo que sempre demonstrou. As suas orientações e conselhos foram um pilar fundamental e essencial para a boa realização e conclusão deste trabalho. Os meus mais sinceros e sentidos agradecimentos.

Ao Mestre Engenheiro Hugo Miguel Inácio Pousinho, pelo sentido de amizade depositada e pelo seu tempo, encorajamento, e conselhos depositados; o qual contribuiu o despertar do meu interesse pela área em que este trabalho se insere.

À Universidade da Beira Interior por todos estes anos que aqui passei, considero-a o meu segundo lar, já que aprendi o rigor científico e ético que caracteriza o curso pelo qual me estou a formar.

A todos os Senhores Professores e colaboradores por me terem inculcido as suas experiências e ensinamentos, proporcionando-me o rigor científico que caracteriza a área pela qual me estou a formar.

A todos os meus amigos, companheiros e colegas, pelo encorajamento que deram para aqui chegar, pelos seus conhecimentos, também preciosos, transmitidos ao longo destes anos. Em especial, todos aqueles que de forma mais persistente me ajudaram nos momentos mais difíceis do meu percurso académico e pessoal.

Quero finalmente exprimir o meu mais sincero agradecimento a todos que directamente ou indirectamente contribuíram para o finalizar deste trabalho e desta etapa na minha vida.



# Resumo

A implementação de um mercado eléctrico liberalizado e a crescente integração de energia eólica na rede eléctrica, particularmente em Portugal, induzem novos desafios associados à crescente competitividade no sector eléctrico entre empresas produtoras e à elevada volatilidade e intermitência inerentes ao vento. Assim, torna-se indispensável para os agentes de mercado a existência de ferramentas computacionais mais eficientes que permitam obter previsões fiáveis e rigorosas dos preços da energia eléctrica e da potência eólica. Estas previsões possibilitam desenvolver melhores estratégias de oferta no mercado, maximizando o lucro, e optimizando a exploração dos recursos energéticos de origem eólica.

Esta dissertação apresenta uma nova metodologia híbrida para a previsão dos preços da energia eléctrica e da potência eólica em Portugal, considerando o horizonte temporal de curto prazo, isto é, de um dia a uma semana. Esta nova metodologia baseia-se na combinação eficaz de sistemas neuro-difusos, programação evolucionária e optimização por enxame de partículas, sendo aplicada em casos de estudo reais. Os resultados obtidos são posteriormente comparados com resultados já publicados em revistas internacionais de referência, permitindo validar a proficiência da nova metodologia proposta.

## Palavras-chave

Mercado eléctrico, previsão, programação evolucionária, sistema neuro-difusos, optimização por enxame de partículas, potência eólica, preços da energia eléctrica.



# Abstract

The implementation of a liberalized electricity market and the growing integration of wind power into the electric grid, particularly in Portugal, pose new challenges associated with the increasing competition in the electricity industry between power producers and the high volatility and intermittence inherent to the wind. Thus, the existence of more effective computational tools becomes essential for market agents, allowing reliable and accurate forecasts of electricity prices and wind power production. These forecasts allow developing enhanced bidding strategies in the market, maximizing the profit, and optimizing the exploitation of the wind energy resources.

This dissertation presents a new hybrid methodology to forecast electricity prices and wind power in Portugal, considering a short-term time horizon, i.e., from one day to one week. This new methodology is based on the successful combination of neuro-fuzzy systems, evolutionary programming and particle swarm optimization, being applied to real case studies. Afterwards, the results obtained are compared with previously reported results in reputable international journals, validating the proficiency of the new methodology proposed.

# Keywords

Electricity market, forecasting, evolutionary programming, neuro-fuzzy systems, particle swarm optimization, wind power, electricity prices.



# Índice

Capítulo 1	
1.1 Introdução	1
1.2 Enquadramento	4
1.3 Motivações	6
1.4 Estado da Arte	7
1.4.1 Previsão da Potência Eólica	9
1.4.2 Previsão dos Preços de Energia Eléctrica	10
1.4.3 Classificação dos Horizontes Temporais	11
1.5 Organização do Texto	12
Capítulo 2	
2.1 Energias Renováveis	14
2.2 Sistema Eléctrico Nacional	18
2.3 Mercado de Energia Eléctrica	21
Capítulo 3	
3.1 Redes Neurais	25
3.1.1 Algoritmos de Aprendizagem Utilizados	32
3.2 Lógica Difusa	34
3.2.1 Conceitos Fundamentais	35
3.3 Sistema de Inferência Neuro-Difuso Adaptativo	42
3.4 Optimização por Enxame de Partículas	44
3.5 Optimização por Enxame de Partículas Evolucionário	49
3.6 Nova Metodologia Híbrida de Previsão	52
3.6.1 Medidas de Erro	55
Capítulo 4	
4.1 Resultados Obtidos	
4.1.1 Previsão dos Preços da Energia Eléctrica	58
4.1.2 Previsão de Potência Eólica	63
Capítulo 5	
5.1 Contribuições	70
5.2 Trabalhos Futuros	70
Bibliografia	72
Anexos	79



# Lista de Figuras

Figura 1.1 - Evolução da potência eólica instalada no Sistema Eléctrico Nacional (SEN) nos últimos anos.

Figura 1.2 - Constituição de um sistema de produção eólica.

Figura 1.3 - Taxonomia das principais metodologias de previsão.

Figura 2.1 - Quota de electricidade gerada por cada recurso renovável em Portugal.

Figura 2.2 - Atlas Português do Vento *Onshore*, representando o NEP's à altura de 60m.

Figura 2.3 - Organização simplificada do SEN.

Figura 2.4 - Organização geral do MIBEL e operadores de mercado.

Figura 3.1 - Constituição de um neurónio.

Figura 3.2 - Constituição de um neurónio artificial.

Figura 3.3 - Exemplo de funções de activação.

Figura 3.4 - Exemplo de um perceptrão multicamada.

Figura 3.5 - Estrutura de uma rede neuronal.

Figura 3.6 - Representação de conjuntos difusos.

Figura 3.7 - Resultados obtidos da aplicação das propriedades da lógica difusa.

Figura 3.8 - Exemplo de uma máquina difusa assente em regras.

Figura 3.9 - Exemplo de algumas funções de pertença frequentemente utilizadas.

Figura 3.10 - Representação de um sistema ANFIS de 5 camadas.

Figura 3.11 - Caminho percorrido pela partícula para a sua nova posição.

Figura 3.12 - Fluxograma representativo do algoritmo PSO.

Figura 3.13 - Fluxograma da Metodologia Híbrida Proposta.

Figura 4.1 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação da Primavera.

Figura 4.2 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Verão.

Figura 4.3 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Outono.

Figura 4.4 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação de Inverno.

Figura 4.5 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação da Primavera.

Figura 4.6 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Verão.

Figura 4.7 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Outono.

Figura 4.8 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Inverno.

# Lista de Tabelas

Tabela 1.1 - Evolução do Mercado eléctrico Ibérico, síntese da REN.

Tabela 3.1 - Comparação entre PSO e EPSO.

Tabela 3.2 - Parâmetros utilizados na previsão de potência eólica.

Tabela 3.3 - Parâmetros utilizados na previsão dos preços da energia eléctrica.

Tabela 4.1 - Resultados dos critérios de avaliação da metodologia EPA para a previsão dos preços da energia eléctrica.

Tabela 4.2 - Comparação do MAPE entre os diferentes métodos de previsão dos preços da energia eléctrica.

Tabela 4.3 - Comparação da Variância do Erro entre diferentes metodologias de previsão dos preços da energia eléctrica.

Tabela 4.4 - Resultados dos critérios de avaliação da metodologia EPA para a previsão da potência eólica.

Tabela 4.5 - Comparação do MAPE entre os diferentes métodos de previsão da potência eólica.

Tabela 4.6 - Comparação da Variância do Erro entre os diferentes métodos de previsão da potência eólica.



# Lista de Acrónimos

ANFIS	<i>Adaptative Neuro-Fuzzy Inference Systems</i>
ANN	<i>Artificial Neural Network</i>
AR	<i>Autoregressive</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
AWNN	<i>Adaptative Wavelet Neural Network</i>
BP	<i>Back Propagation</i>
CL	Comercializador Liberalizado
CML	Clientes de Mercado Liberalizado
CMR	Clientes de Mercado Regulado
CNE	<i>Comisión Nacional de Energia</i>
CNEA	<i>Cascaded Neuro-Evolutionary Algorithm</i>
CUR	Comercializador Último Recurso
DGEG	Direcção Geral de Energia e Geologia
EMQ	Erro Médio Quadrático
ENE	Estratégia Nacional de Energia
EPA	<i>Evolutionary PSO ANFIS</i>
EPSO	<i>Evolutionary Particle Swarm Optimization</i>
ERSE	Entidade Reguladora dos Serviços Energéticos
EUA	Estados Unidos da América
FNN	<i>Fuzzy Neural Network</i>
GARCH	<i>Generalized Autoregressive Conditional Heteroskedastic</i>
GEE	Gases com Efeito de Estufa
HIS	<i>Hybrid Inference Systems</i>
HPA	<i>Hybrid PSO ANFIS</i>
INETI	Instituto Nacional de Engenharia, Tecnologia e Inovação
IOHMM	<i>Input-Output Hidden Markov Mesh</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MC	Método da Centróide
MM	Método da Média dos Máximos
NEP's	Número de Horas de Funcionamento Equivalente a Potência Nominal
NF	<i>Neuro Fuzzy</i>
NN	<i>Neural Network</i>
NNWT	<i>Neural Network Wavelet Transform</i>
OMEL	Operador de Mercado Eléctrico Liberalizado
OMI	Operador de Mercado Ibérico
OMIE	Operador de Mercado Interno Espanhol
OMIP	Operador de Mercado Interno Português
PDF	Estimação Pontual
PRE	Produção em Regime Especial
PRO	Produção em Regime Ordinário
PSO	<i>Particle Swarm Optimization</i>
REE	<i>Red Electrica de España</i>
REN	Redes Energéticas Nacionais
RMP	Regra do Movimento da Partícula

RNA	Redes Neurais Artificiais
RND	Rede Nacional de Distribuição
RNT	Rede Nacional de Transporte
SCADA	<i>Supervisory Control and Data Acquisition</i>
SDE	<i>Standard Deviation of Error</i>
SEN	Sistema Eléctrico Nacional
SSE	<i>Sum of Square of Error</i>
TSK	Takagi-Sugeno
WNN	<i>Wavelet Neural Network</i>



# Capítulo 1

## 1.1 Introdução

Desde o início das civilizações que a energia se destaca pela sua importância no desenvolvimento das sociedades. No entanto, a sua utilização por parte da humanidade, como se tem vindo a assistir, tem importantes repercussões ambientais. Numa tentativa de mudança de paradigma, associada à dependência actual dos combustíveis fósseis, bem como a redução substancial das emissões de gases poluentes e com efeito de estufa (GEE), a produção de energia eléctrica tem vindo cada vez mais a ser realizada por fontes de origem renovável, representando uma alternativa que garanta a sustentabilidade. Neste contexto o Protocolo de Quioto discutido em 1997, e assinado pela maioria dos países desenvolvidos em Março de 1998, foi reconhecido em Março de 1999 pelos países aderentes. Portugal reconheceu a sua importância em Maio de 2002, entrando em vigor em Fevereiro de 2005.

Este Protocolo tem como objectivo a redução a nível global de GEE, em pelo menos 5,2%, até 2012 em relação aos níveis verificados em 1990. Devido a este Protocolo, a União Europeia definiu, mesmo antes da tentativa do novo tratado de Copenhaga em 2009, um conjunto de directivas as quais definem os limites de emissões de GEE pelos países membros exigindo-se uma redução global de 8% entre 2012 e 2020 [1]. Este plano conhecido pelo “Objectivos 20/20/20”, proposto em 2007 e aprovado em 2008, impõe a redução em 20% das emissões de GEE, um aumento em 20% da quota de energias renováveis e um aumento da eficiência energética em 20% [2].

Desde 2001 Portugal tem vindo a adoptar um conjunto de medidas e propostas, lançando, por exemplo, o programa de Eficiência Energética e Energias Endógenas<sup>1</sup>, mais conhecido pelo Programa E4 de 2001. Este programa tem vindo a ser constantemente actualizado, como é o caso da Resolução do Conselho de Ministros n.º 53/2005, no qual, entre outros aspectos, trata-se de um plano de redução de GEE em 27% no período de 2008 a 2012 relativamente aos valores verificados em 1990 [3], e outras reformulações, como é o caso do Decreto-Lei n.º 141/2010 de 31 de Dezembro [4]. De acordo com o Decreto-Lei anterior, devidamente suportado pelo plano da Estratégia Nacional para a Energia (ENE) 2020, são definidas metas para a produção e consumo de energia com base em fontes renováveis.

---

<sup>1</sup> Referem-se as energias endógenas como as energias que são obtidas no próprio país de origem, isto é, energia não importada.

O plano ENE 2020 surge como resposta às medidas impostas pela União Europeia no que respeita à produção de electricidade a partir de fontes renováveis, fomentando a eficiência energética, ou seja, até ao ano de 2020 Portugal prevê a redução da dependência energética em 74%, produzindo para tal o equivalente a 60 milhões de barris anuais de petróleo com recursos endógenos, reduzindo assim a forte dependência em combustíveis fósseis que o país possui. Assim, uma das metas para atingir este objectivo passará pela utilização de fontes renováveis no consumo final bruto na ordem dos 31%.

Desde o início do ano de 2000 tem-se verificado um aumento significativo da produção de electricidade a partir de fontes renováveis, em especial com base eólica, que se deve sobretudo à maturidade da tecnologia, à disponibilidade do recurso no nosso país e às remunerações atractivas incentivadas pelos governos. Em resultado das políticas aplicadas, Portugal é o segundo país a nível mundial em 2010 com maior índice de penetração de recursos eólicos no sistema eléctrico [5].

A Figura 1.1 reflecte a forte implementação da potência eólica em Portugal. Apesar do aumento de 348 MW em 2010, o crescimento é inferior ao que se tem verificado nos últimos anos. Contudo, a potência instalada já ascende aos 4119 MW o que corresponde a uma potência ligada à rede de 3705 MW.

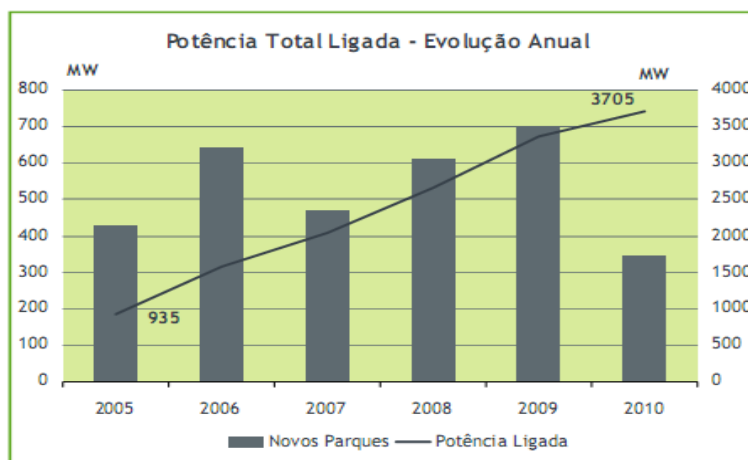


Figura 1.1 - Evolução da potência eólica instalada no Sistema Eléctrico Nacional (SEN) nos últimos anos [6].

Devido à volatilidade associada ao recurso eólico, é necessária a utilização de uma diversidade de tecnologias de forma a possibilitar a existência de opções mais alargadas de produção de electricidade, sendo imperativo assegurar o abastecimento de electricidade de forma segura e económica.

Assim, torna-se relevante considerar os seguintes problemas:

- Participação no Mercado Eléctrico: No qual promotores ou comerciantes representativos dos parques eólicos deverão apresentar as suas propostas de produção de electricidade discretizadas pelo menos de hora a hora com um horizonte temporal cuja antecedência seja igual ou superior a 24 horas.
- Segurança no Abastecimento: Deve-se considerar a possibilidade de avarias das unidades produtoras e a necessidade imperativa de garantir a cobertura dos consumos, conhecendo previamente uma estimativa acerca da produção eólica. Neste caso, os métodos de previsão permitem uma maior eficácia associados à produção dos parques eólicos, reduzindo por sua vez as incertezas.
- Gestão dos Centros Produtores: No processo de despacho é imperativo considerar, para além das restrições da rede eléctrica, quais as estimativas de produção de electricidade e o grau de incerteza associado, isto é, proporcionar um bom escalonamento dos centros convencionais de produção de electricidade.
- Gestão dos Parques Eólicos: A qual exige períodos de manutenção das turbinas eólicas, com o objectivo de responder às necessidades dos operadores de sistema. Assim, a informação disponibilizada pelas ferramentas de previsão do promotor poderão ajudar na assistência ao parque eólico nos períodos de menor capacidade de produção [7].

Ao aumentar-se consideravelmente o número de centrais eólicas em substituição das centrais térmicas implica não só aumentar a complexidade do sistema, mas também melhorar a monitorização, controlo e gestão das centrais de produção, considerando ainda as restrições da rede e do mercado eléctrico. Como é apresentado na Figura 1.2, este aumento de complexidade é controlado pelo centro de despacho, o qual adopta uma arquitectura de controlo hierárquico e realiza o diálogo entre os operadores das redes e o mercado eléctrico.

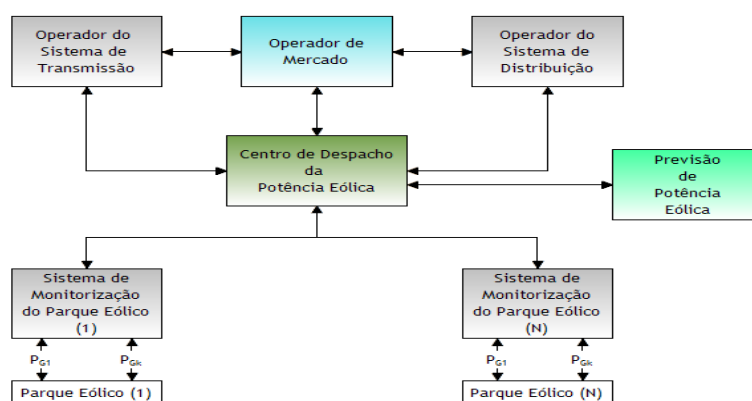


Figura 1.2 - Constituição de um sistema de produção eólica.

Na Figura 1.2, o Centro de Despacho da Potência Eólica faz o controlo dos Parques Eólicos 1 até  $N$ , sendo monitorizados e controlados pelos Sistemas de Monitorização dos mesmos parques 1 até  $N$ , constituídos por  $k$  geradores [8].

Pretende-se, com a presente dissertação, apresentar uma nova metodologia híbrida para a previsão a curto prazo da potência eólica e dos preços da energia eléctrica. No caso da previsão da potência eólica o horizonte temporal considerado é de 24 horas, correspondendo à previsão para um dia. Esta previsão será suportada por sucessivas actualizações de 3 em 3 horas com amostras em intervalos de 15 minutos. No caso da previsão dos preços da energia eléctrica o horizonte temporal considerado é de 168 horas, correspondendo à previsão para uma semana, em intervalos de 1 hora.

## 1.2 Enquadramento

A energia eléctrica é um bem necessário à evolução e bem-estar da sociedade, representando uma grande influência económica em todos os países do globo. Historicamente, a partir da década de 1990 o Mundo presenciou a ocorrência de inúmeras reformas no sector eléctrico, das quais se destacam a mudança de paradigma no que respeita à produção de electricidade e à desregulação ou re-regulação do sector eléctrico, deixando de apresentar uma “estrutura verticalmente integrada”<sup>2</sup> para promover a livre competição entre os diversos participantes do mercado.

Em relação ao mercado português esta reforma foi verificada com a criação de acordos entre Portugal e Espanha, iniciando-se o processo em Novembro de 2001. A Tabela 1.1 apresenta a evolução do mercado eléctrico Ibérico e da criação dos participantes de mercado.

O mercado a curto prazo português foi integrado no mercado Ibérico em 2007. Assim, o Mercado de Electricidade Ibérico é constituído por um Operador de Mercado Ibérico (OMI) subdividido no Operador de Mercado Interno Português (OMIP), que gere o mercado a prazo através de contratos bilaterais, e o Operador de Mercado Interno Espanhol (OMIE), que gere o mercado diário e intradiário.

---

<sup>2</sup> Considera-se uma estrutura verticalmente integrada como o conjunto de operadores eléctricos encadeados entre os mesmos como exemplo de uma estrutura hierárquica.

Para garantir a regularização dos operadores, existem dois agentes reguladores; do lado de Portugal, a Entidade Reguladora dos Serviços Energéticos (ERSE), e do lado de Espanha, a *Comisión Nacional de Energía* (CNE). Existem ainda dois operadores de sistema: do lado de Portugal, a REN, e do lado de Espanha, a *Red Eléctrica de España* (REE). O mercado permite criar um ambiente de livre concorrência no qual o consumidor tem a possibilidade de escolha do fornecedor de energia eléctrica.

Tabela 1.1 - Evolução do Mercado eléctrico Ibérico, síntese da REN [6, 9].

Ano	Evento
2000	Certificação ISO 9001 em linhas e subestações de muito alta tensão Arranque do novo sistema SCADA Separação da REN da EDP
2001	Início dos acordos entre Portugal e Espanha no mercado eléctrico.
2002	Acordo para a criação de um mercado <i>spot</i> entre OMI, OMEL e OMIP
2003	Criação da OMIP Troca de participações entre a OMIP e OMEL
2004	1º Convénio Internacional para criar o MIBEL 2º Convénio Ibérico para criar o MIBEL
2005	Certificação em Portugal do transporte de electricidade segundo as normas ISO 9001, ISO 14001:2004 e OSHAS 18001 Ligação do primeiro parque eólico à RNT Definição da data de arranque da OMIP
2006	Início do novo enquadramento regulamentar para o sector da energia em Portugal Conselho de Reguladores aprova as regras da OMIP e OMIP <i>Clear</i> Inauguração do MIBEL, arranque do OMIP e OMIP <i>Clear</i>
2007	Constituição da REN como Redes Energéticas Nacionais Separação de mercados e definição do preço <i>spot</i> para Portugal Entrada da REN no PS120
2008	Agregação da OMIP e OMEL, criação da OMI Distribuição do capital da REN

O MIBEL é um mercado liberalizado no qual os preços praticados possuem um comportamento inconstante e volátil, determinados pelas ofertas de compra e venda de energia.

Assim, torna-se indispensável possuir ferramentas computacionais para auxiliar os agentes de mercado a tomar as melhores decisões de planeamento, existindo sempre limitações impostas pelo sistema de transporte.

## 1.3 Motivações

Atendendo aos factores enunciados na secção anterior, verifica-se que é de extrema importância realizar a previsão da potência eólica e dos preços da energia eléctrica, visto que, estes parâmetros induzem incertezas para os produtores de energia eléctrica, os agentes de mercado e o gestor do sistema.

O objectivo da previsão a curto prazo consiste em minimizar o risco inerente às ofertas no mercado eléctrico, por um lado, e maximizar a utilização da energia eólica para produção de electricidade, por outro lado, evitando produção de origem térmica.

Assim, pretende-se desenvolver uma nova metodologia capaz de fazer a previsão dos preços da energia eléctrica e da potência eólica baseada em ferramentas de inteligência computacional, minimizando o erro e a variância nos resultados, comparativamente a outras metodologias já reportadas na literatura especializada.

Ainda, pretende-se que os dados de entrada sejam baseados apenas em informação do conhecimento público, como acontece com os dados históricos dos preços da energia eléctrica e da produção eólica, acessíveis nos sites da OMEL e da REN, permitindo a avaliação correcta e isenta das potencialidades da nova metodologia proposta.

A realização desta dissertação fornecerá uma contribuição potencialmente importante para os produtores de energia eléctrica, os agentes de mercado e o gestor do sistema, almejando alcançar simultaneamente uma elevada precisão nas previsões e uma rápida execução computacional, cumprindo os objectivos de forma eficiente.

