

Faculdade de Engenharia da Universidade do Porto



**Metodologia Híbrida para a Previsão dos Preços do
Mercado Elétrico com Integração Renovável**

Vasco Miguel Agante Campos

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

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

Julho de 2018

© Vasco Miguel Agante Campos, 2018

Resumo

Com a introdução de novas tecnologias de produção, e com a crescente aposta na produção dispersa e renovável, tem surgido uma alteração do atual paradigma no setor elétrico, levando à criação de um novo paradigma, mais inteligente, renovável e sustentável. Os desafios para manter a rentabilidade e a correta gestão do setor elétrico e dos agentes que nele operam têm aumentado a sua complexidade. As ferramentas computacionais de previsão permitem uma antevisão do que poderá acontecer num futuro próximo, beneficiando a tomada de decisão no funcionamento do sistema elétrico, minimizando os custos.

No entanto, quer os preços de eletricidade quer a produção renovável, apresentam grande flutuação e incerteza ao longo do tempo. Isto deve-se ao facto de as fontes de energia renováveis dependerem dos fatores da natureza, como também ao facto de os preços dependerem dos níveis de produção renovável disponíveis para o despacho. Neste contexto, surge a necessidade da criação de novas metodologias na área da previsão, cada vez mais robustas, para que se otimizem os despachos de forma a minimizar os erros. Esta dissertação apresenta uma metodologia híbrida para a previsão dos preços de eletricidade, utilizando dados reais extraídos de plataformas públicas, validando os resultados através de um estudo comparativo com outras metodologias.

Através dos resultados obtidos, para a comparação da metodologia proposta com outras metodologias aceites, a metodologia proposta apresenta-se robusta e demonstra resultados satisfatórios nos diferentes mercados onde foi testada.

Palavras-chave

Energias renováveis, Metodologia híbrida, MIBEL, Preços de Eletricidade, Previsão.

Abstract

With the introduction of new production technologies, and with a growing adherence to distributed and renewable production, a paradigmatic change emerged in the electric sector, leading to the creation of a new paradigm, smarter, renewable and sustainable. The challenges to keep the profitability and the correct management of the electric sector have increased its complexity and the agents that operate on it. The computational forecasting tools allow to foresee the near future, helping the decision making process in the electric sector, minimizing the costs.

However, energy prices and renewable production exhibit large fluctuations and uncertainty over time. This is due to the weather-dependence of renewable production and to its effect on energy prices. In this context, there is a growing need to create new methodologies in the forecasting area, increasingly robust, to optimize the dispatch and minimize errors. This dissertation provides an hybrid methodology to forecast electricity prices, using real data extracted from a public platform, validating the results through a comparative study with other methodologies.

Through the obtained results, for the comparison between proposed methodology and other accepted methodologies, the proposed methodology presents the necessary robustness and shows satisfactory results throughout the different markets where it was tested.

Keywords

Electricity Prices, Forecasting, Hybrid Methodology, MIBEL, Renewable Energies.

Agradecimentos

Deixo a minha palavra de agradecimento ao meu orientador, Professor Doutor João Paulo da Silva Catalão, por me ter dado a oportunidade de trabalhar com ele durante todo período de realização da minha dissertação. Por todo o apoio, empenho e disponibilidade ao longo de todo este percurso.

Quero deixar o meu apreço e profundo agradecimento, ao meu co-orientador, Doutor Gerardo José Osório da Silva, por toda a paciência e ajuda prestada, por todos os contactos que efetuámos ao longo desta caminhada. A ajuda prestada foi de facto essencial para que conseguisse chegar ao fim desta etapa, orgulhoso do trabalho apresentado. Ao Doutor Miadrezza Shafie-khah, gostaria de dar uma palavra de agradecimento pela sua gentileza durante estes últimos meses.

De seguida, gostaria de agradecer a todos os meus colegas e amigos que, ao longo destes anos, tiveram um papel fundamental para o meu sucesso académico. Por todos os momentos académicos, e não só, que vivenciamos, tenho a certeza que levo da Faculdade de Engenharia da Universidade do Porto amigos para a vida. Foram sem dúvida um suporte para me motivarem e não me deixarem desistir em momentos cruciais no desenrolar do curso em Engenharia Electrotécnica e de Computadores.

Queria deixar um agradecimento especial à prestigiada Faculdade de Engenharia da Universidade do Porto, assim como, a todos aqueles que fazem parte dela. Aos professores que me acompanharam durante estes anos, por todos os ensinamentos e pela exigência prestada para com os estudantes, no intuito de esses mesmos estudantes saírem do curso com as bases e os conhecimentos necessários para enfrentarmos as próximas etapas que se avizinham.

Por fim, mas não menos importante, aos meus pais, irmã, namorada e restante família, por me terem transmitido todos os meus valores. Por toda a ajuda, ensinamentos e motivação, e que com os quais me fizeram crescer e aprender a não desistir daquilo que realmente importa. Para eles o meu último e sentido agradecimento.

Índice

Resumo	iii
Abstract	v
Agradecimentos	vii
Lista de figuras	x
Lista de tabelas	xii
Abreviaturas e símbolos	xiii
Capítulo 1	1
Introdução.....	1
1.1 - Enquadramento do Mercado Elétrico.....	1
1.2 - Motivação	15
1.3 - Organização da Dissertação.....	16
1.4 - Organização do Texto.....	17
Capítulo 2	19
Estado da Arte.....	19
2.1. Classificação dos Horizontes Temporais	21
2.2. Previsão dos Preços de Eletricidade.....	22
Capítulo 3	29
Ferramenta de Previsão dos Preços de Mercado de Eletricidade	29
3.1. Métodos Computacionais	29
3.1.1. Transformadas de <i>Wavelet</i> (WT).....	30
3.1.2. Otimização Diferencial por Enxame de Partículas Evolucionária (DEEPSO)	32
3.1.3. Sistema de Inferência Neuro-difuso Adaptativo (ANFIS)	34
3.1.4. Simulação de Monte Carlo (MCS).....	39
3.2. Nova Metodologia Híbrida Proposta	42
3.3. Ferramentas Matemáticas de Quantificação do Erro	44
Capítulo 4	45
Caso de Estudo e Resultados Obtidos	45

Capítulo 5	51
Conclusões e Contribuições	51
5.1. Trabalhos Futuros.....	52
5.2. Contribuições Científicas	52
Referências	53
Anexos	61

Lista de Figuras

Figura 1.1 - Paradigma "clássico", organização da rede.	2
Figura 1.2 - Atividades dos mercados elétricos.....	3
Figura 1.3 - Liberalização do setor elétrico no mundo.....	4
Figura 1.4 - Entidades Portuguesas no MIBEL.	5
Figura 1.5 - Entidades Espanholas no MIBEL.	5
Figura 1.6 - Organização do operador de mercado.	7
Figura 1.7- Exemplo dos sinais de procura e de oferta do Mercado diário.	9
Figura 1.8 - Mercado diário e intradiário.	9
Figura 1.9 - Evolução do Biogás, Biomassa, Resíduos Sólidos Urbanos (RSUs), Fotovoltaica e Ondas, em MW.	12
Figura 1.10 - Evolução da Mini-Hídrica, Eólica, Cogeração e Cogeração Renovável, em MW. .	13
Figura 1.11 - Evolução da Eólica em Portugal, em MW	14
Figura 1.12 - Constituição de um sistema de produção eólica.....	15
Figura 2.1 - Esquema dos principais métodos usados na previsão.	21
Figura 3.1- Estrutura do algoritmo das WT.....	31
Figura 3.2 - Regra de movimento das partículas no método DEEPSO.....	34
Figura 3.3 - Exemplo de uma máquina difusa assente em regras.	38
Figura 3.4 - Estrutura da cadeia ANFIS de 5 camadas.	39
Figura 3.5 - Fluxograma do método da Simulação de Monte Carlo.	41
Figura 3.6 - Fluxograma da metodologia proposta (PHFM).	44
Figura 4.1 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação da Primavera.	46
Figura 4.2 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação do Verão.....	46
Figura 4.3 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação do Outono.	47
Figura 4.4 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação do Inverno.....	47
Figura 4.5 - Resultados dos preços de eletricidade do PJM no ano 2002 para a estação do Inverno.	48

Lista de Tabelas

Tabela 1.1 - Evolução da PRE em Portugal.	12
Tabela 1.2 - Evolução da eólica em Portugal, em MW.	13
Tabela 1.3 - Evolução da Potência Eólica Instalada na Europa, em MW.	14
Tabela 2.1 Classificação dos horizontes temporais e suas aplicações no SEE.....	22
Tabela 3.1 - Parâmetros utilizados ao longo deste trabalho para a WT, DEEPSO e ANFIS.	43
Tabela 4.1 - Valores de MAPE e variância para cada um dos casos anteriormente mostrados.....	48
Tabela 4.2 - Comparação dos valores de MAPE do Mercado Espanhol do ano 2002	48
Tabela 4.3 - Comparação dos valores de variância do Mercado Espanhol do ano 2002	49
Tabela 4.4 - Comparação dos valores de MAPE e variância do PJM do ano 2002 para o Inverno	49
Tabela 5.1 - Resumo dos resultados obtidos pela metodologia nos mercados testados.....	52

Abreviaturas e Símbolos

ANFIS	Sistema de Inferência Neuro-difuso Adaptativo
ANN	Reder Neurais Artificiais
AR	<i>Autoregressive</i>
ARFIMA	<i>Autoregressive Fractionally Integrated Moving Average</i>
ARIMA	<i>Autoregressive Integrated Moving Average</i>
ART	Teoria ressonante adaptativa
AT	Alta Tensão
AWNN	<i>Adaptative Wavelet Neural Network</i>
BA	<i>Bat Algorithm</i>
BARIMA	Bivariada Auto-Regressiva Integrada de Média Móvel
BT	Baixa Tensão
CGSA	<i>Cuckoo Search and Gravitational Search Algorithm</i>
CNE	<i>Comisión Nacional de Energía</i>
CNEA	<i>Cascade Neuro-Evolutionary Algorithm</i>
CNN	<i>Composite Neural Network</i>
CLSSVM	<i>Chaotic Least Squares Support Vector Machine</i>
CSLM	<i>Cuckoo Search Levenberg-Marquard</i>
CWT	Transformada de <i>Wavelet</i> Contínua
DCT	<i>Discrete Cosine Transforms</i>
DEEPSO	Otimização Diferencial por Enxame de Partículas Evolucionário
DWT	Transformada de <i>Wavetet</i> Discreta
EGARCH	<i>Exponential Generalized Autorregressive Conditional Heteroscedastic</i>
ELM	<i>Extreme Learning Machine</i>
ENN	<i>Elman Neural Network</i>
EPSO	Otimização por Enxame de Partículas Evolucionário
ERSE	Entidade Reguladora dos Serviços Energéticos
FA	<i>Fuzzy ARTMAP</i>
FA-PSO	<i>Fuzzy Adaptive Particle Swarm Optimization</i>

FCM	<i>Fuzzy C-Means</i>
FF	<i>Firefly Algorithm</i>
FFNN	<i>Feed-Foward Neural Network</i>
FNN	<i>Fuzzy Neural Network</i>
GEE	Gases de Efeito de Estufa
GNL	Gás Natural Liquefeito
IPCC	Painel Intergovernamental sobre a Mudança Climática
KQR	<i>Quantile Regression on Reproducing Kernel Hilbert Space</i>
LAM-GB	<i>Linear Additive Models Gradient Boosting</i>
LM-GM	<i>Linear Models Gradient Boosting</i>
LQR	<i>Linear Quantile Regression</i>
LR	Regressão Linear
LSSVM	<i>Least Squares Support Vector Machine</i>
MA	<i>Moving Average</i>
MAPE	<i>Mean absolute percentage error</i>
MAT	Muito Alta Tensão
MC	Método do Centróide
MIBEL	Mercado Ibérico de Eletricidade
MLP	<i>Multi-layer Perceptron</i>
MM	Método da Média dos Máximos
MT	Média Tensão
MW	<i>Mega Watt</i>
NMAE	<i>Normalized mean absolute error</i>
OMEL	Operador do Mercado Interno Espanhol
OMIClear	Operador de Mercado de Ajuste
OMIE	Operador do Mercado Ibérico (Polo Espanhol)
OMIP	Operador do Mercado Ibérico (Polo Português)
PCPF	<i>Panel Cointegration and Particle Filter</i>
PLSSVM	<i>Particle Least Squares Support Vector Machine</i>
PME	Preços de Mercado de eletricidade
PRE	Produção em Regime Especial
PRO	Produção em Regime Ordinário
PSF	<i>Predicting Samples Framed</i>
PSO	Otimização por Enxame de Partículas
QRF	<i>Quantile Regression Forests</i>
QRNN	<i>Quantile Regression Neural Network</i>
RBFN	<i>Radial Basis Function Neural</i>
RCGA	<i>Real Coding Genetic Algorithms</i>

RDFA	Análise recursiva de um fator dinâmico
REE	<i>Red Eléctrica de España</i>
REN	Redes Energéticas Nacionais
RSUs	Resíduos Sólidos Urbanos
SA	Serviços Auxiliares
SAPSO-KELM	<i>Kernel-Based Extreme Learning Machine on Self-Adapting PSO</i>
SEE	Sistema de Energia Elétrico
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regression</i>
TSDNN	<i>Time Series Time Delay Neural Networks</i>
UE	União Europeia
WNN	<i>Weighted Nearest Neighbors</i>
WT	Transformada de <i>Wavelet</i>

Capítulo 1

Introdução

Serve o presente capítulo para abordar o setor elétrico português, começando por explicar o funcionamento, tendo em conta, a alteração do paradigma “clássico”, com o surgimento de um novo paradigma. A introdução das energias renováveis no sistema de energia elétrica (SEE) substitui o uso dos combustíveis fósseis que, por sua vez, tem um importante peso no impacto ambiental, sendo esta mudança uma das grandes razões para a alteração do paradigma.

Nesta dissertação, destaca-se essencialmente a energia eólica, tentando explicar como esta é usada no setor elétrico português. Ainda neste capítulo, surge a motivação pela qual foi desenvolvido este trabalho, assim como a estruturação e organização da presente dissertação.

1.1 - Enquadramento do Mercado Elétrico

O SEE tem como principal missão alimentar as cargas dos consumidores, garantindo a qualidade e a continuidade do serviço, tentando sempre minimizar os custos associados a todo o processo desde a produção até ao consumidor. Com o aumento da dependência do consumidor relativamente à energia elétrica, surge um aumento do consumo que, combinado com a evolução tecnológica leva ao aparecimento de novas tecnologias de produção com maior capacidade de produção e maior complexidade [1].

Com o aumento da carga, aumenta-se conseqüentemente a complexidade do sistema, pelo que surge a necessidade do aumento dos estudos que têm que ser efetuados ao longo do sistema, para que não surjam imprevistos na qualidade e na continuidade do serviço. Para isto, são efetuados estudos nos grupos geradores para garantir a estabilidade do sistema, aquando do surgimento de perturbações [2].

2 Introdução

Há também necessidade de recorrer a estudos a nível da conceção e do projeto, para que mais tarde, durante a exploração, tais objetivos de qualidade sejam atingidos com o mínimo de investimento [3].

No passado, no sistema elétrico português, a produção seguia a procura de acordo com um fluxo de energia de sentido único da alta tensão (AT) para a baixa tensão (BT). Com isto, o objetivo e caminho do SEE passa por ser tornar num sistema de produção centralizado e flexível, caracterizado ainda por se adaptar às variações [4].

Com a análise da Figura 1.1, pode-se verificar que esta organização da rede, o denominado paradigma “clássico”, possui vantagens e desvantagens. O facto de o fluxo ser unidirecional simplifica as operações na rede de distribuição, assim como a operação e regulação do sistema de transporte interligado, onde se consegue controlar o fluxo de energia com grandes distâncias e perdas reduzidas.

Por outro lado, esta configuração também acarreta desvantagens, como a grande distância entre os centros de produção e os consumidores e, ainda, os impactos ambientais associados aos tipos de centrais de produção utilizadas com esta configuração, geralmente térmicas convencionais.

Da doutrina anterior, uma empresa verticalmente integrada tinha por objetivo a satisfação do consumo com o menor custo possível. Recorria a um planeamento centralizado com a ajuda de centros de produção centralizados e flexíveis, desenvolvendo técnicas de otimização baseadas em processos determinísticos [5].

Não havia possibilidade de escolha do fornecedor, pois a ligação física era sinónimo de ligação comercial. Para além disso, não existia regulação independente dos custos, dos proveitos e na qualidade do serviço.

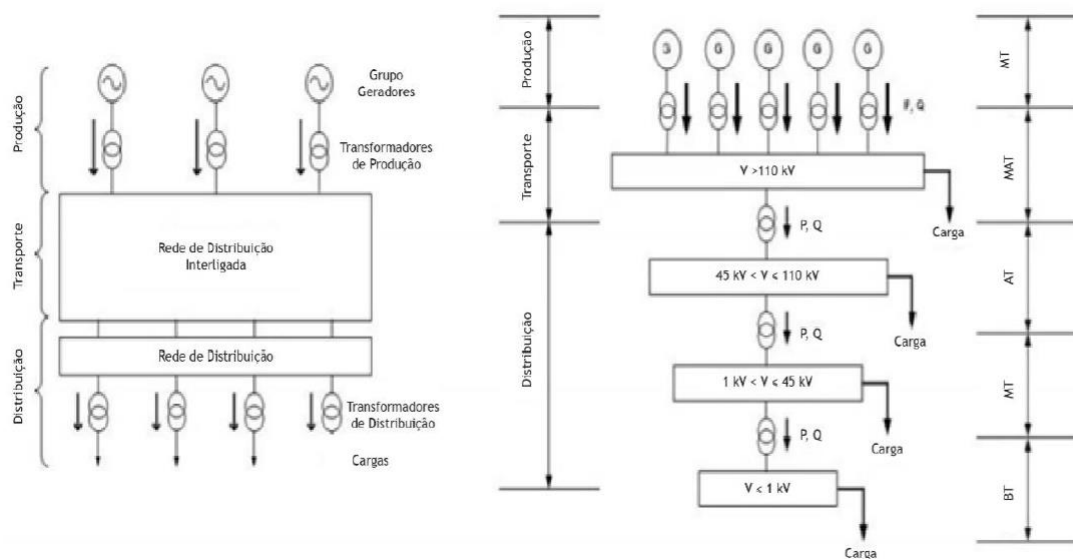


Figura 1.1 - Paradigma "clássico", organização da rede.

Com a introdução de novas tecnologias de produção, de novas metas e obrigações ambientais, e ainda com a necessidade de novas oportunidades no mercado e na regulação do sistema, os SEE têm sofrido algumas alterações, organizando-se de maneira diferente.

Com as metas ambientais, surge a necessidade de se recorrer a fontes de energia renováveis que alteram a estrutura de controlo tradicional da produção, visto que são fontes cuja natureza é intermitente e variável no tempo.

Surgem, portanto, aquando do desenvolvimento tecnológico, novas formas de comunicação e novas tecnologias de controlo que levam a uma revolução na integração e processamento da informação nos SEE, com novos paradigmas como redes, equipamentos e controlos inteligentes [6].

Para além fatores atrás expostos, também está associado à mudança do paradigma do SEE o facto de, por volta dos anos 70 e 80 do século passado, ter ocorrido uma modificação no enquadramento económico, devido a uma crise petrolífera e ao surgimento de elevadas taxas de inflação e de juro, que contribuíram para um ambiente económico mais volátil.

Tal instabilidade económica proporcionou que diversas atividades sociais começassem a ser desreguladas e liberalizadas como a indústria aérea, as redes fixas de telecomunicações, as redes móveis e a distribuição de gás.

Esta liberalização e desregulação ocorreram, mais tarde, também no sector elétrico, e cuja consequência foi o aumento da concorrência o qual possibilita, por exemplo, que os clientes possam ter um papel mais ativo na escolha do seu fornecedor [7].

Os mercados elétricos atuais apresentam tipicamente cinco atividades fundamentais para um funcionamento adequado, apresentadas esquematicamente na Figura 1.2 [8].

Na atividade da **produção**, incluem-se os seguintes tipos:

- **Produção em Regime Ordinário (PRO)**- representada pelas formas mais tradicionais de produção de eletricidade como as centrais térmicas, e ainda as grandes hidroelétricas com capacidade de armazenamento e/ou bombagem. Esta produção não é regulada e a entrada no mercado não possui restrições, para além de que o acesso às redes de transporte e distribuição é livre [8].
- **Produção em Regime Especial (PRE)**- representada pela produção de energia elétrica através de recursos endógenos, renováveis e não renováveis, de tecnologias de produção combinada de calor e de eletricidade (cogeração) e de produção distribuída [9].




