

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



FEUP

Previsão de preços de eletricidade para o mercado MIBEL

João Gonçalo Araújo Ribeiro

VERSÃO FINAL

Mestrado Integrado em Engenharia Electrotécnica e de Computadores

Orientador: Cláudio Domingos Martins Monteiro (Professor)

Junho de 2014

Resumo

Nesta dissertação é feita a comparação entre a precisão de vários modelos de previsão de preços de eletricidade para o dia seguinte para o Mercado Ibérico de Eletricidade (MIBEL). Os diferentes modelos de previsão são obtidos utilizando redes neurais artificiais. Durante a criação e teste dos diferentes modelos, foi feito um estudo acerca da influência que as diferentes variáveis têm sobre os modelos de previsão de preços. As variáveis estudadas incluem valores históricos de preços, de consumos, de vários tipos de produção de energia e de previsões meteorológicas como a velocidade do vento, temperatura entre outras. O estudo de um modelo de referência inovador, criado com o objetivo de interpretação e separação de causalidade explicativa e causalidade especulativa em modelos de previsão de preços está também incluído neste trabalho. A influência preponderante da previsão da velocidade do vento na criação de modelos de previsão de preços também é comprovada neste trabalho. Todos os resultados derivados dos testes efetuados com os diferentes modelos são apresentados nesta dissertação. Por último, está ainda incluído neste trabalho um estudo do estado-da-arte atual para a previsão de preços de eletricidade bem como a presença de um capítulo inteiramente dedicado à explicação do modo de funcionamento e organização do mercado MIBEL.

Abstract

This dissertation compares the predictive accuracy of a set of methods for day-ahead spot price forecasting in the Iberian Electricity Market (MIBEL). The different methods are obtained using artificial neural networks. Within the creation and testing of the methods, different variable influence studies were conducted using variables such as historic values of prices, historic values of loads and several types of energy production and weather predictions for wind speed, temperature among others. The study of a model for “Reference Explanatory Price Estimation”, created with the objective of interpretation and separation of explanatory causality and speculative causality in the price model is also included in this work. The critical influence of the wind speed forecast on price prediction is also proved in this approach. Detailed out-of-sample results of the tested methods are given. Also included in this work is the state-of-the-art for electricity price forecasting as well as a chapter devoted entirely to the study of the Iberian market functioning and daily operations.

Agradecimentos

Dirijo o meu sincero agradecimento ao meu orientador, o professor Cláudio Monteiro, por todo o apoio, orientação e conselhos prestados ao longo desta jornada.

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

Aos meus pais e irmãos pelo inestimável apoio familiar que contribuiu para a minha educação e realização pessoal e profissional.

Finalmente, a todos os meus colegas e amigos e restantes familiares, que me acompanharam num percurso trabalhoso, de ajuda e também momentos divertidos e descontraídos.

João Ribeiro

*“Once you free your mind about a concept of harmony and music being correct, you can do
whatever you want.
So, nobody told me what to do, and there was no preconception of what to do.”*

Giorgio Moroder

Conteúdo

1	Introdução	1
1.1	Enquadramento	1
1.2	Motivações	2
1.3	Objetivos	3
1.4	Caracterização do quadro temporal	3
1.5	Dados e variáveis utilizadas	4
1.5.1	Dados de produção e consumo	4
1.5.2	Dados de mercado	4
1.5.3	Dados meteorológicos	4
1.6	Estrutura da Dissertação	4
2	Mercado Ibérico de Eletricidade	7
2.1	Introdução	7
2.2	O modelo de organização do MIBEL	8
2.2.1	Mercado Grossista	8
2.2.2	Mercado Retalhista	8
2.3	Mercado Diário e Intradiário	9
2.3.1	Mercado Diário e formação de preços	10
2.3.2	Mercado Intradiário	11
2.3.3	Separação de mercados	12
2.4	Mercado a Prazo	13
3	Estado da Arte	15
3.1	Introdução	15
3.2	Panorama geral dos modelos de previsão	16
3.3	Modelos Multi Agente	16
3.3.1	Modelos de Custo de Produção	16
3.3.2	<i>Equilibrium Models</i>	17
3.4	Modelos Fundamentais	17
3.5	Modelos Quantitativos	18
3.5.1	<i>Jump-Diffusion models</i>	18
3.5.2	<i>Markov Regime-Switching models</i>	19
3.6	Modelos Estatísticos	19
3.6.1	Técnicas ARMA, ARIMA	20
3.6.2	<i>Threshold AR</i>	21
3.6.3	<i>TARSW with wavelet filter</i>	22
3.6.4	<i>GARCH-type</i>	22
3.6.5	<i>Similar-Day Method, exponential smoothing</i>	23