## 1.4 Estado da Arte

Neste capítulo são abordadas algumas técnicas e modelos de previsão dos preços da energia eléctrica e da potência eólica a curto prazo. De salientar que na maioria dos mercados eléctricos cuja competitividade é uma realidade verificam-se algumas características, tais como [9-11]:

- Comportamentos não estacionários.
- Sazonalidade diária e semanal.
- Variabilidade com o tipo de dia, seja um dia normal de semana, ou fim-de-semana, ou ainda ser um dia de feriado.
- Volatilidade e aleatoriedade.

Algumas metodologias de previsão a curto prazo baseiam-se em modelos estatísticos, como é o caso das séries temporais, inteligência artificial, entre outros, conforme se apresenta na Figura 1.3. Na pesquisa levada a cabo para a realização deste trabalho é visível que existem diversas técnicas e diversos modelos de elevado interesse.

As séries temporais são modelos que utilizam técnicas de previsão de valores futuros, utilizando valores passados e presentes da própria variável a prever, bem como, os erros associados.

Os modelos frequentemente encontrados na literatura especializada são os *Auto Regressive* (AR), ou Regressão Dinâmica, *Autoregressive Integrated Moving Average* (ARIMA), *Generalized Autoregressive Conditional Heteroskedastic* (GARCH) e o modelo *Wavelet-ARIMA*.

Apesar dos dois últimos representarem uma melhoria dos modelos iniciais, todos estes modelos apesar de fornecer resultados razoáveis, necessitam de um elevado número de parâmetros para modelar correctamente o sistema, apresentando tipicamente um tempo de computação elevado. No caso da previsão de potência eólica são normalmente utilizados métodos baseados em ANN e ARIMA, como referido em [12].

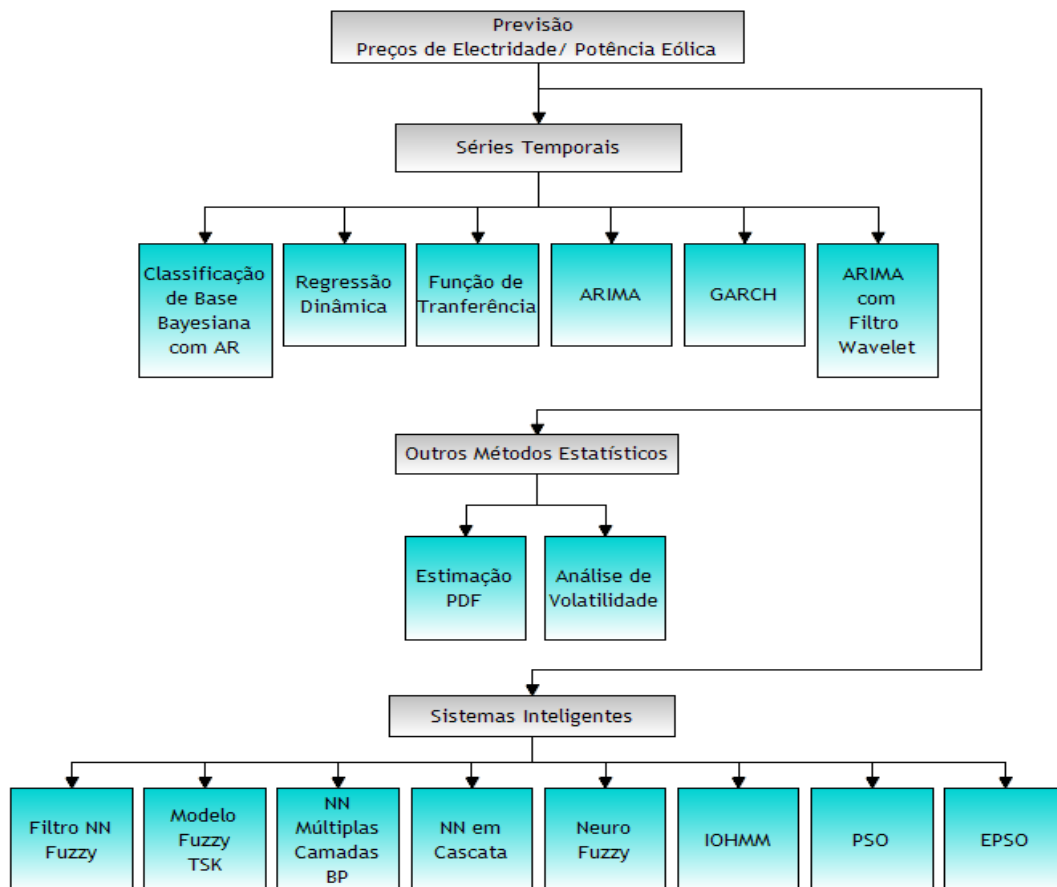


Figura 1.3 - Taxonomia das principais metodologias de previsão.

Os sistemas inteligentes são utilizados tanto na previsão de preços da energia eléctrica como na previsão da potência eólica. Estes modelos são computacionalmente mais eficientes e recorrem na sua grande maioria a uma quantidade inferior de parâmetros para desempenhar a sua função, pelo que se obtêm resultados favoráveis para a sua implementação.

De referir, ainda, que alguns dos métodos expostos na Figura 1.3 serão abordados e fundamentados em capítulos dedicados para o efeito.

## 1.4.1 Previsão da Potência Eólica

Com o elevado investimento na produção de electricidade a partir de fontes renováveis, em especial a eólica em Portugal, temos vindo a assistir nos últimos anos a uma cada vez mais elevada penetração da potência eólica na rede. Para a utilização deste tipo de energia é desejável a utilização de métodos que ajudem a sua previsão, visto que, o recurso eólico é altamente variável: volátil e intermitente.

Desde há alguns anos têm sido utilizados métodos computacionais com capacidade de simularem o comportamento da atmosfera, os quais por sua vez ajudaram a compreender e a criar modelos de persistência. Na actualidade são utilizados modelos estatísticos que podem ser combinados com modelos físicos e modelos inteligentes de previsão [19].

Como referido em [20], os modelos de previsão podem ser divididos em dois grandes grupos:

- Grupo 1, são aqueles que empregam nas previsões séries temporais e dados históricos;
- Grupo 2, são aqueles que utilizam na previsão outros dados numéricos e dados atmosféricos;

Os modelos utilizados pelo Grupo 1 recorrem a aproximações estatísticas para fazer a previsão da potência eólica. A relação estatística poderá ser modelada utilizando diferentes métodos que vão desde a análise de series temporais clássicas, até às técnicas computacionais inteligentes de previsão associadas às séries temporais.

Os modelos do Grupo 2 utilizam adicionalmente como variáveis de entrada os valores previstos por um modelo numérico de previsão meteorológica, a que correspondem certas variáveis, tais como, temperatura, luminosidade, humidade, pluviosidade e direcção do vento.

Estes dois grandes grupos destacam-se por:

- Modelos Físicos, baseiam-se nas leis físicas para a determinação da previsão e modelação do escoamento do ar, atribuindo parâmetros tais como orografia do terreno, rugosidade, e presença de obstáculos. São modelos computacionais que simulam o comportamento da atmosfera baseados nas leis da física. Estes modelos podem recorrer a modelos estatísticos para melhorar as suas performances. Contudo, as variáveis pelas quais são feitas as previsões também são dependentes de outras variáveis, tais como as características do gerador, os coeficientes de controlo das turbinas, entre outros.
- Modelos Estatísticos, baseiam-se na procura das relações entre os valores históricos da produção de energia eléctrica, isto é, os dados obtidos em tempo real. Estes modelos utilizam métodos baseados em redes neuronais e outros tipos de métodos de inteligência computacional. Possuem a vantagem de prescindir de modelos físicos, o que evita os elevados tempos de computação, não prescindindo, contudo, de uma cuidada estimação dos parâmetros, os quais estão interligados a um vasto conjunto de dados históricos [21].

### 1.4.2 Previsão dos Preços da Energia Eléctrica

Devido ao modelo de liberalização do sector eléctrico e da existência de mercados organizados, o reforço do desenvolvimento de diferentes métodos e técnicas de previsão dos preços da energia eléctrica apresenta-se como uma mais-valia num ambiente competitivo. As diversas características que podem ser encontradas nos preços de energia eléctrica, tais como a sazonalidade, volatilidade, entre outros, exigem a utilização de técnicas de previsão que se adaptem a tais características, e à semelhança do que acontece na previsão da potência eólica algumas técnicas de previsão a curto prazo baseiam-se em modelos estatísticos, tais como séries temporais, modelos econométricos e inteligência artificial.

Dos modelos anteriormente enunciados é necessário referir [22]:

- Modelos Estatísticos, que têm como principal objectivo a previsão dos preços da energia, tomando em consideração as suas características estatísticas e intervalo de confiança, permitindo ainda a análise da volatilidade.
  - Dentro dos modelos estatísticos encontram-se inseridos os modelos estatísticos locais, atenuando os factores internos e externos do país, tais como variáveis não controláveis (vento, pluviosidade, entre outros) e factores sociais (sazonabilidade, eventos, entre outros).

- Séries Temporais, que utilizam dados ocorridos no passado e no presente para a previsão de dados futuros, bem como os erros associados da variável utilizada para fazer previsão. Nestes modelos são frequentemente encontrados os modelos autoregressivos, e modelos híbridos baseados nos modelos autoregressivos. Estes modelos são frequentemente encontrados na literatura especializada, e encontram-se presentes na Figura 1.3
- Modelos Econométricos, que utilizam variáveis endógenas. Estes modelos regressivos apresentam, por sua vez, características dos métodos estatísticos, os quais são utilizados para relacionar variáveis de previsão. Da utilização destes modelos é possível obter:
  - Evolução temporal com base no histórico;
  - Regressão das variáveis aplicadas às séries temporais;
  - Previsão de uma variável em função de outras variáveis.

### 1.4.3 Classificação dos Horizontes Temporais

Na recolha de informação na literatura especializada, pode-se compreender que todas as ferramentas de previsão da potência eólica e preços da energia eléctrica são desenvolvidas ponderando um determinado horizonte temporal, o qual é classificado em três grandes grupos:

- Previsões de muito curto prazo, até 6 horas.
- Previsões de curto prazo, até 72 horas.
- Previsões de longo prazo, até algumas semanas.

Como referido em [23], os limites dos horizontes temporais não se encontram verdadeiramente definidos, visto que, alguns autores utilizam diferentes limites dos horizontes temporais na literatura especializada. Contudo, este problema passa pelas regras que são impostas nos mercados de energia eléctrica, já que estas variam de mercado para mercado, pelo que os horizontes temporais de previsão podem ser diferentes.

Para os preços da energia eléctrica é usualmente realizada a previsão para o dia seguinte ou para os próximos 7 dias.

## 1.5 Organização do Texto

A presente Dissertação será estruturada em 5 capítulos da seguinte forma:

- No capítulo 2 são apresentadas noções gerais sobre as energias renováveis, em especial a energia eólica, a constituição do SEN e o mercado da energia eléctrica.
- No capítulo 3 são apresentadas as metodologias que formam parte da nova metodologia híbrida proposta para a previsão dos preços da energia eléctrica e da potência eólica.
- No capítulo 4 são apresentados os resultados obtidos com a nova metodologia proposta, sendo comparado com resultados já reportados na literatura especializada, nomeadamente em revistas internacionais de referência.
- No capítulo 5 são apresentadas as conclusões deste trabalho, as contribuições e as ideias para trabalhos futuros.



## Capítulo 2

### 2.1 Energias Renováveis

Com a liberalização dos mercados eléctricos e o crescente aumento da produção de electricidade recorrendo às energias renováveis, os sistemas passaram a ter uma estrutura descentralizada devido à diversificação das formas de produção de electricidade.

Apesar da energia eólica ser a aposta mais procurada na produção de electricidade hoje em dia, devido aos factores já enunciados, isto é, maturidade do sistema, custo de implementação, entre outros, é difícil questionar qual será a tecnologia de produção de electricidade com recurso a energias renováveis que se destacará no futuro. Deve-se ter presente que todas as formas de produção de electricidade devem ser consideradas interdependentes, na perspectiva da diversificação da produção de electricidade, no desenvolvimento sustentável e na atenuação das alterações climáticas. O incentivo à produção de electricidade com base em energias renováveis visa diminuir a importação e consumo de combustíveis fósseis e, em consequência, atenuar os impactes ambientais e económicos associados a esse consumo, garantindo um aumento na segurança no fornecimento energético.

Contudo, a dificuldade no controlo sobre os padrões de produção nas energias renováveis deve ser salientada, sendo portanto necessário contar com outras formas de geração de energia eléctrica, controláveis, capazes de ir ao encontro entre geração e consumo, visando a garantia de fornecimento.

Assim, surgem algumas soluções, as quais se destacam:

- Previsão do comportamento dos padrões de produção e consumo de electricidade;
- Estudo de alternativas de armazenamento de energia, tais como na produção de hidrogénio, ar comprimido ou ainda o recurso futuro aos veículos eléctricos [24];

Portugal tem vindo a atingir as metas no que diz respeito a um aumento de produção de electricidade com recurso a fontes endógenas de energia, nas quais o vento se destaca não só pela sua abundância como também pela maturidade das tecnologias implementadas. Na Figura 2.1 é apresentada uma análise estatística da quota de electricidade gerada por cada recurso endógeno renovável, relativamente ao consumo total de electricidade em Portugal, a fim de atingir as metas traçadas pela União Europeia, conhecido pelo Objectivo 20/20/20.




Figura 2.1 - Quota de electricidade gerada por cada recurso renovável em Portugal [25].

A energia eólica tem registado nos últimos anos em Portugal um crescimento notável. As principais causas deste forte desenvolvimento são as seguintes:

- A publicação de legislação bem delineada, que promove o desenvolvimento de energias renováveis, focando a agilização de processos administrativos, incentivando a melhoria da gestão dos recursos, introduzindo ainda remunerações atractivas de venda de electricidade consoante o processo de produção ao nível renovável; em suma, trata-se do lançamento do Programa E4 de 2001;
- A aprovação de “Directivas das Renováveis”, cuja aplicação em Portugal levou o Governo a definir metas ambiciosas para a penetração de energias renováveis na rede, com especial destaque para energia eólica, prevendo uma potência instalada de 5100 MW em 2012 [24];

Portugal possui um grande dinamismo no sector eólico, registando-se um número de pedidos de licenciamento de novas instalações que excede largamente o potencial técnico do recurso eólico. A produção eólica pode ser medida através da utilização anual de potência nominal, pela medição das horas de funcionamento equivalente à potência nominal.

Na Figura 2.2 é apresentado o Atlas do Vento em Portugal Continental, o qual representa o número de horas de funcionamento equivalente à potência nominal (NEP's) a uma altura de 60 m em relação à superfície. Este Atlas representa o elevado potencial eólico que Portugal possui. Os dados remontam ao ano de 2004, sendo os estudos mais recentes de acesso mais restrito por parte do Instituto Nacional de Engenharia, Tecnologia e Inovação (INETI).

Apesar de não ser focado na Figura 2.2, Portugal também possui um potencial eólico considerável a nível da costa, o potencial dito *offshore*, como é referido em [24]. O grande desenvolvimento desencadeado pelo estudo e investimento em formas de captação de energia de forma mais eficiente por parte dos aerogeradores nas últimas décadas, e o aumento da potência unitária dos aerogeradores, faz com que a nível económico o impacte ambiental seja menor, na medida em que as infra-estruturas são optimizadas, e no futuro próximo será possível explorar o potencial *offshore* que Portugal Continental oferece.

Outras das razões que levam não só Portugal mas também um pouco por todo o Globo a implementar mais parques eólicos está relacionada com os custos de implementação. Em Portugal o investimento varia entre os 1000 e 1500 €/kW; estima-se que a potência injectada na rede pública com origem em parques eólicos seja remunerada num valor que se situa entre os 70 e 80 €/MW, durante um período de 15 anos, pelo que o retorno do investimento é relativamente rápido. Os estudos realizados referem que, para poder haver rentabilidade dos sistemas, estes têm de ser assegurados com um funcionamento igual ou superior às 2000 h anuais equivalente à potência nominal [24]. Como se pode observar na Figura 2.2, Portugal beneficia de boas condições para a produção eólica.

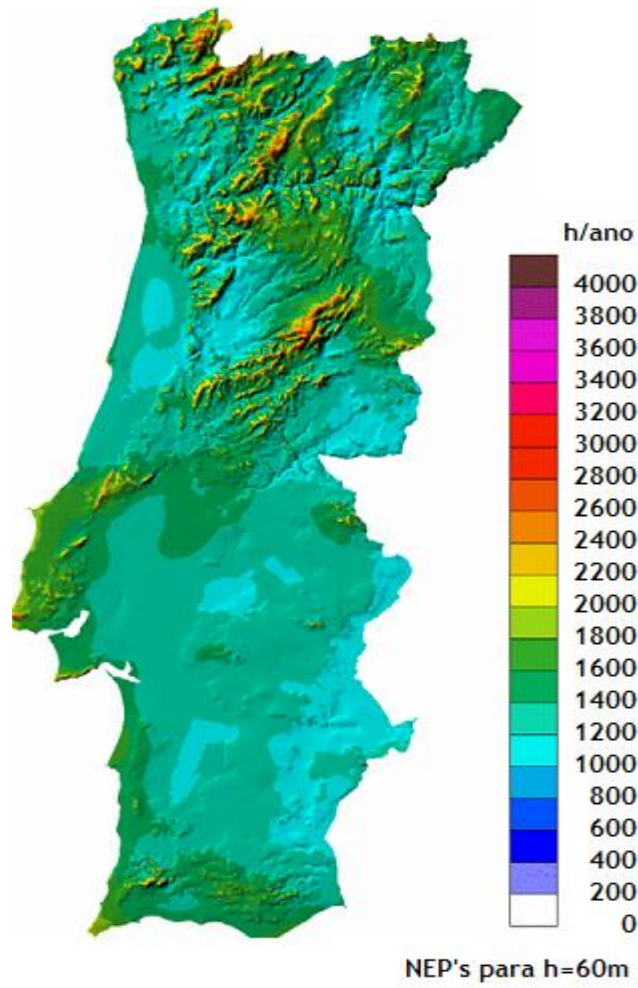


Figura 2.2 - Atlas Português do Vento *Onshore*, representando o NEP's à altura de 60m [26].

## 2.2 Sistema Eléctrico Nacional

Antes de se abordar a constituição do SEN deve-se referir que o sistema actual é fruto de uma profunda reestruturação efectuada desde 1995 até à actualidade. Resumidamente, apresenta-se em grandes traços a evolução concretizada no sector eléctrico:

- Primeira grande reestruturação em 1995.
  - Criação do SEN;
  - Coexistência de um serviço público e serviço eléctrico independente, o que induz a uma orientação numa lógica de mercado;
- Resolução do Conselho de Ministros N.º 169/2005.
  - Estabelece a liberalização mais alargada e promoção da concorrência nos mercados energéticos;
- Reforço das leis energéticas com o Decreto-Lei N.º 172/2006 e Decreto-Lei N.º 264/2007.
  - Estabelece princípios de organização e funcionamento do SEN;
  - Aplicação das regras gerais para a produção, transporte, distribuição e comercialização da energia;
  - Organização dos mercados de electricidade;
- Em contraposição ao Decreto-Lei N.º 182/95 estabelece-se um novo quadro definido por:
  - Um sistema eléctrico nacional integrado;
  - Actividades de produção e comercialização em regime de livre concorrência, mediante a atribuição de licenças;
  - Atribuição de concessões de serviço público de transporte e distribuição de electricidade [24];

Das medidas adoptadas e definidas ao longo destes últimos anos, a Figura 2.3 apresenta o esquema simplificado do SEN de acordo com o Decreto-Lei N.º 29/2006.

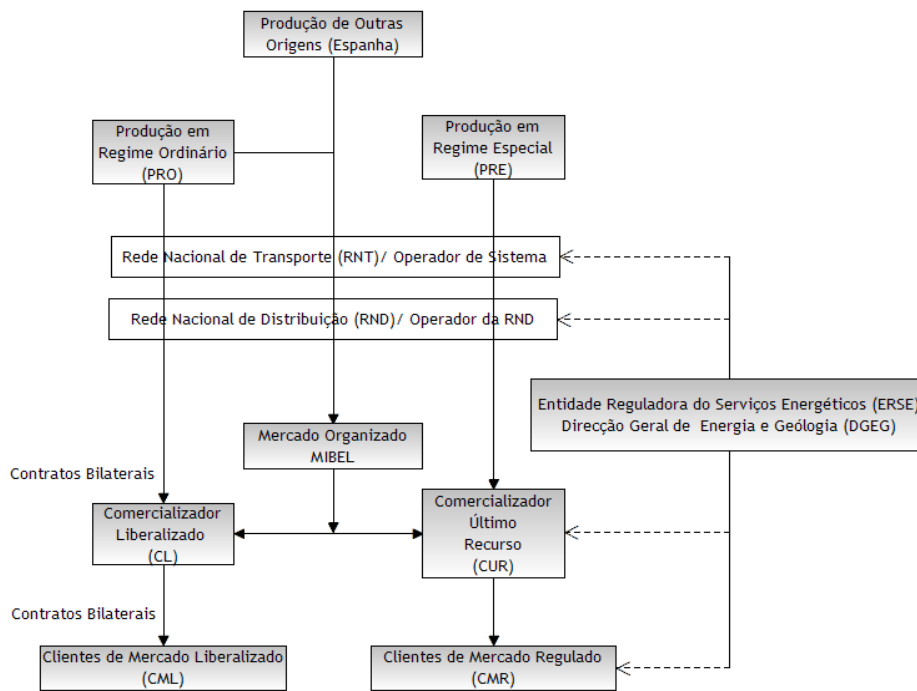


Figura 2.3 - Organização simplificada do SEN [24].

Da Figura 2.3 destacam-se os seguintes aspectos:

- Produção:
  - Produção em Regime Ordinário (PRO) é a produção de electricidade com base em fontes tradicionais, não renováveis de energia e em grandes hídricas;
  - Produção em Regime Especial (PRE) é relativa à co-geração e à produção de electricidade com base em fontes de energia renovável;
  - A produção é otimizada seguindo uma lógica de mercado e não numa produção centralizada.
  - O Estado é responsável pela criação de condições para o desenvolvimento do mercado de electricidade, garantindo o bom funcionamento do mercado, o abastecimento de electricidade, e a monitorização permanente do sector eléctrico. Também compete ao Estado promover através de concurso público as garantias necessárias para assegurar as capacidades de produção.
  - Os PRO podem vender electricidade através de contratos bilaterais com clientes finais e com comercializadores de electricidade, ou ainda participar em mercados organizados, neste caso o Mercado Ibérico de Electricidade (MIBEL).
  - Os PRE possuem o direito de vender a sua produção aos comercializadores de último recurso, ou através da participação em mercados organizados.
  - Ambos produtores podem ainda fornecer serviços de sistema, na celebração de contratos com o Operador de Sistema.