Figura 1.2 - Atividades dos mercados elétricos.

4 Introdução

Na atividade do **transporte** e da **distribuição**, ocorrem fenómenos de operação na rede e de planeamento de manutenção da expansão e da construção. Naturalmente estas atividades terão que ser reguladas a partir das entidades responsáveis pela regulação.

Na atividade da **comercialização** é onde se efetua a ligação entre os consumidores e os produtores. Pode recorrer a contratos bilaterais físicos ou financeiros entre ambos ou então recorrer a mercados do tipo *pool*.

Na atividade de **regulação** é onde se realiza a coordenação técnica entre todos os intervenientes do mercado, desde a produção até aos consumidores, passando pelo transporte e pela distribuição. A sua principal missão é conseguir assegurar, em colaboração com o Operador do Mercado, o funcionamento do sistema dentro dos parâmetros desejáveis.

Mais concretamente, em Portugal, a estrutura de organização do mercado alterou, como na maioria dos países Europeus, de forma faseada, começando por incluir os clientes de maiores consumos e com níveis de tensão mais elevados [8].

Esta alteração foi efetuada entre 1995 e 2006, progressivamente, sendo que, desde de 4 de setembro de 2006, todos os consumidores em Portugal Continental podem escolher o seu fornecedor de energia elétrica [10]. Com a análise da Figura 1.3, é possível verificar os anos em que em determinados países ocorreu a liberalização do setor elétrico [7].

Historicamente, e consoante o protocolo de colaboração entre as administrações espanhola e portuguesa, a 14 de novembro de 2001, chegou-se a acordo para a criação do Mercado Ibérico de Eletricidade (MIBEL), no entanto, as conversações entre ambas as administrações iniciaram a 29 de julho de 1998, onde diversos obstáculos foram eliminados para que a criação do MIBEL fosse possível.

Em outubro de 2004, em Santiago de Compostela, ocorreu a assinatura do acordo entre a República Portuguesa e o Reino de Espanha. Em novembro de 2006, ocorreu a XXII Cimeira Luso-Espanhola de Badajoz e, somente a 1 de julho de 2007, é que o MIBEL arrancou em toda a sua dimensão para benefício dos consumidores de ambos os países ibéricos, garantindo a todos condições de igualdade, transparência e objetividade. De salientar ainda a assinatura em Braga do Acordo que revê o Acordo de Santiago, em janeiro de 2008 [11].

O MIBEL, como todos os restantes mercados europeus, encontra-se sempre em constante adaptação relativamente às necessidades dos consumidores. A partir das Figuras 1.4 e 1.5 é apresentada organização atual do MIBEL, onde são apresentadas todas as suas entidades relevantes.



Figura 1.3 - Liberalização do setor elétrico no mundo [7].

Na Figura 1.4 encontram-se as entidades do lado português, enquanto na Figura 1.5 encontram-se as entidades do lado espanhol. Para as entidades responsáveis pela **gestão da rede na Península Ibérica**:

- A **REN**, Redes Energéticas Nacionais, que atua no transporte de eletricidade em MAT e a gestão técnica global do Sistema Elétrico Nacional português. Para além disso, também atua no transporte de gás natural em alta pressão e a gestão técnica global do Sistema Nacional de Gás Natural, garantindo a receção, armazenamento e regaseificação de GNL (Gás Natural Liquefeito), bem como o armazenamento subterrâneo de gás natural [12].
- A *Red Eléctrica de España* **REE** foi a primeira companhia do mundo dedicada exclusivamente à operação do sistema elétrico de energia e ao transporte de eletricidade. Surgiu a 29 de janeiro de 1985, e desde a sua fundação, o principal objetivo reside em garantir, em todo o momento, a segurança e a continuidade do fornecimento de eletricidade em todo o país, como também no desenvolvimento e manutenção de uma rede de transporte fiável e capaz de contribuir para o avanço da sociedade [13].

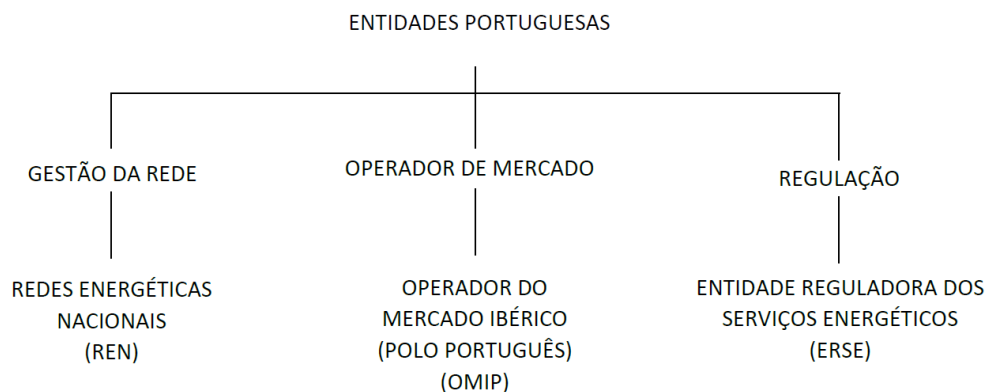


Figura 1.4 - Entidades Portuguesas no MIBEL.

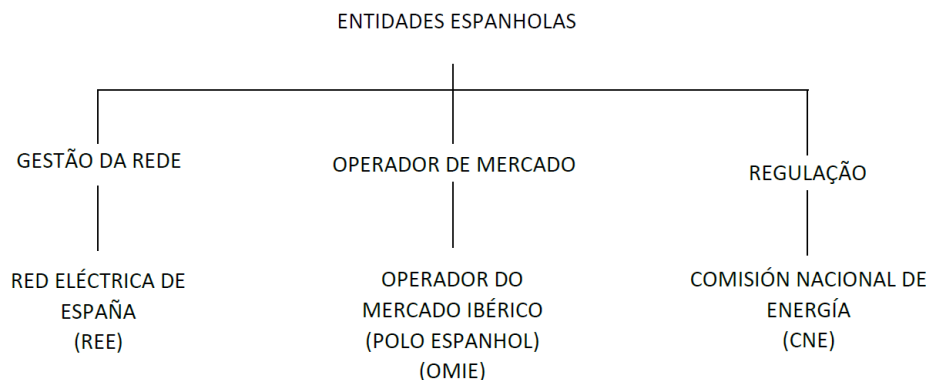


Figura 1.5 - Entidades Espanholas no MIBEL.

6 Introdução

Relativamente aos **operadores do mercado Ibérico**, temos:

- **A Contado:**
 - **OMIE**, Operador do Mercado Ibérico (Polo Espanhol), que é a entidade responsável pela realização das liquidações do mercado diário e intradiário em Espanha. De acordo com estatutos, o OMIE tem as seguintes funções:
 - O desenvolvimento e a gestão económica dos preços dos mercados da eletricidade, do mercado nacional ou internacional;
 - A gestão e liquidação de transações nos mercados da eletricidade.
- **A Prazo:**
 - **OMIP**, Operador do Mercado Ibérico (Polo Português) surgiu a 16 de junho de 2003 e assegura a gestão do mercado a prazo do MIBEL (Mercado Ibérico de Eletricidade), em Portugal. O OMIP tem como principais objetivos:
 - Contribuir para o desenvolvimento do mercado ibérico de eletricidade;
 - Promover preços de referência ibéricos;
 - Disponibilizar instrumentos eficientes de gestão de risco;
 - Superar algumas das limitações do Mercado *Over The Counter* (OTC); é um mercado não regulamentado, não é um mercado de bolsista, mas sim um mercado onde as negociações ocorrem entre duas partes diretamente.

Para além do OMIP, surgiu também outra entidade reguladora, a **OMIClear** que foi autorizada pela Portaria n.º 927/2004, de 27 de julho, e tem como principais funções a compensação, o registo, a gestão do risco e a liquidação das operações negociadas no OMIP [14]. Por fim, para as entidades de **regulação**, temos:

- A **ERSE**, Entidade Reguladora dos Serviços Energéticos, que é a entidade responsável pela regulação dos setores do gás natural e da eletricidade. É uma entidade de direito público, dotada de autonomia administrativa e financeira e de património próprio. Para além disso, é independente no exercício das suas funções, no quadro da lei, sem prejuízo dos princípios orientadores da política energética, exigidos pelo Governo, através dos seus Estatutos, aprovados pelo Decreto-Lei n.º 97/2002, de 12 de abril, alterados pelo Decreto-Lei n.º 212/2012, de 25 de setembro, na redação do Decreto-Lei n.º 84/2013, de 25 de junho [15].
- A **CNE**, Comisión Nacional de Energía, que é uma entidade pública e descentralizada com património próprio e com capacidade para adquirir e exercer direitos e obrigações, aprovados pelo Decreto-Lei n.º 2.224, de 1978, modificado pela lei n.º 20.402 para criar o Ministério de Energia. Tem como principais funções:

- Analisar tecnicamente a estrutura, o nível dos preços e tarifas de bonificações e os serviços energéticos;
- Fixar as normas técnicas e de qualidade indispensáveis para o funcionamento e operação das instalações energéticas;
- Monitorizar e projetar o funcionamento atual e esperado do sector energético e, ainda, propor ao Ministério de Energia as normas legais e regulamentares requeridas pelas atividades da sua competência;
- Assegurar ao Governo, por intermédio do Ministério de Energia, todas as atividades vinculadas ao setor energético para o seu desenvolvimento sustentado [16].

Tendo em consideração a estrutura e a organização do MIBEL, cuja estrutura pode ser observada na Figura 1.6, [17]. O mercado grossista de eletricidade recorre a variados mecanismos legais ou regulamentares específicos para a contratação de eletricidade, dos quais se destacam os seguintes [18]:

- **Mercado Diário** - funciona através do cruzamento de ofertas de compra e de venda, por parte dos diversos agentes. É neste mercado onde é indicada para cada oferta, o dia e a hora a que se reporta, o preço, e a quantidade de energia correspondentes. Ordenam-se, de forma crescente em preço, as ofertas de venda (curva de oferta) e, de forma decrescente o preço, as ofertas de compra (curva de procura) de eletricidade para uma mesma hora.

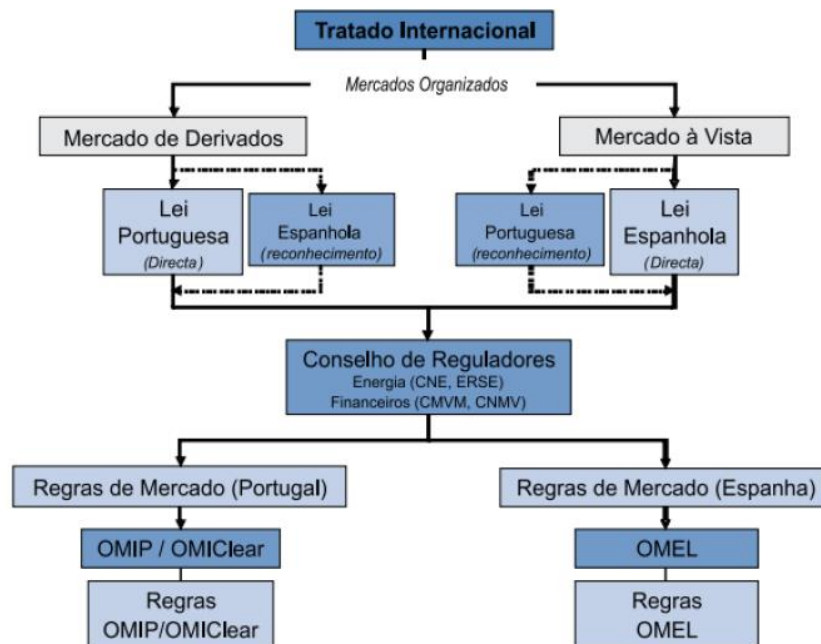


Figura 1.6 - Organização do operador de mercado [17].

8 Introdução

Ainda do mercado diário, o preço de mercado é o menor dos preços que garante que a oferta satisfaz a procura, o que é representado pela interseção das duas curvas. As regras de funcionamento deste mercado são estabelecidas pelo operador de mercado (OMEL). Na Figura 1.7 encontra-se um exemplo dos sinais de procura e de oferta no mercado diário.

- **Mercado Intradiário** - é um mercado que complementa o mercado diário, onde se contrata eletricidade para ajustar as quantidades negociadas do mercado diário com o recurso a 6 sessões diárias de negociação:
 - **1ª sessão:** forma preço para as 4 últimas horas do dia de negociação e para as 24 horas do dia seguinte ao da negociação;
 - **2ª sessão:** forma preço para as 24 horas do dia seguinte ao da negociação;
 - **3ª sessão:** forma preço para as 20 horas compreendidas entre a hora 5 e a hora 24 do dia seguinte ao da negociação;
 - **4ª sessão:** forma preço para as 17 horas compreendidas entre a hora 8 e a hora 24 do dia seguinte ao da negociação;
 - **5ª sessão:** forma preço para as 13 horas compreendidas entre a hora 12 e a hora 24 do dia seguinte ao da negociação;
 - **6ª sessão:** forma preço para as 9 horas compreendidas entre a hora 16 e a hora 24 do dia seguinte ao da negociação.

Também é gerido pelo OMEL e também depende das curvas de compra e venda dos diversos agentes. Com a análise da figura 1.8, [19], podemos verificar como o mercado diário e o mercado intradiário estão organizados dentro da estrutura do MIBEL.

- **Mercado a prazo** - oferece instrumentos de gestão de risco sob a forma de derivados, como contratos de compra e venda de eletricidade para um determinado espaço de tempo, semana, mês, trimestre e ano, de acordo com as regras específicas deste mercado que variam com as necessidades de gestão de risco, e de troca de eletricidade pelos diferentes agentes. Este mercado é gerido pelo OMIP. O OMIP disponibiliza os seguintes instrumentos:
 - **Contratos de futuro** - contrato de compra ou venda de energia para um determinado horizonte temporal. O comprador possui a função de adquirir eletricidade no tempo de entregar, enquanto o vendedor possui a função de atribuir um preço no momento da negociação dessa mesma eletricidade. É um contrato de liquidação diária e os agentes compradores e vendedores não se relacionam diretamente entre si, em que a OMIClear fica responsável de liquidar as margens diárias, entre o preço de transação e a cotação de mercado (a futuro) de cada dia, e o contrato no período de entrega;

- **Contratos *Forward*** - é um contrato padronizado de compra ou venda, semelhante ao mencionado no ponto anterior, no entanto, neste contrato as liquidações não são diárias, as margens durante o período de negociação são liquidadas integralmente nos dias de entrega física ou financeira;
- **Contratos *SWAP*** - é um contrato padronizado em que se pode trocar a posição em preço variável por uma posição de preço fixo, ou vice-versa, dependendo do sentido da troca dos intervenientes. O papel fundamental deste tipo de contratos reside em gerir ou tomar risco financeiro, onde não há entrega do produto subjacente, ocorrendo apenas a liquidação das margens entre os preços de transação e as cotações de mercado [20];
- **Mercados de Serviços de Sistema** - onde ocorre a contratação de potência e energia com a participação nos mercados de serviços de sistema. A contratação dos produtos separados da atividade de produção de energia elétrica é realizada através da existência de curvas de ofertas submetidas por agentes de mercado qualificados ao Gestor do Sistema [21];




Figura 1.7- Exemplo dos sinais de procura e de oferta do mercado diário [18].

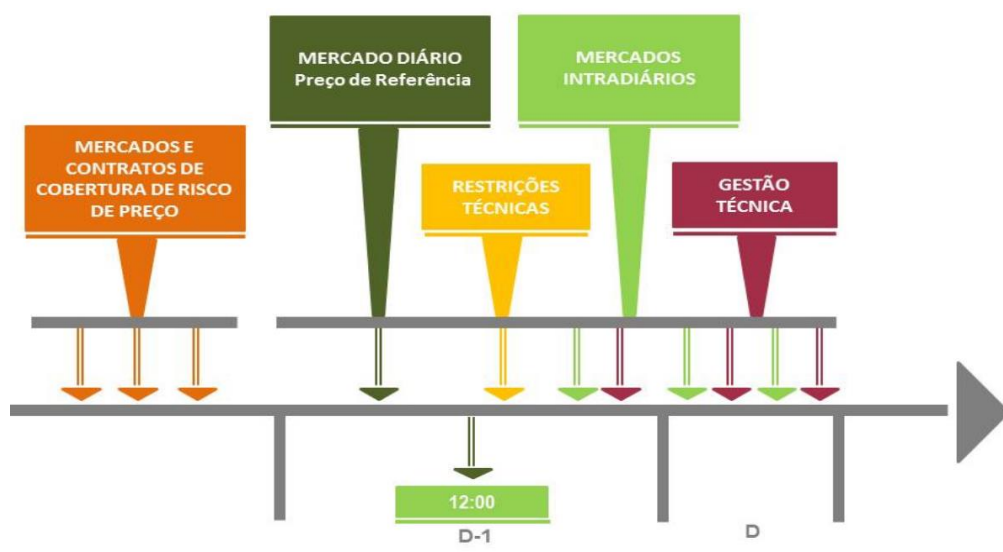


Figura 1.8 - Mercado diário e intradiário [19].

- **Contratação** - o funcionamento do mercado grossista de eletricidade do MIBEL assenta na existência de um conjunto de mobilidades de contratação que se complementam entre si. Posto isto, o mercado grossista compreende atualmente:
 - **Mercado de contratação a prazo:** onde se estabelecem compromissos a futuro de produção e de compra de eletricidade;
 - **Mercado de contratação à vista:** onde se estabelece uma componente de contratação diária e uma componente intradiária, em que os programas de venda e de compra de eletricidade para o dia seguinte ao da negociação são estabelecidos;
 - **Mercado de serviços de sistema:** onde se efetua o ajuste do equilíbrio da produção e do consumo de eletricidade. Este ajuste é realizado em tempo real;
 - **Mercado de contratação bilateral:** onde os agentes contratam a compra e venda de eletricidade em diferentes horizontes temporais [22];
- **Mercado retalhista de eletricidade** - Qualquer que seja o mercado retalhista existente, qualquer cliente, com o desenvolvimento da liberalização do setor elétrico, poderá eleger livremente o seu fornecedor. Isto faz com que haja a necessidade de se reforçar a atividade de supervisão, para que se consiga garantir em simultâneo a concorrência entre os diferentes operadores e a minimização das assimetrias de informação entre os consumidores e os restantes agentes de mercado [23], [24].

Com a alteração do paradigma e com a crescente preocupação na redução da emissão dos Gases de Efeito de Estufa (GEE), surge o Protocolo de Quioto [25]. Trata-se do primeiro tratado internacional com compromissos mais rígidos para a redução da emissão dos GEE.

A primeira reunião no âmbito deste protocolo foi em 1988, no Canadá, seguindo-se em 1990 o *IPCC's* (Painel Intergovernamental sobre a Mudança Climática) que se trata do primeiro relatório com base na colaboração científica de nível internacional. Em 1992, mais de 160 governos assinam a Convenção-Quadro das Nações Unidas sobre a Mudança Climática, na ECO-92 no Brasil [25].

De seguida, em 1995, surge um segundo relatório do IPCC e, finalmente, em 1997, em Quioto, no Japão, foi discutido e negociado sendo, posteriormente, o protocolo aberto a assinaturas. O Protocolo foi reconhecido em março de 1999 pelos países aderentes. Em Portugal, foi reconhecida a sua importância em maio de 2002, entrando somente em vigor em fevereiro de 2005 [26].

- Vantagens do Protocolo de Quioto:
 - Reduções significativas nas emissões de gases;
 - Redução da temperatura ambiente global;

- Investimento em energias renováveis;
- Reforma dos setores de energia e transportes;
- Proteção das florestas.
- Desvantagens do Protocolo de Quioto:
 - Há pessoas que consideram as reduções de gases pouco significativas;
 - Há também pessoas que consideram que emissões de gases em causa não são as principais responsáveis pelo aquecimento global;
 - Há atividades económicas responsáveis pela emissão de gases, como a pecuária e a indústria que são importantes para a economia de cada país;
 - Há países que poderão comprometer a sua estabilidade económica para cumprirem as metas estabelecidas, segundo alguns críticos [26].

Houve um primeiro período de compromisso, entre 2008 e 2012, em que a meta era reduzir em pelo menos 5,2% o nível de gases emitidos comparativamente ao que era emitido na década de 90, tendo Portugal conseguido emissões abaixo da meta definida, reduzindo as emissões de gases em cerca de 27%, comparativamente às emissões registadas em 1990.

Surge, portanto, de 2013 até 2020, o segundo período de compromisso, em que a meta agora imposta assenta numa descida de pelo menos 18% dos níveis de emissão de GEE, relativamente aos anos de 1990 [25].