3.7	Modelos baseados em Inteligência Artificial	23
3.7.1	<i>Redes Neurais Artificiais (Artificial Neural Network)</i>	23
3.7.2	<i>Data-mining models</i>	28
3.8	Aplicações	28
4	Características e fatores de influência dos preços MIBEL	31
4.1	Picos nos preços (<i>Price Spikes</i>)	31
4.1.1	O que origina os spikes?	33
4.2	Sazonalidade	34
4.3	Fatores Meteorológicos	36
4.3.1	Temperatura	36
4.3.2	Vento	37
4.4	Consumo	38
4.5	Preço D e Preço D-6	39
4.6	A influência do despacho	40
4.6.1	Caso de estudo - Janeiro e Fevereiro de 2013	40
4.6.2	Caso de estudo - Março e Abril 2013	42
4.6.3	Caso de estudo - Julho e Agosto de 2013	44
4.6.4	Caso de estudo - Preços elevados verificados durante o mês de Dezembro de 2013	46
5	Modelos de previsão de preços MIBEL	49
5.1	Modelo de Referência	51
5.1.1	Aplicação do Modelo de Referência	51
5.2	Modelo 1 - Modelo Multivariável Direto	54
5.2.1	Aplicação do Modelo Multivariável Direto - Melhor Caso	56
5.3	Modelo 2 - Modelo Autoregressivo	58
5.4	Modelo 3 - Estruturas de Submodelos	58
5.4.1	Previsão do Consumo	59
5.4.2	Previsão da produção Eólica	60
5.4.3	Previsão da produção Hídrica	61
5.4.4	Previsão da produção Solar + Cogeração	62
5.4.5	Previsão da produção de Carvão, Nuclear e Gás Natural	62
5.4.6	Aplicação do Modelo 3 - Estruturas de Submodelos	63
5.5	Comparação dos modelos	65
6	Conclusões e trabalhos futuros	71
6.1	Trabalhos Futuros	72
7	Bibliografia	73
8	Anexos	77
8.1	Resultados do Modelo 1	77
8.2	Resultados do Modelo 2	79
8.3	Resultados do Modelo 3	81

Lista de Figuras

1.1	Quadro temporal das previsões.	3
2.1	Esquema temporal de funcionamento do MIBEL. Fonte: OMEL	9
2.2	Obtenção do preço de equilíbrio do mercado. [62]	11
2.3	Estrutura por sessões do mercado intradiário do MIBEL. Fonte: OMEL	12
2.4	Diagrama representativo da ocorrência de <i>market splitting</i> . [62]	13
3.1	Características de entrada e saída de um " <i>equilibrium model</i> ". [3]	17
3.2	Exemplo de um modelo estatístico. [3]	20
3.3	Série não estacionária	21
3.4	Série estacionária (após diferenciação)	21
3.5	Homoscedasticidade	22
3.6	Heteroscedasticidade	22
3.7	Estrutura de uma unidade pertencente a uma rede neuronal. [63]	24
3.8	Exemplo de uma rede neuronal. Fonte: ICMC-USP	24
3.9	Modo de funcionamento feedforward. [64]	25
3.10	Esquema representativo do modo de funcionamento do algoritmo de retropropagação. [66]	26
3.11	Modo de funcionamento recurrent. [65]	27
4.1	Perfil horário de preços spot do MIBEL com identificação de spikes relevantes durante o ano 2012	31
4.2	Perfil horário de preços spot do MIBEL com identificação de spikes relevantes durante o ano 2013	32
4.3	Spike ocorrido em Maio de 2013	33
4.4	Esquema que mostra a oferta de energia com duas curvas de consumo hipotéticas. Mostra também o preço spot, dado pela interseção entre a oferta e o consumo. [4]	33
4.5	Evolução do preço da eletricidade para o MIBEL (2010-2013)	34
4.6	Evolução do preço da eletricidade durante duas semanas distintas	35
4.7	Correlação existente entre o preço da eletricidade e o dia da semana.	35
4.8	Correlação existente entre o preço da eletricidade e a hora do dia.	36
4.9	Correlação existente entre o preço da eletricidade e a temperatura. Dados de temperatura registados às 9 horas da manhã de todos os dias de 2013	36
4.10	Correlação existente entre o preço da eletricidade e a velocidade do vento. Dados relativos ao ano 2013 - MIBEL	37
4.11	Correlação existente entre o preço da eletricidade e o consumo. Dados relativos ao mês de Janeiro de 2013 - MIBEL	38
4.12	Relação entre a variável consumo D (MW) e o preço real	39
4.13	Relação entre a variável consumo D-6 (MW) e o preço real	39