- Transporte:
  - Feito mediante a exploração da RNT, correspondendo a uma única concessão em regime de serviço público, ou seja, às Redes Energéticas Nacionais (REN).
  - Esta tem a responsabilidade de:
    - Fazer 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.
  - A RNT funciona como o Operador de Sistema.
- Distribuição:
  - Realizada através da exploração da Rede Nacional de Distribuição (RND), mediante a concessão em regime de serviço público do Estado pela EDP Distribuição;
  - Tem como principais responsabilidades assegurar a exploração, manutenção, condições de segurança, fiabilidade e qualidade de serviço;
  - Gere os fluxos de electricidade na rede de forma a garantir a interoperacionalidade entre as redes a que esteja ligada e com as instalações dos clientes;
  - Possui a função de Operador da Rede de Distribuição;
  - Pode relacionar-se comercialmente com os utilizadores da rede;
  - Tem o direito a ser retribuída por tarifas reguladas;
  - Não pode adquirir electricidade para comercialização;
- Comercialização: É uma actividade livre, ficando apenas sujeita à atribuição de licenças onde se definem os direitos e deveres de forma a haver transparência do exercício. A actividade de comercialização de electricidade consiste na compra e venda de electricidade com fins de comercialização a clientes finais ou outros agentes, bem como na participação de outros mercados ou ainda na celebração de contratos bilaterais.
  - Os comercializadores podem livremente comprar e vender electricidade.
  - Os comercializadores têm acesso mediante o pagamento de tarifas reguladas às redes de transporte e distribuição de electricidade;
  - Os consumidores são protegidos pelos Comercializadores de Ultimo Recurso (CUR) cujas responsabilidades são:
    - Garantia do fornecimento em condições de qualidade e continuidade;
    - Protecção dos utilizadores no que concerne a tarifas e preços;
    - Dever de aquisição obrigatória da electricidade PRE;
    - Pode adquirir electricidade em mercados organizados MIBEL;
    - Pode adquirir electricidade mediante a celebração de contratos bilaterais, realização de concursos ou em leilões;

- O principal CUR é a EDP Serviço Universal.
- Regulação e Segurança do Abastecimento:
  - À Entidade Reguladora dos Serviços Energéticos (ERSE) compete regular as actividades de transporte, distribuição, comercialização de electricidade de último recurso e da operação logística da mudança de comercializador;
  - A segurança do abastecimento é monitorizada e garantida pela Direcção Geral de Energia e Geologia (DGEG), agente do Estado [24].

## 2.3 Mercado de Energia Eléctrica

Na Figura 2.4 é apresentado o esquema e organização do MIBEL, no qual a sua regularização é garantida pela ERSE, do lado português, e pela *Comisión Nacional de Energía* (CNE), do lado espanhol. Todos os agentes que constituem o MIBEL estão sujeitos a supervisão, de forma a tornar transparente e concorrencial a sua actividade. O MIBEL é um mercado liberalizado onde os preços da energia eléctrica adquirem um comportamento volátil e incerto, já que estes são determinados através das ofertas de compra e venda de electricidade.

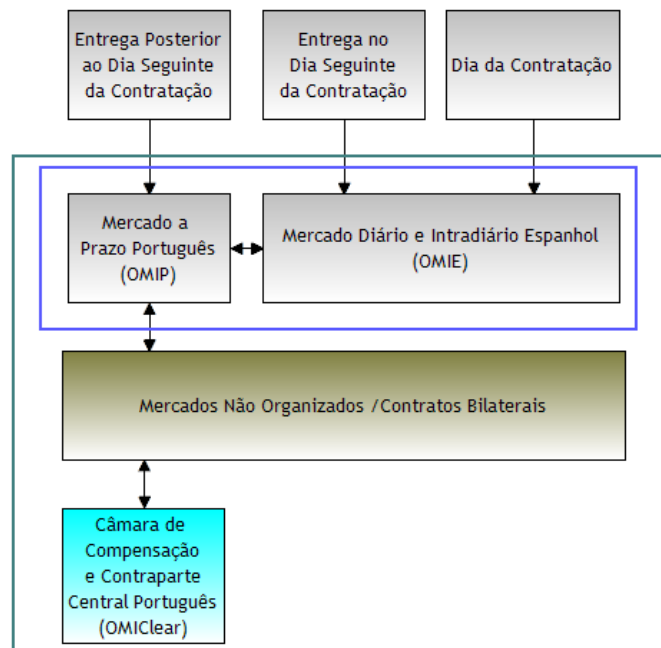


Figura 2.4 - Organização geral do MIBEL e operadores de mercado [27].

O mercado processa-se da seguinte forma [28]:

- O mercado inicia-se no dia  $d - 1$  onde são apresentadas ao operador de mercado as propostas de compra e venda de electricidade até às 11h;
- Entre as 11h e as 14h do mesmo dia são definidos os despachos horários para o dia  $d$ ,<sup>3</sup> tomando em consideração os contratos bilaterais e restrições técnicas que são coordenados pelos operadores de mercado e sistema;
- No período das 14h às 16h decorre o mercado de serviços auxiliares que são controlados pelo operador de sistema;
- Por último, segue-se a introdução de mercados intra-diários que decorrem ao longo do dia  $d$  para o ajuste final entre a produção e o consumo.

Deve-se ainda referir que o MIBEL é organizado em seis mercados intra-diários [24]:

- Intra-diário 1 corresponde às previsões realizadas para as 28 horas seguintes do dia  $d$ ;
- Intra-diário 2 corresponde às previsões realizadas para as 24 horas seguintes do dia  $d$ ;
- Intra-diário 3 corresponde às previsões realizadas para as 20 horas seguintes do dia  $d$ ;
- Intra-diário 4 corresponde às previsões realizadas para as 17 horas seguintes do dia  $d$ ;
- Intra-diário 5 corresponde às previsões realizadas para as 13 horas seguintes do dia  $d$ ;
- Intra-diário 6 corresponde às previsões realizadas para as 9 horas seguintes do dia  $d$ ;

Nas ferramentas de previsão podem ser considerados diversos factores [28]:

- Factores Económicos, que são influenciados pelo tipo de consumidor, factores geográficos, entre outros;
- Factores Temporais, influenciados pelos efeitos sazonais, semanais, fins-de-semana e feriados;
- Factores Meteorológicos, como a temperatura que afectam os padrões de consumo no inverno e no verão ao longo do ano. Os índices de precipitação e de humidade, condições adversas tais como tempestades, e ainda índices de vento e luminosidade;

---

<sup>3</sup> O dia  $d$  é definido como o dia em que se utiliza a previsão dada pelo dia  $d - 1$ .

- Distúrbios Aleatórios, alterações abruptas no comportamento da indústria e no quotidiano da sociedade devido a um evento marcante;
- Volatilidade dos Preços da Energia Eléctrica, os quais são condicionados pelos seguintes factores:
  - Variação do preço das energias primárias de produção, como gás natural, *fuel*, entre outros;
  - Incerteza da carga;
  - Flutuações na produção hidroeléctrica;
  - Incerteza na produção;
  - Congestionamento do transporte;
  - Manipulação do mercado;
  - Comportamento dos intervenientes no mercado com base na antecipação do preço, e possibilidade da ocorrência de *prices spikes*<sup>4</sup>;
- Outros Factores, tais como padrões de consumo em diferentes zonas; por exemplo, uma zona rural apresenta padrões de consumo muito diferentes a uma zona urbana.

As metodologias de previsão auxiliam na decisão e o agendamento da produção de electricidade, o que aumenta as garantias de maior segurança nos sistemas de geração, e por último ajudam controlar os sistemas de reserva, os quais permitem atenuar as falhas do sistema, como é o caso do armazenamento de energia através da bombagem<sup>5</sup>.

---

<sup>4</sup> Considera-se *Prices Spikes* um comportamento abrupto do preço da energia eléctrica devido a factores económicos ou mesmo da dinâmica do mercado de electricidade, originando momentos de subida significativa dos preços ou de desvalorização significativa.

<sup>5</sup> Refere-se a Bombagem ao processo de transportar água de jusante para montante de forma a armazenar energia sob a forma de energia potencial.



## Capítulo 3

### 3.1 Redes Neurais

As redes neuronais ou *Neural Networks* (NN) são métodos computacionais que se baseiam em algoritmos matemáticos desenvolvidos para simular e assemelhar-se ao desempenho do cérebro humano, ou seja, é uma estrutura capaz de apreender através da experiência. Este método surgiu em 1943 nos EUA pelos cientistas *Warren McCulloch* e *Walter Pitts*.

Também designadas por Redes Neuronais Artificiais (RNA), estes cientistas simularam o comportamento do neurónio biológico, no qual o neurónio artificial possuía apenas uma saída, que era uma função soma de valores das suas diversas entradas. Entende-se que se tratava de um neurónio simples. O trabalho consistiu em desenvolver um modelo de resistências variáveis e amplificadores, que representavam ligações sinápticas de um neurónio biológico. Após os desenvolvimentos tecnológicos que se tem vindo a assistir, nomeadamente com a evolução dos computadores, começou-se a encarar estas máquinas como “inteligentes”, consignando assim a capacidade de inteligência à máquina, inteligência esta que era tradicionalmente atribuída ao homem.




Figura 3.1 - Constituição de um neurónio [29].

Os neurónios são as células fundamentais do cérebro humano estimando-se que existe na constituição do cérebro uma população de cerca de  $10^{11}$  neurónios. Estes são caracterizados em três componentes: o corpo celular, as dendrites e o axónio, como é apresentado na Figura 3.1. A informação do neurónio é transmitida por pequenos impulsos electroquímicos que são recebidos através das dendrites e passados para o corpo celular, posteriormente para o axónio, seguindo para o próximo neurónio através da conexão entre axónios e as dendrites, designado por sinapse, formando assim uma rede de neurónios [30].

As NNs apresentam várias vantagens, já que se baseiam na estrutura do sistema nervoso humano, nomeadamente o cérebro, realizando diversas tarefas em tempo útil para um volume elevado de dados. Destacam-se as seguintes vantagens [30]:

- Aprendizagem, fase na qual se fornece os dados à entrada do sistema, designando-se assim por fase de aprendizagem, que por sua vez dará uma resposta na saída.
- Auto-Organização, processo no qual as NNs criam a sua própria representação de informação no seu interior.
- Tolerância a Falhas, já que uma NN armazena informação de forma redundante, mesmo que esteja parcialmente danificada, ou a própria informação de entrada seja incompleta, podendo dar uma resposta aceitável.
- Flexibilidade, uma NN pode adaptar-se à medida que novos dados são introduzidos.
- Trabalho em Tempo Real, já que uma NN é uma estrutura paralela, o que permite realizar tarefas complexas num espaço temporal curto.
- Não Linearidade, o que permite uma modelação não linear.

Na utilização de NNs para a previsão estão envolvidos, como foi abordado, dois processos: - o treino e a aprendizagem. O processo de treino pode ser realizado sob a supervisão do utilizador, que assume a existência de um conjunto de treino obtido através de dados históricos válidos, contendo ainda as entradas e correspondentes saídas de forma a obter o sucesso pretendido do treino. No processo de aprendizagem, também supervisionado, as NNs aprendem a partir do conjunto de treino constituído pelos pares entrada/saída, ajustando os pesos e as polarizações em cada iteração de forma a minimizar uma determinada medida de erro imposta pelo utilizador, entre a saída prevista e a saída desejada. Este processo iterativo assume uma paragem quando o critério de paragem é alcançado [31]. O algoritmo de treino mais popular utilizado nas NNs será descrito posteriormente.

Analogamente aos neurónios biológicos, as NNs são constituídas por uma ou mais camadas interligadas por um grande número de ligações, designado por perceptrão. Cada ligação é associada a um valor numérico, isto é, um peso, que caracteriza a força da ligação entre dois neurónios e representa também o conhecimento armazenado na ligação. A aprendizagem de uma NN é feita através do processo de adaptação dos seus pesos sinápticos [30].

O modelo apresentado na Figura 3.2 recebe um vector  $x_i$  de dimensão  $n$ , o qual corresponde a um valor real  $y$ . O valor atribuído a  $y$  está dependente do vector dos pesos  $[w_0 w_1 \dots w_n]$  e da função de activação escolhida  $F(\cdot)$ . A estrutura possui ainda uma entrada específica  $x_0$  designada por viés, a qual permite deslocar a função de activação. No caso de o viés ser negativo, a soma das entradas tem de superar o seu valor para que o neurónio produza um valor positivo à saída [31].




Figura 3.2 - Constituição de um neurónio artificial [31].

Assim, os valores presentes nas entradas do neurónio são expressos pela equação:

$$s = \sum_{i=1}^n w_i x_i + w_0 \quad (3.1.1)$$

Após o resultado obtido da expressão anterior, este valor passa por uma função designada por função de activação, que é normalmente uma função não linear, produzindo assim a saída do neurónio. Esta função descreve o modelo do perceptrão que genericamente é dado pela expressão:

$$y = F \left( \sum_{i=1}^n w_i x_i + w_0 \right) \quad (3.1.2)$$

As funções de activação são tipicamente funções monótonas e crescentes, verificando-se a excepção da função de activação linear, com as seguintes propriedades:

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

As formas mais utilizadas das funções de activação em redes neuronais são:

- Função Linear:

$$F(s) = \beta \cdot s \quad (3.1.3)$$

- Função Degrau Unitário:

$$F(s) = \begin{cases} \beta_2, & s \geq 0 \\ \beta_1, & s < 0 \end{cases}, \beta_1 \text{ Pode assumir o valor } 0 \text{ ou } -1. \quad (3.1.4)$$

- Função Rampa Unitária:

$$F(s) = \begin{cases} \beta, & s \geq \beta \\ s, & |s| < \beta \\ -\beta, & s \leq -\beta \end{cases} \quad (3.1.5)$$

- Função Sigmóide:

$$F(s) = \frac{1}{1 + e^{-\lambda s}} \quad (3.1.6)$$

- Função Tangente Hiperbólica:

$$F(s) = \frac{e^{\lambda s} - e^{-\lambda s}}{e^{\lambda s} + e^{-\lambda s}} \quad (3.1.7)$$

A Figura 3.3 apresenta graficamente as funções de activação usualmente utilizadas nas NNs, anteriormente descritas; no caso de previsões de séries temporais são mais adequadas as funções da tangente hiperbólica e função linear para a camada escondida e camada de saída, respectivamente.

Devido à limitação da utilização de apenas um perceptrão, pela teoria criada por Rosenblatt na década de 1950, os problemas deveriam ser linearmente separáveis, ou seja, o perceptrão apenas seria capaz de resolver problemas com um grau de complexidade relativamente baixo [32].

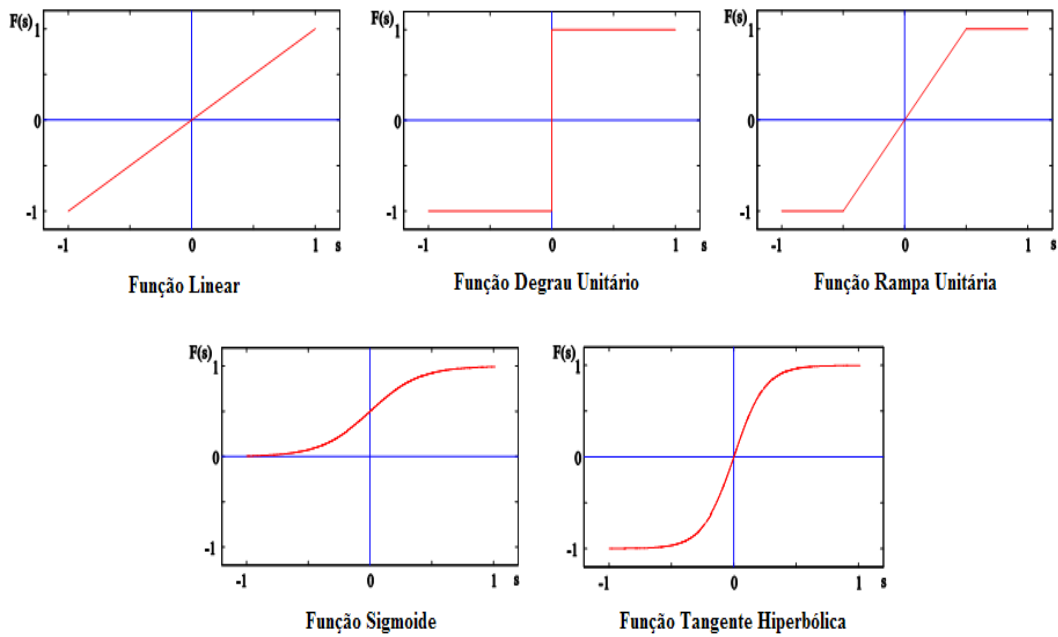


Figura 3.3 - Exemplos de funções de activação [22].

Assim, torna-se necessário implementar um sistema multicamada, também designado por perceptrão multicamada, na qual a interligação das entradas à camada de saída terá pelo menos uma camada de neurónios intermédia, designada por camada escondida, eliminando desta forma a limitação apresentada pelo modelo de Rosenblatt, ampliando o universo de soluções possíveis no qual estes sistemas podem trabalhar, ou seja, poderão resolver problemas que não são linearmente separáveis [32]. Na Figura 3.4 é apresentado o esquema de um sistema de perceptrão multicamada [30].

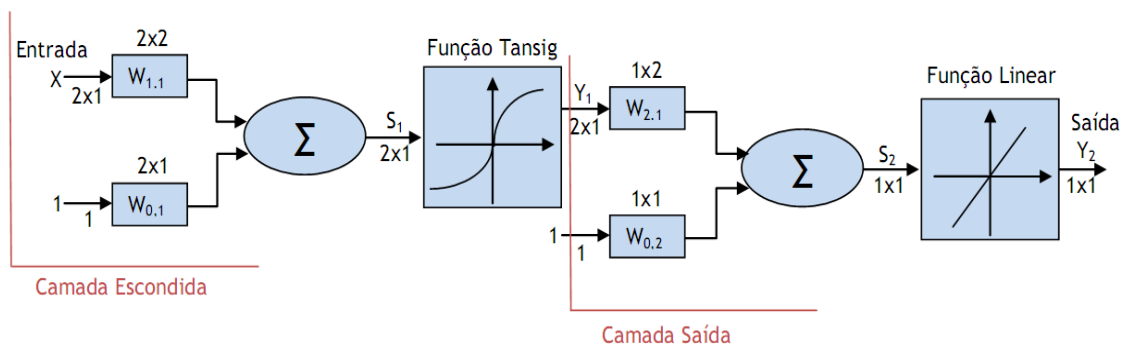


Figura 3.4 - Exemplo de um perceptrão multicamada [30].

Na entrada à NN encontra-se um vector de dois elementos dado por:

$$x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad (3.1.8)$$

Também associado a entrada anterior, encontram-se as matrizes que atribuem os pesos de cada ligação, designadamente:

$$w_{0,1} = \begin{bmatrix} w_{0,1}^1 \\ w_{0,1}^2 \end{bmatrix}, \quad w_{1,1} = \begin{bmatrix} w_{1,1}^{1,1} & w_{1,1}^{1,2} \\ w_{1,1}^{2,1} & w_{1,1}^{2,2} \end{bmatrix} \quad (3.1.9)$$

Aplicando álgebra linear, o valor resultante da soma dos valores atribuídos à entrada pelos respectivos pesos será:

$$s_1 = \begin{bmatrix} w_{1,1}^{1,1} & w_{1,1}^{1,2} \\ w_{1,1}^{2,1} & w_{1,1}^{2,2} \end{bmatrix} \cdot \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \begin{bmatrix} w_{0,1}^1 \\ w_{0,1}^2 \end{bmatrix} \Leftrightarrow s_1 = \begin{bmatrix} s_1^1 \\ s_1^2 \end{bmatrix} \quad (3.1.10)$$

Neste exemplo a saída atribuída à camada escondida possui a função de activação designada por tangente hiperbólica, que se traduz algebricamente pela expressão:

$$y_1 = \text{tansig} \left( \begin{bmatrix} s_1^1 \\ s_1^2 \end{bmatrix} \right) \Leftrightarrow y_1 = \begin{bmatrix} y_1^1 \\ y_1^2 \end{bmatrix} \quad (3.1.11)$$

No próximo passo, os resultados provenientes da camada escondida serão enviados à camada de saída a qual possui também uma função de activação, tipicamente uma função linear, a qual dará uma matriz que irá corresponder aos pesos sinápticos de cada ligação. Define-se como:

$$w_{0,2} = [w_{0,2}^1], \quad w_{2,1} = [w_{2,1}^{1,1} w_{2,1}^{1,2}] \quad (3.1.12)$$

O valor resultante da soma dos valores atribuídos à entrada da camada de saída pelos seus respectivos pesos é dado pela expressão:

$$s_2 = [w_{2,1}^{1,1} w_{2,1}^{1,2}] \cdot \begin{bmatrix} y_1^1 \\ y_1^2 \end{bmatrix} + [w_{0,2}^1] \Leftrightarrow s_2 = [s_2^1] \quad (3.1.13)$$

Por último, é determinado através da função de activação linear o valor da matriz da camada de saída, dado pela expressão:

$$y_2 = \text{linear}([s_2^1]) \quad (3.1.14)$$

Torna-se agora necessário nas NNs determinar o seu tamanho mais adequado para se obter um desempenho satisfatório e uma capacidade adequada de generalização. Esta generalização nas NNs é imposta pelos seguintes factores:

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

Assim, para resolver um determinado problema os dois primeiros pontos podem ser avaliados e analisados, visto que, o problema a resolver poderá ser abordado de duas formas distintas:

- Fixar a arquitectura e o tamanho da NN, sendo determinado o conjunto de treino.
- Fixar o conjunto de treino da NN e escolher uma arquitectura com melhor desempenho.

No caso em que a extensão dos dados é de grau elevado, a segunda opção torna-se mais viável. Como foi referido, é extremamente importante fazer a escolha adequada do número de neurónios da camada escondida, já que no caso de não ser bem dimensionada, isto é, com uma aplicação excessiva de neurónios, leva o sistema a criar um *overfitting*, isto é, a memorizar os padrões de treino em vez de extrair as características gerais que permitem a generalização ou o reconhecimento de padrões não observados durante o treino. No caso análogo, se tivermos poucos neurónios na camada escondida, o sistema irá desencadear um *underfitting*, ou seja, o sistema não irá dar os resultados que se esperam, divergindo assim durante o treino [32].

Assim, o dimensionamento da camada escondida pode ser dado pela expressão que se segue, a qual é uma equação dependente do número de entradas [33].

$$N_{\text{escondidas}} = 2N_{\text{entradas}} + 1 \quad (3.1.15)$$

sendo:

- $N_{\text{escondidas}}$  o número de neurónios que constituem a camada escondida.
- $N_{\text{entradas}}$  o número de entradas na NN.

A Figura 3.5 apresenta uma estrutura típica de uma NN [33], onde se representa a entrada designada por um vector  $x$ , uma camada escondida e um conjunto de saída definido por um vector  $y$ . Esta estrutura é normalmente designada por percepção multicamada.




Figura 3.5 - Estrutura de uma rede neuronal.

### 3.1.1 Algoritmos de Aprendizagem Utilizados

Existem diferentes algoritmos de aprendizagem, uns mais eficientes que outros, nomeadamente no que respeita ao tempo útil de execução da previsão, ou seja, à complexidade do sistema a implementar. Deve-se ter também a noção de que, consoante o espaço temporal ao qual é necessário fazer a previsão, existem algoritmos de aprendizagem mais adequados do que outros, o que se traduz numa resposta do sistema em tempo útil mais fiável.

De entre os algoritmos mais populares, destaca-se o Algoritmo da Retro Propagação do Erro. Este algoritmo baseia-se no seguinte conceito: - Os dados recolhidos pela camada de entrada são propagados até a camada de saída [32]. Assim, o algoritmo pode ser descrito da seguinte forma:

- A saída prevista pelo sistema é comparada com a saída desejada para avaliar o erro, que é retro propagado ao longo das várias camadas.
- Cada unidade da camada escondida recebe apenas uma fracção do erro, que é proporcional à contribuição relativa dessa unidade na elaboração da saída prevista.
- Os pesos e polarizações são actualizados progressivamente visando a minimização da soma do quadrado dos erros, podendo ser utilizado o método do gradiente nessa minimização.

Contudo, apesar da sua simplicidade, o algoritmo da Retro Propagação exige um tempo de computação significativo, não garantindo sempre a convergência para o mínimo global.