Ao longo deste segundo período, a União Europeia, UE, tem como missão auxiliar na redução em cerca de 8%, o que equivale a um pouco mais de 1% por ano desde 2013 até 2020. Para tal, lançou como objetivo para alcançar a meta proposta, o plano dos objetivos [20/20/20] que reside em:

- 20% de redução, pelo menos, das GEE, relativamente aos níveis de 1990;
- 20 % da energia obtida a partir de fontes renováveis;
- 20 % de melhoria da eficiência energética [27].

Em Dezembro de 2015, em Paris na conferência climática (COP 21), realizou-se uma conferência onde 195 países discutiram um novo acordo, que foi aberto para assinaturas a 22 de Abril de 2016. Em 5 de Outubro de 2016, a UE ratificou formalmente o Acordo de Paris que entrou em vigor a 4 de Novembro de 2016.

Neste acordo, ficou decidido que de 5 em 5 anos todos os Governos envolvidos no processo se reúnem para definirem metas mais ambiciosas, criando assim um balanço global e transparência na informação. Para a redução da emissão dos GEE, foi acordado pelos 195 países que estes estivessem envolvidos num esforço coletivo para tentar conter a subida da temperatura do planeta a 1.5°C [28], [29].

12 Introdução

Em Portugal, em setembro de 2001, surgiu uma diretiva lançada pelo Parlamento Europeu e pelo Conselho de Ministros, conhecida por diretiva 2001/77/CE, onde foram criados incentivos e motivações para o uso de fontes de energia renováveis, com o objetivo de se conseguir atingir as metas propostas no protocolo de Quioto [30].

Com isto, surgiram de seguida programas para que se consigam atingir as metas como o Programa de Eficiência Energética e Energias Endógenas, conhecido como o Programa E4, que tem vindo a ser constantemente atualizado de maneira a que os objetivos traçados sejam alcançados [31].

Com este incentivo à evolução das fontes de energia renováveis, houve um aumento no investimento e consequentemente um aumento na potência instalada em diversas fontes de energia renováveis. Com análise da Tabela 1.1, assim como das Figuras 1.9 e 1.10, é possível ver a evolução em Portugal da produção em PRE que engloba as fontes de energia renováveis, sendo que, no que toca à Hídrica, apenas são consideradas as mini-hídricas, em que a potência instalada é inferior a 10 MW.

Tabela 1.1 - Evolução da PRE em Portugal, [32].

		ANO									
		2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Potência Instalada [MW]	Biogás	11	20	32	55	62	63	72,13	73,94	77,24	84,24
	Biomassa	23	91	112	112	112	112	138,3	138,3	135,58	135,58
	RSUs	67	90	90	90	90	90	94,76	94,76	94,76	94,76
	Fotovoltaica	16	81	105	110	122	122	242,17	269,28	281,49	293,59
	Mini-hídrica	400	450	480	480	490	490	460,96	472,07	477,93	460,16
	Eólica	2 700	3 500	3 900	4 200	4 300	4 400	5 206,20	5 304,61	5 552,54	5 577,81
	Cogeração	800	800	850	950	950	950	1 123,60	1 046,17	984,91	984,73
	Cogeração Renovável	-	100	200	200	250	250	617,46	493,73	463,84	463,84
	Ondas	-	-	-	-	-	-	0,4	0,4	0,4	0

Valores aproximados, retirados de um gráfico de barras




Figura 1.9 - Evolução do Biogás, Biomassa, Resíduos Sólidos Urbanos (RSUs), Fotovoltaica e Ondas, em MW.

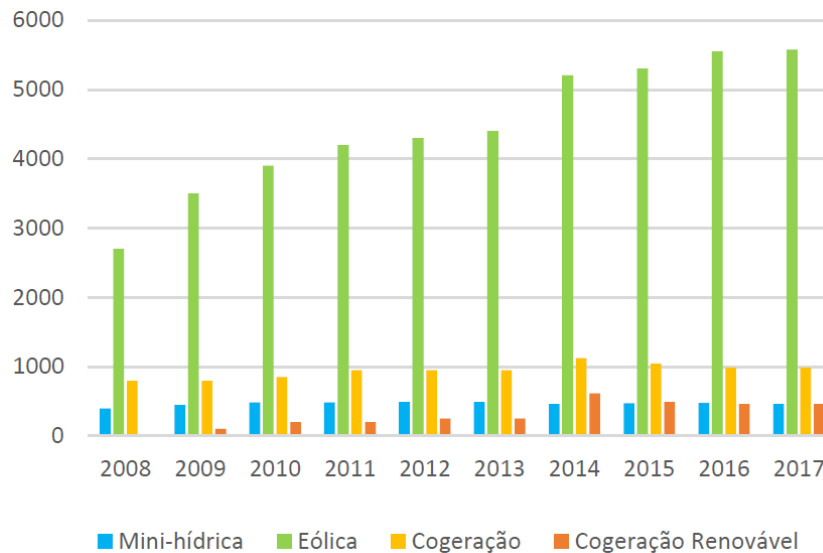


Figura 1.10 - Evolução da Mini-Hídrica, Eólica, Cogeração e Cogeração Renovável, em MW.

Como é fácil de verificar, o investimento nas diversas fontes de energia renováveis é notável. De salientar que, ainda que em diferente escala, o investimento é notório, nomeadamente na eólica e na fotovoltaica. Isto tudo tem que ver com a localização geográfica de Portugal que impulsiona e suscita o interesse na adoção destes tipos de fonte de energia. Na Tabela 1.2 e na Figura 1.11, encontra-se representada a evolução da Eólica em Portugal, desde o ano 2008 até 2017.

Para mostrar a evolução de energia eólica na UE, foram retirados os valores dos relatórios estatísticos anuais da *WindEurope*, desde 2010 até 2017. De salientar que, até 2013, a União Europeia possuía 27 países, e que, nesse ano, passaram a ser 28, com a entrada da Croácia, ficando conhecida a UE como UE-28. Os dados da evolução da energia eólica encontram-se organizados na Tabela 1.3 [33].

Como podemos constatar, as principais potências europeias na eólica são a Alemanha, a Espanha, a Grã-Bretanha e ainda a Itália. No entanto, é de salientar que, de momento, Portugal se encontra bem posicionado no ranking, sendo também uma potência europeia na produção de energia eólica, apesar da dimensão e espaço geográfico onde se insere.

Sendo a energia eólica um recurso bastante volátil, é necessário que, num sistema elétrico de energia, haja outros tipos de tecnologias, para que seja possível assegurar o fornecimento de eletricidade, com a qualidade e a segurança desejada, e com o menor custo associado possível. Posto isto, surgem problemas na participação no mercado, na segurança do abastecimento, na gestão dos centros produtores e na gestão dos parques eólicos.

Tabela 1.2 - Evolução da eólica em Portugal, em MW.

Potência Instalada [MW]	ANO									
	2008	2009	2010	2011	2012	2013	2014	2015	2016	2017
Eólica	2 700	3 500	3 900	4 200	4 300	4 400	5 206,20	5 304,61	5 552,54	5 577,81

14 Introdução




Figura 1.11 - Evolução da Eólica em Portugal, em MW

Tabela 1.3 - Evolução da Potência Eólica Instalada na Europa, em MW, [34].

Potência eólica instalada [MW]	ANO							
	2010	2011	2012	2013	2014	2015	2016	2017
Alemanha	27 191	29 060	31 308	33 730	39 165	44 946	50 019	56 132
Áustria	1 014	1 084	1 378	1 684	2 095	2 412	2 632	2 828
Bélgica	886	1 708	1 375	1 651	1 959	2 229	2 386	2 843
Dinamarca	3 749	3 871	4 162	4 772	4 845	5 064	5 227	5 476
Espanha	20 623	21 674	22 796	22 959	22 987	23 025	23 075	23 170
França	5 970	6 800	7 564	8 254	9 285	10 358	12 065	13 759
Grã-Bretanha	5 204	6 540	8 445	10 531	12 440	13 603	14 542	18 872
Grécia	1 323	1 629	1 749	1 865	1 980	2 152	2 374	2 651
Holanda	2 269	2 328	2 391	2 693	2 805	3 431	4 328	4 341
Itália	5 797	6 747	8 144	8 551	8 663	8 958	9 257	9 479
Irlanda	1 392	1 631	1 734	2 037	2 272	2 486	2 830	3 127
Polónia	1 180	1 616	2 497	3 390	3 834	5 100	5 316	6 397
Portugal	3 900	4 200	4 300	4 400	5 206	5 305	5 553	5 578
Roménia	462	982	1 905	2 599	2 954	2 976	3 028	3 029
Suécia	2 163	2 907	3 745	4 470	5 243	6 025	6 519	6 691
Outros*	1767	2061	2498	2860	3129,8	3736,5	4350	5207

* Finlândia, Bulgária, Malta, República Checa, Chipre, Croácia (a partir de 2013), Eslováquia, Eslovénia, Estónia, Hungria, Letónia, Lituânia e Luxemburgo

Na participação no mercado elétrico, os comerciantes ou promotores dos parques eólicos têm que apresentar, de hora em hora, as suas propostas de produção, com um tempo de antecedência de mais de um dia. Na segurança do abastecimento, caso haja uma avaria, como já é conhecida a produção para pelo menos as 24h seguintes, as unidades produtoras têm que garantir a cobertura dos consumos, considerando as perdas com a avaria ou indisponibilidade do grupo eólico. Este processo pode ser ilustrado através da Figura 1.12.

Neste ponto da segurança, é mostrada a importância de uma boa ferramenta de previsão para a diminuição dos erros associados. Na gestão dos centros produtores, como no processo de despacho, é necessário considerar todas as restrições associadas à rede elétrica, assim como as previsões de carga a alimentar e as incertezas associadas na produção, isto traduz-se num prolema, pois, o objetivo é garantir um bom escalonamento dos centros convencionas de produção.

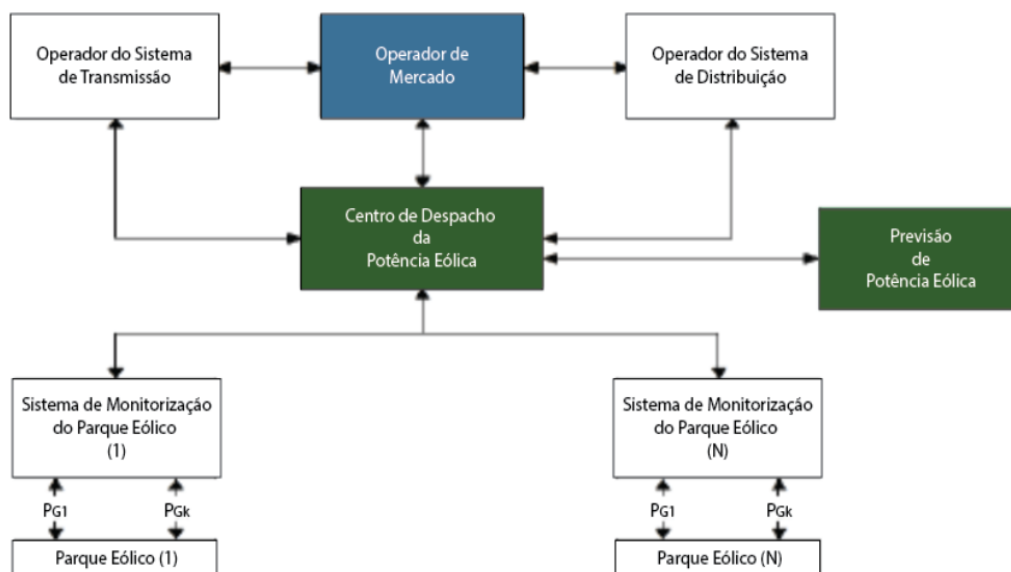


Figura 1.12 - Constituição de um sistema de produção eólica [31].

Na gestão dos parques eólicos, o facto de se ter que considerar os tempos de manutenção das unidades eólicas acarreta um problema na gestão dos parques [7]. Com o aumento do número de centrais eólicas para substituição das centrais convencionais térmicas, a complexidade do sistema aumenta. No entanto, a monitorização, o controlo e a gestão das centrais do sistema melhoram, mesmo considerando as restrições do sistema.

A complexidade do sistema é controlada pelo centro de despacho que, como mostra a Figura 1.12, tem o papel de comunicar com os operadores das redes e o mercado elétrico. O centro de despacho de potência eólica controla todos os parques eólicos, no entanto, a monitorização destes parques é efetuada pelos sistemas de monitorização [31].

1.2 - Motivação

Como mencionado na secção anterior, a dependência do consumidor relativa à energia elétrica tem aumentado e com a introdução das energias renováveis, nomeadamente a energia eólica, a complexidade para uma eficiente gestão do SEE aumenta significativamente. Com isto, uma boa estimativa/previsão nos preços de mercado de eletricidade possui uma elevada importância.

As metodologias híbridas que representam uma junção de várias técnicas têm vindo a ser utilizadas na área da previsão dos preços de mercado de eletricidade, tendo em conta os valores históricos das séries temporais, assumindo assim um papel importante para a minimização das incertezas associadas a estes problemas. Estas metodologias permitem que os operadores do mercado elétrico possam gerir os seus recursos, de forma clara e objetiva, para que se possa abastecer os consumidores sem comprometer a segurança, a robustez, a qualidade e a continuidade do serviço prestado aos clientes.

Posto isto, nesta dissertação ira ser proposta uma metodologia híbrida para a previsão dos preços de eletricidade recorrendo a ferramentas computacionais. Esta metodologia possui dados de entrada de conhecimento público, para os preços de mercado, retirados da OMEL e da REN. Com o recurso a estes dados reais, é possível uma efetuar uma avaliação isenta e justa da capacidade e da metodologia criada.

Esta metodologia surge depois de ter sido efetuado um levantamento das ferramentas computacionais utilizadas recentemente na área da previsão, que contribuiu, não só para um enquadramento com o tema, como para uma perceção do funcionamento das mesmas.

1.3 - Organização da Dissertação

A presente dissertação encontra-se dividida em 5 capítulos, sumariamente descritos a seguir. No Capítulo 1 é efetuado um enquadramento do mercado elétrico. Foram abordados o antigo e o novo paradigma, cuja alteração se deveu essencialmente à introdução de novas tecnologias de produção de eletricidade, nomeadamente a introdução dos recursos endógenos renováveis, assim como, a introdução da produção dispersa, que acarretou uma aproximação entre os locais de produção e os consumidores.

Ainda neste capítulo, foi apresentada a evolução dos mercados elétricos com a liberalização dos mesmos, e foi apresentada a estrutura e a organização do Mercado Ibérico de Eletricidade (MIBEL). Por fim, foram descritas as motivações para o crescente investimento quer na Europa quer em Portugal nas energias renováveis, mostrando a evolução das energias renováveis em Portugal e a evolução da energia eólica na Europa.

No Capítulo 2 é apresentado o atual estado de arte na área da previsão dos preços de eletricidade, onde foram apresentados os métodos e as metodologias híbridas que foram apresentadas anteriormente para a previsão dos preços de eletricidade. Ainda no mesmo capítulo, são descritos em pormenor alguns métodos computacionais geralmente utilizados nas metodologias de previsão dos preços de eletricidade.

No capítulo 3 é apresentada e descrita ao pormenor, a nova metodologia híbrida proposta para a previsão dos preços de eletricidade. Esta metodologia usa as transformadas de *Wavelet*, o *Differential Evolutionary Particle Swarm Optimization* (DEEPSO) combinado com o *Adaptative Network Fuzzy Inference System* (ANFIS) e por fim a Simulação de Monte Carlo (MCS) que permite que se possam visualizar os resultados finais dentro de um intervalo de valores

No capítulo 4 são apresentados os resultados finais, e foi realizada a comparação dos resultados obtidos com métodos já publicados e validados anteriormente pela comunidade científica. Para o efeito, os dados históricos utilizados para análise da ferramenta híbrida proposta serão os mesmos daqueles utilizados nas ferramentas validadas e em comparação, para efeitos de uma comparação exímia e livre das potencialidades da metodologia proposta.

No capítulo 5 são apresentadas as conclusões, as indicações para os trabalhos futuros que podem vir a ser realizados na no intuito de melhoria da ferramenta aqui proposta e as contribuições científicas resultantes no âmbito do tema desta dissertação desenvolvido.

1.4 - Organização do Texto

O presente trabalho de dissertação utiliza de forma semelhante as notações que a literatura da comunidade científica utiliza, harmonizando os aspetos comuns em todas as secções. As figuras, tabelas e expressões matemáticas serão mencionadas em relação ao capítulo onde são inseridas, reiniciando-se a numeração quando um novo capítulo é iniciado.

As referências que suportam os diferentes capítulos que compõem a presente dissertação estarão estruturadas e identificadas por [XX] e a distinta formulação matemática por (X.X). Os acrónimos utilizados encontram-se estruturados pela sintetização de nomes e informação técnica oriunda da língua portuguesa, ou quando não for possível a tradução adequada, na língua anglo-saxónica, ambas aceites na comunidade técnica e científica.

Capítulo 2

Estado da Arte

Neste capítulo, irá ser efetuado o levantamento do estado da arte relativo à área da previsão dos preços de eletricidade, onde primeiramente serão apresentadas as metodologias que têm vindo a ser utilizadas e/ou apresentadas pela comunidade científica para a previsão dos preços de eletricidade.

As metodologias de previsão estão empiricamente relacionadas com erros entre os resultados obtidos e o que de facto acontece. Estes erros devem-se a diversos fatores que interferem com a qualidade dos resultados obtidos, dos quais se destacam os seguintes [35]:

- **Fatores económicos** - A forma de onda da carga pode ser afetada pela situação económica da área onde vai ser realizada a previsão. Esta situação varia consoante o tipo de consumidores, das condições geográficas, das atividades industriais, e da sua população;
- **Fatores temporais** - A forma de onda da carga pode ser afetada pelos efeitos sazonais, pelos dias da semana e também pelos feriados. Por exemplo, para os efeitos sazonais a carga é afetada diretamente devido ao número de horas de radiação solar.
Na indústria, a carga durante os dias da semana é muito diferente da dos dias de fim de semana, pelo que a forma de onda da carga também irá sofrer alterações. Os dias de feriado também apresentam cargas inferiores relativamente aos dias normais;
- **Fatores meteorológicos** - Na previsão, a temperatura é o fator que apresenta uma maior influência nos perfis das cargas. No inverno há uma maior dependência de aquecimento e no verão existe uma maior dependência do ar-condicionado. Outros fatores meteorológicos que podem afetar o perfil da carga são os índices de humidade e de precipitação, as tempestades e ainda os índices de vento e de luminosidade;

- **Distúrbios aleatórios** - As alterações comportamentais nas grandes indústrias, assim como eventos do cotidiano, como um programa televisivo ou mesmo um evento desportivo, podem afetar significativamente as formas de onda das cargas;
- **Volatilidade dos preços de eletricidade** - deve-se à incerteza da produção renovável que irá, por sua vez, interferir com a quantidade de energia proveniente de combustíveis fósseis necessária para cobrir as necessidades associadas às incertezas dos consumos da energia elétrica. Esta variação dos preços também está relacionada com os comportamentos dos diversos intervenientes no mercado de eletricidade, devido às suas ações na antevisão dos preços e dos portfólios a apresentar. O congestionamento na rede de transporte e distribuição também influencia o perfil da carga;
- **Outros fatores** - Os padrões de carga podem ser afetados por outros fatores como os geográficos, isto porque o tipo de consumo de uma zona rural é diferente do tipo de consumo de uma zona urbana e ainda existe o perfil do consumidor, residencial, comercial e industrial.

Com o aumento da aposta em novas fontes de energia renováveis e com a contínua expansão das fontes renováveis já conhecidas, nomeadamente a energia eólica, a complexidade do sistema aumenta.

Com isto, o esforço da comunidade científica para a criação de novas ferramentas de previsão tem vindo a aumentar, como é mencionado em [50] e [51]. Devido aos fatores mencionados anteriormente, é fácil de compreender a dificuldade presente na previsão dos preços, assim como, nos perfis dos consumos, tendo então surgido nos últimos anos novas propostas.

Para a previsão dos preços de eletricidade, normalmente são usados modelos que se baseiam essencialmente em modelos estatísticos (como é o caso das séries temporais), e na inteligência computacional. Na Figura 2.1, são apresentados alguns desses modelos estatísticos e de inteligência computacional. Os modelos estatísticos, normalmente usam técnicas de previsão de valores futuros, que recorrem a dados históricos e atuais das séries a prever, para que se possa fazer uma análise dos erros.

Alguns exemplos desses modelos estatísticos são os Autorregressivos (AR), ou Regressão Dinâmica, o *Autoregressive Integrated Moving Average* (ARIMA) [38], o *Generalized Autoregressive Conditional Heteroskedastic* (GARCH) [39] e o modelo *Wavelet-ARIMA* [40], [41]. No entanto, estes modelos estatísticos requerem grandes recursos computacionais, visto que necessitam de um elevado número de parâmetros para modelar o sistema corretamente.