4.14	Relação entre a variável preço D e o preço real	39
4.15	Relação entre a variável preço D-6 e o preço real	39
4.16	Energia colocada em mercado diário e preços médio diário para o mês de Janeiro de 2013	41
4.17	Energia colocada em mercado diário e preços médio diário para o mês de Fevereiro de 2013	41
4.18	Porcentagem de energia colocada em mercado diário e variações entre diferentes meses do ano de 2013.	42
4.19	Energia colocada em mercado diário e preços médio diário para o mês de Março de 2013	43
4.20	Energia colocada em mercado diário e preços médio diário para o mês de Abril de 2013	43
4.21	Produção de Solar FV	44
4.22	Produção Eólica	44
4.23	Restante PRE	44
4.24	Energia colocada em mercado diário e preços médio diário para o mês de Julho de 2013	45
4.25	Energia colocada em mercado diário e preços médio diário para o mês de Agosto de 2013	45
4.26	Evolução do mercado diário - Preços médios diários e renda de congestionamento (Dezembro 2013, MIBEL)	46
4.27	Energia colocada em mercado diário (Dezembro 2013, MIBEL)	47
5.1	Diagrama do conjunto de dados utilizado	49
5.2	Diagrama representativo das variáveis de entrada e saída do modelo de referência	52
5.3	Representação dos desvios médios dos preços em função da hora do dia	53
5.4	Representação dos desvios médios dos preços em função do dia da semana	53
5.5	Representação dos desvios médios dos preços em função da estação do ano	53
5.6	Comparação entre os modelos M1 e M13 para uma semana de Fevereiro/2013	55
5.7	Comparação entre os modelos M1 e M9 para uma semana de Abril/2013	56
5.8	Diagrama representativo das variáveis de entrada e saída do modelo 1.	57
5.9	Diagrama representativo das variáveis de entrada e saída do modelo 2.	58
5.10	Diagrama representativo das variáveis de entrada e saída do modelo 3.	59
5.11	Relação entre o consumo (MW) e a hora do dia	60
5.12	Relação entre o consumo (MW) e o dia da semana	60
5.13	Relação entre o consumo (MW) e o mês	60
5.14	Relação entre o consumo (MW) e a temperatura (°C)	60
5.15	Relação entre a produção eólica (MW) e a velocidade do vento (m/s).	61
5.16	Relação entre a produção eólica (MW) e a direção do vento (°).	61
5.17	Relação entre a produção solar + cogeração (MW) e a irradiância (W/m2).	62
5.18	Relação entre a produção solar + cogeração (MW) e a temperatura (°C).	62
5.19	Relação entre a produção térmica agregada (MW) e a hora	63
5.20	Relação entre a produção térmica agregada (MW) e o dia da semana	63
5.21	Relação entre a produção térmica agregada (MW) e a produção térmica agregada do dia anterior (MW)	63
5.22	Relação entre a produção térmica agregada (MW) e a produção térmica agregada da semana anterior (MW)	63
5.23	Indicadores de MAPE dos diferentes modelos em função da hora do dia	66
5.24	Indicadores de MAPE dos diferentes modelos em função do dia da semana	66

5.25	Indicadores de MAPE dos diferentes modelos em função do mês	67
5.26	Perfis das previsões de preços para a primeira semana do mês de Janeiro	68
5.27	Perfis das previsões de preços para a primeira semana do mês de Março	68
5.28	Perfis das previsões de preços para a primeira semana do mês de Maio	69
5.29	Perfis das previsões de preços para a primeira semana do mês de Julho	69
5.30	Perfis das previsões de preços para a primeira semana do mês de Agosto	70
5.31	Perfis das previsões de preços para a primeira semana do mês de Novembro	70
8.13	Previsões obtidas com o modelo multivariável	78
8.26	Previsões obtidas com o modelo autoregressivo	80
8.39	Previsões obtidas com o modelo estruturado	82