Outro método utilizado na aprendizagem do sistema é o método de Levenberg-Marquardt, que corresponde a uma actualização do método de Newton, sendo 10 a 100 vezes mais rápido que o método da Retro Propagação do Erro, garantindo uma melhor convergência dos resultados [33]. Este método corresponde a um processo iterativo que visa a minimização de uma função  $\Omega$  através da seguinte equação de actualização:

$$\Delta y = -[\nabla^2 \Omega(y)]^{-1} \nabla \Omega(y) \quad (3.1.16)$$

onde  $\nabla^2 \Omega$  corresponde à matriz Hessiana  $H$ , e  $\nabla \Omega$  corresponde ao vector do gradiente  $g$ . Assumindo que a função  $\Omega$  determina a soma do quadrado dos erros, esta expressão é definida por:

$$\Omega(y) = \sum_{k=1}^K e_k^2(y) \quad (3.1.17)$$

Seja  $e_K$  o vector dos erros e  $J$  a matriz Jacobiana definida como sendo:

$$J(y) = \begin{bmatrix} \frac{\partial e_1(y)}{\partial y_1} & \frac{\partial e_1(y)}{\partial y_2} & \dots & \frac{\partial e_1(y)}{\partial y_k} \\ \frac{\partial e_2(y)}{\partial y_1} & \frac{\partial e_2(y)}{\partial y_2} & \dots & \frac{\partial e_2(y)}{\partial y_k} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_K(y)}{\partial y_1} & \frac{\partial e_K(y)}{\partial y_2} & \dots & \frac{\partial e_K(y)}{\partial y_k} \end{bmatrix} \quad (3.1.18)$$

obtêm-se:

$$\nabla \Omega(y) = 2J^T(y)e(y) \quad (3.1.19)$$

$$\nabla^2 \Omega(y) = 2J^T(y)J(y) + 2S(y) \quad (3.1.20)$$

Dado que a matriz  $S$  é definida como sendo:

$$S(y) = \sum_{k=1}^K e_k(y) \nabla^2 e_k(y) \quad (3.1.21)$$

desprezando as segundas derivadas dos erros, ou seja, considerando que  $\mathbf{S} \approx \mathbf{0}$ , a matriz Hessiana define-se como sendo:

$$\nabla^2 \Omega(\mathbf{y}) = 2\mathbf{J}^T(\mathbf{y})\mathbf{J}(\mathbf{y}) \quad (3.1.22)$$

Substituindo a expressão (3.1.22) e (3.1.19) na expressão (3.1.16) obtém-se a equação de actualização do método de Gauss-Newton, definida como:

$$\Delta\mathbf{y} = -[\mathbf{J}^T(\mathbf{y})\mathbf{J}(\mathbf{y})]^{-1}\mathbf{J}^t(\mathbf{y})\mathbf{e}(\mathbf{y}) \quad (3.1.23)$$

A vantagem deste método em comparação com o método de Newton reside no facto de se desprezar o cálculo das segundas derivadas do vector dos erros, as quais podem ser difíceis de obter. Contudo, este método apresenta uma desvantagem, que pode ser ultrapassada pelo método de Levenberg-Marquardt, e que reside no facto da matriz  $\mathbf{J}^T(\mathbf{y})\mathbf{J}(\mathbf{y})$  poder não ser invertível. Como tal, o método de Levenberg-Marquardt propõe a seguinte expressão que substituirá a expressão (3.1.23), definida como [32]:

$$\Delta\mathbf{y} = -[\mathbf{J}^T(\mathbf{y})\mathbf{J}(\mathbf{y}) + \varsigma\mathbf{I}]^{-1}\mathbf{J}^t(\mathbf{y})\mathbf{e}(\mathbf{y}) \quad (3.1.24)$$

## 3.2 Lógica Difusa

A lógica *fuzzy* ou lógica difusa foi desenvolvida por Lotfi Zadeh em 1965 com o intuito de encontrar um equilíbrio entre a imprecisão e incerteza contidas na informação do quotidiano, isto é, dar resposta a informação vaga à qual a teoria das probabilidades não consegue responder. Esta teoria dá um leque maior de resposta em comparação à lógica bivalente (lógica binária) [34]. Por outras palavras, esta teoria tenta responder, por exemplo, quão escuro um dado objecto é, e não dizer que esse dado objecto é somente claro ou somente escuro, atribuindo para tal um conjunto de parâmetros que permitem quantificar o nível de tonalidade desse objecto.

Actualmente, esta teoria é largamente utilizada na indústria; exemplo disso é o controlo de processos complexos na automação, entre outros. Para além disso, têm sido utilizados em sistemas híbridos para a previsão.

Esta ferramenta baseia-se num controlador lógico condicional, isto é, um controlador que funciona de forma a lidar com dados de ordem ordinária, utilizados naturalmente na linguagem do dia-a-dia. Esse conjunto de possíveis resultados, apesar de inicialmente não possuir uma visão bem definida, irá ser interpretado por um conjunto de termos linguísticos e regras que definem o resultado do problema de forma definida. Uma das formas de definir esses termos e regras é fazer uso da combinação da lógica difusa com NN, o que se irá referir posteriormente.

### 3.2.1 Conceitos Fundamentais

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

Assim, a função de pertença  $\mu_A(x)$  pode ser descrita pelo grau de compatibilidade entre o discurso do universo definido por  $A$  e o elemento  $x$  seguindo as seguintes propriedades e restrições [34,35]:

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

Comparativamente com a lógica difusa pode-se ainda afirmar que existe uma diferença evidente no que diz respeito à compatibilidade da função na lógica bivalente [35]:

$$\mu_A(x) = \begin{cases} 1, & \text{se } x \in A \\ 0, & \text{caso contrario} \end{cases} \quad (3.2.1)$$

Têm-se, assim, as condições necessárias para definir os domínios nos quais um dado conjunto difuso pode operar, isto é, no domínio contínuo ou discreto. Deve-se salientar que a notação dos dois domínios são distintos entre si e que os operadores de somatório e integral não devem ser entendidos como sendo operadores algébricos, mas sim como distinção dos domínios que se está a estudar, destacando-se [35]:

- No caso de tratar-se de informação no domínio contínuo:

$$A = \int_{\Omega} \mu_A(x)/x \quad (3.2.2)$$

- No caso de tratar-se de informação no domínio discreto:

$$A = \sum_{i=1}^n \mu_A(x_i)/x_i \quad (3.2.3)$$

No que toca ao tratamento e interpretação entre conjuntos, isto é, dado um conjunto  $A$  e um conjunto  $B$  os quais pertencem a um universo  $\Omega$ , os conjuntos difusos deverão ainda ter presente o seguinte [34, 35]:

- Os conjuntos difusos terão obrigatoriamente estar contidos e sujeitos à condição  $A, B \in \Omega$ .
- Dois conjuntos difusos são iguais entre si, só e só se é satisfeita a condição:

$$\mu_A(x) = \mu_B(x), \quad \forall x \in \Omega \quad (3.2.4)$$

- $A$  é um sub-conjunto de  $B$ , só e só se:  $\mu_A(x) \leq \mu_B(x), \forall x \in \Omega$ . Fala-se assim de pertença de subconjuntos difusos, o qual ainda se pode escrever como sendo  $A \subseteq B$ .
- $\bar{A}$  diz-se complemento de  $A$  quando:

$$\forall x \in \Omega, \mu_{\bar{A}}(x) = 1 - \mu_A(x) \quad (3.2.5)$$

- Diz-se que os conjuntos difusos  $A$  e  $B$  são intersectados quando se garante a expressão:

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\}, \quad \forall x \in \Omega \quad (3.2.6)$$

- Analogamente, diz-se que os conjuntos difusos  $A$  e  $B$  são unidos quando se garante a expressão:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\}, \quad \forall x \in \Omega \quad (3.2.7)$$

Para melhor compreensão da lógica difusa, expõe-se de forma simples o seguinte problema: considere um conjunto difuso  $A$  que representa a potência eólica cujos valores estão compreendidos entre 10 e 50 MW; considere, também, que o conjunto difuso  $B$  representa um pequeno conjunto de turbinas eólicas desse parque cuja potência total é de 9 MW. Pretende-se:

- Representar graficamente os conjuntos difusos.
- Determinar e representar o complemento do conjunto difuso  $A$ .
- Determinar e representar o resultado  $A \cap B$  e  $A \cup B$ .

Resolução do problema: na Figura 3.6 é apresentada a representação dos conjuntos difusos acima descritos, considerando que sofreram de fuzificação, processo que se irá abordar posteriormente.




Figura 3.6 - Representação de conjuntos difusos.

Para determinar e representar o complemento do conjunto difuso  $A$  considera-se um conjunto de pontos representados na Figura 3.6; no entanto, para melhor compreensão, a representação gráfica do resultado é apresentada na Figura 3.7:

$$\mu_{\bar{A}}(x) = 1 - \mu_A(x)$$

$$\left\{ \begin{array}{ll} \text{Pontos A e B,} & \mu_{\bar{A}}(x) = 1 - \mu_A(x) = 1 - 0 = 1 \\ \text{Pontos C e D,} & \mu_{\bar{A}}(x) = 1 - \mu_A(x) = 1 - 0.5 = 0.5 \\ \text{Pontos E e F,} & \mu_{\bar{A}}(x) = 1 - \mu_A(x) = 1 - 1 = 0 \end{array} \right.$$

Para determinar e representar o resultado gráfico da intersecção (ver Figura 3.7), dos dois conjuntos difusos, considera-se da mesma forma o conjunto de pontos, representados na Figura 3.6, tendo-se:

$$\mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\}$$

$$\begin{cases} \text{Pontos } A \text{ e } A', & \mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} = \{0/A, 0/A'\} = 0 \\ \text{Pontos } E \text{ e } E', & \mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} = \{1/E, 1/E'\} = 1 \\ \text{Pontos } C \text{ e } C', & \mu_{A \cap B}(x) = \min\{\mu_A(x), \mu_B(x)\} = \{0.5/C, 0/C'\} = 0 \end{cases}$$

Para determinar e representar o resultado gráfico da união (ver Figura 3.7), ao considerar-se os mesmos pontos da Figura 3.6 obtém-se:

$$\mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\}$$

$$\begin{cases} \text{Pontos } A \text{ e } A', & \mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} = \{0/A, 0/A'\} = 0 \\ \text{Pontos } E \text{ e } E', & \mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} = \{1/E, 1/E'\} = 1 \\ \text{Pontos } C \text{ e } C', & \mu_{A \cup B}(x) = \max\{\mu_A(x), \mu_B(x)\} = \{0.5/C, 0/C'\} = 0.5 \end{cases}$$

Na Figura 3.7 são apresentados os resultados gráficos obtidos para os pontos anteriormente calculados.




Figura 3.7 - Resultados obtidos da aplicação das propriedades da lógica difusa.

Algumas das principais propriedades da lógica difusa [35] são:

- Normalização, Diz-se que o conjunto  $A$  é normalizado quando contém um elemento com grau de pertença igual a 1, ou seja,

$$\exists x \in \Omega: \mu_A(x) = 1 \rightarrow \text{Normalização}(A) = \frac{\mu_A(x)}{\text{Altura}(x)} \quad (3.2.8)$$

- Altura, define-se pelo supremo da função de pertinência de  $A$ , ou seja,

$$Altura(A) = \sup_{x \in \Omega} \mu_A(x) \quad (3.2.9)$$

- Suporte, existe quando o conjunto da função de pertinência de  $A$  é maior que zero, ou seja,

$$Suporte(A) = \{x \in \Omega: \mu_A(x) > 0\} \quad (3.2.10)$$

- Núcleo, são todos os elementos do domínio  $\Omega$  que pertencem ao conjunto  $A$ , cujo grau de pertinência seja unitário. Matematicamente tem-se:

$$Núcleo(A) = \{x \in \Omega: \mu_A(x) = 1\} \quad (3.2.11)$$

- Corte- $\alpha$ , define-se como sendo o conjunto de elementos de  $A$  cuja função de pertinência seja maior ou igual a  $\alpha \in [0, 1]$ , isto é,

$$corte - \alpha(A) = \{x \in \Omega: \mu_A(x) \geq \alpha\} \quad (3.2.12)$$

- Diz-se que um conjunto  $A$  é unimodal quando a sua função de pertinência tem apenas um máximo.

Contudo, a teoria difusa usufrui ainda das seguintes propriedades [35]:

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

A aplicação na prática da lógica difusa corresponde a um conjunto de regras “se (condição), então (resultado)”. Estas regras serão válidas se as condições para que tal aconteça também são válidas. Contudo, o problema que se coloca é que, para uma dada condição poderá haver um conjunto de resultados, e a solução do problema passará pelo melhor resultado.

Assim, é necessário aplicar uma metodologia que permita inferir, ou seja, determinar qual das regras ou conjunto de regras se aplicam de forma a determinar a melhor solução para um determinado problema.

Os problemas são expressos em funções de pertença e a acção é determinada pela inferência difusa, consoante os dados disponíveis. As regras normalmente são definidas pelo programador.

Nas regras difusas os antecedentes são o conjunto de operadores lógicos, e os consequentes são formados por uma ou várias combinações dos operadores lógicos do conjunto difuso, formando-se assim o conhecimento do sistema. Assim, o sistema difuso é decomposto em três etapas, denominadas por Fuzificação, Inferência e Desfuzificação [36], como se apresenta na Figura 3.8.

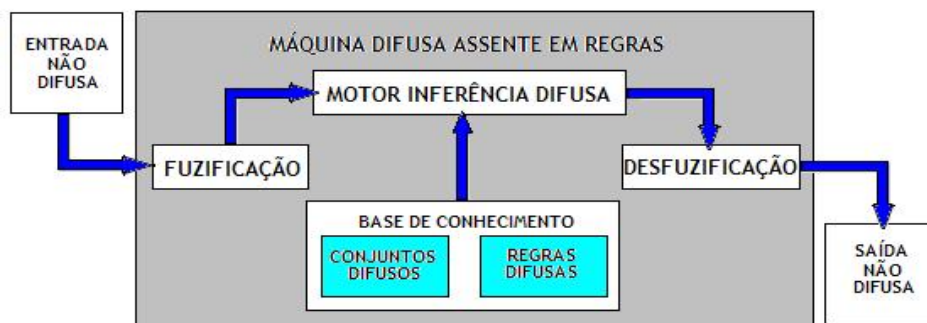


Figura 3.8 - Exemplo de uma máquina difusa assente em regras [37].

Da Figura 3.8 tem-se que:

- O espaço difuso de entrada é constituído pelos antecedentes das regras difusas e, analogamente, o espaço difuso de saída é constituído pelos consequentes das regras difusas.
- A fuzificação será responsável pela representação difusa dos dados de entrada não difusos, isto é, escalares, aplicando para tal valores da função de pertença associados aos conjuntos difusos; analogamente, a desfuzificação será a responsável pela representação não difusa dos dados de saída, isto é, de dados escalares, aplicando para tal valores associados às regras difusas impostas pelos conjuntos difusos.
- O motor de inferência difusa tem como objectivo processar os dados recebidos após a fuzificação com as regras difusas para obter, assim, os resultados à saída de cada uma das regras difusas.

O motor de inferência irá definir o modo como as regras são combinadas, existindo vários modelos de motores de inferência difusa, sendo de destacar o modelo de Mandami e Takagi-Sugeno [38].

Já na desfuzificação existem vários métodos, de destacar [37]:

- Método Bissetor da Área, que determina o valor que define a área da função de pertinência em duas regiões de áreas iguais.
- Método do Primeiro Máximo, que determina o valor correspondente ao primeiro máximo da função de pertinência.
- Método da Média dos Máximos (MM), que define o valor médio de todos os máximos atingidos pela função de pertinência, matematicamente:

$$MM = \sum_{i=1}^m \frac{x_i}{m} \quad (3.2.13)$$

- Método da Centróide (MC); será dado pela área abaixo da função de pertinência cuja abcissa da centróide é definida pela saída do controlador, matematicamente:

$$MC = \begin{cases} \frac{\sum_x \mu_A(x) \cdot x}{\sum_x \mu_A(x)}, & \text{se } x \text{ é discreto} \\ \frac{\int_x \mu_A(x) \cdot x \, dx}{\int_x \mu_A(x) \, dx}, & \text{se } x \text{ é contínuo} \end{cases} \quad (3.2.14)$$

Na Figura 3.9 são apresentadas as funções de pertinência frequentemente utilizadas na resolução de problemas com lógica difusa. As mais utilizadas são as triangulares, cujas características de eficiência computacional são superiores [37].

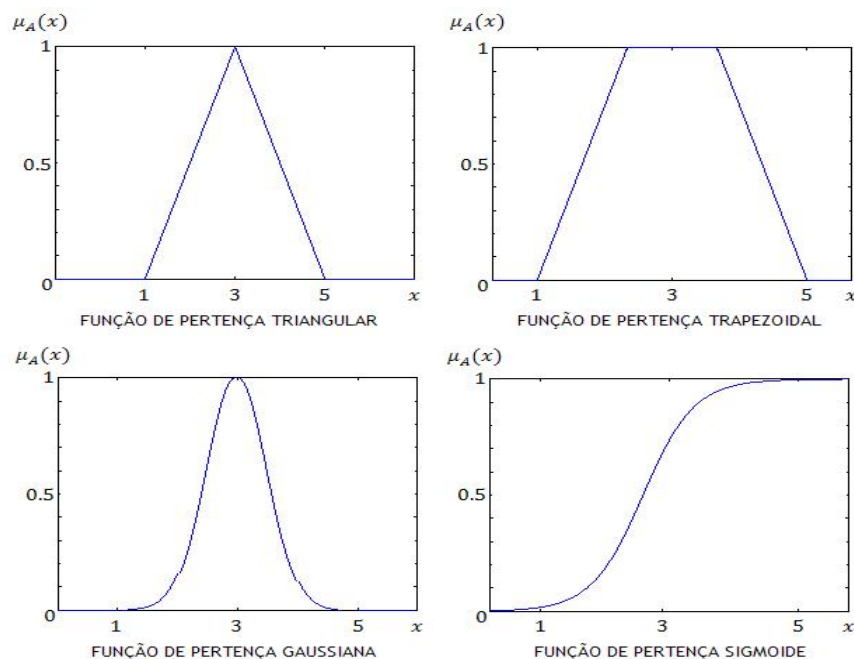


Figura 3.9 - Exemplo de algumas funções de pertinência frequentemente utilizadas [39].

### 3.3 Sistema de Inferência Neuro-Difuso Adaptativo

Esta metodologia é híbrida, contendo as vantagens dos dois métodos já descritos, ou seja, das NNs, e da lógica difusa. Por outras palavras, este sistema conjuga a boa aprendizagem das NNs e a boa capacidade de interpretação linguística da lógica difusa. É especialmente interessante, visto que, reúne os seguintes factores [34]:

- Possibilidade de utilização dos algoritmos desenvolvidos para as NNs.
- Possibilidade de integração de conhecimento (implícito e explícito).
- Possibilidade de extracção de conhecimento, a partir de um conjunto de dados, sob o formato de regras.

A combinação das NNs com a lógica difusa permite aproveitar o que de melhor elas possuem, ou seja, as NNs extraem as regras difusas a partir dos dados de forma automática, enquanto no processo de aprendizagem a lógica difusa é aplicada com o ajuste das funções de pertinência [35].

Um exemplo disso é apresentado na Figura 3.10, a qual representa um sistema ANFIS que possui um controlador difuso, o qual é interpretado como uma NN de cinco camadas. Cada camada contém os nós descritos pela função nó. Por sua vez, a função nó  $O_i^j$  representa a saída do nó  $i$  na camada  $j$ .

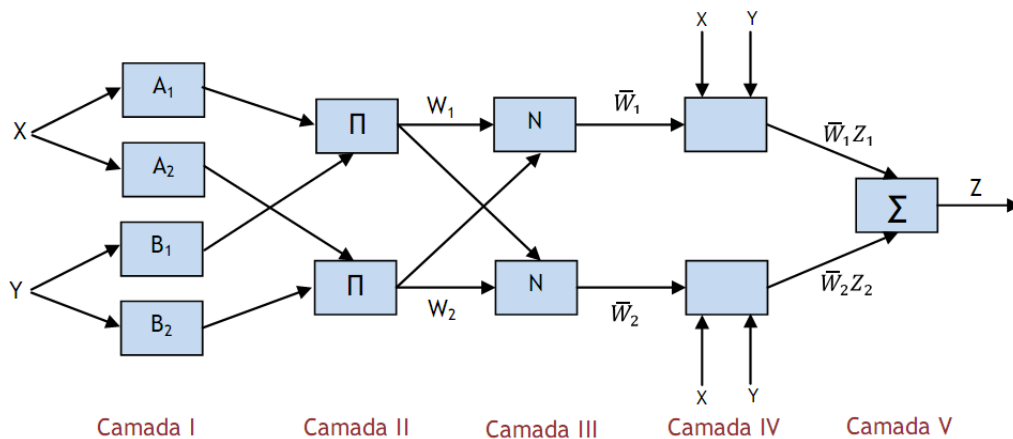


Figura 3.10 - Representação de um sistema ANFIS de 5 camadas [36].

O utilizador deverá deixar o sistema em modo de auto-aprendizagem, de modo a que as regras que moldam a solução do sistema sejam definidas dinamicamente, e como tal, as regras de inferência sejam actualizadas visando obter assim melhores resultados.

Matematicamente a Figura 3.10 pode ser decomposta pelas expressões que representam cada camada, tendo-se que [36]:

- Na camada I, cada nó  $i$  é um nó adaptativo dado pela função:

$$O_i^1 = \mu A_i(x), \quad i = 1, 2 \text{ ou } O_i^1 = \mu B_{i-2}(y), \quad i = 3, 4 \quad (3.3.1)$$

onde  $x$  ou  $y$  é a entrada para o nó  $i$  e  $A_i$  ou  $B_{i-2}$  é um rotulo linguístico associado a esse nó. Assim,  $O_i^1$  será o grau de pertença de um conjunto difuso  $A$  ou  $B$  especificando, também, o grau em que um dado de entrada  $x$  ou  $y$  satisfaz o quantificador do conjunto difuso.

A função de pertença é dada pela função Gaussiana descrita como:

$$\mu A_i(x) = \frac{1}{1 + \left| \frac{x-r_i}{p_i} \right|^{2q_i}} \quad (3.3.2)$$

dos quais os parâmetros  $\{p_i, q_i, r_i\}$  determinam a função Gaussiana.

- Na camada II, cada nó é definido como nó fixo, cuja saída será o produto de todos os sinais de entrada, isto é,

$$O_i^2 = w_i = \mu A_i(x) \mu B_i(y), \quad i = 1, 2 \quad (3.3.3)$$

Em suma, teremos à saída de cada nó desta camada o nível de disparo  $w_i$  de uma regra.

- Na camada III, temos o processo de desfuzificação do sistema para cada nó designado por  $N$ . Nesta camada determina-se o nível de disparo normalizado, o qual será dado pelo quociente entre o  $i$ -ésimo nível de disparo da regra e a soma de todos os níveis.

$$O_i^3 = \bar{w}_i z_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (3.3.4)$$

- Na camada IV, cada nó  $i$  é um nó adaptativo, dado pela expressão:

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i (a_i x + b_i y + c_i), \quad i = 1, 2 \quad (3.3.5)$$

no qual o parâmetro  $\bar{w}_i$  é o nível de disparo normalizado da camada III e os parâmetros  $\{a_i, b_i, c_i\}$  são os parâmetros consequentes.

- Na camada V, é realizada a soma que determina a saída geral do sistema de todos os sinais de entrada, definidos pela expressão:

$$O_i^5 = \sum_i \bar{w}_i z_i = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (3.3.6)$$

Por último, o motor de inferência difusa utilizado neste trabalho baseia-se na ideia de Takagi-Sugeno, o qual assemelha-se ao método de Mandami; contudo, o resultado da saída no método de Takagi-Sugeno é determinístico. Ao utilizar constantes ou funções lineares, os resultados são mapas nitidamente parametrizados. Portanto, com a técnica de Takagi-Sugeno é possível encontrar técnicas de otimização de forma a encontrar melhores parâmetros para ajustar os dados, ao invés de como ocorre no caso do método de Mandami que faz esta mesma procura de forma heurística. Assim, o método de Takagi-Sugeno resulta em um número exacto, enquanto o método de Mandami pode ir ao encontro de um conjunto de possíveis soluções [39-41].

### 3.4 Otimização por Enxame de Partículas

*Particle Swarm Optimization* (PSO), ou Otimização por Enxame de Partículas, é um método desenvolvido por James Kennedy e Russell Eberhart em 1995, inspirado no comportamento e dinâmica das sociedades de aves, peixes e alguns insectos, para resolver problemas de otimização com variáveis contínuas.