Os sistemas inteligentes são utilizados como alternativa para a previsão de preços da eletricidade e são computacionalmente mais eficientes, requerendo na sua grande maioria uma menor capacidade computacional para desempenhar a sua função, pelo que se obtêm melhores resultados.

Como a área da previsão dos preços de eletricidade é uma área que já tem um vasto trabalho realizado, é necessário em primeiro lugar, o horizonte temporal em que a metodologia se insere.

2.1. Classificação dos Horizontes Temporais

Conforme [31], as previsões para os preços de eletricidade normalmente são efetuadas para o dia seguinte ou mesmo para a semana seguinte. Os limites temporais não se encontram verdadeiramente definidos, isto porque não existe uma concordância na comunidade científica no estabelecimento dos limites dos horizontes temporais na literatura especializada.

Conforme descrito em [36], tal como no caso da previsão dos preços de eletricidade, a classificação dos horizontes temporais dos métodos de previsão para a potência eólica também diferencia na diversa literatura da especialidade.

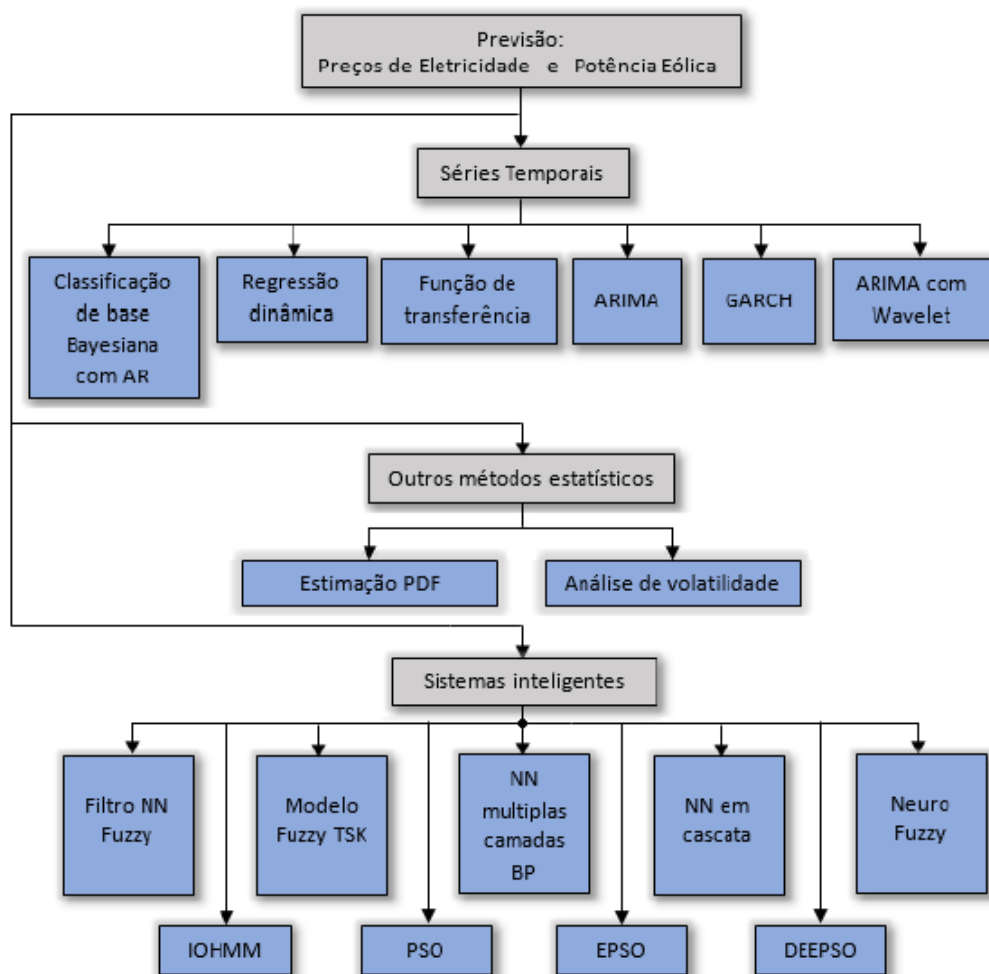


Figura 2.1 - Esquema dos principais métodos usados na previsão [31].

No entanto, pela concordância existente na diversa literatura, os horizontes temporais podem ser divididos em 4 categorias:

- Muito curto prazo (de alguns segundos e/ou minutos até à hora seguinte);
- Curto prazo (de 1h até algumas horas depois)
- Médio prazo (de algumas horas até à semana seguinte);
- Longo prazo (da semana seguinte até 1 ano).

Na tabela 2.1, encontram-se representados os horizontes temporais, assim como as suas aplicações na operação dos sistemas elétricos [36].

2.2. Previsão dos Preços de Eletricidade

A liberalização do setor elétrico e a existência de mercados organizados, em conjunto com a alteração do paradigma do setor, incentivou o reforço do desenvolvimento de diferentes métodos de previsão dos preços da eletricidade, pois apresenta uma mais-valia num ambiente competitivo.

Por exemplo, o consumidor procura satisfazer as suas necessidades de eletricidade minimizando os custos, enquanto o interesse de um produtor de eletricidade é realizar as suas propostas de transação de eletricidade de modo a maximizar os seus lucros. Dessa premissa, no mercado de eletricidade liberalizado, o sinal mais importante para todos os intervenientes no mercado é o preço [42].

Tabela 2.1 Classificação dos horizontes temporais e suas aplicações no SEE [36]

Escala	Intervalo	Aplicações
Muito curto prazo	de alguns segundos e/ou minutos até à hora seguinte	<ul style="list-style-type: none"> • Ações de regulação; • Operações na rede em tempo real; • Equilíbrio do mercado de eletricidade.
Curto prazo	de 1h até algumas horas depois	<ul style="list-style-type: none"> • Planeamento do despacho económico; • Segurança operacional no mercado de eletricidade;
Médio prazo	de algumas horas até à semana seguinte	<ul style="list-style-type: none"> • Decisões de ligar ou desligar geradores; • Decisões de Unit Commitment; • Decisões de reserva requerida.
Longo prazo	da semana seguinte até 1 ano	<ul style="list-style-type: none"> • Planeamento das manutenções; • Custo de operação ótimo; • Estudos de fiabilidade; • Gestão de operações.

As características que podem ser encontradas nas séries dos preços eletricidade, tais como a sazonalidade, volatilidade, efeito calendário e o comportamento não-estacionário, fazem com que a previsão rigorosa e próxima da realidade dos mesmos seja mais difícil do que para o caso das séries da carga diária [43].

Para além disso, devido aos pontos atrás descritos, e ainda ao que se descreve na comunidade científica, as técnicas de previsão deverão possuir a capacidade de se adaptarem as características acima descritas, e para o efeito, algumas técnicas de previsão de curto prazo se baseiam em modelos estatísticos, tais como séries temporais, modelos econométricos e inteligência artificial. Dos modelos anteriormente enunciados é necessário referir [44]:

- **Modelos Estatísticos:** têm como principal objetivo a previsão dos preços da eletricidade, levando em consideração as suas características estatísticas e intervalos de confiança, permitindo ainda a análise da volatilidade. Dentro destes modelos estão inseridos fatores internos como as variáveis incontroláveis (vento, pluviosidade, radiação solar, entre outros ...) e ainda os fatores sociais como sazonalidade, eventos, feriados, entre outros.
- **Séries Temporais:** utilizam dados históricos e dados do momento para a previsão de dados futuros. Neste tipo de modelos, é possível fazer um estudo dos erros associados às variáveis utilizadas na previsão. Exemplos destes modelos são os modelos autorregressivos, os modelos inteligentes, e os modelos híbridos baseados nos modelos autorregressivos.
- **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. Com a utilização destes modelos é possível obter, a evolução temporal com base no histórico, a regressão das variáveis aplicadas às séries temporais, e ainda a previsão de uma variável em função de outras variáveis.

Como o estado de arte dos últimos anos demonstra, os esforços realizados pela comunidade académica tem sido elevados, segundo [45]-[47], para propor soluções mais viáveis e confiáveis para as técnicas de previsão dos preços de eletricidade, considerando modelos estatísticos, ou físicos, em computação leve ou computação complexa, como mostrado em [48], [49].

Na computação complexa, a média móvel integrada regressiva automática (ARIMA) [50], as transformadas de *Wavelet* (WT) e o WT combinado com o ARIMA [40] são alguns exemplos dos modelos que exigem a computação complexa. Isto porque, essas metodologias precisam de um grande número de dados físicos, exigindo também a modelagem exata do sistema, o que faz com que estes métodos necessitem de uma elevada capacidade computacional.

Na computação leve, as metodologias usam um processo de autoaprendizagem a partir dos conjuntos históricos para identificar dados futuros com os padrões presentes nos dados históricos. Como reflexo dos esforços levados a cabo pela comunidade científica no avanço de novas metodologias de previsão mais robustas, segue um levantamento efetuado, do elevado número de propostas disponíveis.

No ano de 2012, em [51] foi proposto um modelo híbrido para prever os preços do mercado de eletricidade (PME) do mercado *Nordpool*, usando os dados históricos do ano de 2012. *Nordpool* é o mercado que opera na Noruega, Dinamarca, Suécia, Estónia, Letónia, Lituânia, Alemanha e Reino Unido. Esta metodologia assenta na combinação do *autoregressive fractionally integrated moving average* (ARFIMA) e das redes neuronais artificiais (ANN).

Em 2013, para o mercado do Irão, surgiram duas propostas. Em [52], para prever o dia seguinte (24h) dos PME para o ano de 2013 foi proposta uma metodologia que usa um modelo de agrupamento de dados, conhecido por *Fuzzy C-Means* (FCM), que é combinado com um algoritmo de aprendizagem, em que a sua aprendizagem resulta de uma teoria estatística, conhecida por *Support Vector Machine* (SVM). Para além destes métodos, a metodologia conta ainda com um algoritmo de otimização, *Bat Algorithm* (BA) que imita o comportamento das microbactérias.

No entanto, em [53], surgiu outra metodologia híbrida para prever os PME do Irão do ano de 2012, em que foi usada a combinação entre as transformadas de *Wavelet* (WT) e o *Least Squares Support Vector Machine* (LSSVM), em que o treino de otimização é baseado num processo de *Cuckoo Search and Gravitational Search Algorithm* (CGSA).

No ano de 2015, surgiu uma nova metodologia para prever os PME do mercado Nórdico do ano de 2009 [54], que resultou numa junção entre o *Cuckoo Search Levenberg- Marquard trained* (CSLM) e as *Feed-Forward Neural Networks* (FFNN).

Em 2016, para prever os dias seguintes do mercado Italiano e do mercado Indiano, surgiram duas propostas. Em [55], para o mercado Italiano, foram propostas duas metodologias para prever os PME dos anos 2014 e 2015. Uma primeira que resulta da combinação das ANN, com *Support Vector Machine* (SVR) e a Regressão linear (LR) e outra que combina as ANN com SVR e um método de persistência. No caso do mercado Indiano, foram previstos os PME para as 72h seguintes (3 dias seguintes) com o recurso as ANN, usando os dados históricos dos preços do ano de 2016.

Para o mercado de eletricidade da Austrália, existem diversas metodologias criadas para previsão dos PME ao longo dos anos. Começando no ano de 2011, usando uma técnica de agrupamento de dados ou, *Clustering Technique* (CT) em conjunto com um algoritmo focado em previsão de amostras enquadradas, *Predicting Samples Framed* (PSF), foi criada uma metodologia capaz de prever os preços dos dados históricos do mercado Australiano do ano de 2006 [56].

Também para prever os preços do ano de 2006, em 2012, foi proposta uma metodologia, segundo [57], em que se combina as WT com ARIMA e *Particle Least Squares Support Vector Machine* (PLSSVM), em que, neste último método, o *Particle Swarm Optimization* (PSO) é selecionado como técnica de otimização com vista a otimizar os seus próprios parâmetros. O horizonte temporal usado para a previsão neste trabalho fora as 168h seguintes (semana seguinte).

No ano de 2013, em [58], para previsão das 24h seguintes dos PME do ano de 2005 foi proposto um método de análise recursiva de um fator dinâmico (RDFA, *Recursive Dynamic Factor Analysis*). Em 2016, foi criada uma metodologia para prever os preços de mercado do ano de 2010, tanto para as 24h como para as 168h seguintes, como apresentado em [59]. A metodologia combina, numa primeira fase *Flexible Wavelet Packet Transform* (FWPT), para decompor o sinal, com *Conditional Mutual Information* (CMI).

Numa segunda fase, o modelo *Multi-Input Multi-Output* (MIMO), baseado em *Non-linear Least Square Support Vector Machine* (NLSSVM) e ARIMA, é usado para correlacionar linearmente e não-linearmente o preço e a carga em duas etapas. Numa terceira e última fase desta metodologia, é implementada uma versão modificada do algoritmo *Artificial Bee Colony* (ABC), baseado em *Time-Varying Coefficients and Stumble Generation Operator* (TV-SABC), para serem otimizados os parâmetros do modelo NLSSVM no seu processo de aprendizagem.

Ainda para o ano de 2016 e para o mercado Australiano, em [60], surgiu um modelo híbrido que combina as WT com *Time Series Time Delay Neural Networks* (TSDNN) e com *Zero Phase Filter* (ZPF), que foi testado usando os dados históricos do ano 2015.

Relativamente ao mercado do Canadá, mais concretamente para o Mercado de Ontário, existe um vasto estudo realizado. Por exemplo, Em 2012, através de um método rápido de previsão baseado numa, *Extreme Learning Machine* (ELM) numa ANN feed-forward, (FFNN), foram previstos os PME para o ano de 2006, [61]. Ainda em 2012, para a previsão dos PME do ano de 2010, em [62], foi proposta uma metodologia híbrida que resulta na combinação das WT com *Firefly Algorithm* (FF) e *Fuzzy ARTMAP* (FA), em que a rede FA é supervisionada por um modelo da família das ANN que usa uma Teoria Ressonante Adaptativa (ART).

Já em 2014, a metodologia proposta, WT combinada com a ELM, que é um algoritmo de aprendizagem para uma camada escondida de uma FFNN, foi usada para prever os PME das 168h seguintes do ano de 2004 [63]. Em [64], no ano de 2015, através das ANN, foram previstos os preços de eletricidade para a hora seguinte, usando os dados históricos dos preços de 2012.

Em 2016, em [65] foi apresentada uma metodologia que resulta da combinação do LSSVM com Algoritmos Genéticos (GA) para prever os PME da semana seguinte do ano de 2004. Em [66], no ano de 2017, foi criada uma metodologia para prever os preços do dia seguinte.

Esta metodologia, numa primeira fase, agrupa os dados através de um sistema difuso (*fuzzy systems*), de seguida, os dados são decompostos através das WT e são selecionados através de uma técnica de seleção. Depois, através de uma *Fuzzy ANN* (FNN) são previstos os resultados e reconstruídos a partir da inversa das WT.

O *PJM interconnection* é uma organização regional de transmissão que coordena o movimento das vendas de mercado grossista nos seguintes estados dos Estados Unidos da América: Delaware, Illinois, Indiana, Kentucky, Maryland, Michigan, New Jersey, North Carolina, Ohio, Pennsylvania, Tennessee, Virginia, West Virginia e o District of Columbia [67].

Para o *PJM*, irão ser destacadas 8 metodologias, que foram propostas entre os anos de 2008 e 2017.

Começando em 2008, foi utilizado o método *Adaptative Wavelet ANN* (AWNN) para prever a semana seguinte dos PME deste mercado do ano de 2004, [68]. Em 2009, em [69], foi criada uma metodologia para prever os PME da semana seguinte do *PJM*, usando os dados do ano 2006. Para tal, foi apresentada uma metodologia que combina uma técnica de informação mútua (MI) com um algoritmo neuro-evolucionário, conhecido como *Cascade Neuro-Evolutionary Algorithm* (CNEA).

Seguidamente, em 2011, em [70], foi criada uma metodologia que utiliza a técnica da MI, apresentada em [69], no entanto, esta é combinada com um método *Composite ANN* (CNN) e foi testada para prever os PME do ano de 2002, considerando um horizonte temporal de uma semana.

Com a combinação de três métodos, as WT, *Chaotic Least Squares Support Vector Machine* (CLSSVM) e *Exponential Generalized Autoregressive Conditional Heteroscedastic* (EGARCH) foi uma metodologia criada em 2012, [71], para prever os preços de eletricidade da semana seguinte do mercado *PJM* do ano de 2004. Em [72], no ano de 2012, foram previstos os PME do dia seguinte, usando dados históricos do ano de 2008, através do método *Panel Cointegration and Particle Filter* (PCPF).

Em 2014, em [73], através da combinação entre a informação mútua, as WT, o *Evolutionary Particle Swarm Optimization* (EPSO) e o *Adaptative Network Fuzzy Inference System* (ANFIS), foram previstos os preços de eletricidade no mercado *PJM* com base nos dados do ano de 2002, em que o horizonte temporal selecionado foram as 24h e as 168h seguintes. Em [59] também foi usada para prever os preços de eletricidade, das 24h e 168h seguintes do *PJM*, usando os dados de 2013.

Em 2017, uma combinação entre as WT, *Autoregressive Moving Average* (ARMA) e *Kernel-Based Extreme Learning Machine on Self-Adapting PSO* (SAPSO-KELM) foi apresentada em [74] para prever os PME da semana seguinte do *PJM* para os anos de 2004 e 2006.

Relativamente ao mercado espanhol, de seguida, irão ser apresentadas diversas metodologias desde o ano 2005 até 2017.

Começando em 2005, em [75], utilizando as ferramentas de WT e modelos ARIMA, foram previstos para os dados de 2002, os PME das 168h seguintes. Já em 2006, para o mesmo ano (2002) e para o mesmo horizonte temporal (168h seguintes) foram previstos os PME com base nas ANN [76] e com base nas FNN [77]. As FNN usadas em [77], apresentam uma capacidade de aprendizagem maior que as ANN tradicionais.

Em 2007, em [78], foram previstos os PME para o dia e para a semana seguinte do ano de 2002, com base numa técnica denominada por vizinhos mais próximos (WNN), ou *Weighted Nearest Neighbors*. Também para os preços do ano 2002, em 2009, foi proposta uma nova metodologia híbrida inteligente a que lhe foi atribuída a designação de *hybrid inference system* (HIS).

A metodologia HIS é a combinação de uma estrutura *Multi-layer Perceptron* (MLP) e um algoritmo de aprendizagem *Real Coding Genetic Algorithms* (RCGA), [79]. Ainda em 2009, foi utilizada uma combinação entre as WT e as ANN para prever os preços da semana seguinte do mercado espanhol, usando também os dados históricos dos PME de 2002, [80].

As metodologias apresentadas em [69] e [70], , também foram implementadas para prever os PME do mercado espanhol, em detalhe, em [69] foram previstos os preços da semana seguinte usando os dados de 2000, enquanto que em [70] foi realizada a previsão para as 168h seguintes considerando os dados históricos de 2002.

No ano de 2011, foram propostas várias metodologias, das quais irão ser destacadas 5 metodologias diferentes. Em [81], a combinação entre as WT e o ANFIS foi usada para prever os PME da semana seguinte do mercado espanhol para o ano de 2002. Em [82], foi apresentada uma metodologia híbrida que combina as WT com ARIMA e redes *Radial Basis Function Neural* (RBFN) para prever os PME das 24h seguintes do mercado espanhol do ano de 2002.

A metodologia proposta em [56], foi testada para prever os PME do mercado espanhol do dia seguinte, no entanto, neste caso, foram usados os dados históricos do ano de 2006. Por fim, no ano de 2011 é de realçar ainda que, para prever os PME de 2002 do mercado elétrico espanhol, foram propostas ainda mais duas metodologias que usam o método ANFIS. Em [83], o ANFIS é combinado com as WT e o PSO para prever a semana seguinte.

Já em [84], o ANFIS é em junção com o PSO evolucionário (EPSO) foi modelado para prever os PME do mercado espanhol da semana seguinte. Em 2012, a metodologia apresentada em [61], também foi utilizada para prever os PME do mercado espanhol para o dia seguinte, usando os dados do ano de 2006.

Em [85], usando as *Recurrent ANN* (RNN) foram previstos os PME do ano 2002, em que o horizonte temporal utilizado foi o das 168h seguintes. No entanto, em [86], uma metodologia que assenta na junção do PSO e o ANFIS foi apresentada no ano de 2012 para prever os PME das 168h seguintes do ano de 2002.