Lista de Tabelas

5.1	Passo 1 - Aquisição das 5 previsões individuais para obtenção do modelo <i>ensemble</i> .	50
5.2	Passo 2 - Cálculo do erro de cada modelo individual para obtenção do erro <i>ensemble</i> .	50
5.3	Indicadores de MAPE anuais das previsões individuais e dos <i>ensembles</i> - modelo de referência	51
5.4	Indicadores de MAPE anuais das previsões individuais e dos <i>ensembles</i> para os diferentes modelos - modelo multivariável direto	54
5.5	Indicadores de MAPE anuais das previsões individuais e dos <i>ensembles</i> para os diferentes modelos por ordem ascendente - modelo multivariável direto	55
5.6	Indicadores de MAPE semanais, mensais e anual - - modelo multivariável direto .	56
5.7	Indicadores de MAPE semanais, mensais e anual - modelo autoregressivo	58
5.8	Indicadores de MAPE anuais de teste para os submodelos - modelo estruturado .	64
5.9	Indicadores de MAPE anuais de teste - modelo estruturado	64
5.10	Indicadores de MAPE anuais para os diferentes modelos construídos	67

Abreviaturas e Símbolos

MIBEL	Mercado Ibérico de Eletricidade
PPE	Previsão de Preços de Eletricidade
ERSE	Entidade Reguladora dos Serviços Energéticos
CNE	Comisión Nacional de Energía
REN	Redes Energéticas Nacionais
REE	Red Eléctrica de España
OMI	Operador de Mercado Ibérico
OMEL	Operador do Mercado Ibérico de Energia (Pólo Espanhol)
OMIP	Operador do Mercado Ibérico de Energia (Pólo Português)
PDBF	Programa diário base de funcionamento
PDVP	Programas diários viáveis provisórios
PHF	Programa horário final
PRE	Produção em regime especial
AR	Autoregressive
ARMA	Autoregressive Moving Average
ARIMA	Autoregressive Integrated Moving Average
SARIMA	Seasonal Autoregressive Integrated Moving Average
TAR	Threshold Autoregressive
SETAR	Self Exciting Threshold Autoregressive
STAR	Smooth Transition Autoregressive
TARSW	Threshold Autoregressive Switching
ARCH	Autoregressive Conditional Heteroskedastic
GARCH	Generalized Autoregressive Conditional Heteroskedastic
ANN	Artificial Neural Network
CCGT	Centrais de ciclo combinado a gás natural
$\hat{p}(D+1)_h (D)_t$	Preço previsto p a um tempo t , no dia (D), para a hora h , do dia (D+1)
$p(D)_h$	Preço real p para a hora h , no dia (D)
$C(D)_h$	Valor ibérico agregado do consumo médio horário à hora h para o dia (D) em (MW)
$S(D)_h$	Valor ibérico agregado da produção média horária de energia solar fotovoltaica à hora h para o dia (D) em (MW)
$H(D)_h$	Valor ibérico agregado da produção média horária de energia hídrica à hora h para o dia (D) em (MW)
$E(D)_h$	Valor ibérico agregado da produção média horária de energia eólica à hora h para o dia (D) em (MW)
$Ca(D)_h$	Valor ibérico agregado da produção média horária de energia termoelétrica proveniente do carvão à hora h para o dia (D) em (MW)
$N(D)_h$	Valor ibérico agregado da produção média horária de energia termoelétrica nuclear à hora h para o dia (D) em (MW)