Os estudos realizados para a criação deste algoritmo reportavam que os animais que vivem em sociedade encontram e tentam resolver as suas necessidades por meio de um esforço conjunto, ou seja, os animais que vivem em sociedade são capazes de partilhar informação.

Considerando essa mesma sociedade de animais como partículas, essas partículas movem-se aleatoriamente no espaço de procura. Assim, o sistema é inicializado com uma população de soluções aleatórias e procura as soluções óptimas actualizando as novas gerações. Isto é, o processo é realizado mediante a partilha de informação entre o enxame, no qual a memória, a inércia e cooperação das partículas contidas nesse enxame irão definir um ponto óptimo para a solução do problema.

O PSO define-se como sendo uma técnica de optimização computacional inteligente que não é influenciável pelo tamanho ou pela não linearidade do problema, e que consegue convergir para a solução óptima, onde a maioria dos métodos analíticos falham [42].

No entanto, o PSO não possui operadores evolutivos como o *crossover* e mutação que iremos ver no decorrer do trabalho. Assim, no PSO as potenciais soluções das chamadas partículas do enxame percorrem o espaço do problema seguindo a melhor partícula actual [43].

Em comparação com os algoritmos genéticos, as vantagens e desvantagens do PSO são as seguintes [43]:

- Vantagens:
  - É indiferente a mudança de escala das variáveis.
  - É de fácil implementação, visto que possui poucos parâmetros que tenham de ser definidos e ajustados pelo utilizador.
  - Ao contrário da maioria dos algoritmos genéticos o PSO não requer cálculos de derivadas.
  - É um algoritmo adequado para encontrar mínimos globais.
- Desvantagens:
  - É inflexível no ajuste fino de parâmetros.

Cada partícula  $i$  é considerada como uma potencial solução para um dado problema de otimização, num espaço de dimensão  $D$ , representando-se [43]:

- Vector de posição:

$$X_i = [x_{i1}, x_{i2}, \dots, x_{iD}] \quad (3.4.1)$$

- Vector de velocidade:

$$V_i = [v_{i1}, v_{i2}, \dots, v_{iD}] \quad (3.4.2)$$

- Vector para a melhor posição ocupada pela partícula até ao momento:

$$b_i = [b_{i1}, b_{i2}, \dots, b_{iD}] \quad (3.4.3)$$

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

$$b_G = [b_{g1}, b_{g2}, \dots, b_{gD}] \quad (3.4.4)$$

Assim, quando uma partícula se desloca no hiperespaço, a sua velocidade  $V_i$  e posição  $X_i$  variam de acordo com as seguintes equações [43]:

$$V_i^{novo} = Dec(t)W_{i0}V_i + rand_1W_{i1}(b_i - X_i) + rand_2W_{i2}(b_G - X_i) \quad (3.4.5)$$

$$X_i^{novo} = X_i + V_i^{novo} \quad (3.4.6)$$

Das equações anteriores podem denotar-se alguns aspectos [44]:

- Da expressão da (3.4.5);
  - A soma dos termos é composta pelo primeiro termo que ilustra a inércia da partícula em seguir o movimento anteriormente descrito; o segundo termo ilustra a memória da partícula que a atrai para o melhor ponto encontrado durante a trajectória que ela segue; o último termo representa a cooperação, conduzindo o conjunto de partículas para o melhor ponto então encontrado pelo enxame em si.

- Os termos  $W_{i1}$  e  $W_{i2}$  são constantes de valor positivo e não superior a 2. Já o termo  $W_{i0}$  toma o valor inicial não superior a 1.4, o qual vai diminuindo conforme for diminuindo o parâmetro da inércia.
- Os termos  $rand_1$  e  $rand_2$  são valores aleatórios compreendidos entre 0 e 1.
- O parâmetro  $Dec(t)$  é uma função decrescente em função do tempo, responsável pela redução progressiva da importância da inércia.
- Da expressão (3.4.6);
  - A nova posição vai ser dada pela adição da nova velocidade adquirida pela partícula, pela posição anterior que tinha sido adoptada por essa partícula.

A nova posição da partícula, descrita pela equação da nova posição  $X_i^{novo}$ , é dada pela soma vectorial apresentada na Figura 3.11, onde se mostra a influência que a inércia, memória e cooperação possuem para definir o caminho e a nova posição da partícula.

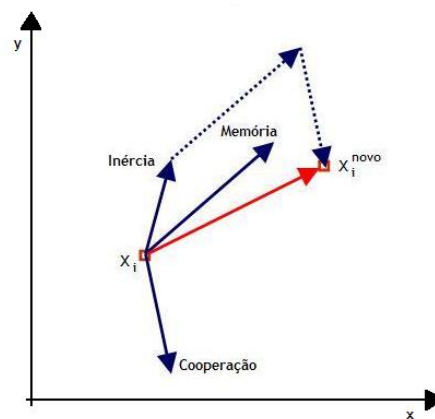


Figura 3.11 - Caminho percorrido pela partícula para a sua nova posição [44].

Contudo, opostamente aos algoritmos evolucionários, o PSO não executa a selecção, isto é, todas as partículas são mantidas como elementos do enxame no decorrer do algoritmo. Porém, o algoritmo utiliza o conceito de *fitness*, ou aptidão, como qualquer algoritmo evolucionário. Assim, o ajuste da velocidade através da informação partilhada de outras posições é comparável ao que acontece com os algoritmos genéticos, ocorrendo assim o processo de mutação, já que os elementos da memória e cooperação vão sendo alterados em cada iteração [43].

O algoritmo adoptado na grande generalidade dos problemas que envolvem a metodologia do PSO é apresentado na Figura 3.12.

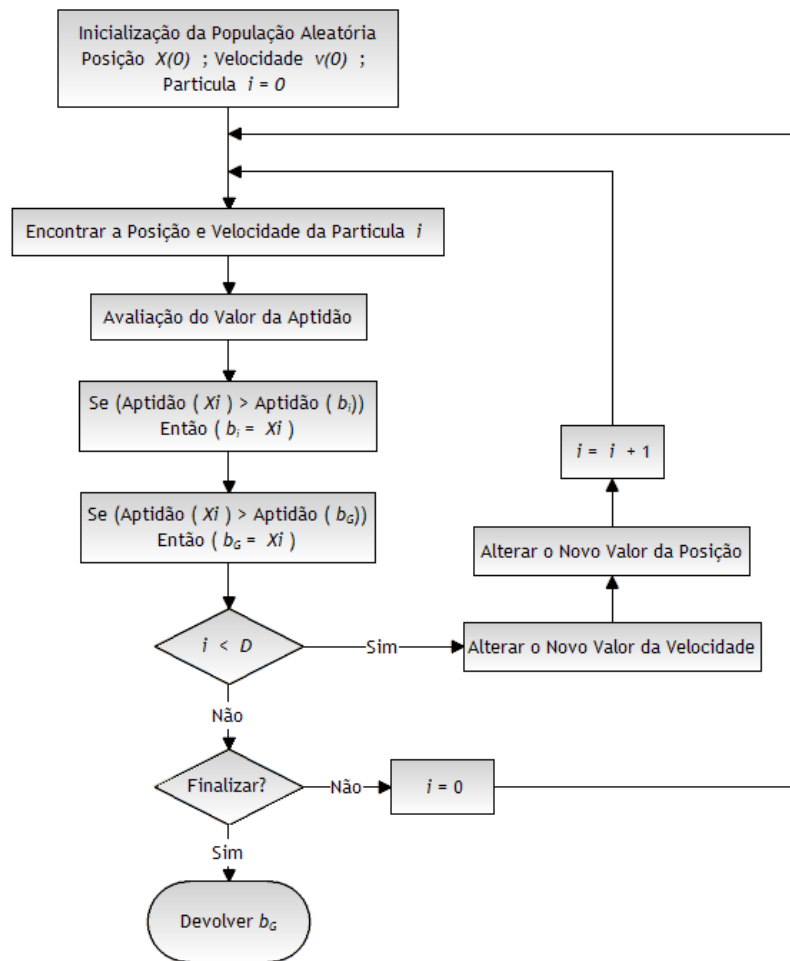


Figura 3.12 - Fluxograma representativo do algoritmo do PSO [45].

Da Figura 3.12 salienta-se o seguinte:

- Inicializar o enxame considerando uma posição aleatória do espaço do problema para cada partícula.
- Avaliar a aptidão de cada partícula.
- Para cada partícula dever-se-á comparar com o valor de aptidão de posição actual  $X_i$  com o valor de aptidão de melhor posição  $b_i$ . No caso do valor de aptidão de melhor posição  $b_i$  for maior que o valor de posição actual  $X_i$ , substituir o valor actual  $X_i$  pelo valor  $b_i$ .
- Identificar o melhor valor de aptidão da partícula. O valor da função de aptidão é identificado como sendo  $b_g$ .
- Actualizar os novos valores de velocidade e posição de todas as partículas.
- Repetir os pontos 2 a 5 até à condição de paragem ser encontrada, isto é, o número de iterações ser alcançado, ou o melhor valor ser encontrado.

Nesta metodologia é aconselhado seguir as seguintes recomendações [40]:

- As constantes  $W_{i1}$  e  $W_{i2}$  devem ter um valor constante igual a 2.
- A constante inicial de inércia  $W_{i0}$  deve ser actualizada seguindo a expressão:

$$W_{i0} = w_{m\acute{a}x} - \frac{w_{m\acute{a}x} - w_{m\acute{i}n}}{Itr_{m\acute{a}x}} Itr \quad (3.4.7)$$

Onde  $w_{m\acute{a}x}$  e  $w_{m\acute{i}n}$  são os pesos iniciais de inércia,  $Itr_{m\acute{a}x}$  é o número máximo de iterações e  $Itr$  corresponde à iteração que está a decorrer nesse momento.

## 3.5 Optimização por Enxame de Partículas Evolucionário

Esta ferramenta da variante meta-heurística designada por Optimização por Enxame de Partículas Evolucionário, ou do anglo-saxónico *Evolutionary Particle Swarm Optimization* (EPSO), é um algoritmo cujas raízes e conceitos de optimização estão contidas em Estratégias Evolucionárias e Auto-Adaptativas e por Enxame de Partículas [45, 46].

No modelo de Estratégias Auto-Adaptativa e Evolucionária, conota-se em determinada iteração denominada por geração uma série de soluções ou alternativas designadas por individuais. Cada partícula é caracterizada por um parâmetro do objecto (o valor das variáveis descrevem a solução) e por parâmetros estratégicos (coeficiente de mutação de cada variável, o ângulo de correlação da mutação e semelhantes).

É de salientar que:

- Cada partícula é duplicada.
- O parâmetro estratégico de cada partícula sofre uma transformação.
- O parâmetro do objecto de cada partícula é transformado em um procedimento comandado pelos seus parâmetros estratégicos, gerando assim novas partículas.
- O número de partículas que sofrem de uma recombinação gera novas partículas.
- Para um universo constituído por partículas “mães” e “filhos” (a antiga partícula e a nova partícula criada, respectivamente), o melhor ajuste seleccionado deverá originar uma nova geração.

O processo de selecção tem uma série de variantes e pode ser controlado por um processo estocástico, ou pode ser puramente determinístico, ou envolvendo elitismo, entre outros [47].

O conceito do EPSO é atribuir ao algoritmo PSO um esquema explícito de procedimentos de selecção e com propriedades auto-adaptativas para os mesmos parâmetros. Assim, as variáveis da formulação do EPSO são divididas, de acordo com o utilizado pela comunidade de Estratégias Evolucionárias, sendo composto por parâmetros objecto que são as variáveis  $X$  e por parâmetros estratégicos que são os pesos  $W$ .

Numa dada iteração, considera-se uma série de soluções ou alternativas as quais se designam por partículas. Assim, a partícula é a série do objecto e do parâmetro estratégico  $[X, W]$ , cujo esquema geral é o seguinte [48, 49]:

- Multiplicação, no qual cada partícula é multiplicada  $r$  vezes.
- Mutação, no qual cada partícula contém um peso  $W$  mutado.
- Reprodução, no qual cada partícula gera um conjunto de partículas de acordo com a Regra do Movimento da Partícula (RMP).
- Avaliação, no qual cada conjunto de partículas é avaliado pelo seu peso  $W$ .
- Seleção, realizada através de processos estocásticos, em que a melhor partícula sobrevive para criar um novo conjunto.

Dada a partícula  $X_i$ , o resultado da nova partícula  $X_i^{novo}$  é determinada pelas expressões [46]:

$$X_i^{new} = X_i + V_i^{new} \quad (3.5.1)$$

$$V_i^{new} = w_{i0}^* V_i + w_{i1}^* (b_i - X_i) + w_{i2}^* (b_g^* - X_i) \quad (3.5.2)$$

Pode-se observar que estas expressões são semelhantes ao algoritmo PSO, ou seja, a regra do movimento mantém-se para os termos de inércia, memória e cooperação. A diferença reside nos pesos, os quais são tomados como objecto após sofrer mutação:

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (3.5.3)$$

onde  $N(0, 1)$  é uma variável aleatória Gaussiana, com média 0 e variância 1, e onde o melhor  $b_g$  é alterado aleatoriamente para se obter:

$$b_g^* = b_g + \tau' N(0,1) \quad (3.5.4)$$

A lógica subjacente a esta modificação é a seguinte:

- Se o melhor global é já o óptimo global, é irrelevante para a formulação descrita anteriormente nas expressões 3.5.1 e 3.5.2; no entanto,
- Se o óptimo ainda não foi encontrado, mas pode estar na vizinhança, faz sentido não apontar o actual exactamente como melhor global, especialmente quando a procura é focada numa determinada região, numa fase mais terminal do processo.

Os termos  $\tau, \tau'$  encontram-se a aprender parâmetros (fixos ou tratados também dos parâmetros estratégicos, como tal, sofrem mutação).

Este esquema beneficia do processo da selecção Darwinista<sup>6</sup> e a regra do movimento da partícula. É natural esperar que isto apresente desvantagens sobre as propriedades de convergência quando comparado às estratégias evolucionárias ou ao PSO separadamente. Contudo, o EPSO pode ser considerado como um algoritmo auto-adaptativo, visto que, assenta na mutação e selecção dos parâmetros estratégicos, tal como qualquer algoritmo de estratégia evolucionária [47]. A Tabela 2 apresenta as comparações existentes entre os algoritmos PSO e EPSO.

Tabela 3.1 - Comparação entre PSO e EPSO.

PSO	EPSO
Não é afectado pelo tamanho ou não linearidade do sistema.	Características semelhantes ao PSO.
Convergência na maioria dos problemas não lineares.	Estratégias Evolucionárias na selecção para à aptidão.
Implementação, parâmetros iniciais de ajustamento mínimos.	A velocidade de convergência é mais rápida face ao PSO.
Memória do sistema é eficiente.	Utiliza recursos de auto-adaptação.
Eficiência na manutenção da diversidade do enxame de partículas.	A capacidade de busca e exploração melhoradas face ao PSO.
Capacidade de adaptação eficiente.	Ajuste dos parâmetros iniciais com maior tolerância.
Peso computacional reduzido.	Comunicação entre partículas é mais eficiente.
	Peso computacional reduzido e eficiente.

<sup>6</sup> Considera-se a selecção Darwinista como sendo a selecção e evolução natural dos elementos mais fortes e com melhores capacidades de adaptação no meio que os rodeia de forma a sobreviver no meio.

## 3.6 Nova Metodologia Híbrida de Previsão

A nova metodologia proposta combina a metodologia EPSO com a metodologia ANFIS para a previsão dos preços da energia eléctrica e da potência eólica a curto prazo em Portugal. Futuramente, designar-se-á por EPA (*Evolutionary PSO ANFIS*) a metodologia híbrida proposta. O EPA utiliza um conjunto de dados que serve simultaneamente de entrada à estrutura ANFIS e à estrutura EPSO. O EPSO é utilizado em conjunto com a metodologia ANFIS para melhorar significativamente o seu desempenho, acrescentando as funções que lhe são características para alcançar uma menor margem de erro.

De referir que, as previsões realizadas para os preços da energia eléctrica e para a potência eólica são feitas independentemente umas das outras; no entanto, o algoritmo proposto é semelhante na sua generalidade, variando somente em alguns parâmetros os quais serão apresentados no final do capítulo. Assim, o algoritmo é descrito da seguinte forma:

- Passo 1: Formar uma matriz com o conjunto de dados históricos (preços da energia eléctrica ou potência eólica) dispostos numa matriz  $P$ . Cada coluna da matriz  $P$  possui um perfil associado a uma semana ou um dia onde estão inseridos os dados previamente conhecidos. Nesta primeira etapa, a matriz terá seis colunas no caso da série de preços da energia eléctrica, e seis colunas no caso da potência eólica. Dá-se especial ênfase para que as matrizes utilizadas sejam diferentes na sua dimensão e no conteúdo de dados, visto que, para a previsão de preços da energia eléctrica a matriz é constituída por vectores com 168 valores cada, enquanto a matriz da potência eólica é constituída por vectores com 96 valores cada.
- Passo 2: Seleccionar um número de colunas da matriz  $P$  de forma aleatória para que o conjunto dos dados escolhidos represente os dados reais de entrada. Nesta etapa são seleccionados os melhores dados com base numa análise correlativa superior a 0,8 em ambos os casos de previsão.
- Passo 3: Realização do treino do ANFIS com dados anteriormente escolhidos. O processo de treino permite que o sistema possa apresentar ajustes aleatórios dos seus parâmetros, tais como entradas/saídas. No caso em estudo, em ambas as situações (previsão de preços da energia eléctrica ou previsão de potência eólica) o sistema é referido somente a uma saída. Este processo termina sempre que o número de iterações ou o erro de treino seja alcançado. O número de épocas é determinado pelo tipo de dados que se estejam a prever, bem como a temporada a que estes dados se referem (estações do ano). Isto será determinado por tentativa em erro dos diferentes dados tratados. Após a definição dos dados de treino, o número de iterações e o tipo de funções de pertinência, o sistema ANFIS é optimizado adaptando os parâmetros das funções de filiação. A auto-aprendizagem do sistema ANFIS, na

qual actualiza o número de regras de inferência de forma dinâmica e automática, é de extrema importância, visto que, devido ao elevado número de dados é extremamente difícil definir um número elevado de regras de inferência de forma metódica e manual. Assim, o EPSO é convenientemente utilizado para escolher os dados e treinar os parâmetros associados com os membros das funções do sistema ANFIS, o que constitui uma contribuição relevante para as previsões em causa nesta dissertação.

- Passo 4: Criação de um vector de dimensão  $N$ , o qual representa o número de membros da função. Contém, ainda, os parâmetros da função de associação, e será posteriormente optimizado pelo EPSO. Esta função é definida pelo critério do erro quadrático médio.
- Passo 5: Definir os parâmetros associados ao algoritmo EPSO. Estes parâmetros são actualizados sendo a sua inicialização efectuada de forma aleatória. Por outras palavras, estes parâmetros irão ser agrupados num vector que estará a ser optimizado a cada iteração. O algoritmo EPSO é o seguinte:
  - 5.1: Inicializar as posições e velocidades da população aleatoriamente com o tamanho da dimensão do problema;
  - 5.2: Avaliar a capacidade de cada partícula individualmente, e no caso de ser mais favorável a melhor local, redefinir a nova posição da partícula, actualizando também o seu valor individual;
  - 5.3: Guardar os resultados de aptidão da velocidade e da posição da partícula, e criar novos descendentes;
  - 5.4: Testar os novos descendentes e repetir os pontos 5.2 e 5.3, até encontrar os melhores pontos;
  - 5.5: Terminar o algoritmo se a condição de paragem é verificada. Se exceder o número de iterações, ou o erro mínimo proposto, apresentar o melhor resultado encontrado até então.
- Passo 6: Avaliar e armazenar os resultados da saída do ANFIS utilizando os parâmetros encontrados pelo EPSO, realizando um novo treino com os dados obtidos pelo EPSO e ANFIS no Passo 3 e realizar a avaliação do resultado.
- Passo 7: Representar o resultado pelo EPA e mostrar os erros associados da previsão obtida.

Graficamente, o algoritmo utilizado pode ser interpretado pelo fluxograma apresentado na Figura 3.13.

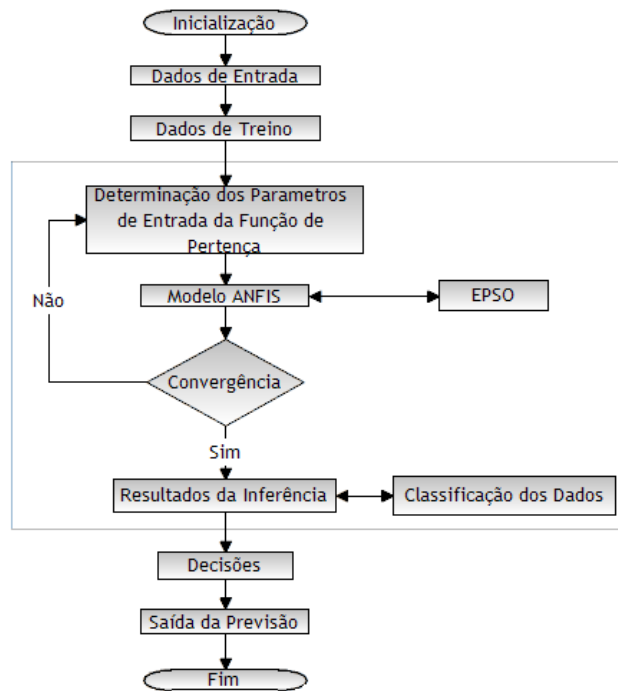


Figura 3.13 - Fluxograma da Metodologia Híbrida Proposta.

Por último, as Tabelas 3.2 e 3.3 representam os parâmetros utilizados na definição do algoritmo, nomeadamente, a parametrização da estrutura ANFIS e EPSO utilizadas na previsão da potência eólica e dos preços da energia eléctrica.

Tabela 3.2 - Parâmetros utilizados na previsão da potência eólica.

		Parâmetros	Tipo/Tamanho
ANFIS		Número de Funções de Pertença Inicial	2
		Número de Iterações Necessárias	10
		Função de Pertença Utilizada	Triangular
EPSO		Aceleração de Aptidão	2
		Aceleração de Partilha	2
		Peso Inicial da Inércia da População	0,9
		Peso Final da Inércia da População	0,4
		Tamanho da População	12
		Número Máximo de Gerações	24
		Número de Descendentes	12
		Geração por cada Partícula “Mãe”	2
		Número de Iterações Necessárias	96
		Valor Mínimo da Nova Posição da Partícula	100
	Valor Máximo da Nova Posição da Partícula	800	

Tabela 3.3 - Parâmetros utilizados na previsão dos preços da energia eléctrica.

Parâmetros		Tipo ou Tamanho
ANFIS	Número de Funções de Pertença Inicial	4
	Número de Iterações Necessárias	25
	Função de Pertença Utilizada	Triangular
EPSO	Aceleração de Aptidão	2
	Aceleração de Partilha	2
	Peso Inicial da Inércia da População	0,9
	Peso Final da Inércia da População	0,4
	Tamanho da População	168
	Número Máximo de Gerações	320
	Número de Descendentes	168
	Geração por cada Partícula “Mãe”	2
	Número de Iterações Necessárias	320
	Valor Mínimo da Nova Posição da Partícula	30
	Valor Máximo da Nova Posição da Partícula	60

### 3.6.1 Medidas de Erro

Neste trabalho foi introduzido como medida de comparação, entre a metodologia EPA e outras já publicadas em revistas internacionais de referência, um conjunto de critérios de avaliação do erro, nomeadamente: MAPE - *Mean Absolute Percentage Error*, ou, Erro Médio Absoluto em Percentagem, SDE - *Standard Deviation of Error*, ou, Desvio Estandarizado do Erro, e SSE - *Sum of Square of Error*, ou Soma Quadrática do Erro e a Variância do Erro. Este último é uma medida estatística utilizada para caracterizar a precisão associada aos resultados obtidos pela metodologia. Quanto menor for esta variação, mais precisa será a previsão. De referir, ainda, que os critérios utilizados neste trabalho são os normalmente utilizados pela maioria dos autores de outras metodologias de previsão [45, 46].