Em 2013, a metodologia apresentada em [73] também foi testada para a previsão dos PME do mercado espanhol do ano de 2002. Neste caso, foram considerados dois horizontes temporais: do dia seguinte e da semana seguinte. A metodologia apresentada para a previsão dos PME do mercado Iraniano [53], no ano de 2013, também foi utilizada para prever os PME da semana seguinte do ano de 2002 no mercado espanhol.

Ainda em 2013, em [87], foi efetuado um estudo de métodos probabilísticos para prever os PME do MIBEL em 2007. Alguns dos métodos apresentados foram:

- LM-GB - *Linear Models Gradient Boosting*;
- LAM-GB - *Linear Additive Models Gradient Boosting*;
- QRF - *Quantile Regression Forests*;
- QRNN - *Quantile Regression ANN*;
- KQR - *Quantile Regression on Reproducing Kernel Hilbert Space*;
- LQR - *Linear Quantile Regression*.

Em 2014, em [88], foi apresentada uma metodologia com vista a prever os PME do mercado Espanhol. Para isso, foram usados os dados históricos do ano de 2002 e o horizonte temporal considerado foi o das 24h seguintes. Essa metodologia assenta na combinação entre DCT (*Discrete Cosine Transforms*) com as FFNN.

Em 2015, a metodologia apresentada em [54], também foi utilizada para prever os PME do ano de 2002 das 24h seguintes. Ainda em 2015, em [89], o método *Elman ANN* (ENN) foi usado para a previsão da semana seguinte, usando os dados históricos dos PME do ano em que a maior parte das metodologias foram testadas no mercado espanhol (ano de 2002).

Finalmente, em 2016, em [30], foi proposta uma metodologia que combina as WT com o *Differential Evolutionary PSO* (DEEPSO) e o ANFIS para a previsão dos PME no mercado espanhol, considerando os dados históricos dos PME do ano de 2002,. Em 2017, em [90], foi proposta uma metodologia que resulta da combinação das WT, com *Fuzzy Adaptive PSO* (FA-PSO) e as FFNN para a previsão dos PME do mercado espanhol considerando os históricos de 2002 para a obtenção de previsões para as próximas 168h.

Capítulo 3

Ferramenta de Previsão dos Preços de Mercado de Eletricidade

Neste capítulo serão abordados alguns dos métodos computacionais que irão ser utilizados para a metodologia híbrida proposta, mas que também são frequentemente utilizados nas metodologias propostas pela comunidade científica. Para além disto, irão ser apresentada as ferramentas que permitiram a criação da metodologia híbrida para a previsão dos PME, descrevendo em detalhe os princípios e o funcionamento da mesma. Por fim, ainda serão apresentados os critérios matemáticos usados para calcular os erros existentes nos resultados das previsões obtidas.

3.1. Métodos Computacionais

Ao longo desta secção, são apresentados alguns dos métodos computacionais estudados neste trabalho de dissertação, nomeadamente:

- Transformadas de *Wavelet* (WT);
- Sistema de Inferência Neuro-difuso Adaptativo (ANFIS);
- Otimização Diferencial por Enxame de Partículas Evolucionário (DEEPSO);
- Simulação de Monte Carlo (MCS).

3.1.1. Transformadas de Wavelet (WT)

Nas ferramentas de previsão atuais, para a análise de séries temporais, como os PME, as WT, têm sido bastante usadas, isto porque detetam padrões e tendências. As séries temporais dos PME apresentam diversas flutuações e picos que são muito complicados de prever e as WT são uma ferramenta capaz de isolar essas irregularidades das séries temporais não estacionárias [91].

As WT também são geralmente usadas em análises da qualidade de serviço de energia, na análise transitória, na modelação de distúrbios do sistema de energia de curto prazo, e ainda na detecção de defeitos no sistema [92].

Trata-se de uma ferramenta matemática, em que o processamento de dados, em várias escalas ou resoluções, é feito comprimindo ou estendendo uma função mãe, permitindo uma representação das séries temporais no domínio do tempo e da frequência [93].

Este processamento pode ser atingido através da WT contínua (CWT) e da WT discreta (DWT). Relativamente à CWT, tendo em conta o sinal a ser analisado $x(t)$ e a função mãe $\psi_{a,b}(t)$, esta é definida por [91]:

$$CWT_x(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{+\infty} \psi^*(t) \times x(t) dt, a > 0 \quad (3.1)$$

com,

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} wt \left(\frac{t-b}{a} \right), a > 0 \quad e \quad -\infty < b < +\infty \quad (3.2)$$

em que,

a – parâmetro escalar que é reponsável pelo controlo da propagação

b – parâmetro de translação que é responsável por determinar a posição da janela;

$\psi_{a,b}(t)$ – função mãe, que é calculada usando a função, $wt \left(\frac{t-b}{a} \right)$

As baixas frequências (larga escala) expandem o sinal e fornecem informação não detalhada sobre o sinal, enquanto as altas frequências (baixa escala) comprimem o sinal e fornecem informação sobre o sinal.

Como a CWT é obtida por escalonamento e translação da função mãe, são geradas informações substanciais e redundantes [91]. Posto isto, calcular os coeficientes em todas as escalas e translações leva muito tempo e acarreta uma elevada carga computacional.

Na DWT, ao contrário da CWT, a função mãe pode ser escalada e transladada usando certas escalas e posições, reduzindo assim o tempo e a sobrecarga computacional exigida [93]. A DWT é definida por:

$$DWT_x(m, n) = 2^{-(m/2)} \times \sum_{t=0}^{T-1} x(t) \times \psi \left(\frac{t - n \times 2^m}{2^m} \right) \quad (3.3)$$

em que,

T – representa o comprimento do sinal;

$a = 2^m$ – parâmetro de escala, cujo valor depende de uma variável inteira, m ;

$b = n \times 2^m$ – parâmetro de translação, cujo valor depende de uma variável inteira, n ;

t – representa o índice de tempo discreto.

O cálculo da DWT é feito para o subconjunto de escalas e posição escolhidos, sendo este esquema conduzido usando filtros e cálculo denominados por aproximações e detalhes, destacando assim a informação escondida pelo sinal, $x(t)$.

As aproximações são de alta escala, ou seja, componentes do sinal de baixa frequência, enquanto os detalhes são de baixa escala, ou seja, componentes do sinal de alta frequência [94].

Ao longo deste trabalho, a análise das WT foi realizada, com recurso às DWT, através de uma análise de muti resolução, com a ajuda do MATLAB, que possui duas etapas: a decomposição do sinal e a reconstrução do sinal. Esta análise pode ser implementada por séries de consecutivos pares de filtros.

O processo de decomposição é um processo que pode ser iterativo e o sinal, $x(t)$, é dividido noutros componentes de menor resolução, ficando conhecido como a árvore de decomposição de WT. Este sinal, num primeiro nível, é passado através de um filtro passa-baixo e um filtro passa-alto e depois as saídas dos filtros são subtraídas por 2, resultando daí os coeficientes de aproximação e de detalhe do primeiro nível (A_1 e D_1).

Este processo é repetido iterativamente até que se atinjam os níveis desejados. Neste trabalho foram usados 3 níveis, pelo que resultam os 6 coeficientes, 3 de aproximação e 3 de detalhe (A_1, A_2, A_3 e D_1, D_2, D_3), como mostra a Figura 3.1.

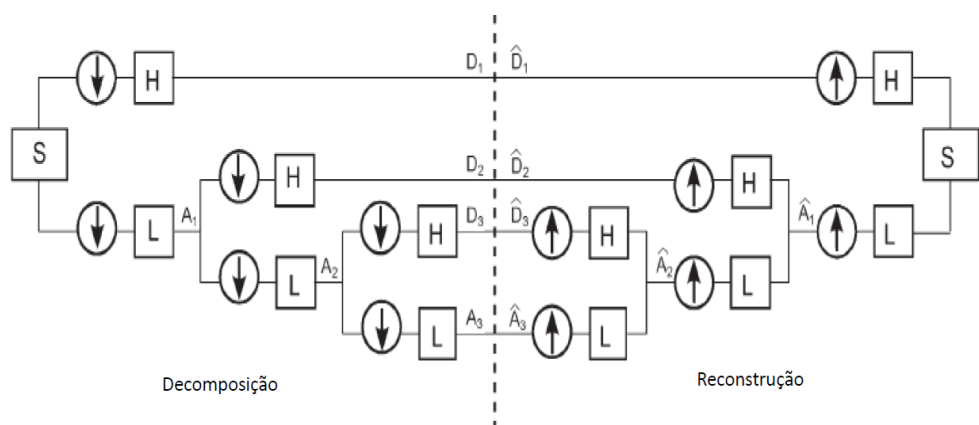


Figura 3.1- Estrutura do algoritmo das WT [91]

3.1.2. Otimização Diferencial por Enxame de Partículas Evolucionária (DEEPSO)

A otimização por enxame de partículas (PSO) é uma metodologia que foi primeiramente desenvolvida por Russel Eberhardt e James Kennedy. A ideia inteligente por trás deste método foi criar um modelo iterativo para uma partícula móvel numa população, durante a pesquisa num espaço variável [95].

Teve como inspiração para a sua criação o comportamento e a dinâmica de movimento de animais, como pássaros, peixes ou insetos. Existem inúmeras aplicações para as quais este método tem sido bem-sucedido [96].

Isto deve-se ao facto de este método apresentar uma implementação simples, por ter poucos parâmetros a serem definidos pelo utilizador e também porque não necessita de cálculos de derivadas que são cálculos matematicamente mais complexos.

Para além disto, este método é insensível à mudança de escalas das variáveis e ainda é adequado e rápido a encontrar os mínimos globais. Apesar de com o PSO ser fácil e bastante rápido a encontrar a zona das boas soluções, encontrar o ponto ótimo já não é assim tão simples, pois o ajuste da solução final é um processo lento [97].

Trata-se de um algoritmo não-evolucionário porque não depende da operação de seleção. A uma dada população, designada por enxame, contribui, em cada passo ou iteração do processo, para criar uma população inteira nova numa nova posição. A chave do sucesso deste processo reside na sua regra do movimento [95].

O peso de inércia neste método varia linearmente com o número da iteração. Visa amortecer a velocidade entre iterações, à medida que estas vão avançando, possibilitando assim que o enxame convirja mais rapidamente e eficientemente para a solução ótima do problema em questão.

A nova posição de cada partícula depende da sua posição na iteração anterior, assim como da sua velocidade nessa iteração, que, por sua vez, é dada pela influência da inércia (memória) e da cooperação (taxas de aprendizagem e melhores posições das partículas).

O PSO não tem em consideração a operação da seleção, ou seja, de todas as partículas nenhuma partícula é eliminada do enxame no decorrer do algoritmo. No entanto, o PSO usa o conceito de aptidão ou *fitness*. Como o ajuste da velocidade é efetuado através da informação partilhada de outras posições, ocorre a operação da mutação, isto porque os elementos de memória e de cooperação são alterados em todas as iterações [96].

Tal como acontece nos processos evolutivos, o EPSO é um algoritmo cujos alicerces e conceitos de otimização estão contidos em estratégias evolucionárias, auto adaptativas e por enxames de partículas tal como o PSO [95], [98], [99].

O EPSO atribui ao algoritmo do PSO uma capacidade explícita de procedimentos de seleção com propriedades auto adaptativas para os parâmetros de objeto e para os parâmetros estratégicos.

Cada partícula é caracterizada pelos parâmetros de objeto (o valor das variáveis que descrevem a solução, que são as variáveis X) e pelos parâmetros estratégicos (os coeficientes de mutação de cada variável, ângulo de correlação das variáveis de mutação ou semelhantes, que são os pesos W) [100]. Cada estará sujeita às seguintes etapas [101], [102]:

- **Multiplicação** - cada partícula é multiplicada r vezes;
- **Mutação** - cada partícula possui um peso, w , mutado;
- **Reprodução** - cada partícula gera um conjunto de partículas através da regra do movimento da partícula;
- **Avaliação** - cada conjunto de partículas é avaliado pelo seu peso, w ;
- **Seleção** - através de processos estocásticos, em que, a melhor partícula sobrevive para criar um novo conjunto (descendência).

No EPSO, os pesos sofrem um processo de mutação. Numa diversidade de problemas, o EPSO tem apresentado um desempenho melhor do que outras metodologias meta-heurísticas, como os algoritmos genéticos ou o algoritmo clássico PSO. Isto porque o EPSO tende a escapar do ótimo local e é robusto, isto é, gera resultados com uma variação pequena em problemas com uma inicialização aleatória [103].

O método de Otimização Diferencial por Enxame de Partículas Evolucionária (DEEPSO) é uma combinação híbrida de sucesso do EPSO (originário do PSO). Neste algoritmo, os parâmetros de peso têm capacidades auto adaptativas, que quando combinados com a programação evolucionária, originam operadores auto adaptativos, e um algoritmo de evolução diferencial, que geram uma nova solução de uma partícula atual do enxame, por adição de uma fração diferente entre dois outros pontos experimentados do enxame que se encontra em avaliação [104].

Desta forma, a formulação deste novo método evolucionário é semelhante à do EPSO, no entanto, a regra de movimento tem uma nova notação:

- A posição da partícula i , X_i , na iteração k :

$$X_i(k) = X_i(k-1) + V_i(k); \quad i = 1, 2, \dots, N \quad (3.4)$$

- Sendo a velocidade da partícula i , V_i , na iteração k :

$$V_i(k) = w_{i0}^* \times V_i(k-1) + w_{i1}^* \times (X_{r1}^i(k-1) - X_{r2}^i(k-1)) + Pw_{i2}^* \times (G_{best,i}^* - X_i(k-1)), \quad i = 1, 2, \dots, N \quad (3.5)$$

Em que, os pesos, w_{ik}^* , sofrem uma mutação semelhante à do EPSO, e são dados pela expressão:

$$w_{ik}^* = w_{ik} + \tau N(0,1) \quad (3.6)$$

No entanto, a melhor posição global das partículas até ao momento, $G_{best,i}^*$, é dada pelo novo peso, w_g que por sua vez, é obtido através de uma matriz diagonal, e é definida por:

$$G_{best,i}^* = G_{best,i} \times (1 + w_g N(0,1)) \quad (3.7)$$

A partir da Eq. (3.4), se o caso de otimização pretendido for uma minimização, os elementos $X_r^i(k-1)$ devem ser diferentes de qualquer par de partículas testadas anteriormente e devem ser ordenadas da seguinte forma:

$$f(X_{r_1}^i(k-1)) < f(X_{r_2}^i(k-1)) \quad (3.8)$$

Os elementos $X_{r_1}^i(k-1)$ e $X_{r_2}^i(k-1)$ asseguram que o modelo se encontra a seguir a direção desejada para chegar ao ponto ótimo, o que não acontece no EPSO. Posto isto, a componente $X_{r_1}^i(k-1)$ é amostrada a partir do conjunto dos melhores antepassados do enxame de n partículas, ou seja, $S_{bA} = \{P_{best,1}, P_{best,2}, \dots, P_{best,N}\}$, [105].

O DEEPSO possui um fator de comunicação P , que representa uma matriz binária diagonal, em que os seus elementos têm valor 1, caso a probabilidade seja p , e 0, caso seja $(1-p)$. Na Figura 3.2, encontra-se representada a regra do movimento da partícula considerando o método DEEPSO.

3.1.3. Sistema de Inferência Neuro-difuso Adaptativo (ANFIS)

Antes de se iniciar a descrição do Sistema de Inferência Neuro-difuso Adaptativo (ANFIS), é realizada uma introdução teórica sobre as redes neuronais artificiais (ANN) e a lógica difusa. Isto porque, o ANFIS resulta da combinação destes dois algoritmos, tornando-o por natureza, um sistema híbrido.

As ANN representam um paradigma conexionista do processamento da informação, onde o processo cognitivo é associado ao comportamento de um computador, sendo assim um ramo muito importante da inteligência computacional. Uma ANN corresponde então a um processo massivamente paralelo de efetuar cálculo numérico.

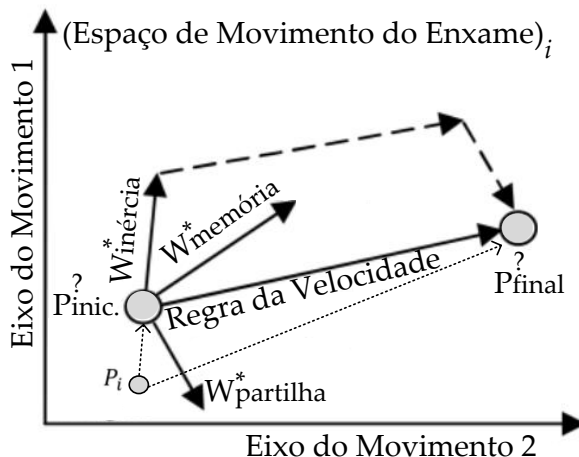


Figura 3.2 - Regra de movimento das partículas no método DEEPSO.

Como elemento base de uma ANN, tem-se o “neurónio”, que é uma unidade de processamento elementar. A ideia do “neurónio” como unidade computacional, tem por base o funcionamento dos neurónios do sistema nervoso humano [106].

Em 1943, através de Mac-Culloch e Pitts surgiu um modelo básico de um neurónio, que era, ao mesmo tempo, simples e poderoso. As suas pesquisas foram fundamentadas e suportadas em 5 premissas básicas [107]:

- A atividade de um neurónio é um processo de tudo-ou-nada;
- Um número de sinapses, maior que um, necessita de ser excitado, dentro de um período estabelecido anteriormente para o neurónio ser excitado e disparar;
- O único atraso significativo dentro do sistema nervoso é o atraso sináptico;
- A atividade de qualquer sinapse inibitória impede a excitação do neurónio naquele momento;
- A estrutura de interconexão da rede não muda com o tempo.

Estas pesquisas efetuadas em 1943 foram muito importantes, devido ao facto de serem as primeiras em que o cérebro foi tratado como um “organismo computacional”. Segundo [31] e [108], as ANN apresentam várias vantagens, isto porque se baseiam na estrutura do sistema nervoso humano, onde se efetuam múltiplas tarefas em tempo útil para um volume elevado de dados. Destacam-se as seguintes vantagens:

- Aprendizagem, onde se fornece os dados à entrada do sistema, e através de um processo de treino dará uma resposta na saída;
- As redes neuronais constroem a sua própria representação de informação no seu interior;
- As redes neuronais armazenam informação de forma redundante. Se a informação estiver destruída, ou mesmo se a informação de entrada não estiver completa, as redes neuronais podem mesmo assim dar uma resposta coerente;
- Flexibilidade, porque uma NN consegue adaptar-se à medida que são introduzidas novas informações;
- As NN, como são uma estrutura paralela, conseguem realizar tarefas complexas num curto espaço de tempo;
- Não Linearidade, o que permite uma modelação não linear.

Tendo um sistema de multicamadas, em que a interligação entre a entrada e a saída desejada é feita por uma ou mais camadas intermédias, também conhecidas como camadas escondidas, é possível ampliar o universo de soluções possíveis no qual estes sistemas operam [109].

De salientar que, a aplicação de um número elevado de neurónios na camada escondida faz com que o sistema crie um *overfitting*, ou afinação excessiva, no entanto, por outro lado, se o número de neurónios na camada escondida for demasiado reduzido, o sistema irá desencadear um *underfitting*, ou afinação deficiente.

O processo de *overfitting* tem como consequência a memorização dos padrões de treino e não o reconhecimento dos padrões através das características gerais das informações introduzidas na ANN. No processo de *underfitting*, os resultados não são os desejados, porque estes divergem durante o treino [109].

Quando se trata de qualidade de informação, dois aspetos que ditam essa qualidade que suscitam mais atenção são a imprecisão e a incerteza. Estas duas características possuem uma relação entre elas: quanto mais se aumenta a incerteza, mais se diminui a imprecisão e vice-versa [110]. Para se tratar da imprecisão, a teoria que é mais utilizada é a teoria dos conjuntos e, para se tratar da incerteza, a teoria que é mais utilizada é a teoria das probabilidades.

A teoria dos conjuntos nebulosos, ou difusos, foi desenvolvida a partir de 1965 por Lofti Zadeh [111], para tratar da qualidade da informação que, quando utilizada em um contexto lógico, é conhecida como a lógica nebulosa, ou lógica difusa, ou ainda como lógica “*fuzzy*”.

A lógica difusa é umas das tecnologias atuais bem-sucedidas para o desenvolvimento de sistemas de controlo de processos complexos como é descrito [112].

É uma ferramenta fortemente utilizada na indústria, no entanto, esta teoria também tem sido utilizada na área da previsão, como se mostrará no decorrer do presente trabalho. A lógica difusa tem por base um controlador lógico condicional que lida com dados de ordem ordinária.