Assim, o critério MAPE é definido por:

$$MAPE = \frac{100}{K} \sum_{k=1}^K \frac{|\hat{p}_k - p_k|}{\bar{p}} \quad (3.6.1.1)$$

$$\bar{p} = \frac{1}{K} \sum_{k=1}^K p_k \quad (3.6.1.2)$$

O critério SSE é definido por:

$$SSE = \sum_{k=1}^K (\hat{p}_h - p_h)^2 \quad (3.6.1.3)$$

O critério SDE é definido por:

$$SDE = \sqrt{\frac{1}{K} \sum_{k=1}^K (e_h - \bar{e})^2} \quad (3.6.1.4)$$

$$e_h = \hat{p}_h - p_h \quad (3.6.1.5)$$

$$\bar{e} = \frac{1}{K} \sum_{k=1}^K e_h \quad (3.6.1.6)$$

Por último, a Variância do Erro é definida por:

$$\sigma_{e,dia}^2 = \frac{1}{K} \left( \frac{|\hat{p}_h - p_h|}{\bar{p}} - (e_{day}) \right)^2 \quad (3.6.1.7)$$

$$e_{day} = \frac{1}{K} \sum_{k=1}^K \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (3.6.1.8)$$

Das expressões 3.6.1.1 a 3.6.1.8 definem-se:

- $\hat{p}_h$  e  $p_h$ , respectivamente os dados previstos e os dados reais no período  $k$ ;
- $\bar{p}$  é a média dos dados reais;
- $K$  é o número total de períodos;
- $e_h$  é o erro de previsão no período  $k$ ;
- $\bar{e}$  é o erro médio.



# Capítulo 4

## 4.1 Resultados Obtidos

### 4.1.1 Previsão de Preços da Energia Eléctrica

A abordagem a este problema passa pela previsão dos preços da energia eléctrica no mercado eléctrico espanhol para uma semana, isto é, considerando  $K = 168$  horas. Os dados foram obtidos do *website* da OMEL [50], e remontam ao ano de 2002. De referir que não são consideradas quaisquer variáveis exógenas, permitindo a avaliação correcta e isenta das potencialidades da nova metodologia proposta. Isto é, apenas são utilizados os dados históricos dos preços. Ainda, para se poder ter uma base de comparação equitativa, as mesmas semanas de teste de [51-60] são escolhidas, correspondendo às quatro estações do ano de 2002.

Diferentes conjuntos de preços têm sido propostos como dados de entrada para a previsão de preços no mercado eléctrico espanhol. Nesta dissertação é considerado o histórico horário dos preços nas seis semanas (42 dias) anteriores à semana para a qual será realizada a previsão dos preços da energia eléctrica. A saída da metodologia de previsão corresponde a um vector de dimensão igual à dimensão do horizonte temporal de previsão, isto é, 168 horas.

Assim, as Figuras 4.1 a 4.4 apresentam os resultados obtidos para as diferentes estações do ano, mostrando em cada uma das figuras o resultado da previsão obtido com a nova metodologia EPA e os valores reais dos preços da energia eléctrica nessa semana. A Figura 4.1 corresponde aos resultados da previsão para a estação da Primavera; a Figura 4.2 corresponde aos resultados da previsão para a estação do Verão; a Figura 4.3 corresponde aos resultados da previsão para a estação do Outono; e a Figura 4.4 corresponde aos resultados da previsão para a estação de Inverno.




Figura 4.1 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação da Primavera.




Figura 4.2 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Verão.




Figura 4.3 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Outono.




Figura 4.4 - Resultado da previsão de preços da energia eléctrica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação de Inverno.

Observa-se das Figuras 4.1 a 4.4 que a metodologia EPA conduz a óptimos resultados para as diferentes estações do ano, observando-se em qualquer um dos casos, uma semelhança evidente entre o sinal previsto e o sinal real; observa-se, ainda, uma boa aproximação na previsão dos máximos e mínimos da série original.

Todos os casos de teste foram obtidos num computador com 1 GB de RAM e processador de 1,8 GHz. O tempo médio de processamento foi inferior a 1 minuto, mostrando um desempenho eficiente.

Na Tabela 4.1 são apresentados os resultados dos critérios de avaliação da metodologia EPA na previsão dos preços de energia eléctrica. O valor médio do MAPE é de 5,12%.

Tabela 4.1 - Resultados dos critérios de avaliação da metodologia EPA para a previsão dos preços de energia eléctrica.

	MAPE	SDE	SSE	Variância do Erro
Primavera	4,10	1,76	28,37	0,0012
Verão	6,39	2,81	49,50	0,0048
Outono	6,40	1,72	35,30	0,0032
Inverno	3,59	1,52	32,86	0,0016
Média	5,12	1,95	36,51	0,0027

A Tabela 4.2 apresenta a comparação entre a nova metodologia proposta e outras dez metodologias (ARIMA, *Mixed-Model*, NN, *Wavelet-ARIMA*, WNN, FNN, HIS, AWNN, NNWT e CNEA) já publicadas em revistas internacionais de referência, mostrando os resultados do critério MAPE para todas as metodologias.

Ao observar-se a Tabela 4.2 conclui-se que a nova metodologia proposta apresenta melhorias significativas relativamente às anteriores, no que concerne ao MAPE, em 48,6%, 44,9%, 42,5%, 36,9%, 36,4%, 31,9%, 26,5%, 24,1%, 23,0% e 3,8%, respectivamente.

Tabela 4.2 - Comparação do MAPE entre os diferentes métodos de previsão dos preços de energia eléctrica.

	Primavera	Verão	Outono	Inverno	Média
ARIMA [51]	6,36	13,39	13,78	6,32	9,96
<i>Mixed-Model</i> [54]	4,46	14,90	11,68	6,15	9,30
NN [55]	5,36	11,40	13,65	5,23	8,91
<i>Wavelet-ARIMA</i> [52]	5,69	10,70	11,27	4,78	8,11
WNN [56]	4,34	10,89	11,83	5,15	8,05
FNN [57]	5,30	9,84	10,32	4,62	7,52
HIS [58]	7,07	7,47	7,30	6,06	6,97
AWNN [59]	4,67	9,64	9,29	3,43	6,75
NNWT [60]	4,22	9,50	9,28	3,61	6,65
CNEA [53]	4,65	5,79	5,96	4,88	5,32
EPA	4,10	6,39	6,40	3,59	5,12

A estabilidade dos resultados é outro factor importante para a comparação entre as metodologias de previsão. A Tabela 4.3 apresenta a comparação entre a nova metodologia proposta e outras oito metodologias (ARIMA, NN, *Wavelet-ARIMA*, FNN, AWNN, NNWT, HIS e CNEA), relativamente às Variâncias dos Erros semanais. A média da Variância do Erro é menor para a nova metodologia proposta, indicando um grau de incerteza menor nas previsões. As melhorias na Variância do Erro são de 70,7%, 61,4%, 57,8%, 50,0%, 43,8%, 27,0%, 25,0% e 25,0%, respectivamente. Para as metodologias WNN e *Mixed-Model*, a Variância do Erro não foi apresentada nas respectivas referências, pelo que não são apresentadas como comparação para este caso.

Pode-se concluir que a nova metodologia proposta, baseada em EPSO e ANFIS, é inovadora e eficaz para a previsão dos preços da energia eléctrica, tendo em conta os resultados reportados anteriormente na literatura especializada.

Tabela 4.3 - Comparação da Variância do Erro entre diferentes metodologias de previsão dos preços da energia eléctrica.

	Primavera	Verão	Outono	Inverno	Média
ARIMA [51]	0,0020	0,0158	0,0157	0,0034	0,0092
NN [55]	0,0018	0,0109	0,0136	0,0017	0,0070
<i>Wavelet</i> -ARIMA [52]	0,0025	0,0108	0,0103	0,0019	0,0064
FNN [57]	0,0019	0,0092	0,0088	0,0018	0,0054
AWNN [59]	0,0031	0,0074	0,0075	0,0012	0,0048
NNWT [60]	0,0017	0,0074	0,0049	0,0009	0,0037
HIS [58]	0,0049	0,0029	0,0031	0,0034	0,0036
CNEA [53]	0,0027	0,0043	0,0039	0,0036	0,0036
EPA	0,0012	0,0048	0,0032	0,0016	0,0027

Verifica-se, ainda, que devido à auto-aprendizagem do sistema ANFIS, definindo e actualizando o número de regras de inferência de forma dinâmica e automática, isto é, sem que o utilizador tenha de o fazer manual e metodicamente, permite que os resultados sejam os mais adequados.

#### 4.1.2 Previsão da Potência Eólica

A nova metodologia híbrida EPA foi também aplicada para a previsão da potência eólica em Portugal. Os dados foram obtidos do *website* da REN. Estes dados da potência eólica serão os únicos elementos de entrada para o treino, ou seja, não são consideradas quaisquer variáveis exógenas, permitindo a avaliação correcta e isenta das potencialidades da nova metodologia proposta.

Como referido em [24], conforme o estipulado pelo MIBEL, no mercado intradiário são necessárias seis previsões realizadas em momentos diferentes, para três, quatro ou cinco horas consecutivas, sempre com três horas de avanço.

Assim, a previsão da potência eólica foi realizada com base numa previsão de sub-séries de dados de três em três horas, com leituras realizadas a cada 15 minutos, para totalizar uma previsão das 24 horas seguintes. Ainda, para se poder ter uma base de comparação equitativa, os mesmos dias de teste de [61-64] são escolhidos, correspondendo às quatro estações do ano em 2007/2008.

Nesta dissertação é considerado um conjunto de dados que correspondem a 72 horas das diferentes estações do ano, para fazer-se a previsão das 24 horas seguintes, subdivididas em previsões sucessivas de 3 horas.

Assim, as Figuras 4.5 a 4.8 apresentam os resultados obtidos para as diferentes estações do ano, mostrando em cada uma das figuras o resultado da previsão obtido com a nova metodologia EPA e os valores reais da potência eólica nesse dia. A Figura 4.5 corresponde aos resultados da previsão para a estação da Primavera; a Figura 4.6 corresponde aos resultados da previsão para a estação do Verão; a Figura 4.7 corresponde aos resultados da previsão para a estação do Outono; e a Figura 4.8 corresponde aos resultados da previsão para a estação de Inverno.




Figura 4.5 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação da Primavera.




Figura 4.6 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Verão.




Figura 4.7 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Outono.




Figura 4.8 - Resultado da previsão da potência eólica (linha tracejada) comparativamente aos valores reais (linha contínua), para a estação do Inverno.

Observa-se das Figuras 4.5 a 4.8 que a metodologia EPA conduz a óptimos resultados para as diferentes estações do ano, observando-se em qualquer um dos casos, um acompanhamento do sinal previsto com o sinal real.

Tal como no caso da previsão dos preços da energia eléctrica, todos os casos de teste foram obtidos num computador com 1 GB de RAM e processador de 1,8 GHz. O tempo médio de processamento foi inferior a 1 minuto, mostrando um desempenho eficiente.

Na Tabela 4.4 são apresentados os resultados dos critérios de avaliação da metodologia EPA na previsão da potência eólica. O valor médio do MAPE é de 5,03%.

Tabela 4.4 - Resultados dos critérios de avaliação da metodologia EPA para a previsão da potência eólica.

	MAPE	SDE	SSE	Variância do Erro
Primavera	6,68	37,31	336,19	0,0032
Verão	4,45	15,35	153,65	0,0017
Outono	2,85	20,02	196,15	0,0011
Inverno	6,13	40,05	394,33	0,0022
Média	5,03	28,18	270,08	0,0021

A Tabela 4.5 apresenta a comparação existente entre a nova metodologia proposta e outras seis metodologias (Persistência, ARIMA, NN, NNWT, NF e HPA) já publicadas em revistas internacionais de referência, mostrando os resultados do critério MAPE para todas as metodologias.

Ao observar-se a Tabela 4.5 conclui-se que a nova metodologia proposta apresenta melhorias significativas relativamente às anteriores, no que concerne ao MAPE, em 73,6%, 51,4%, 30,7%, 27,8%, 24,2% e 7,0%, respectivamente.

Tabela 4.5 - Comparação do MAPE entre os diferentes métodos de previsão da potência eólica.

	Primavera	Verão	Outono	Inverno	Média
Persistência	32,40	13,43	16,49	13,89	19,05
ARIMA [62]	12,05	11,04	7,35	10,93	10,34
NN [62]	9,92	6,34	3,26	9,51	7,26
NNWT [61]	9,55	5,97	3,14	9,23	6,97
NF [63]	8,96	5,63	3,11	8,85	6,64
HPA [64]	7,22	4,59	3,13	6,71	5,41
EPA	6,68	4,45	2,85	6,13	5,03

Tal como acontece na previsão dos preços da energia eléctrica, também na previsão da potência eólica, além do MAPE, a estabilidade dos resultados é outro factor importante para a comparação entre as metodologias de previsão. A Tabela 4.6 apresenta a comparação entre a nova metodologia proposta e outras seis metodologias (Persistência, ARIMA, NN, NNWT, NF e HPA), relativamente às Variâncias dos Erros diários. A média da Variância do Erro é menor para a nova metodologia proposta, indicando um grau de incerteza menor nas previsões. As melhorias na Variância do Erro são de 91,0%, 73,8%, 58,8%, 55,3%, 51,1%, e 8,7%, respectivamente.

Tabela 4.6 - Comparação da Variância do Erro entre os diferentes métodos de previsão da potência eólica.

	Primavera	Verão	Outono	Inverno	Média
Persistência	0,0592	0,0085	0,0179	0,0074	0,0233
ARIMA [62]	0,0164	0,0090	0,0039	0,0025	0,0080
NN [62]	0,0106	0,0043	0,0010	0,0044	0,0051
NNWT [61]	0,0083	0,0038	0,0012	0,0055	0,0047
NF [63]	0,0086	0,0038	0,0008	0,0041	0,0043
HPA [64]	0,0038	0,0023	0,0006	0,0026	0,0023
EPA	0,0032	0,0017	0,0011	0,0022	0,0021

Pode-se concluir que a nova metodologia proposta, baseada em EPSO e ANFIS, também é inovadora e eficaz para a previsão da potência eólica, tendo em conta os resultados reportados anteriormente na literatura especializada.

Verifica-se, ainda, que os parâmetros utilizados na aplicação do EPSO foram os mais adequados, conferindo ao sistema ANFIS uma melhor garantia de convergência.



# Capítulo 5

## 5.1 Contribuições

Esta dissertação almejou desenvolver uma nova metodologia híbrida inteligente para previsão dos preços da energia eléctrica e da potência eólica, a curto prazo, comparando os resultados obtidos com os resultados fornecidos por outras metodologias já publicadas na literatura especializada. Esta metodologia, denominada EPA, consiste na combinação eficaz de EPSO com ANFIS.

Na aplicação da metodologia ANFIS resulta vantajoso possuir um equilíbrio dos dados de entrada para o treino da rede, visto que, obtemos assim melhores resultados à saída. No caso de se aumentar em demasia o volume de dados para o treino, o resultado afectará o desempenho da metodologia, comprometendo ainda o tempo útil de execução.

Deve-se salientar também que, as características das regras de inferência e linguísticas utilizadas pelo ANFIS são automaticamente e dinamicamente actualizadas pelo próprio sistema. O EPSO é utilizado em conjunto com a metodologia ANFIS para melhorar significativamente o seu desempenho, acrescentando as funções que lhe são características para alcançar uma menor margem de erro.

De maneira geral, os erros na previsão obtidos com a nova metodologia proposta são inferiores aos reportados em artigos já publicados em revistas internacionais. Ainda, a variância do erro é inferior, indicando maior estabilidade dos resultados. Pode-se concluir, assim, que a nova metodologia proposta é inovadora e eficaz.

## 5.2 Trabalhos Futuros

Como trabalho futuro lança-se o desafio de desenvolvimento de outras metodologias híbridas baseadas nas metodologias abordadas neste trabalho, mas com a introdução de *Mutual Information* e transformadas de *Wavelet*.

Em termos intuitivos, a técnica de selecção de dados baseada na *Mutual Information* mede a informação que dois conjuntos partilham entre si, ou seja, mede o nível de conhecimento desses conjuntos, reduzindo o grau de incerteza que existe entre um conjunto e o outro.

Igualmente, com a introdução de transformadas de *Wavelet* será expectável que o sistema melhore ainda mais o seu desempenho, visto que, esta técnica funciona como um “filtro” das variações bruscas verificadas nas séries dos preços da energia eléctrica e da potência eólica, sendo que o “ruído” captado pelas *Wavelet* deverá ser novamente introduzido no resultado final.

# Bibliografia

- [1] Portal das Energias (2011). *Protocolo de Quioto*. Acedido a 17 de Maio de 2011, em: <http://www.portalenergia.com/protocolo-de-quioto/>
- [2] Portal da União Europeia (2011). *Energias e Ambiente*. Acedido a 17 de Maio de 2011, em: <http://europa.eu/generalreport/pt/2010/index.html>
- [3] Diário da República - I Série - B, N.º 44 - 3 de Março de 2005, Resolução do Conselho de Ministros n.º53/2005, pp. 1910 - 1927.
- [4] Diário da República - I Série - N.º 253 - 31 de Dezembro de 2010, Ministério da Economia, da Inovação e do Desenvolvimento, Decreto-Lei n.º 141/2010 de 31 de Dezembro, pp. 6093-6098.
- [5] WWEA, “World Wind Energy Report 2010”, *10th World Wind Energy Conf. and Ren. Energy Exhibition*, German, 2011.
- [6] Portal da REN- Redes Energéticas Nacionais (2011). Potência Eólica, História. Acedido a 17 Maio de 2011, em: <http://www.centrodeinformacao.ren.pt/PT/publicacoes/EnergiaEolica/AEnergiaEolicaemPortugal-2010.pdf>
- [7] J. P. T. Saraiva, J. L. P. P. da Silva, M. T. P. de Leão, “Mercados de Electricidade - Regulação e Tarificação de Uso das Redes”, *FEUP edições*, 2002.
- [8] A. Rodrigues, J. P. Lopes, D. E. Miranda, J. Palma, C. Monteiro, J. Sousa, R. Bessa, C. Rodrigues, J. Matos, “EPREV - A Wind Power Forecasting Tool for Portugal”, Presented at *EWEC2007, Milan, Italy*, 2007.
- [9] Liberalização do Sector da Energia, O MIBEL. Acedido a 18 Maio de 2011, em: <http://www.omip.pt/OMIP/MIBEL/tabid/72/language/pt-PT/Default.aspx>
- [10] S. K. Aggarwal, L. M. Saini, A. Kumar, “Electricity Price Forecasting in Deregulated Markets: A Review and Evaluation”, *Elect. Power Energy Syst.*, vol. 31, pp. 13-22, 2009.
- [11] F. J. Nogales, J. Contreras, A. J. Conejo, R. Espínola, “Forecasting Next-Day Electricity Prices by Time Series Models”, *IEEE Trans. Power Syst.*, vol. 17, 2002.
- [12] S. A. Pourmousavi Kani, G. H. Riahy, “A New ANN-Based Methodology for Very Short-Term Wind Speed Prediction Using Markov Chain Approach”, *IEEE Electric Power Conf. EPEC 2008.*, Canada, 2008.

- [13] G. Li, C-C. Liu, C. Mattson, J. Lawarrée, “Day-Ahead Electricity Price Forecasting in a Grid Environment”, *IEEE Trans. Power Syst.*, vol. 22, pp. 226-274, 2007.
- [14] E. Bompard, G. Ciwei, R. Napoli, F. Torelli, “Dynamic Price Forecast in a Competitive Electricity Market”, *IET Gener. Transm. Distrib.*, vol. 1, pp. 776-783, 2007.
- [15] R. C. Garcia, J. Contreras, M. van Akkeren, J. B. C. Garcia, “A GARCH Forecasting Model to predict Day-Ahead Electricity Prices”, *IEEE Trans. Power Syst.*, vol. 20, pp. 867-874, 2005.
- [16] N. M. Pindoriya, S. N. Singh, S. K. Singh, “An Adaptive Wavelet Neural Network-Based Energy Price Forecasting in Electricity Markets”, *IEEE Trans. Power Syst.*, vol. 23, pp. 1423-1432, 2008.
- [17] J. Contreras, R. Espínola, F. J. Nogales, A. J. Conejo, “ARIMA Models to Predict Next-Day Electricity Prices”, *IEEE Trans. Power Syst.*, vol. 18, pp. 1014-1020, 2003.
- [18] A. J. Conejo, M. A. Plazas, R. Espínola, A. B. Molina, “Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models”, *IEEE Trans. Power Syst.*, vol. 20, pp. 1035-1042, 2005.
- [19] F. D. L. Silva, P. C. M. de Carvalho, R. P. S. Leão, “Estado da Arte dos Métodos de Previsão da Velocidade e Potência Eólica”, *The 8th Latin-American Congress on Electricity Generation and Transmission - CLAGTEE 2009*.
- [20] I. J. R. Rosado, L. A. F. Jimenez, C. Monteiro, “Comparison of Two New Short-Term Wind-Power Forecasting Systems”, *Renew. Energy*, vol. 34, pp. 1848-1854, 2009.
- [21] J. N. M. S. Sousa, “Previsão da Produção Eléctrica em Parques Eólicos”, *Dissertação, Faculdade de Engenharia da Universidade do Porto*, Porto, 2007.
- [22] J. P. L. Coimbra, “Previsão Curto Prazo de Preços no Mercado de Electricidade”, *Versão Provisória de Dissertação, Faculdade de Engenharia da Universidade do Porto*, Porto, 2010.
- [23] C. Monteiro, R. Bessa, V. Miranda, A. Botterud, J. Wang, G. Conzelmann, “Wind Power Forecasting: State-of-the-Art 2009”, *Decision and Information Sciences Division, Argonne National Laboratory, Argonne, Illinois*, 2009.
- [24] R. Castro, “Uma Introdução às Energias Renováveis: Eólica, Fotovoltaica e Mini-Hídrica”, *IST Press*, Edição 1, 2011.
- [25] APREN, Associação de Energias Renováveis, REPAP 2020. Acedido em 15/04/2011, em: [http://www.apren.pt/fotos/editor2/divulgacao/sumario\\_executivo\\_repap\\_em\\_portugues.pdf](http://www.apren.pt/fotos/editor2/divulgacao/sumario_executivo_repap_em_portugues.pdf)

- [26] T. M. V. N. S. Esteves, “Base de Dados do Potencial Energético do Vento em Portugal - Metodologia e Desenvolvimento”, *Universidade de Lisboa, Faculdade de Ciências, Dissertação para a obtenção de grau de Mestre em Ciências e Engenharia da Terra*, 2004.
- [27] R. Pedras, “Mercado Ibérico de Electricidade - A Regulação do MIBEL e Perspectivas de Evolução”, *Seminário APOCEEP*, 2006.
- [28] M. Shahidehpour, H. Yamin, Z. Li, “Market Operations in Electric Power Systems - Forecasting, Scheduling, and Risk Management”, *Wiley*, 2002.
- [29] Constituição de um neurónio. Acedido em 05/03/2011, em: [http://www.cerebromente.org.br/n05/tecnologia/nervoso\\_i.htm](http://www.cerebromente.org.br/n05/tecnologia/nervoso_i.htm)
- [30] S. Haykin, “Neural Networks - A Comprehensive Foundation”, *Pearson Hall*, 2º Edition, 2005
- [31] J. P. S. Catalão, H. M. I. Pousinho, V. M. F. Mendes, “An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal”, in *Proc. 15th Int. Conf. on Intelligent System Applications to Power Systems*, 2009.
- [32] J. M. Barreto, “Introdução às Redes Neurais Artificiais”, *UFSC - Departamento de Informática e Estatística, Florianópolis, Brasil*, 2002.
- [33] J. S. Medeiros, “Banco de Dados Geográficos e redes Neurais Artificiais: Tecnologias de Apoio à Gestão do Território”, *Tese de Doutorado, Universidade de São Paulo, Brasil*, 1999.
- [34] S. Sandri, C. Correa, “Lógica Nebulosa”, *INPE, São José dos Campos, Brasil*, 1999.
- [35] P. P. Bonissone, “Adaptative Neural Fuzzy Inference Systems (ANFIS): Analysis and Applications”, *Piero P. Bonissone*, 2002.
- [36] J. P. S. Catalão, H. M. I. Pousinho, V. M. F. Mendes, “Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Electricity Prices Forecasting”, *IEEE Trans. Power Syst.*, vol. 2, pp. 50-59, 2011.
- [37] H. Koivo, “ANFIS (Adaptive Neuro-Fuzzy Inference System)”, *Heikki Koivo*, 2000.
- [38] V. Miranda, C. Cerqueira, C. Monteiro, “Training a FIS with EPSO under an entropy criterion for wind power prediction”, in *Proc. International Conference on Probabilistic Methods Applied to Power Systems*, 2006.
- [39] Introdução aos Controladores Neuro-Difusos. Acedido em 10/04/2011, em: [http://paginas.fe.up.pt/~ajm/www\\_sc/cnf.pdf](http://paginas.fe.up.pt/~ajm/www_sc/cnf.pdf)