Os resultados obtidos, inicialmente, não apresentam uma forma bem definida. Para tal, é utilizada uma combinação com outros métodos que permitam definir os resultados consoante a forma pretendida. Uma das combinações que pode ser efetuada é a combinação entre a lógica difusa e as ANN [31]. Assim como as ANN, um sistema lógico difuso é um modelo não linear de um vetor de entrada, com uma saída escalar, no entanto, os sistemas difusos podem manipular valores numéricos e o conhecimento linguístico.

Geralmente, um sistema lógico difuso contém quatro componentes: fuzificador, regras, máquina de inferência e desfuzificador. Na Figura 3.3, encontra-se representado um exemplo de uma máquina de inferência difusa assente em regras. O espaço difuso de entrada é constituído pelos antecedentes das regras difusas. O fuzificador converte uma variável de entrada nítida, ou seja, de valor numérico, numa representação difusa, em que as funções de pertença fornecem o grau de pertença da variável a um determinado atributo.

As regras difusas são do tipo “se”- premissa e “então”- conclusão, e podem ser derivadas de dados numéricos ou de linguística especializada. As máquinas de inferência de Mamdani e/ou Sugeno são dois dos principais tipos de mecanismos de inferência mais utilizados.

A máquina de inferência é responsável por processar os dados recebidos após a fuzificação e relacionar as entradas difusas com o conjunto de saídas, determinando, por fim, os resultados à saída de cada uma das regras difusas. O desfuzificador converte um conjunto difuso num valor numérico [113]. Esta conversão pode ser efetuada utilizando várias metodologias, nas quais se destacam o método bissetor da área, o método do primeiro máximo, o método da média dos máximos (MM) e o método da centróide (MC) [31].

Assim sendo, o ANFIS é uma combinação híbrida dos algoritmos das ANN e lógica difusa, contendo as vantagens dos dois métodos já descritos, isto é, conjuga a boa aprendizagem das ANN com a boa capacidade de interpretação linguística da lógica difusa, tornando por si só numa metodologia híbrida, reunindo os seguintes fatores [110]:

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

O ANFIS é capaz de trabalhar com uma grande quantidade de dados usando um requisito computacional menor. Além disso, o ANFIS incorpora as capacidades de autoaprendizagem, o que ajuda a auto ajustar os seus parâmetros [114]. A combinação das ANN com a lógica difusa permite aproveitar o que de melhor elas possuem, ou seja, as ANN 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 pertença [115]. A estrutura da rede ANFIS, que se encontra representada na Figura 3.4, é composta de cinco camadas, onde cada camada contém nós descritos pela função do nó O_i^j [116]:

O_i^j – representa a saída do nó i na camada j

Na **camada 1**, cada nó i é adaptativo com a função nó O_i^1 :

$$O_i^1 = \mu A_i(x), \quad i = 1,2 \quad (3.9)$$

ou,

$$O_i^1 = \mu B_{i-2}(x), \quad i = 1,2 \quad (3.10)$$

em que,

x ou y são as entradas do nó i

A_i ou B_{i-2} representam o rótulo linguístico associado a esse nó

As funções de pertença para A_i e B_{i-2} são geralmente descritas por funções, cuja forma de onda é semelhante à função Gaussiana, mas qualquer função contínua e variável podem ser usadas como funções de pertença. Ao longo deste trabalho, foram usadas funções de pertença do tipo triangular e piramidal.

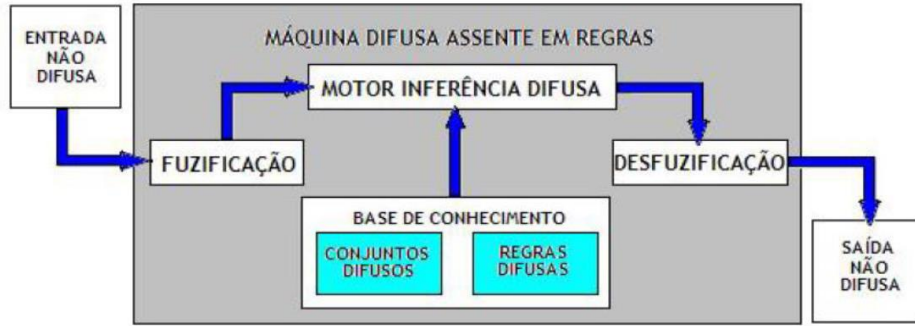


Figura 3.3 - Exemplo de uma máquina difusa assente em regras [31].

Estes tipos de funções podem ser definidos como:

$$\mu A_i(x) = \frac{1}{1 + \left| \frac{x - r_i}{p_i} \right|^{2q_i}} \quad (3.11)$$

onde,

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

Na **camada 2**, cada nó multiplica os sinais de entrada, que são as saídas da camada 1, e envia o produto como a saída:

$$\mu O_i^2 = w_i = \mu A_i(x) \times \mu B_i(y), \quad i = 1,2 \quad (3.12)$$

com isso, cada nó de saída nesta camada representa a força de disparo da regra w_i . Na **camada 3**, cada nó calcula a proporção entre a força de disparo da regra w_i e a soma das forças de disparo de todas as regras.

$$O_i^3 = \bar{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1,2 \quad (3.13)$$

em que, essas saídas são conhecidas como forças de disparo normalizadas. Na **camada 4**, é calculada a influência de cada regra i_m para a saída global em cada nó, que é dada pela multiplicação da saída da camada anterior (camada 3) com o conjunto de parâmetros $\{a_i, b_i, c_i\}$, onde os valores destes parâmetros são referidos como parâmetros consequentes:

$$O_i^4 = \bar{w}_i z_i = \bar{w}_i \times (a_i x + b_i y + c_i), \quad i = 1,2 \quad (3.14)$$

Na **camada 5** e última camada, é calculada a saída final da estrutura ANFIS como a soma de todos os sinais de entrada, que são as saídas da camada anterior:

$$O_i^5 = \sum_i \bar{w}_i z_i = \frac{\sum_i w_i z_i}{\sum_i w_i} \quad (3.15)$$

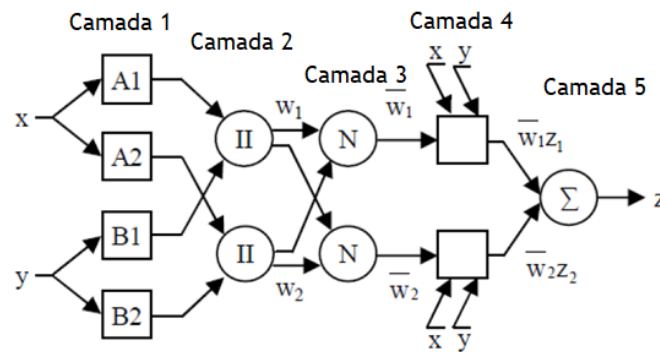


Figura 3.4 - Estrutura da cadeia ANFIS de 5 camadas [116].

Neste trabalho, o motor de inferência difusa utilizado tem como base a metodologia de Takagi-Sugeno, no entanto, o resultado da saída é determinístico. Ao utilizar as constantes ou funções lineares, os resultados obtidos são mapas parametrizados, portanto, é possível encontrar técnicas de otimização que vão ao encontro dos melhores parâmetros para ajustar os dados, resultando num número exato [117], [118].

3.1.4. Simulação de Monte Carlo (MCS)

A designação de MCS surge da cidade de Monte Carlo, no Mônaco, que é famosa por jogos de sorte e azar. Como o processo de simulação envolve a geração de variáveis aleatórias e exhibe comportamentos aleatórios, o autor da ferramenta, deu como nome a cidade onde se inspirou. O MCS é uma poderosa ferramenta de análise estatística e amplamente utilizada na engenharia e não só [119].

As metodologias baseadas em MCS são normalmente utilizadas para modelar a variabilidade inerente em sistemas dos quais uma expressão analítica de forma fechada não pode ser obtida ou é complexa [120].

Foi inicialmente usado para resolver problemas de difusão de neutrões no trabalho de bombas atômicas no *Alamos Scientific Laboratory*, em 1944. O MCS foi aplicado em diversos problemas, desde a simulação de fenômenos físicos complexos, como colisões de átomos, até à simulação de fluxo de tráfego.

O MCS também é adequado para resolver problemas complexos de engenharia, porque é capaz de lidar com um grande número de variáveis aleatórias, com vários tipos de distribuição, séries temporais e modelos de engenharia fortemente não-lineares [119].

Em sistemas de energia, o MCS tem sido utilizado numa ampla gama de aplicações, quando existe incerteza. Uma das aplicações tradicionais do MCS tem sido a avaliação da fiabilidade e segurança, onde se considera que o valor médio dos índices de fiabilidade do sistema não reflete a fiabilidade vista pelo cliente, devido à inerente variabilidade desses índices.

Outra aplicação do MCS está relacionado com os estudos sobre a incerteza na carga, os efeitos da produção eólica e outras fontes renováveis e ainda a probabilidade de interrupções, demonstram claramente que o MCS captura não apenas incertezas devido às interrupções e falhas dos componentes do sistema, mas também a variabilidade da carga e da produção de energia renovável, apresentando assim uma avaliação mais precisa e completa nestes estudos [120].

Ao longo do presente trabalho de dissertação, o MCS foi usado para a análise dos resultados obtidos pela ferramenta de num intervalo de valores onde a previsão resultante se possa inserir. Assim, o resultado final obtido adquire contornos probabilísticos já que os resultados expectáveis poderão ser analisados de uma forma mais realista.

Para o efeito, o modelo de MCS utilizado baseia-se no algoritmo de amostras com controlo de variável, pois, com este controlo de variáveis, o modelo corre em torno de valores em que os resultados não divergem para valores que não correspondem aos valores reais (considerando o comportamento dos resultados históricos).

Os possíveis dados de entrada $X = (X_1, X_2, \dots, X_n)$ são os dados amostrados de acordo com as suas distribuições. Em seguida, os valores da variável de saída Y são calculados através da função de desempenho $Y = g(X)$ nas amostras das variáveis de entrada. Depois das experiências nesse sentido, um conjunto de amostras de variáveis de saída Y é gerado para a análise estatística que estimará as características da variável de saída Y .

A estrutura deste modelo encontra-se representada na Figura 3.5, na qual através da sua análise, é possível reparar que são necessárias três etapas no seu processo de simulação:

- **Etapla 1** - amostragem em variáveis de entrada aleatórias X ;
- **Etapla 2** - avaliação da saída do modelo Y ;
- **Etapla 3** - análise estatística na saída do modelo [119].

Supondo que N amostras de variáveis aleatórias são geradas, então todas as amostras de variáveis aleatórias constituem um conjunto de entradas $x_i = (x_{i1}, x_{i2}, \dots, x_{iN})$, $i = 1, 2, \dots, N$, para o modelo $Y = g(X)$. Resolvendo o problema N vezes deterministicamente, produz-se N pontos de amostra da saída Y .

$$y_i = g(x_i) \quad , \quad i = 1, 2, \dots, N \quad (3.16)$$

Depois de as amostras da saída serem obtidas, a análise estatística pode ser realizada para estimar as características da saída Y , como a média, a variância, a fiabilidade, a probabilidade de falha, a PDF (função de distribuição de probabilidade) e a CDF (função de distribuição acumulada).

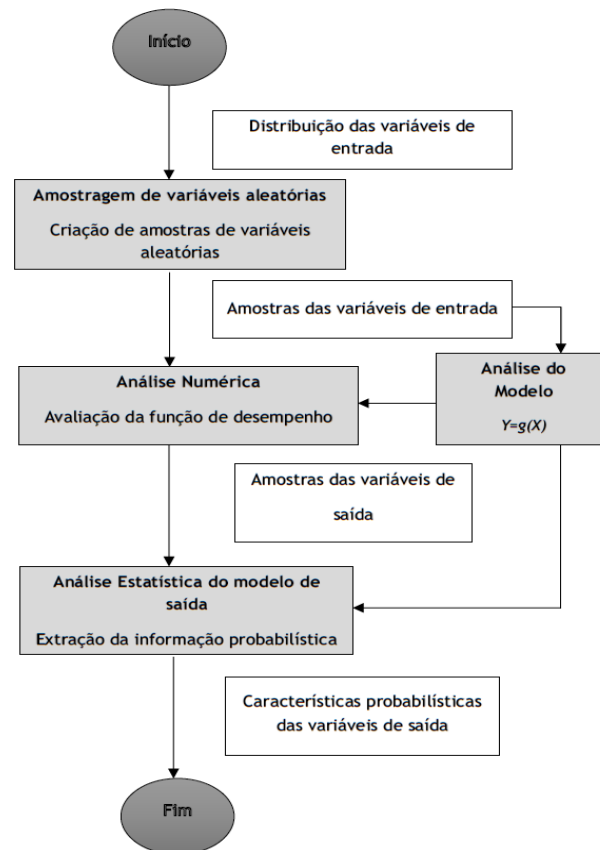


Figura 3.5 - Fluxograma do método da Simulação de Monte Carlo [119].

As funções associadas a estas características estão representadas nas seguintes equações:

- Média:

$$\bar{Y} = \frac{1}{N} \times \sum_{i=1}^N y_i \quad (3.17)$$

- Variância:

$$\sigma_Y^2 = \frac{1}{N-1} \times \sum_{i=1}^N (y_i - \bar{Y})^2 \quad (3.18)$$

Se a falha é definida pelo evento $g \leq 0$, a probabilidade falha é dada por:

$$p_f = P\{g \leq 0\} = \int \dots \int_{g(x) \leq 0} f_{x_1, x_2, \dots, x_n}(x_1, x_2, \dots, x_n) dx_1 dx_2 \dots dx_n = \int_{g(x) \leq 0} f_x(x) dx \quad (3.19)$$

Onde a expressão pode ser reduzida a:

$$p_f = \int_{-\infty}^{+\infty} I(x) f_x(x) dx \quad (3.20)$$

se,

$$I(x) = \begin{cases} 1 & \text{se } g(x) \leq 0 \\ 0 & \text{se } g(x) > 0 \end{cases} \quad (3.21)$$

Como o integral da equação anterior é simplesmente o valor esperado (média) de $I(x)$, a probabilidade de falhas pode então ser dada por:

$$p_f = \bar{Y} = \frac{1}{N} \times \sum_{i=1}^N I(x_i) = \frac{N_f}{N} \quad (3.22)$$

em que,

N_f – número de amostras que tem a função de desempenho menor ou igual a 0.

Com isto, a função de distribuição acumulada é dada por:

$$F_y(y) = P(g \leq y) = \frac{1}{N} \times \sum_{i=1}^N I'(y_i) \quad (3.23)$$

onde a função do indicador é definida por:

$$I'(x) = \begin{cases} 1 & \text{se } g(x) \leq y \\ 0 & \text{se } g(x) > y \end{cases} \quad (3.24)$$

A função de distribuição de probabilidades pode ser obtida pela diferenciação numérica da função de distribuição acumulada $F_y(y)$.

3.2. Nova Metodologia Híbrida Proposta

Ao longo deste trabalho foi desenvolvida uma metodologia para previsão PME do mercado Espanhol do ano de 2002 e dos PME do ano de 2006 para o mercado PJM. A metodologia assenta na combinação das WT em combinação com os métodos DEEPSO e ANFIS, contando ainda com a ferramenta MCS. A metodologia usada encontra-se representada através do fluxograma descrito na Figura 3.6, atribuindo-se de agora em diante a abreviatura PHFM, oriunda da denominação anglo-saxônica *Probabilistic Hybrid Forecasting Model*.

As WT são usadas para decompor as séries de dados em novas séries que apresentam um melhor comportamento. O DEEPSO permite melhorar a performance do ANFIS através do ajuste das suas funções de pertinência de modo a reduzir o erro de previsão.

Com as suas capacidades auto adaptativas e o seu conceito de evolução diferencial do DEEPSO, pode fazer a diferença na convergência do ANFIS. As inversas das WT são utilizadas para recompor os sinais de saída, obtendo-se assim os resultados finais para os PME. Por fim, o MCS permite que se possam visualizar os resultados finais dentro de um intervalo de valores, onde estes mesmos resultados podem estar. Em suma, o algoritmo desta metodologia pode ser descrito pelos seguintes passos:

- **Passo 1:** Iniciar o modelo PHFM com um conjunto histórico dos preços de eletricidade, considerando a escala de tempo de previsão (168 horas para cada conjunto escolhido);

- **Passo 2:** Selecionar o conjunto de dados históricos que será decomposto pelas WT;
- **Passo 3:** Selecionar os parâmetros do DEEPSO (resumidos na Tabela 3.1);
- **Passo 4:** Selecionar o conjunto de semanas que serão usadas no DEEPSO para obter os recursos necessários para ajuste e aumentar o desempenho do modelo ANFIS;
- **Passo 5:** Selecionar os parâmetros do modelo ANFIS (resumidos na Tabela 3.1);
- **Passo 6:** Selecionar as entradas de cada iteração do método ANFIS;
- **Passo 7:** Calcular os erros de previsão com os diferentes critérios de medição de erro para validar o modelo de PHFM proposto;
 - **Passo 7.1:** Se a meta de erro de critério não for atingida, passe para o passo 4;
 - **Passo 7.2:** Se a meta de erro de critério não for encontrada na etapa 7, passe para o passo 4 para encontrar outro conjunto de soluções;
 - **Passo 7.3:** Se os melhores resultados de previsão forem encontrados ou o número de iterações máximo for atingido, guarde o último registro mais recente e vá para o passo 8;
- **Passo 8:** Usar a inversa da transformada WT para incluir os dados previamente filtrados na saída prevista;
- **Passo 9:** Obter o resultado da análise usando o MCS;
- **Passo 10:** Imprimir os resultados da previsão e terminar a previsão.

Esta metodologia foi validada e comparada com outras metodologias criadas para os PME do Mercado Espanhol e para o mercado PJM. A previsão a curto-prazo reside na previsão da semana seguinte (168h), tendo como dados de entrada os dados históricos dos PME das seis semanas anteriores.

Tabela 3.1 - Parâmetros utilizados ao longo deste trabalho para a WT, DEEPSO e ANFIS.

	Parâmetros	Tipo ou tamanho
WT	WT direção	"row"
	Nível de (Re)Decomposição	3
	Função-mãe WT	"Db3", "Db4"
	Análise da ferramenta de ruído	"sqtwolog", "minimaxi"
	o reescalonamento do limiar multiplicativo	"one", "sln", "mIn"
DEEPSO	Probabilidade de informação partilhada	0,1
	Peso inicial de inércia	0,01-0,9
	Peso final de inércia	0,01-0,1
	Coefficiente da aprendizagem do sistema	1-4
	Coefficiente da cooperação do sistema	1-4
	Velocidade inicial	1-4
	Tamanho da População	168
	Ponto mínimo da nova posição	Set of Min. inputs
	Ponto máximo da nova posição	Set of Max. inputs
	Parâmetro Cognitivo	0.1
	Número de iterações	50-1000
ANFIS	Número de funções de pertença	2-15
	Número de iterações por simulação	2-50
	Tipo de função de Pertença	"pimf", "trimf"

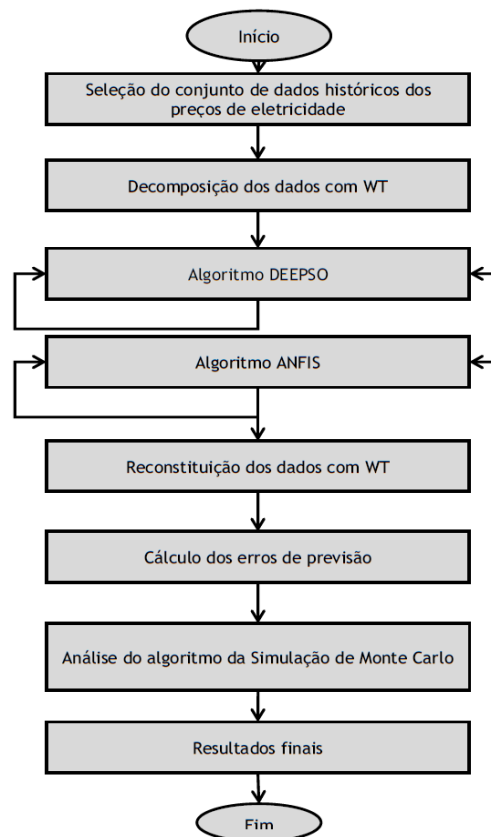


Figura 3.6 - Fluxograma da metodologia proposta (PHFM).