- [40] H. Ying, “ General Takagi-Sugeno Fuzzy Systems with Simplified Linear Rule Consequent Are Universal Controllers, Model and Filters”, *Elsevier, Information Sciences*, vol. 108, pp. 91-107, 1997.
- [41] H. M. I. Pousinho, V. M. F. Mendes, J. P. S. Catalão, “A Hybrid PSO-ANFIS Approach for Short-Term Wind Power Prediction in Portugal”, *Energy Conv. Manag.*, vol. 52, pp. 397-402, 2011.
- [42] J. P. S. Catalão, H. M. I. Pousinho, V. M. F. Mendes, “Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting”, *IEEE Trans. Power Syst.*, vol. 26, pp. 137-144, 2011.
- [43] E. G. M. Lacerda, “A Otimização Nuvem de Partículas (Particle Swarm)”, *Departamento de Engenharia e Automação UFRN*, Brasil, 2007.
- [44] Y. del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J-C Hernandez, R. G. Harley, “Particle Swarm Optimization: Basic Concepts, Variants and Applications in Power Systems”. *IEEE Trans. Evolutionary Computation*, vol. 12, pp. 171-195, 2008.
- [45] V. Miranda, N. Fonseca, “EPSO - Evolutionary Particle Swarm Optimization, a New Algorithm with Applications in Power Systems”, *Transmission and Distribution Conference and Exhibition 2002, Asia Pacific - IEEE/PES*, 2002.
- [46] V. Miranda, N. W. Oo, “New experiments with EPSO -Evolutionary Particle Swarm Optimization”, *Proceedings of the IEEE Swarm Intelligence Symposium*, Indianapolis, Indiana, USA, pp. 162-169, 2006.
- [47] M. Chen, C. Wu, P. Flening, “An Evolutionary Particle Swarm Algorithm for Multi-Objective Optimisation”, *Proceedings of the 7th World Congress on Intelligent Control and Automation*, Chongqing, China, 2008.
- [48] M. B. Abdelhalim, A. E. Salama, S. E.-D Habib, “Hardware Software Partitioning Using Particle Swarm Optimization”, *IEEE, System-on-Chip for Real-Time Applications, The 6th International Workshop*, 2007.
- [49] C. A. A. Cerqueira, “Relatório - Estudo de Variantes de Otimização por Enxames de Partículas (EPSO) e o seu Comportamento num Problema Real de Previsão de Potência de um Parque Eólico”, *INESCPORTO*, 2005.
- [50] OMEL, Operador de Mercado de Espanha (2010). Acedido em 25/10/2010, em:<http://www.omwl.es/>
- [51] J. Contreras, R. Espínola, F. J. Nogales, A. J. Conejo, “ARIMA Models to Predict Next-Day Electricity Prices”, *IEEE Trans. PowerSyst.*, vol. 18, pp. 1014-1020, 2003.

- [52] A. J. Conejo, M. A. Plazas, R. Espínola, A. B. Molina, "Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models", *IEEE Trans. Power Syst.*, vol. 20, pp. 1035-1042, 2005.
- [53] N. Amjady, F. Keynia, "Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm", *IEEE Trans. PowerSyst.*, vol. 24, pp. 306-318, 2009.
- [54] C. Garcia-Matos, J. Rodriguez, M. J. Sanchez, "Mixed Models for Short-Run Forecasting of Electricity Prices: Application for the Spanish Market", *IEEE Trans. Power Syst.*, vol. 22, pp. 544-552, 2007.
- [55] J. P. S. Catalão, S. J. P. S. Mariano, V. M. F. Mendes, L. A. F. M. Ferreira, "Short-Term Electricity Prices Forecasting in a Competitive Market: A Neural Network Approach", *Elect. Power Syst. Res.*, vol. 77, pp. 1297-1304, 2007.
- [56] A. T. Lora, J. M. R Santos, A. G. Expósito, J. L. M. Ramos, J. C. R. Santos, "Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques", *IEEE Trans. Power Syst.*, vol. 22, pp. 1294-1301, 2007.
- [57] N. Amjady, "Day-Ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network", *IEEE Trans. Power Syst.*, vol. 21, pp. 887-896, 2006.
- [58] N. Amjady, H. Hemmati, "Day-Ahead Price Forecasting of Electricity Markets by a Hybrid Intelligent System", *Eur. Trans. Elect. Power*, vol. 19, pp. 89-102, 2009.
- [59] N. M. Pindoriya, S. N. Singh, S. K. Singh, "An adaptive Wavelet Neural Network-Based Energy Price Forecasting in Electricity Markets", *IEEE Trans. Power Syst.*, vol. 23, pp.1423-1432, 2008.
- [60] J. P. S. Catalão, H. M. I Pousinho, V. M. F. Mendes, "Neural Networks and Wavelet Transform for Short-Term Electricity Prices Forecasting", in *Proc. 15th Int. Conf. on Intelligent System Applications to Power Systems*, Nov. 2009.
- [61] J. P. S Catalão, H. M. I. Pousinho, V. M. F. Mendes, "Short-Term Wind Power Forecasting in Portugal by Neural Networks and Wavelet Transform", *Renew. Energy*, vol. 36, pp. 1245-1251, 2011.
- [62] J. P. S. Catalão, H. M. I. Pousinho, V. M. F. Mendes, "An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal", *Eng. Intell. Syst. Elect. Eng. Commun.*, vol 17, pp. 5-11, 2009.
- [63] H. M. I. Pousinho, V.M.F. Mendes, J.P.S. Catalão, "Application of adaptive neuro-fuzzy inference for wind power short-term forecasting", *IEEJ Transactions on Electrical and Electronic Engineering*, 2011, aceite.

[64] H. M. I. Pousinho, V. M. F. Mendes, J. P. S. Catalão, “A Hybrid PSO-ANFIS Approach for Short-Term Wind Power Prediction in Portugal”, *Energy Conv. Manag.*, vol. 52, pp. 397-402, 2011.



## Anexos

Duas comunicações científicas aceites para apresentação na ISAP 2011, *International Conference on Intelligent System Applications to Power Systems*, Grécia, Setembro 2011

*Short-Term Wind Power Forecasting using a Hybrid  
Evolutionary Intelligent Approach*

*Application of an Intelligent System Based on EPSO  
and ANFIS to Price Forecasting*

# Short-Term Wind Power Forecasting using a Hybrid Evolutionary Intelligent Approach

J. P. S. Catalão, *Member, IEEE*, G. J. Osório, and H. M. I. Pousinho

**Abstract**—This paper presents a hybrid evolutionary intelligent approach, based on a combination of evolutionary particle swarm optimization (EPSO) with an adaptive-network-based fuzzy inference system (ANFIS), for short-term wind power forecasting in Portugal. The increased integration of wind power into the electric grid, as nowadays occurs in Portugal, poses challenges due to its intermittency and volatility. Hence, good forecasting tools are important for tackling these challenges. The accuracy of the wind power forecasting attained with the proposed approach is evaluated, reporting the numerical results from a real-world case study.

**Index Terms**—Forecasting, evolutionary programming, neuro-fuzzy, particle swarm optimization, wind power.

## I. INTRODUCTION

THE wind energy is free, so all wind-generated electric energy is accepted as it comes, i.e. as it is available. However, the availability of the power supply generated from wind energy is not known in advance [1]. Hence, the integration of a large share of wind power in an electricity system leads to some important challenges [2]. Wind power forecasting plays a key role in tackling these challenges [3].

Short-term wind power forecasting is an extremely important field of research for the energy sector, as the system operators must handle an important amount of fluctuating power from the increasing installed wind power capacity. The time scales concerning short-term prediction are in the order of some days (for the forecast horizon) and from minutes to hours (for the time-step) [4]. In the technical literature, several methods to predict wind power have been reported, namely physical and statistical methods.

The physical method requires a lot of physical considerations to reach the best prediction precision. For a physical model, the input variables will be the physical or meteorology information, such as description of orography, roughness, obstacles, pressure, and temperature. The statistical method aims at finding the relationship of the on-line measured power data. For a statistical model, the historical data of the wind farm may be used. Physical method has advantages in long-term prediction while statistical method does well in short-term prediction [5].

The conventional statistical models are time-series-based models, including auto regressive integrated moving average (ARIMA) models [6], [7]. The persistence models are considered as the simplest time-series models, but they can surpass many other models in very short-term prediction [5]. The persistence model is a useful first approximation for short-term wind power forecasting.

Some new methods are catching researcher's attention, namely neural networks (NN) [7], [8], neural networks combined with wavelet transform (NNWT) [9], adaptive wavelet neural networks (AWNN) [10], data mining [11], fuzzy logic and neuro-fuzzy (NF) [12], [13], evolutionary algorithms [14], and some hybrid methods [15], [16]. The accurate comparison of all the methods is quite difficult because these methods depend on different situations and the data collection is a formidable task. However, it has been reported that artificial intelligence methods outperformed others in short-term prediction [5].

This paper presents a successful application of combining evolutionary particle swarm optimization (EPSO) with an adaptive-network-based fuzzy inference system (ANFIS), hereafter defined as EPA approach, for short-term wind power forecasting in Portugal.

The EPA approach is compared with persistence, ARIMA, NN, NNWT, NF and hybrid PSO-ANFIS (HPA) approaches, to demonstrate its effectiveness regarding forecasting accuracy and computation time.

This paper is structured as follows. Section 2 presents the proposed hybrid evolutionary intelligent approach to forecast wind power. Section 3 provides the different criteria used to evaluate the forecasting accuracy. Section 4 provides the results from the case study. Finally, Section 5 provides conclusions.

## II. HYBRID EVOLUTIONARY INTELLIGENT APPROACH

The proposed hybrid evolutionary intelligent approach is based on a combination of EPSO and ANFIS. The EPSO is used to improve the performance of ANFIS, tuning the membership functions required to achieve a lower error.

### A. Evolutionary Particle Swarm Optimization

EPSO incorporates a selection procedure to the original PSO algorithm, as well as self-adapting properties for its parameters [17]. The general scheme of EPSO is the following [18], [19]:

- Replication: each particle is replicated  $r$  times.
- Mutation: each particle has its weights mutated.

---

The work of H. M. I. Pousinho was supported by the Fundação para a Ciência e a Tecnologia (FCT) under Ph.D. grant (SFRH/BD/62965/2009).

J. P. S. Catalão, G. J. Osório and H. M. I. Pousinho are with the University of Beira Interior, Covilha, Portugal, and also with the Center for Innovation in Electrical and Energy Engineering, IST, Lisbon, Portugal (e-mail: catalao@ubi.pt).

- Reproduction: each mutated particle generates an offspring according to the particle movement rule.
- Evaluation: each offspring has its fitness evaluated.
- Selection: by stochastic tournament the best particles survive to form a new generation.

The particle movement is defined as:

$$X_i^{(k+1)} = X_i^{(k)} + V_i^{(k+1)} \quad (1)$$

$$V_i^{(k+1)} = w_{i1}^* V_i^{(k)} + w_{i2}^* (b_i - X_i) + w_{i3}^* P (b_g^* - X_i) \quad (2)$$

where  $X_i^{(k)}$  is the location of particle  $i$  at generation  $k$ ,  $V_i^{(k)}$  is the velocity of particle  $i$  at generation  $k$ ,  $b_i$  is the best point found by particle  $i$  in its past life up to the current generation,  $b_g$  is the best overall point found by the swarm of particles in their past life up to the current generation,  $w_{i1}$  is the weight conditioning the *inertia* term (a new particle is created in the same direction as its previous couple of ancestors),  $w_{i2}$  is the weight conditioning the *memory* term (the new particle is attracted to the best position occupied by its ancestors),  $w_{i3}$  is the weight conditioning the *cooperation* or *information exchange* term (the new particle is attracted to the overall best-so-far found by the swarm), and  $P$  is the communication factor, a diagonal matrix containing value 1 with probability  $p$  and value 0 with probability  $(1-p)$ .

The weights undergo evolution under a mutation process:

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (3)$$

where  $N(0,1)$  is a random number following a normalized Gaussian distribution with zero mean and unit variance; the global best  $b_g$  is also randomly disturbed to give:

$$b_g^* = b_g + \tau' N(0,1) \quad (4)$$

The  $\tau$  and  $\tau'$  are learning parameters that can be either fixed or treated as strategic parameters and therefore subject to mutation.

This scheme benefits from two ‘‘pushes’’ in the right direction: the Darwinistic process of selection and the particle movement rule. Therefore, it is natural to expect that it may display advantageous convergence properties when compared to evolution strategies or PSO alone. Furthermore, EPSO can also be classified as a self-adaptive algorithm, because it relies on the mutation and selection of strategic parameters [18].

## B. ANFIS

ANFIS is a class of adaptive multi-layer feedforward networks, applied to nonlinear forecasting where past samples are used to forecast the sample ahead. ANFIS incorporates the self-learning ability of NN with the linguistic expression function of fuzzy inference [20].

The ANFIS network is composed of five layers. Each layer contains several nodes described by the node function. Let  $O_i^j$  denote the output of the  $i$ th node in layer  $j$ . In layer 1, every node  $i$  is an adaptive node with node function:

$$O_i^1 = \mu A_i(x), \quad i=1,2 \quad (5)$$

or

$$O_i^1 = \mu B_{i-2}(y), \quad i=3,4 \quad (6)$$

where  $x$  (or  $y$ ) is the input to the  $i$ th node and  $A_i$  (or  $B_{i-2}$ ) is a linguistic label associated with this node.

The membership functions for  $A$  and  $B$  are usually described by generalized bell functions, e.g.:

$$\mu A_i(x) = \frac{1}{1 + \left| \frac{x-r_i}{p_i} \right|^{2q_i}} \quad (7)$$

where  $\{p_i, q_i, r_i\}$  is the parameter set. Parameters in this layer are referred to as premise parameters.

In layer 2, each node  $\Pi$  multiplies incoming signals and sends the product out:

$$O_i^2 = w_i = \mu A_i(x) \mu B_i(y), \quad i=1,2 \quad (8)$$

In layer 3, each node  $N$  computes the ratio of the  $i$ th rules’ firing strength to the sum of all rules’ firing strengths:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i=1,2 \quad (9)$$

In layer 4, each node computes the contribution of the  $i$ th rule to the overall output:

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i (a_i x + b_i y + c_i), \quad i=1,2 \quad (10)$$

where  $\bar{w}_i$  is the output of layer 3 and  $\{a_i, b_i, c_i\}$  is the parameter set. Parameters of this layer are referred to as consequent parameters.

In layer 5, the single node  $\Sigma$  computes the final output as the summation of all incoming signals:

$$O_i^5 = \sum_i \bar{w}_i z_i = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (11)$$

Thus, an adaptive network is functionally equivalent to a Sugeno-type fuzzy inference system.

In this paper, ANFIS employs EPSO method to adjust the parameters of the membership functions. The membership functions considered in this study are triangular-shaped.

## III. FORECASTING ACCURACY EVALUATION

To evaluate the accuracy in forecasting wind power, the mean absolute percentage error (MAPE) is considered.

The MAPE criterion is defined as follows:

$$MAPE = \frac{100}{N} \sum_{h=1}^N \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (12)$$

$$\bar{p} = \frac{1}{N} \sum_{h=1}^N p_h \quad (13)$$

where  $\hat{p}_h$  and  $p_h$  are respectively the forecasted and actual wind power at period  $h$ ,  $\bar{p}$  is the average wind power of the forecasting horizon and  $N$  is the number of forecasted periods. For daily MAPE,  $N$  equals to 24.

A measure of the uncertainty of a model is the variability of what is still unexplained after fitting the model, which can be measured through the estimation of the variance of the error. The smaller this variance, the more precise is the prediction [21]. Consistent with definition (12), daily error variance can be estimated as:

$$\sigma_{e,day}^2 = \frac{1}{N} \sum_{h=1}^N \left( \frac{|\hat{p}_h - p_h|}{p} - (e_{day}) \right)^2 \quad (14)$$

$$e_{day} = \frac{1}{N} \sum_{h=1}^N \frac{|\hat{p}_h - p_h|}{p} \quad (15)$$

Daily MAPE and error variance are used in the case study.

#### IV. CASE STUDY

The EPA approach has been applied for wind power forecasting in Portugal. The numerical results presented take into account the wind farms that have telemetry with the National Electric Grid (REN). Historical wind power data are the only inputs for training the ANFIS. For the sake of clear comparison, no exogenous variables are considered.

Our forecaster predicts the value of the wind power subseries for 3 hours ahead, taking into account the wind power data of the previous 12 hours with a time-step of 15 minutes. This procedure is repeated until the next 24 hours values are predicted.

For the sake of a fair comparison, the same test days as in [1], [7], [9], [13] and [16] are selected (July 3, 2007, October 31, 2007, January 14, 2008, and April 2, 2008), corresponding to the four seasons of the year. Hence, days with particularly good wind power behavior are deliberately not chosen.

Numerical results with the EPA approach are shown in Figs. 1 to 4 respectively for the winter, spring, summer and fall days.




Fig. 1. Winter day: actual wind power, solid line, together with the forecasted wind power, dashed line.




Fig. 2. Spring day: actual wind power, solid line, together with the forecasted wind power, dashed line.

Table I shows a comparison between the EPA approach and six other approaches (persistence, ARIMA, NN, NNWT, NF and HPA), regarding the MAPE criterion.

The proposed hybrid evolutionary intelligent approach presents better forecasting accuracy: the MAPE has an average value of 5.03%.

Improvement in the average MAPE of the proposed approach with respect to the six previous approaches is 73.6%, 51.4%, 30.7%, 27.8%, 24.2% and 7.0%, respectively.

In addition to the MAPE, stability of results is another important factor for the comparison of forecast approaches.




Fig. 3. Summer day: actual wind power, solid line, together with the forecasted wind power, dashed line.




Fig. 4. Fall day: actual wind power, solid line, together with the forecasted wind power, dashed line.

TABLE I  
COMPARATIVE MAPE RESULTS

	Winter	Spring	Summer	Fall	Average
Persistence	13.89	32.40	13.43	16.49	19.05
ARIMA [7]	10.93	12.05	11.04	7.35	10.34
NN [1]	9.51	9.92	6.34	3.26	7.26
NNWT [9]	9.23	9.55	5.97	3.14	6.97
NF [13]	8.85	8.96	5.63	3.11	6.64
HPA [16]	6.71	7.22	4.59	3.13	5.41
EPA	6.13	6.68	4.45	2.85	5.03

Table II shows a comparison between the EPA approach and the six other approaches (persistence, ARIMA, NN, NNWT, NF and HPA), regarding daily error variance.

TABLE II  
DAILY FORECASTING ERROR VARIANCE

	Winter	Spring	Summer	Fall	Average
Persistence	0.0074	0.0592	0.0085	0.0179	0.0233
ARIMA [7]	0.0025	0.0164	0.0090	0.0039	0.0080
NN [1]	0.0044	0.0106	0.0043	0.0010	0.0051
NNWT [9]	0.0055	0.0083	0.0038	0.0012	0.0047
NF [13]	0.0041	0.0086	0.0038	0.0008	0.0043
HPA [16]	0.0026	0.0038	0.0023	0.0006	0.0023
EPA	0.0022	0.0032	0.0017	0.0011	0.0021

The average error variance is smaller for the proposed hybrid evolutionary intelligent approach, indicating less uncertainty in the predictions.

Improvement in the average error variance of the proposed hybrid evolutionary intelligent approach with respect to the six previous approaches is 91.0%, 73.8%, 58.8%, 55.3%, 51.1%, and 8.7%, respectively.

All the cases have been run on a PC with 1 GB of RAM and a 1.8-GHz-based processor. The average computation time is less than 1 minute. Hence, the proposed hybrid evolutionary intelligent approach presents not only better forecasting accuracy, but also an acceptable computation time.

## V. CONCLUSIONS

This paper proposed a hybrid evolutionary intelligent approach based on EPSO and ANFIS for short-term wind power forecasting in Portugal. The application of the EPA approach to wind power forecasting is both novel and effective. The MAPE has an average value of 5.03%, while the average computation time is less than 1 minute. Hence, the proposed hybrid evolutionary intelligent approach presents a good trade-off between forecasting accuracy and computation time, taking into account results previously reported in the technical literature.

## VI. ACKNOWLEDGMENT

This work is funded by FEDER funds (European Union) through the Operational Programme for Competitiveness Factors – COMPETE, and by Portuguese funds through the Fundação para a Ciência e a Tecnologia – FCT, under Project No. FCOMP-01-0124-FEDER-014887 (Ref. FCT PTDC/EEA-EEL/110102/2009).

## VII. REFERENCES

- [1] J. P. S. Catalão, H. M. I. Pousinho, and V. M. F. Mendes, "An artificial neural network approach for short-term wind power forecasting in Portugal," in *Proc. 15th Int. Conf. on Intelligent System Applications to Power Systems*, Nov. 2009.
- [2] J. Kabouris and F. D. Kanellos, "Impacts of large-scale wind penetration on designing and operation of electric power systems," *IEEE Trans. Sust. Energy*, vol. 1, pp. 107-114, Jul. 2010.
- [3] B. Ernst, B. Oakleaf, M. L. Ahlstrom, M. Lange, C. Moehrlen, B. Lange, U. Focken, and K. Rohrig, "Predicting the wind," *IEEE Power & Energy Magazine*, vol. 5, pp. 78-89, Nov.-Dec. 2007.
- [4] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa, "A review on the young history of the wind power short-term prediction," *Renew. Sust. Energy Rev.*, vol. 12, pp. 1725-1744, Aug. 2008.
- [5] L. Ma, S. Y. Luan, C. W. Jiang, H. L. Liu, and Y. Zhang, "A review on the forecasting of wind speed and generated power," *Renew. Sust. Energy Rev.*, vol. 13, pp. 915-920, May 2009.
- [6] R. G. Kavasseri and K. Seetharaman, "Day-ahead wind speed forecasting using f-ARIMA models," *Renew. Energy*, vol. 34, pp. 1388-1393, May 2009.
- [7] J. P. S. Catalão, H. M. I. Pousinho, and V. M. F. Mendes, "An artificial neural network approach for short-term wind power forecasting in Portugal," *Eng. Intell. Syst. Elect. Eng. Commun.*, vol. 17, pp. 5-11, Mar. 2009.
- [8] I. J. Ramirez-Rosado, L. A. Fernandez-Jimenez, C. Monteiro, J. Sousa, and R. Bessa, "Comparison of two new short-term wind-power forecasting systems," *Renew. Energy*, vol. 34, pp. 1848-1854, Jul. 2009.
- [9] J. P. S. Catalão, H. M. I. Pousinho, and V. M. F. Mendes, "Short-term wind power forecasting in Portugal by neural networks and wavelet transform," *Renew. Energy*, vol. 36, pp. 1245-1251, Apr. 2011.
- [10] K. Bhaskar and S. N. Singh, "Wind speed forecasting using MRA based adaptive wavelet neural network," in *Proc. 16th National Power Systems Conf.*, Dec. 2010.

- [11] A. Kusiak, H. Y. Zheng, and Z. Song, "Short-term prediction of wind farm power: a data mining approach," *IEEE Trans. Energy Convers.*, vol. 24, pp. 125-136, Mar. 2009.
- [12] G. Sideratos and N. D. Hatzigiorgiou, "An advanced statistical method for wind power forecasting," *IEEE Trans. Power Syst.*, vol. 22, pp. 258-265, Feb. 2007.
- [13] H. M. I. Pousinho, V. M. F. Mendes, and J. P. S. Catalão, "Application of adaptive neuro-fuzzy inference for wind power short-term forecasting," *IEEJ Trans. Electr. Electron. Eng.*, to be published.
- [14] R. Jursa, K. Rohrig, "Short-term wind power forecasting using evolutionary algorithms for the automated specification of artificial intelligence models," *Int. J. Forecast.*, vol. 24, pp. 694-709, Oct.-Dec. 2008.
- [15] R. J. Bessa, V. Miranda, and J. Gama, "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, Nov. 2009.
- [16] H. M. I. Pousinho, V. M. F. Mendes, and J. P. S. Catalão, "A hybrid PSO-ANFIS approach for short-term wind power prediction in Portugal," *Energy Conv. Manag.*, vol. 52, pp. 397-402, Jan. 2011.
- [17] Y. del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J.-C. Hernandez, and R. G. Harley, "Particle swarm optimization: basic concepts, variants and applications in power systems," *IEEE Trans. Evol. Comput.*, vol. 12, pp. 171-195, Apr. 2008.
- [18] V. Miranda and N. Fonseca, "EPSO - best-of-two-worlds meta-heuristic applied to power system problems," in *Proc. Congr. Evol. Comput.*, vol. 2, pp. 1080-1085, May 2002.
- [19] V. Miranda, "Evolutionary algorithms with particle swarm movements," in *Proc. 13th Int. Conf. on Intelligent Systems Application to Power Systems*, pp. 6-21, Nov. 2005.
- [20] Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming, and S. Yang, "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, Aug. 2008.
- [21] A. J. Conejo, M. A. Plazas, R. Espínola, and A. B. Molina, "Day-ahead electricity price forecasting using the wavelet transform and ARIMA models," *IEEE Trans. Power Syst.*, vol. 20, pp. 1035-1042, May 2005.

## VIII. BIOGRAPHIES

**J. P. S. Catalão** (M'04) received the M.Sc. degree from the Instituto Superior Técnico, Lisbon, Portugal, in 2003 and the Ph.D. degree from the University of Beira Interior (UBI), Covilha, Portugal, in 2007.

Currently, he is a Professor at UBI. His research interests include hydro scheduling, unit commitment, price forecasting, wind energy systems, and electricity markets.

Prof. Catalão is an Editor of IEEE TRANSACTIONS ON SUSTAINABLE ENERGY.

**G. J. Osório** received the B.Sc. degree from the University of Beira Interior (UBI), Covilha, Portugal, in 2009.

Currently, he is a M.Sc. student at UBI. His research interests include price forecasting and wind power forecasting.

**H. M. I. Pousinho** received the M.Sc. degree from the University of Beira Interior (UBI), Covilha, Portugal, in 2009.

Currently, he is a Ph.D. student at UBI, in collaboration with the Instituto Superior de Engenharia de Lisboa. His research interests include hydro scheduling, unit commitment, price forecasting, and wind power forecasting.

# Application of an Intelligent System based on EPSO and ANFIS to Price Forecasting

J. P. S. Catalão, *Member, IEEE*, G. J. Osório, and H. M. I. Pousinho

**Abstract**—This paper proposes evolutionary particle swarm optimization (EPSO) combined with an adaptive-network-based fuzzy inference system (ANFIS) for short-term electricity prices forecasting. In a deregulated framework, producers and consumers require short-term price forecasting to derive their bidding strategies to the electricity market. Accurate forecasting tools are required for producers to maximize their profits and for consumers to maximize their utilities. The accuracy of the price forecasting attained with the proposed intelligent system is thoroughly evaluated, reporting the numerical results from a real-world case study.

**Index Terms**—Electricity market, neuro-fuzzy, evolutionary programming, particle swarm optimization, price forecasting.

## I. INTRODUCTION

IN a deregulated framework, producers and consumers require short-term electricity prices forecasting to derive their bidding strategies to the market. Accurate forecasting tools are required for producers to maximize their profits and for consumers to maximize their utilities [1].

In most competitive electricity markets, price series present the following features: high frequency, non-constant mean and variance, daily and weekly seasonality, calendar effect on weekend and public holidays, high volatility and high percentage of unusual prices [2]. Therefore, price forecasting is essential for all market participants.

In the technical literature, several techniques to predict electricity prices have been reported [3], namely hard and soft computing techniques.

The hard computing techniques include auto regressive integrated moving average (ARIMA) [4], wavelet-ARIMA [5], and mixed model [6] approaches. Usually, an exact model of the system is required, and the solution is found using algorithms that consider the physical phenomena that govern the process. Although these approaches can be very accurate, they require a lot of information, and the computational cost is very high.

The soft computing or artificial intelligence techniques include neural networks (NN) [7], fuzzy neural networks (FNN) [8], weighted nearest neighbors (WNN) [9], adaptive wavelet neural network (AWNN) [10], hybrid intelligent

system (HIS) [11], neural networks combined with wavelet transform (NNWT) [1], and cascaded neuro-evolutionary algorithm (CNEA) [12]. Usually, an input-output mapping is learned from historical examples, thus there is no need to model the system. Hence, these approaches can be much more efficient computationally and as accurate as the first ones, if the correct inputs are considered [13].

This paper proposes evolutionary particle swarm optimization (EPSO) combined with an adaptive-network-based fuzzy inference system (ANFIS), hereafter defined as EPA approach, for short-term electricity prices forecasting. The proposed intelligent system is examined on the electricity market of mainland Spain, commonly used as the test case in several price forecasting papers [4]-[12]. It has been concluded that the Spanish market has a hard nonlinear behavior and time variant functional relationship [5], [8]. So, this market is a real world case study with sufficient complexity. The EPA approach is compared with ARIMA, mixed-model, NN, wavelet-ARIMA, WNN, FNN, HIS, AWNN, NNWT and CNEA approaches, to demonstrate its effectiveness regarding forecasting accuracy and computation time.

This paper is structured as follows. Section 2 presents the proposed intelligent system to forecast electricity prices. Section 3 provides the different criterions used to evaluate the forecasting accuracy. Section 4 provides the results from a case study based on the electricity market of mainland Spain. Finally, Section 5 provides conclusions.

## II. PROPOSED INTELLIGENT SYSTEM

The proposed intelligent system is based on a combination of EPSO and ANFIS. The EPSO is used to improve the performance of ANFIS, tuning the membership functions required to achieve a lower error.

### A. Evolutionary Particle Swarm Optimization

EPSO incorporates a selection procedure to the original PSO algorithm, as well as self-adapting properties for its parameters [14]. The general scheme of EPSO is the following [15], [16]:

- Replication: each particle is replicated  $r$  times.
- Mutation: each particle has its weights mutated.
- Reproduction: each mutated particle generates an offspring according to the particle movement rule.
- Evaluation: each offspring has its fitness evaluated.
- Selection: by stochastic tournament the best particles survive to form a new generation.

---

The work of H. M. I. Pousinho was supported by the Fundação para a Ciência e a Tecnologia (FCT) under Ph.D. grant (SFRH/BD/62965/2009).

J. P. S. Catalão, G. J. Osório and H. M. I. Pousinho are with the University of Beira Interior, Covilha, Portugal, and also with the Center for Innovation in Electrical and Energy Engineering, IST, Lisbon, Portugal (e-mail: catalao@ubi.pt).

The particle movement is defined as:

$$X_i^{(k+1)} = X_i^{(k)} + V_i^{(k+1)} \quad (1)$$

$$V_i^{(k+1)} = w_{i1}^* V_i^{(k)} + w_{i2}^* (b_i - X_i) + w_{i3}^* P (b_g^* - X_i) \quad (2)$$

where  $X_i^{(k)}$  is the location of particle  $i$  at generation  $k$ ,  $V_i^{(k)}$  is the velocity of particle  $i$  at generation  $k$ ,  $b_i$  is the best point found by particle  $i$  in its past life up to the current generation,  $b_g$  is the best overall point found by the swarm of particles in their past life up to the current generation,  $w_{i1}$  is the weight conditioning the *inertia* term (a new particle is created in the same direction as its previous couple of ancestors),  $w_{i2}$  is the weight conditioning the *memory* term (the new particle is attracted to the best position occupied by its ancestors),  $w_{i3}$  is the weight conditioning the *cooperation* or *information exchange* term (the new particle is attracted to the overall best-so-far found by the swarm), and  $P$  is the communication factor, a diagonal matrix containing value 1 with probability  $p$  and value 0 with probability  $(1-p)$ .

The weights undergo evolution under a mutation process:

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (3)$$

where  $N(0,1)$  is a random number following a normalized Gaussian distribution with zero mean and unit variance; the global best  $b_g$  is also randomly disturbed to give:

$$b_g^* = b_g + \tau' N(0,1) \quad (4)$$

The  $\tau$  and  $\tau'$  are learning parameters that can be either fixed or treated as strategic parameters and therefore subject to mutation.

This scheme benefits from two ‘‘pushes’’ in the right direction: the Darwinistic process of selection and the particle movement rule. Therefore, it is natural to expect that it may display advantageous convergence properties when compared to evolution strategies or PSO alone. Furthermore, EPSO can also be classified as a self-adaptive algorithm, because it relies on the mutation and selection of strategic parameters [15].

### B. ANFIS

ANFIS is a class of adaptive multi-layer feedforward networks, applied to nonlinear forecasting where past samples are used to forecast the sample ahead. ANFIS incorporates the self-learning ability of NN with the linguistic expression function of fuzzy inference [17].

The ANFIS network is composed of five layers. Each layer contains several nodes described by the node function. Let  $O_i^j$  denote the output of the  $i$ th node in layer  $j$ . In layer 1, every node  $i$  is an adaptive node with node function:

$$O_i^1 = \mu A_i(x), \quad i = 1, 2 \quad (5)$$

or

$$O_i^1 = \mu B_{i-2}(y), \quad i = 3, 4 \quad (6)$$

where  $x$  (or  $y$ ) is the input to the  $i$ th node and  $A_i$  (or  $B_{i-2}$ ) is a linguistic label associated with this node.

The membership functions for  $A$  and  $B$  are usually described by generalized bell functions, e.g.:

$$\mu A_i(x) = \frac{1}{1 + \left| \frac{x - r_i}{p_i} \right|^{2q_i}} \quad (7)$$

where  $\{p_i, q_i, r_i\}$  is the parameter set. Parameters in this layer are referred to as premise parameters.

In layer 2, each node  $\Pi$  multiplies incoming signals and sends the product out:

$$O_i^2 = w_i = \mu A_i(x) \mu B_i(y), \quad i = 1, 2 \quad (8)$$

In layer 3, each node  $N$  computes the ratio of the  $i$ th rules’ firing strength to the sum of all rules’ firing strengths:

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (9)$$

In layer 4, each node computes the contribution of the  $i$ th rule to the overall output:

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i (a_i x + b_i y + c_i), \quad i = 1, 2 \quad (10)$$

where  $\bar{w}_i$  is the output of layer 3 and  $\{a_i, b_i, c_i\}$  is the parameter set. Parameters of this layer are referred to as consequent parameters.

In layer 5, the single node  $\Sigma$  computes the final output as the summation of all incoming signals:

$$O_i^5 = \sum_i \bar{w}_i z_i = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (11)$$

Thus, an adaptive network is functionally equivalent to a Sugeno-type fuzzy inference system.

In this paper, ANFIS employs EPSO method to adjust the parameters of the membership functions. The membership functions considered in this study are triangular-shaped.

### III. FORECASTING ACCURACY EVALUATION

To evaluate the accuracy in forecasting electricity prices, the mean absolute percentage error (MAPE) is considered, as in [4]-[12].

The MAPE criterion is defined as follows:

$$MAPE = \frac{100}{N} \sum_{h=1}^N \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (12)$$

$$\bar{p} = \frac{1}{N} \sum_{h=1}^N p_h \quad (13)$$

where  $\hat{p}_h$  and  $p_h$  are respectively the forecasted and actual electricity prices at hour  $h$ ,  $\bar{p}$  is the average price of the forecasting period, and  $N$  is the number of forecasted hours. For weekly MAPE,  $N$  equals to 168. The average price is used in (12) to avoid the adverse effect of prices close to zero [18].

A measure of the uncertainty of a model is the variability of what is still unexplained after fitting the model, which can be measured through the estimation of the variance of the error.

The smaller this variance, the more precise is the prediction of prices [5]. Consistent with definition (12), weekly error variance can be estimated as:

$$\sigma_{e,week}^2 = \frac{1}{168} \sum_{h=1}^{168} \left( \frac{|\hat{p}_h - p_h|}{\bar{p}} - (e_{week}) \right)^2 \quad (14)$$

$$e_{week} = \frac{1}{168} \sum_{h=1}^{168} \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (15)$$

Weekly MAPE and error variance are used in the case study.

#### IV. CASE STUDY

The EPA approach is applied to forecast next-week (168 hours) prices in the electricity market of mainland Spain. Price forecasting is computed using historical data of year 2002 for the Spanish market, available at [19]. It should be noted that the Spanish market is a duopoly with a dominant player, resulting in price changes related to the strategic behavior of the dominant player, which are hard to predict [5].

For the sake of simplicity and clear comparison, no exogenous variables are considered. Also, for the sake of a fair comparison, the same test weeks as in [4]-[12] are selected, which correspond to the four seasons of year 2002.

Different sets of lagged prices have been proposed as input features for price forecasting in the Spanish market. For the proposed price forecasting model, 168-h ahead predictions are computed, taking into account the hourly historical price data of the 6 weeks (or 42 days) previous to the week whose prices are to be forecasted. Thus, the forecaster output directly provides a vector of dimension equal to the length of the forecasting horizon (168-h ahead).

Numerical results with the EPA approach are shown in Figs. 1 to 4 respectively for the winter, spring, summer and fall weeks.




Fig. 1. Winter week: actual prices, solid line, together with the forecasted prices, dashed line, in euro per megawatt hour.




Fig. 2. Spring week: actual prices, solid line, together with the forecasted prices, dashed line, in euro per megawatt hour.

Table I shows a comparison between the EPA approach and ten other approaches (ARIMA, mixed-model, NN, wavelet-ARIMA, WNN, FNN, HIS, AWNN, NNWT and CNEA), regarding the MAPE criterion.

The proposed intelligent system presents better forecasting accuracy: the MAPE for the Spanish market has an average value of 5.12%.

Improvement in the average MAPE of the proposed intelligent system with respect to the ten previous approaches is 48.6%, 44.9%, 42.5%, 36.9%, 36.4%, 31.9%, 26.5%, 24.1%, 23.0% and 3.8%, respectively.




Fig. 3. Summer week: actual prices, solid line, together with the forecasted prices, dashed line, in euro per megawatt hour.




Fig. 4. Fall week: actual prices, solid line, together with the forecasted prices, dashed line, in euro per megawatt hour.

TABLE I  
COMPARATIVE MAPE RESULTS

	Winter	Spring	Summer	Fall	Average
ARIMA [4]	6.32	6.36	13.39	13.78	9.96
Mixed-model [6]	6.15	4.46	14.90	11.68	9.30
NN [7]	5.23	5.36	11.40	13.65	8.91
Wavelet-ARIMA [5]	4.78	5.69	10.70	11.27	8.11
WNN [9]	5.15	4.34	10.89	11.83	8.05
FNN [8]	4.62	5.30	9.84	10.32	7.52
HIS [11]	6.06	7.07	7.47	7.30	6.97
AWNN [10]	3.43	4.67	9.64	9.29	6.75
NNWT [1]	3.61	4.22	9.50	9.28	6.65
CNEA [12]	4.88	4.65	5.79	5.96	5.32
EPA	3.59	4.10	6.39	6.40	5.12

In addition to the MAPE, stability of results is another important factor for the comparison of forecast approaches.

Table II shows a comparison between the EPA approach and eight other approaches (ARIMA, NN, wavelet-ARIMA, FNN, AWNN, NNWT, HIS and CNEA), regarding weekly error variances.

The average error variance is smaller for the proposed intelligent system, indicating less uncertainty in the predictions as occurred in [20].

Improvement in the average error variance of the proposed intelligent system with respect to the eight previous approaches is 70.7%, 61.4%, 57.8%, 50.0%, 43.8%, 27.0%, 25.0%, and 25.0%, respectively. For the WNN and mixed-model, the error variance has not been presented in the respective references.

TABLE II  
WEEKLY FORECASTING ERROR VARIANCE

	Winter	Spring	Summer	Fall	Average
ARIMA [4]	0.0034	0.0020	0.0158	0.0157	0.0092
NN [7]	0.0017	0.0018	0.0109	0.0136	0.0070
Wavelet-ARIMA [5]	0.0019	0.0025	0.0108	0.0103	0.0064
FNN [8]	0.0018	0.0019	0.0092	0.0088	0.0054
AWNN [10]	0.0012	0.0031	0.0074	0.0075	0.0048
NNWT [1]	0.0009	0.0017	0.0074	0.0049	0.0037
HIS [11]	0.0034	0.0049	0.0029	0.0031	0.0036
CNEA [12]	0.0036	0.0027	0.0043	0.0039	0.0036
EPA	0.0012	0.0016	0.0048	0.0032	0.0027

All the cases have been run on a PC with 1 GB of RAM and a 1.8-GHz-based processor. The average computation time is less than 1 minute. Hence, the proposed intelligent system presents not only better forecasting accuracy, but also lower modeling complexity.

## V. CONCLUSIONS

This paper proposed an intelligent system based on EPSO and ANFIS for short-term electricity prices forecasting on the Spanish market. The application of the EPA approach to price forecasting is both novel and effective. The MAPE has an average value of 5.12%, while the average computation time is less than 1 minute. Hence, the proposed intelligent system presents a good trade-off between forecasting accuracy and computation time, taking into account results previously reported in the technical literature.

## VI. ACKNOWLEDGMENT

This work is funded by FEDER funds (European Union) through the Operational Programme for Competitiveness Factors – COMPETE, and by Portuguese funds through the Fundação para a Ciência e a Tecnologia – FCT, under Project No. FCOMP-01-0124-FEDER-014887 (Ref. FCT PTDC/EEA-EEL/110102/2009).

## VII. REFERENCES

- [1] J. P. S. Catalão, H. M. I. Pousinho, and V. M. F. Mendes, "Neural networks and wavelet transform for short-term electricity prices forecasting," in *Proc. 15th Int. Conf. on Intelligent System Applications to Power Systems*, Nov. 2009.
- [2] F. J. Nogales, J. Contreras, A. J. Conejo, and R. Espinola, "Forecasting next-day electricity prices by time series models," *IEEE Trans. Power Syst.*, vol. 17, pp. 342-348, May 2002.
- [3] S. K. Aggarwal, L. M. Saini, and A. Kumar, "Electricity price forecasting in deregulated markets: A review and evaluation," *Int. J. Electr. Power Energy Syst.*, vol. 31, pp. 13-22, Jan. 2009.
- [4] J. Contreras, R. Espinola, F. J. Nogales, and A. J. Conejo, "ARIMA models to predict next-day electricity prices," *IEEE Trans. Power Syst.*, vol. 18, pp. 1014-1020, Aug. 2003.
- [5] A. J. Conejo, M. A. Plazas, R. Espinola, and A. B. Molina, "Day-ahead electricity price forecasting using the wavelet transform and ARIMA models," *IEEE Trans. Power Syst.*, vol. 20, pp. 1035-1042, May 2005.

- [6] C. Garcia-Martos, J. Rodriguez, and M. J. Sanchez, "Mixed models for short-run forecasting of electricity prices: Application for the Spanish market," *IEEE Trans. Power Syst.*, vol. 22, pp. 544-552, May 2007.
- [7] J. P. S. Catalão, S. J. P. S. Mariano, V. M. F. Mendes, and L. A. F. M. Ferreira, "Short-term electricity prices forecasting in a competitive market: A neural network approach," *Elect. Power Syst. Res.*, vol. 77, pp. 1297-1304, Aug. 2007.
- [8] N. Amjady, "Day-ahead price forecasting of electricity markets by a new fuzzy neural network," *IEEE Trans. Power Syst.*, vol. 21, pp. 887-896, May 2006.
- [9] A. T. Lora, J. M. R. Santos, A. G. Expósito, J. L. M. Ramos, and J. C. R. Santos, "Electricity market price forecasting based on weighted nearest neighbors techniques," *IEEE Trans. Power Syst.*, vol. 22, pp. 1294-1301, Aug. 2007.
- [10] N. M. Pindoriya, S. N. Singh, and S. K. Singh, "An adaptive wavelet neural network-based energy price forecasting in electricity markets," *IEEE Trans. Power Syst.*, vol. 23, pp. 1423-1432, Aug. 2008.
- [11] N. Amjady and H. Hemmati, "Day-ahead price forecasting of electricity markets by a hybrid intelligent system," *Eur. Trans. Elect. Power*, vol. 19, pp. 89-102, Jan. 2009.
- [12] N. Amjady and F. Keynia, "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, Feb. 2009.
- [13] C. P. Rodriguez and G. J. Anders, "Energy price forecasting in the Ontario competitive power system market," *IEEE Trans. Power Syst.*, vol. 19, pp. 366-374, Feb. 2004.
- [14] Y. del Valle, G. K. Venayagamoorthy, S. Mohagheghi, J.-C. Hernandez, and R. G. Harley, "Particle swarm optimization: basic concepts, variants and applications in power systems," *IEEE Trans. Evol. Comput.*, vol. 12, pp. 171-195, Apr. 2008.
- [15] V. Miranda and N. Fonseca, "EPSO - best-of-two-worlds meta-heuristic applied to power system problems," in *Proc. Congr. Evol. Comput.*, vol. 2, pp. 1080-1085, May 2002.
- [16] V. Miranda, "Evolutionary algorithms with particle swarm movements," in *Proc. 13th Int. Conf. on Intelligent Systems Application to Power Systems*, pp. 6-21, Nov. 2005.
- [17] Z. Yun, Z. Quan, S. Caixin, L. Shaolan, L. Yuming, and S. Yang, "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, Aug. 2008.
- [18] M. Shahidehpour, H. Yamin, and Z. Li, *Market Operations in Electric Power Systems: Forecasting, Scheduling and Risk Management*. New York: Wiley, 2002.
- [19] Market operator of the electricity market of mainland Spain, OMEL. (2010). [Online]. Available: <http://www.omel.es/>
- [20] J. P. S. Catalão, H. M. I. Pousinho, and V. M. F. Mendes "Hybrid wavelet-PSO-ANFIS approach for short-term electricity prices forecasting," *IEEE Trans. Power Syst.*, vol. 26, pp. 137-144, Feb. 2011.

## VIII. BIOGRAPHIES

**J. P. S. Catalão** (M'04) received the M.Sc. degree from the Instituto Superior Técnico, Lisbon, Portugal, in 2003 and the Ph.D. degree from the University of Beira Interior (UBI), Covilha, Portugal, in 2007.

Currently, he is a Professor at UBI. His research interests include hydro scheduling, unit commitment, price forecasting, wind energy systems, and electricity markets.

Prof. Catalão is an Editor of IEEE TRANSACTIONS ON SUSTAINABLE ENERGY.

**G. J. Osório** received the B.Sc. degree from the University of Beira Interior (UBI), Covilha, Portugal, in 2009.

Currently, he is a M.Sc. student at UBI. His research interests include price forecasting and wind power forecasting.

**H. M. I. Pousinho** received the M.Sc. degree from the University of Beira Interior (UBI), Covilha, Portugal, in 2009.

Currently, he is a Ph.D. student at UBI, in collaboration with the Instituto Superior de Engenharia de Lisboa. His research interests include hydro scheduling, unit commitment, price forecasting, and wind power forecasting.