3.3. Ferramentas Matemáticas de Quantificação do Erro

Para comparar a metodologia proposta com outras metodologias publicadas e validadas pela comunidade científica internacional, realizadas para prever os PME de curto-prazo, o *mean absolute percentage error* (MAPE), é normalmente utilizado. O critério MAPE pode ser expresso pela seguinte equação [114], [121]:

$$MAPE = \frac{100}{N} \times \sum_{n=1}^N \frac{|\hat{p}_n - p_n|}{\bar{p}} \quad (3.25)$$

$$\bar{p} = \frac{1}{N} \times \sum_{i=1}^N p_n \quad (3.26)$$

onde, \hat{p}_n é o valor previsto para a hora n , p_n é o valor real para a hora n , \bar{p}_n é o valor médio para o horizonte temporal de previsão, e N é o espaço da amostra. Seguindo a mesma ideia do critério anterior, as incertezas das metodologias podem ser avaliadas a partir do erro da variância, dada por:

$$\sigma_{e,n}^2 = \frac{1}{N} \times \sum_{n=1}^N \left(\frac{|\hat{p}_n - p_n|}{\bar{p}} - e_n \right)^2 \quad (3.27)$$

$$e_n = \frac{1}{N} \times \sum_{i=1}^N \frac{|\hat{p}_n - p_n|}{\bar{p}} \quad (3.28)$$

Capítulo 4

Caso de Estudo e Resultados Obtidos

Neste capítulo vão ser apresentados os resultados para a previsão dos PME para as 168h seguintes com um passo de 1h. Para tal, foram consideradas as 6 semanas anteriores como dados históricos. Foram previstas as quatro estações do ano para o ano 2002 do mercado espanhol e para o inverno do ano 2006 para o PJM.

Para o efeito, e devido ao processo levado a cabo pelas outras metodologias que servirão de comparação, foram somente usados os dados históricos dos PME, não tendo sido considerados os dados exógenos, como a carga, produção renovável, demanda, entre outros, de forma a obter uma comparação justa e livre das potencialidades da metodologia proposta.

As Figuras 4.1 - 4.4 representam os resultados das diferentes estações para o ano de 2002 do mercado espanhol. Na Figura 4.5, encontra-se representada a previsão para o Inverno, para o ano 2006 do mercado PJM.

Como se pode verificar pela análise das figuras acima expostas, a metodologia proposta apresenta bons resultados, visto que o comportamento da previsão ao longo de todas as semanas é relativamente adequado e acompanhado em grande parte o comportamento do perfil dos PME reais para a semana em análise.

É de salientar o bom comportamento da metodologia perante o fenómeno dos preços de pico (*price spikes*), o que permitiu que os resultados finais fossem consideravelmente melhores. No entanto, o estudo deste fenómeno não foi objeto de análise no presente trabalho.

Na Tabela 4.1, encontra-se um resumo dos resultados, para cada um dos mercados em análise, onde são apresentados os MAPE's e as variâncias para as diferentes estações do ano. Além disso, nas Tabelas 4.2 e 4.3, encontram-se as comparações dos resultados obtidos dos MAPE's e variâncias, respetivamente, entre a metodologia proposta, HPFM, e outras metodologias existentes para o mercado espanhol.

Na Tabela 4.4, encontram-se as comparações dos resultados obtidos dos MAPE's e variâncias entre a metodologia proposta e outras metodologias existentes para o mercado PJM.

Esta análise foi efetuada para que se possa verificar se a metodologia proposta se encontra dentro dos valores esperados dos erros e despistando eventuais afinações adicionais para a convergência dos resultados obtidos.




Figura 4.1 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação da Primavera. Valores reais (azul), valores previstos (preto).




Figura 4.2 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação do Verão. Valores reais (azul), valores previstos (preto).




Figura 4.3 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação do Outono. Valores reais (azul), valores previstos (preto).




Figura 4.4 - Resultados dos preços de eletricidade do mercado espanhol no ano 2002 para a estação do Inverno. Valores reais (azul), valores previstos (preto).




Figura 4.5 - Resultados dos preços de eletricidade do PJM no ano 2002 para a estação do Inverno. Valores reais (azul), valores previstos (preto).

Tabela 4.1 - Valores de MAPE e variância para cada um dos casos anteriormente mostrados

		MAPE	Variância
Mercado Espanhol	Primavera	4,13	0,0016
	Verão	5,21	0,0021
	Outono	4,77	0,0010
	Inverno	4,48	0,0011
Mercado PJM	Inverno	5,88	0,0026

Tabela 4.2 - Comparação dos valores de MAPE do Mercado Espanhol do ano 2002

[73], [76], [121]	Primavera	Verão	Outono	Inverno	Média
NN (2007)	5,36	11,40	13,65	5,23	8,91
HIS (2009)	6,06	7,07	7,47	7,30	6,97
MICNN (2012)	4,28	6,47	5,27	4,51	5,13
EPA (2011)	4,10	6,39	6,40	3,59	5,12
HPM (2016)	3,70	6,16	6,28	3,55	4,92
HEA (2014)	3,33	5,38	4,97	4,29	4,18
PHFM (2018)	4,13	5,21	4,77	4,48	4,65

Tabela 4.3 - Comparação dos valores de variância do Mercado Espanhol do ano 2002

[73], [76], [121]	Primavera	Verão	Outono	Inverno	Média
NN (2007)	0,0018	0,0109	0,0136	0,0017	0,0070
HIS (2009)	0,0049	0,0029	0,0031	0,0034	0,0036
MICNN (2012)	0,0014	0,0033	0,0022	0,0014	0,0021
EPA (2011)	0,0016	0,0048	0,0032	0,0012	0,0027
HPM (2016)	0,0016	0,0037	0,0032	0,0008	0,0019
HEA (2014)	0,0011	0,0026	0,0014	0,0008	0,0015
PHFM (2018)	0,0016	0,0021	0,0010	0,0011	0,0014

Tabela 4.4 - Comparação dos valores de MAPE e variância do PJM do ano 2002 para o Inverno

[73], [76], [121]	MAPE	Variância
HIS (2009)	7,30	0,0031
EPA (2011)	6,40	0,0032
HEA (2014)	3,08	0,0017
PHFM (2018)	5,88	0,0026

A metodologia proposta (PHFM) apresenta um valor médio de MAPE e de variância, para a previsão dos valores dos PME do mercado espanhol, de 4,65% e 0,0014, respetivamente. A metodologia demora, em média, entre 1min e 1min e 30 segundos a prever qualquer uma das estações do ano, depois de ter sido encontrado o melhor resultado vindo do DEEPSO. As simulações realizadas foram efetuadas utilizando um computador pessoal com um sistema CPU Intel Core i3-2310M, 2,10GHz e 4,00 GB de RAM, num ambiente de Windows 10 e usando o MATLAB R2016b.

Capítulo 5

Conclusões e Contribuições

Neste trabalho foi criada uma nova metodologia híbrida, denominada HPFM, para previsão dos PME a curto prazo (168h). Como mencionado no Capítulo 3, esta metodologia assenta na combinação entre WT, que suaviza a volatilidade dos dados de entrada, com o DEEPSO e o ANFIS, tendo por fim uma análise probabilística dos valores previstos, dada pela introdução da análise realizada através da ferramenta de MCS.

Para a validação da metodologia proposta, foram usados dados utilizados por outras metodologias já validadas e publicadas na comunidade científica. Os resultados da metodologia proposta foram comparados com os resultados de outras metodologias para que a avaliação fosse justa e livre das potencialidades da metodologia HPFM. Para tal, foram usados dois critérios para a avaliação e comparação dos resultados (MAPE e variância).

Através da análise das figuras e das tabelas apresentadas na análise dos resultados obtidos, é possível verificar que a metodologia demonstra resultados aceitáveis comparativamente às outras metodologias que suportam a comparação realizada. São de salientar os resultados obtidos nas estações do Outono e do Verão, que apresentam MAPE's de 4,77% e 5,21%, respetivamente, pois foram resultados que superaram todos os outros valores apresentados. Já os valores da variância são em todo semelhante aos reportados por outras metodologias, o que traduz a precisão da metodologia proposta. Na tabela 5.1 encontra-se um resumo dos resultados obtidos por esta metodologia.

Uma das contribuições apresentadas relativamente à metodologia HWDA, apresentada em 2016, é que a metodologia PHFM apresenta um novo método na sua estrutura, o MCS, que é capaz de dar uma visão probabilística aos resultados finais, através da análise dos resultados obtidos e onde os mesmos se poderão encontrar, em relação ao comportamento dos dados históricos. Para além disto, foi conseguido o desenvolvimento de uma técnica capaz de otimizar os resultados e a convergência dos resultados vindos do DEEPSO, antes de estes serem introduzidos na cadeia ANFIS.

Tabela 5.1 - Resumo dos resultados obtidos pela metodologia nos mercados testados

PHFM	MAPE	Variância
Mercado Espanhol	4,65	0,0014
Mercado PJM	5,88	0,0026

Por fim, outro avanço apresentado por esta nova metodologia, é que esta apresenta uma interação entre o utilizador e a ferramenta desenvolvida, ou seja, o utilizador pode escolher qual a semana que quer prever, assim como os parâmetros e os dados de entrada da metodologia proposta.

Como referido anteriormente, a metodologia demora, em média, entre 1 minuto e 1 minuto e 30 segundos, em média, para realizara a previsão em qualquer uma das estações do ano. No entanto, é de salientar que tal acontece depois de ter sido encontrado o melhor resultado vindo do DEEPSO. Para a modelação da metodologia proposta foi utilizado um computador pessoal com um sistema CPU Intel Core i3-2310M, 2,10GHz e 4,00 GB de RAM, num ambiente de Windows 10 e usando o MATLAB R2016b.

5.1. Trabalhos Futuros

Um dos trabalhos futuros que podem ser implementados para melhoria da metodologia proposta passa pela introdução de um método que seja capaz de correlacionar os dados históricos dos PME com variáveis exógenas, tais como as produções renováveis e a carga. Com este avanço, a metodologia irá certamente responder de uma forma melhor aos fenómenos dos picos de preço, uma vez que uma das causas desta incerteza nos preços se deve essencialmente à presença das renováveis no despacho ao invés das centrais térmicas convencionais. Uma outra abordagem para trabalho futuro passa essencialmente pela maior automatização do processo de previsão e da melhoria do tempo computacional necessário para otimização dos dados necessários para a previsão.

5.2. Contribuições Científicas

No âmbito deste trabalho foi possível realizar uma publicação, atualmente sob avaliação, cuja ilustração se encontra na secção dos anexos do presente trabalho:

- Vasco M. A. Campos, G. J. Osório, M. Shafie-khah, J. P. S. Catalão, "Hybrid Probabilistic Forecasting Model for Electricity Market Prices in Short-Term", *in Proc. Twentieth International Middle East Power Systems Conference (MEPCON)*, Universidade do Cairo, Cairo, Egito, 18-20 Dezembro, 2018 (em revisão)

Referências

- [1] F. Maciel Barbosa, *Análise de Fiabilidade da Rede de Transporte e Distribuição*. Portugal, 2013.
- [2] F. Maciel Barbosa, *Estabilidade de Sistemas Elétricos de Energia*. Portugal, 2017.
- [3] F. Maciel Barbosa, *Sobretensões de Manobra*. Portugal, 2017.
- [4] A. Figueiredo e P. Oliveira, *A Regulação da Energia em Portugal 2007-2017*. Portugal: Entidade Reguladora dos Serviços Energéticos, ERSE, 2016.
- [5] A. Leite Garcia, J. J. E. Santana, M. J. Resende, e P. Verdelho, *Análise Técnico-Económica do Sistema Elétrico*. Portugal, 2016.
- [6] J. P. S. Catalão, *Electric Power Systems- Advanced Forecasting Techniques and Optimal Generation Scheduling*. CRC Press, 2012.
- [7] J. T. Saraiva, J. L. Pereira da Silva, e M. T. Ponce de Leão, *Mercados de Electricidade - Regulação e Tarifação de Uso das Redes*. FEUP Edições, 2002.
- [8] P. M. Martins Monteiro, *Desenvolvimento de um Simulador do Mercado de Electricidade do MIBEL, Recorrendo a Funcionalidades do MATLAB - Propostas Simples*. Faculdade de Engenharia da Universidade do Porto, FEUP, Porto, Portugal: Tese de Mestrado, 2015.
- [9] «PRE - Produção em Regime Especial». Disponível em: <http://www.erse.pt/pt/desempenhoambiental/prodregesp/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [10] «Liberalização do Setor». Disponível em: <http://www.erse.pt/pt/electricidade/liberalizacaodosector/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [11] Net2U, «Mibel», 27-Fev-2007. Disponível em: <http://www.mibel.com/index.php?mod=pags&mem=detalle&relmenu=9&relcategoria=1026&idpag=67>. [Acedido: 20-Jun-2018].
- [12] «REN - Perfil da Empresa». Disponível em: https://www.ren.pt/pt-PT/quem_somos/perfil_da_empresa/. [Acedido: 20-Jun-2018].
- [13] «Red Eléctrica de España | Red Eléctrica en 2 minutos». [Em linha]. Disponível em: <http://www.ree.es/es/conocenos/ree-en-2-minutos>. [Acedido: 20-Jun-2018].
- [14] «Mibel - Electricidade», 27-Fev-2007. Disponível em: <http://www.mibel.com/index.php?mod=pags&mem=detalle&relmenu=40&relcategoria=101&id=28>. [Acedido: 20-Jun-2018].
- [15] «Portal ERSE - A ERSE». Disponível em: <http://www.erse.pt/pt/aerse/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [16] S. I.-C. N. Energia, «Quiénes Somos - Comisión Nacional de Energía».
- [17] L. Braga da Cruz, *A liberalização do sector da energia, o MIBEL e o OMIP*. OMIP, 2008.
- [18] «Mercado Diário».. Disponível em: <http://www.erse.pt/pt/supervisaodemercados/mercadodeelectricidade/mercadodiario/Paginas/default.aspx>. [Acedido: 20-Jun-2018].

- [19] «Mercado Diário e Intradiário | OMIE». Disponível em: <http://www.omel.es/pt/principal/mercados-e-produtos/mercado-da-electricidade/os-nossos-mercados-de-eletricidade/diario-e-i>. [Acedido: 20-Jun-2018].
- [20] « Mercado a Prazo». Disponível em: <http://www.erse.pt/pt/supervisaodemercados/mercadodeelectricidade/mercadoaprazo/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [21] « Mercado de Serviços de Sistema». Disponível em: <http://www.erse.pt/pt/supervisaodemercados/mercadodeelectricidade/sistema/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [22] «Portal ERSE - Contratação». Disponível em: <http://www.erse.pt/pt/supervisaodemercados/mercadodeelectricidade/contratacao/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [23] « Mercado Retalhista de Eletricidade». Disponível em: <http://www.erse.pt/pt/supervisaodemercados/MercadoRetalhista/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [24] «Portal ERSE - Mercado Retalhista de Gás Natural». Disponível em: <http://www.erse.pt/pt/supervisaodemercados/mrgn/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [25] «História e definições do protocolo de Quioto». Disponível em: <https://www.portal-energia.com/historia-e-definicoes-do-protocolo-quioto/>. [Acedido: 20-Jun-2018].
- [26] «Vantagens e desvantagens do protocolo de Quioto». [Em linha]. Disponível em: <https://www.portal-energia.com/protocolo-de-quioto/>. [Acedido: 20-Jun-2018].
- [27] Anonymous, «Energia - EUROPA», *União Européia*, 16-Jun-2016. [Em linha]. Disponível em: https://europa.eu/european-union/topics/energy_pt. [Acedido: 20-Jun-2018].
- [28] R. Garcia, «Cimeira do clima de Paris. Cimeira de Paris aprova acordo histórico para conter o aquecimento global», *PÚBLICO*. Disponível em: <https://www.publico.pt/2015/12/12/ecosfera/noticia/acordo-climatico-de-paris-foi-aprovado-1717259>. [Acedido: 20-Jun-2018].
- [29] Anonymous, «Paris Agreement», *Climate Action - European Commission*, 23-Nov-2016. Disponível em: https://ec.europa.eu/clima/policies/international/negotiations/paris_en. [Acedido: 20-Jun-2018].
- [30] J. N. D. Lopes Gonçalves, *Metodologia Híbrida de Previsão de Preços de Eletricidade e Potência Eólica*, Tese de Mestrado. Faculdade de Engenharia da Universidade do Porto, FEUP, Porto, Portugal, 2016.
- [31] G. J. Osório da Silva, *Nova Metodologia Híbrida Para a Previsão dos Preços da Energia Elétrica e da Potência Eólica a Curto Prazo*, Dissertação de Mestrado. Covilhã, Portugal, 2011.
- [32] «Portal ERSE - PRE - Produção em Regime Especial- Evolução». Disponível em: <http://www.erse.pt/pt/desempenhoambiental/prodregesp/Paginas/default.aspx>. [Acedido: 20-Jun-2018].
- [33] «Glossary:EU enlargements - Statistics Explained». Disponível em: http://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:EU_enlargements. [Acedido: 20-Jun-2018].
- [34] «Statistics», *WindEurope*. Disponível em: <https://windeurope.org/about-wind/statistics/>. [Acedido: 20-Jun-2018].
- [35] M. Shahidehpour, H. Yamin, e Z. Li, *Market Operations in Electric Power Systems*. New York, USA: John Wiley & Sons, Inc., 2002.
- [36] W.-Y. Chang, «A Literature Review of Wind Forecasting Methods», *J. Power Energy Eng.*, vol. 02, n. 04, pp. 161-168, 2014.

- [37] S. N. Chandramowli e F. A. Felder, «Impact of climate change on electricity systems and markets - A review of models and forecasts», *Sustain. Energy Technol. Assess.*, vol. 5, pp. 62-74, Mar. 2014.
- [38] Z. Zhao, C. Wang, M. Nokleby, e C. J. Miller, «Improving short-term electricity price forecasting using day-ahead LMP with ARIMA models», 2017, pp. 1-5.
- [39] T. Bollerslev, «Generalized autoregressive conditional heteroskedasticity», *J. Econom.*, vol. 31, n. 3, pp. 307-327, Abr. 1986.
- [40] A. J. Conejo, M. A. Plazas, R. Espinola, e A. B. Molina, «Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models», *IEEE Trans. Power Syst.*, vol. 20, n. 2, pp. 1035-1042, Mai. 2005.
- [41] Z. J. Hou, P. V. Etingov, Y. V. Makarov, e N. A. Samaan, «Uncertainty Reduction in Power Generation Forecast Using Coupled Wavelet-ARIMA», p. 5.
- [42] T. Niknam, S. Sharifinia, e R. Azizipanah-Abarghooee, «A new enhanced bat-inspired algorithm for finding linear supply function equilibrium of GENCOs in the competitive electricity market», *Energy Convers. Manag.*, vol. 76, pp. 1015-1028, Dez. 2013.
- [43] X. R. Li, C. W. Yu, S. Y. Ren, C. H. Chiu, e K. Meng, «Day-ahead electricity price forecasting based on panel cointegration and particle filter», *Electr. Power Syst. Res.*, vol. 95, pp. 66-76, Fev. 2013.
- [44] J. P. L. Coimbra, «Previsão Curto Prazo de Preços no Mercado de Electricidade». Versão provisória de Dissertação, Faculdade de Engenharia da Universidade do Porto, FEUP, 2010.
- [45] J. P. S. Catalão, H. M. I. Pousinho, e V. M. F. Mendes, «Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach», *Energy Convers. Manag.*, vol. 52, n. 2, pp. 1061-1065, Fev. 2011.
- [46] W.-M. Lin, H.-J. Gow, e M.-T. Tsai, «Electricity price forecasting using Enhanced Probability Neural Network», *Energy Convers. Manag.*, vol. 51, n. 12, pp. 2707-2714, Dez. 2010.
- [47] H. Shayeghi e A. Ghasemi, «Day-ahead electricity prices forecasting by a modified CGSA technique and hybrid WT in LSSVM based scheme», *Energy Convers. Manag.*, vol. 74, pp. 482-491, Out. 2013.
- [48] Y. Ren, P. N. Suganthan, e N. Srikanth, «Ensemble methods for wind and solar power forecasting—A state-of-the-art review», *Renew. Sustain. Energy Rev.*, vol. 50, pp. 82-91, Out. 2015.
- [49] R. Weron, «Electricity price forecasting: A review of the state-of-the-art with a look into the future», *Int. J. Forecast.*, vol. 30, n. 4, pp. 1030-1081, Out. 2014.
- [50] J. Contreras, R. Espinola, F. J. Nogales, e A. J. Conejo, «ARIMA Models to Predict Next-Day Electricity Prices», *IEEE Power Eng. Rev.*, vol. 22, n. 9, pp. 57-57, Set. 2002.
- [51] N. Chaâbane, «A hybrid ARFIMA and neural network model for electricity price prediction», *Int. J. Electr. Power Energy Syst.*, vol. 55, pp. 187-194, Fev. 2014.
- [52] H. Taherian, I. Nazer Kakhki, e M. R. Aghaebrahimi, «Application of an improved SVR based Bat algorithm for short-term price forecasting in the Iranian Pay-as-Bid electricity market», 2013, pp. 161-166.
- [53] H. Shayeghi e A. Ghasemi, «Day-ahead electricity prices forecasting by a modified CGSA technique and hybrid WT in LSSVM based scheme», *Energy Convers. Manag.*, vol. 74, pp. 482-491, Out. 2013.
- [54] M. K. Kim, «Short-term price forecasting of Nordic power market by combination Levenberg-Marquardt and Cuckoo search algorithms», *IET Gener. Transm. Distrib.*, vol. 9, n. 13, pp. 1553-1563, Out. 2015.
- [55] F. Davo, M. T. Vespucci, A. Gelmini, P. Grisi, e D. Ronzio, «Forecasting Italian electricity market prices using a Neural Network and a Support Vector Regression», 2016, pp. 1-6.

- [56] F. Martinez Alvarez, A. Troncoso, J. C. Riquelme, e J. S. Aguilar Ruiz, «Energy Time Series Forecasting Based on Pattern Sequence Similarity», *IEEE Trans. Knowl. Data Eng.*, vol. 23, n. 8, pp. 1230-1243, Ago. 2011.
- [57] J. Zhang, Z. Tan, e S. Yang, «Day-ahead electricity price forecasting by a new hybrid method», *Comput. Ind. Eng.*, vol. 63, n. 3, pp. 695-701, Nov. 2012.
- [58] H. C. Wu, S. C. Chan, K. M. Tsui, e Y. Hou, «A New Recursive Dynamic Factor Analysis for Point and Interval Forecast of Electricity Price», *IEEE Trans. Power Syst.*, vol. 28, n. 3, pp. 2352-2365, Ago. 2013.
- [59] A. Ghasemi, H. Shayeghi, M. Moradzadeh, e M. Nooshyar, «A novel hybrid algorithm for electricity price and load forecasting in smart grids with demand-side management», *Appl. Energy*, vol. 177, pp. 40-59, Set. 2016.
- [60] S. Sharma e M. M. Tripathi, «Novel hybrid price forecasting model using wavelet transform, time series time delay neural network and zero phase filter in AEMC market», 2016, pp. 1-6.
- [61] X. Chen, Z. Y. Dong, K. Meng, Y. Xu, K. P. Wong, e H. W. Ngan, «Electricity Price Forecasting With Extreme Learning Machine and Bootstrapping», *IEEE Trans. Power Syst.*, vol. 27, n. 4, pp. 2055-2062, Nov. 2012.
- [62] P. Mandal, A. U. Haque, Julian Meng, R. Martinez, e A. K. Srivastava, «A hybrid intelligent algorithm for short-term energy price forecasting in the Ontario market», 2012, pp. 1-7.
- [63] N. A. Shrivastava e B. K. Panigrahi, «A hybrid wavelet-ELM based short term price forecasting for electricity markets», *Int. J. Electr. Power Energy Syst.*, vol. 55, pp. 41-50, Fev. 2014.
- [64] K. B. Sahay, «One hour ahead price forecast of Ontario electricity market by using ANN», 2015, pp. 1-6.
- [65] I. A. W. A. Razak, I. Z. Abidin, K. S. Yap, A. A. Z. Abidin, T. K. A. Rahman, e M. N. M. Nasir, «A novel hybrid method of LSSVM-GA with multiple stage optimization for electricity price forecasting», 2016, pp. 390-395.
- [66] W. Gao, V. Sarlak, M. R. Parsaei, e M. Ferdosi, «Combination of fuzzy based on a meta-heuristic algorithm to predict electricity price in an electricity markets», *Chem. Eng. Res. Des.*, vol. 131, pp. 333-345, Mar. 2018.
- [67] «PJM - Who We Are». Disponível em: <http://www.pjm.com/about-pjm/who-we-are.aspx>. [Acedido: 20-Jun-2018].
- [68] N. M. Pindoriya, S. N. Singh, e S. K. Singh, «An Adaptive Wavelet Neural Network-Based Energy Price Forecasting in Electricity Markets», *IEEE Trans. Power Syst.*, vol. 23, n. 3, pp. 1423-1432, Ago. 2008.
- [69] N. Amjady e F. Keynia, «Day-Ahead Price Forecasting of Electricity Markets by Mutual Information Technique and Cascaded Neuro-Evolutionary Algorithm», *IEEE Trans. Power Syst.*, vol. 24, n. 1, pp. 306-318, Fev. 2009.
- [70] F. Keynia, «A new feature selection algorithm and composite neural network for electricity price forecasting», *Eng. Appl. Artif. Intell.*, vol. 25, n. 8, pp. 1687-1697, Dez. 2012.
- [71] J. Zhang e Z. Tan, «Day-ahead electricity price forecasting using WT, CLSSVM and EGARCH model», *Int. J. Electr. Power Energy Syst.*, vol. 45, n. 1, pp. 362-368, Fev. 2013.
- [72] X. R. Li, C. W. Yu, S. Y. Ren, C. H. Chiu, e K. Meng, «Day-ahead electricity price forecasting based on panel cointegration and particle filter», *Electr. Power Syst. Res.*, vol. 95, pp. 66-76, Fev. 2013.
- [73] G. J. Osório, J. C. O. Matias, e J. P. S. Catalão, «Electricity prices forecasting by a hybrid evolutionary-adaptive methodology», *Energy Convers. Manag.*, vol. 80, pp. 363-373, Abr. 2014.

- [74] Z. Yang, L. Ce, e L. Lian, «Electricity price forecasting by a hybrid model, combining wavelet transform, ARMA and kernel-based extreme learning machine methods», *Appl. Energy*, vol. 190, pp. 291-305, Mar. 2017.
- [75] A. J. Conejo, M. A. Plazas, R. Espinola, e A. B. Molina, «Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models», *IEEE Trans. Power Syst.*, vol. 20, n. 2, pp. 1035-1042, Mai. 2005.
- [76] J. P. S. Catalão, S. J. P. S. Mariano, V. M. F. Mendes, e L. A. F. M. Ferreira, «Short-term electricity prices forecasting in a competitive market: A neural network approach», *Electr. Power Syst. Res.*, vol. 77, n. 10, pp. 1297-1304, Ago. 2007.
- [77] N. Amjady, «Day-Ahead Price Forecasting of Electricity Markets by a New Fuzzy Neural Network», *IEEE Trans. Power Syst.*, vol. 21, n. 2, pp. 887-896, Mai. 2006.
- [78] A. T. Lora, J. M. R. Santos, A. G. Exposito, J. L. M. Ramos, e J. C. R. Santos, «Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques», *IEEE Trans. Power Syst.*, vol. 22, n. 3, pp. 1294-1301, Ago. 2007.
- [79] N. Amjady e M. Hemmati, «Day-ahead price forecasting of electricity markets by a hybrid intelligent system», *Eur. Trans. Electr. Power*, vol. 19, n. 1, pp. 89-102, Jan. 2009.
- [80] J. P. S. Catalao, H. M. I. Pousinho, e V. M. F. Mendes, «Neural Networks and Wavelet Transform for Short-Term Electricity Prices Forecasting», 2009, pp. 1-5.
- [81] J. P. S. Catalão, H. M. I. Pousinho, e V. M. F. Mendes, «Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach», *Energy Convers. Manag.*, vol. 52, n. 2, pp. 1061-1065, Fev. 2011.
- [82] M. Shafie-khah, M. P. Moghaddam, e M. K. Sheikh-El-Eslami, «Price forecasting of day-ahead electricity markets using a hybrid forecast method», *Energy Convers. Manag.*, vol. 52, n. 5, pp. 2165-2169, Mai. 2011.
- [83] J. P. S. Catalao, H. M. I. Pousinho, e V. M. F. Mendes, «Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal», *IEEE Trans. Sustain. Energy*, Jan. 2010.
- [84] J. P. S. Catalao, G. J. Osorio, e H. M. I. Pousinho, «Application of an intelligent system based on EPSO and ANFIS to price forecasting», 2011, pp. 1-5.
- [85] S. Anbazhagan e N. Kumarappan, «Day-Ahead Deregulated Electricity Market Price Forecasting Using Recurrent Neural Network», *IEEE Syst. J.*, vol. 7, n. 4, pp. 866-872, Dez. 2013.
- [86] H. M. I. Pousinho, V. M. F. Mendes, e J. P. S. Catalão, «Short-term electricity prices forecasting in a competitive market by a hybrid PSO-ANFIS approach», *Int. J. Electr. Power Energy Syst.*, vol. 39, n. 1, pp. 29-35, Jul. 2012.
- [87] R. Moreira, R. Bessa, e J. Gama, «Probabilistic forecasting of day-ahead electricity prices for the Iberian electricity market», 2016, pp. 1-5.
- [88] S. Anbazhagan e N. Kumarappan, «Day-ahead deregulated electricity market price forecasting using neural network input featured by DCT», *Energy Convers. Manag.*, vol. 78, pp. 711-719, Fev. 2014.
- [89] N. H. Vardhan e V. Chintham, «Electricity price forecasting of deregulated market using Elman Neural Network», em *2015 Annual IEEE India Conference (INDICON)*, 2015, pp. 1-5.
- [90] A. Yadav, R. Peesapati, e N. Kumar, «Electricity Price Forecasting and Classification Through Wavelet-Dynamic Weighted PSO-FFNN Approach», *IEEE Syst. J.*, pp. 1-10, 2017.
- [91] A. U. Haque, P. Mandal, J. Meng, A. K. Srivastava, T. L. Tseng, e T. Senjyu, «A Novel Hybrid Approach Based on Wavelet Transform and Fuzzy ARTMAP Networks for Predicting Wind Farm Power Production», *IEEE Trans. Ind. Appl.*, vol. 49, n. 5, pp. 2253-2261, Set. 2013.
- [92] W. A. Qureshi, N. K. C. Nair, e M. M. Farid, «Demand-price analysis of electricity market using Discrete Wavelet Transform», em *2009 Australasian Universities Power Engineering Conference*, 2009, pp. 1-6.

- [93] K. G. Sharma, A. Bhargava, K. Gajrani, e R. Bansal, «Impact of integration of solar and wind power on small signal stability using wavelet transform», em *2013 IEEE Conference on Clean Energy and Technology (CEAT)*, 2013, pp. 293-298.
- [94] L. Dong, L. Wang, X. Liao, Y. Gao, Y. Li, e Z. Wang, «Prediction of wind power generation based on time series wavelet transform for large Wind Farm», em *2009 3rd International Conference on Power Electronics Systems and Applications (PESA)*, 2009, pp. 1-4.
- [95] *EPSO and DEEPSO: Evolutionary Particle Swarms as Highly Competitive Meta-Heuristics*. INESC TEC, Porto, Portugal: Conference and Debate ISAP, 2015.
- [96] A. T. Eseye, J. Zhang, D. Zheng, H. Li, e G. Jingfu, «A double-stage hierarchical hybrid PSO-ANN model for short-term wind power prediction», em *2017 IEEE 2nd International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*, 2017, pp. 489-493.
- [97] E. Lacerda, «A Otimização Nuvem de Partículas (particle swarm)», p. 27, 2007.
- [98] V. Miranda e N. Fonseca, «EPSO-evolutionary particle swarm optimization, a new algorithm with applications in power systems», 2002, vol. 2, pp. 745-750.
- [99] V. Miranda e N. W. Oo, «New experiments with EPSO - Evolutionary Particle Swarm Optimization», p. 8.
- [100] Minyou Chen, Chuansheng Wu, e P. Fleming, «An evolutionary particle swarm algorithm for multi-objective optimization», 2008, pp. 3269-3274.
- [101] M. B. Abdelhalim, A. E. Salama, e S. E. D. Habib, *Hardware software partitioning using particle swarm optimization technique*. Cairo, Egypt: Proc. 6th Int. workshop on system-on-chip for real-time appl., 2007.
- [102] V. Miranda e N. Fonseca, «EPSO - best-of-two-worlds meta-heuristic applied to power system problems», em *Proceedings of the 2002 Congress on Evolutionary Computation, 2002. CEC '02*, 2002, vol. 2, pp. 1080-1085.
- [103] V. Miranda, C. Cerqueira, e C. Monteiro, «Training a FIS with EPSO under an Entropy Criterion for Wind Power prediction», em *2006 International Conference on Probabilistic Methods Applied to Power Systems*, 2006, pp. 1-8.
- [104] J. N. D. L. Gonçalves, G. J. Osório, J. M. Lujano-Rojas, T. D. P. Mendes, e J. P. S. Catalão, «DEEPSO to predict wind power and electricity prices series in the short-term», em *2016 51st International Universities Power Engineering Conference (UPEC)*, 2016, pp. 1-6.
- [105] «DEEPSO basics – EPSO». Disponível em: <http://epso.inescporto.pt/deepso/deepso-basics>. [Acedido: 20-Jun-2018].
- [106] V. Miranda, *Redes Neurais - treino por retropropagação*. Porto, Portugal, 2007.
- [107] J. S. de Medeiros, «Bancos de dados geográficos e redes neurais artificiais: tecnologias de apoio à gestão do território.», text, Universidade de São Paulo, 1999.
- [108] S. Haykin, *Neural Networks - A Comprehensive Foundation*, 2nd ed. Pearson Hall, 2005.
- [109] J. M. Barreto, «Introdução às Redes Neurais Artificiais», *Laboratório Conex. E Ciênc. Cogn. UFSC -Dep. Informática E Estat. 88040-900*, p. 57, Florianópolis - SC 2002.
- [110] S. Sandri e C. Correa, *Lógica Nebulosa*, INPE. São José dos Campos, Brasil, 1999.
- [111] «Fuzzy sets - ScienceDirect».. Disponível em: <https://www.sciencedirect.com/science/article/pii/S001999586590241X>. [Acedido: 20-Jun-2018].
- [112] D. Driankov, H. Hellendoorn, e M. Reinfrank, *An Introduction to Fuzzy Control*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1993.
- [113] J. P. S. Catalao, H. M. I. Pousinho, e V. M. F. Mendes, «Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Electricity Prices Forecasting», *IEEE Trans. Power Syst.*, vol. 26, n. 1, pp. 137-144, Fev. 2011.

- [114] G. J. Osório, J. C. O. Matias, e J. P. S. Catalão, «Electricity prices forecasting by a hybrid evolutionary-adaptive methodology», *Energy Convers. Manag.*, vol. 80, pp. 363-373, Abr. 2014.
- [115] P. P. Bonissone, *Adaptative Neural Fuzzy Inference Systems (ANFIS): Analysis and Applications*. 2002.
- [116] J. P. S. Catalao, H. M. I. Pousinho, e V. M. F. Mendes, «Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Wind Power Forecasting in Portugal», *IEEE Trans. Sustain. Energy*, vol. 2, n. 1, pp. 50-59, Jan. 2011.
- [117] H. Ying, «General Takagi-Sugeno fuzzy systems with simplified linear rule consequent are universal controllers, models and filters», *Inf. Sci.*, vol. 108, n. 1-4, pp. 91-107, Jul. 1998.
- [118] H. M. I. Pousinho, J. P. S. Catalão, e V. M. F. Mendes, «Wind power short-term prediction by a hybrid PSO-ANFIS approach», em *Melecon 2010 - 2010 15th IEEE Mediterranean Electrotechnical Conference*, 2010, pp. 955-960.
- [119] «Me360_presentation». Disponível em:
http://web.mst.edu/~dux/repository/me360/me360_presentation.html.
[Acedido: 21-Jun-2018].
- [120] B. Binayak, J. Dilan, e I. Syed, *Smart Power Systems and Renewable Energy System Integration*. Chapter: «Modelling and Simulation of Power Systems», 2016.
- [121] G. J. Osório, J. C. O. Matias, e J. P. S. Catalão, «Short-term wind power forecasting using adaptive neuro-fuzzy inference system combined with evolutionary particle swarm optimization, wavelet transform and mutual information», *Renew. Energy*, vol. 75, pp. 301-307, Mar. 2015.

Anexos

Hybrid Probabilistic Forecasting Model for Electricity Market Prices in Short-Term

Vasco M. A. Campos
FEUP, Porto, Portugal
up201305876@fe.up.pt

Gerardo J. Osório, Miadreza Shafie-khah
C-MAST/UBI, Covilhã, Portugal
miadreza@ubi.pt
osorio.silva@ubi.pt

João P. S. Catalão
INESC TEC and FEUP, Porto,
C-MAST/UBI, Covilha, and
INESC-ID/IST-UL, Lisbon, Portugal
catalao@fe.up.pt

Abstract—With the integration of new power production technologies and the growing focus on dispersed production, there has been a change in the paradigm in the electric sector, mostly under a renewable and sustainable way. As consequence, the challenges for the profitability, as well as, a correct management of the electricity sector have increased its complexity. With this, through the forecasting tools that allow a real and robust approach, it is possible to improve the operation and operation of the system, minimizing the costs associated with the activities of the electric sector. By other words, the forecasting approaches have an essential key role in all stages of the electricity markets. In this work, it is presented a hybrid probabilistic forecasting model (HPFM), for the short-term electricity market prices (EMP), combining Wavelet Transform (WT), hybrid particle swarm optimization (DEEPSO), Adaptive Neuro-Fuzzy Inference System (ANFIS), together with Monte Carlo Simulation (MCS). The proposed HPFM was tested and validated with real data from the Spanish EMP and with Pennsylvania-New Jersey-Maryland (PJM) EMP, considering the next week ahead and the results were compared with other methods already validated.

Keywords— *Adaptive Neuro-Fuzzy Inference System; hybrid particle swarm optimization; Electricity market prices; Forecasting; Monte Carlo simulation; Short-term; Wavelet transform.*

I. INTRODUCTION

In competitive and liberalized electricity markets, where renewable integration is prominent, the natural renewable stochasticity is totally echoed in the market players' decisions, bringing more challenges for a sustainable, profitable and reliable management of the electricity framework [1]. Moreover, the integration of microgeneration together with the natural evolution of renewable energy technologies leads to the change of the paradigm of electricity sector. The previous sets and more, makes the forecasting EMP tools more needed than demand series forecasting tools [2].

One of the ways to turns the electricity sector more flexible is by integrating innovative storage systems, where the main goal is to manage the wild behavior of renewable. However, the integration is highly costly, the lifetime is limited, and is most of the cases are prototypal systems [3].

In engineering, the forecasting EMP study has grown as one of the biggest research areas, where the massive efforts are widespread at current days [4].

EMP forecasting is a critical and inevitable task for all market players in their making decision, especially with the advance of smart grids, together with the aforementioned progress in electricity systems, and the necessary and unavoidable mitigation of human footprint impact [5]-[7].

As the scientific community shows, the EMP forecasting models are acceptable divided as statistical or physical models, with soft or hard computing techniques, [8], and realized for the very-short-term (from few seconds till few hours), short-term (from few hour till few days), and long-term (from few days till months) horizon forecasting [9]-[11].

In hard computing, the most known models are related with auto-regressive integrated moving average (ARIMA), with or without pre-processing data [12], [13], where the need of a large number of physical data, and also an exact modelling of the system is mandatory. In contrast, soft computing, the models usually use an auto-learning procedure from the historical sets to identify the future data with the outlines presents on the historical data. A widespread of models can be found, mostly related with neural network (NN) philosophy [14]-[16] and hybrid models [17]-[22], where the goals is to take opportunity of the best features from the techniques that composed the hybrid forecasting model.

Nowadays, the efforts of scientific community are focused on innovative probabilistic forecasting models, where the hybridization process also happens, but with the goal of more realistic outputs [x1], [x2], [x3]. To validate the accuracy and applicability of proposed forecasting models, it is necessary the usage of similar historical data, not with the goal of tuning the proposed model, but to prove its advantages among other models proposed.

As example, for instance, in [21] was presented a full study of hybrid forecasting models applied in electrical system and it was proposed two hybrid forecasting models to predict the next-day base load electricity prices for Great Britain electricity market.

Hence, In [22] was presented a hybrid forecasting model combining, WT, differential evolutionary particle swarm optimization (DEEPSO) and ANFIS methods to forecast the EMP series for the Spain market from years 2002 and 2006, and PJM market from year 2006, considering also different horizon prediction time between 24 hours until 168 hours ahead with a time-step of 1 hour.

J.P.S. Catalão acknowledges the support by FEDER funds through COMPETE 2020 and by Portuguese funds through FCT, under Projects SAICT-PAC/0004/2015 - POCl-01-0145-FEDER-016434, POCl-01-0145-FEDER-006961, UID/EEA/50014/2013, UID/CEC/50021/2013, UID/EMS/00151/2013, and 02/SAICT/2017 - POCl-01-0145-FEDER-029803, and also funding from the EU 7th Framework Programme FP7/2007-2013 under GA no. 309048.