$GN(D)_h$	Valor ibérico agregado da produção média horária de energia termoelétrica proveniente das centrais de ciclo combinado a gás natural à hora h para o dia (D) em (MW)
$Ca, GNeN(D)_h$	Soma dos valores ibéricos agregados da produção média horária de energia termoelétrica proveniente das centrais de ciclo combinado a gás natural, das centrais nucleares e do carvão à hora h para o dia (D) em (MW)
$\hat{v}(D-1)_h (D)_t$	Previsão média ibérica pesada da velocidade do vento, a um tempo t , no dia (D) para a hora h do dia (D+1) em (m/s)
$\hat{T}(D-1)_h (D)_t$	Previsão média ibérica pesada da temperatura, a um tempo t , no dia (D) para a hora h do dia (D+1) em ($^{\circ}$ C)
$\hat{i}(D-1)_h (D)_t$	Previsão média ibérica pesada da irradiância, a um tempo t , no dia (D) para a hora h do dia (D+1)
$\hat{d}(D-1)_h (D)_t$	Previsão média ibérica pesada da direção do vento, a um tempo t , no dia (D) para a hora h do dia (D+1)

Capítulo 1

Introdução

Esta dissertação foi desenvolvida no âmbito do Mestrado Integrado em Engenharia Eletrotécnica e de Computadores da Faculdade de Engenharia da Universidade do Porto.

O objetivo deste dissertação é o desenvolvimento de novos modelos de previsão de preços de eletricidade a curto prazo, com o intuito de prever preços para o dia seguinte. Os modelos utilizarão como variáveis de entrada as previsões de consumos, produção hídrica, produção eólica e outras variáveis de influência que venham a ser identificadas como sendo relevantes.

No desenvolvimento do trabalho foram utilizadas ferramentas de análise estatística e redes neurais como técnicas de previsão de preços. Neste trabalho serão utilizados dados históricos de previsões meteorológicas e outras previsões de entrada do sistema elétrico ibérico fornecidos pela empresa Smartwatt.

1.1 Enquadramento

O Mercado Ibérico de Eletricidade – MIBEL, é fruto de um processo de cooperação conduzido pelos Governos de Portugal e de Espanha com o objectivo de promoverem a integração dos sistemas eléctricos dos dois países. Os resultados que daí advieram constituíram um contributo significativo não só para a concretização do mercado de energia eléctrica a nível ibérico, mas também, à escala europeia, como um passo significativo para a construção do Mercado Interno de Energia.

A 1 de Julho de 2007, o MIBEL arrancou em toda a sua dimensão, coroando o trabalho de harmonização de condições entre os dois sistemas eléctricos ibéricos, na perspectiva de que do seu funcionamento adviriam benefícios para os consumidores de ambos os países, num quadro de garantia do acesso a todos os interessados em condições de igualdade, transparência e objectividade.

Recentemente, teve início no dia 13 de Maio de 2014 o acoplamento efectivo da região do Sudoeste da Europa o que representa um importante passo para a integração do mercado eléctrico europeu. Como resultado, os mercados diários do Noroeste Europeu e do Sudoeste Europeu, que se estendem desde a Finlândia a Portugal, operam agora sob um processo de cálculo de preços comum para o mercado diário utilizando a solução do *Price Coupling of Regions* (PCR).

O acoplamento efectivo entre os mercados diários do Noroeste Europeu e do Sudoeste Europeu permite o cálculo simultâneo dos preços e transacções de energia na região. Este facto trará benefícios, para os consumidores finais, que advêm de uma utilização mais eficiente do sistema eléctrico e das infra-estruturas transfronteiriças em consequência de uma maior coordenação e cooperação entre mercados de energia.

A assegurar a regularização do mesmo encontram-se duas entidades reguladoras, a ERSE (Entidade Reguladora dos Serviços Energéticos) do lado Português e CNE (Comissão Nacional de Energia) do lado Espanhol. Os operadores de sistemas são a REN (lado português) e a REE (lado espanhol).

A criação de mercados de electricidade tem como objetivo terminar com a existência de monopólios, originando assim um ambiente concorrencial de liberdade na transacção da energia onde o consumidor é livre de escolher o seu fornecedor de energia eléctrica. O MIBEL é um mercado liberalizado onde os preços adquirem características voláteis e incertas, visto que os mesmos são obtidos através de propostas de oferta e de compra de energia. Este tipo de ambiente acaba por ser vantajoso não só para os produtores de energia mas também para o consumidor final que pode ver o preço da energia diminuir.

Assim num ambiente competitivo como este, torna-se imperativo prever o preço futuro da energia não só para a definição de uma estratégia de despacho e aumento do lucro por parte dos produtores de energia, mas também para benefício financeiro de quem a compra.

1.2 Motivações

O mercado de energia, por ser um ambiente muito competitivo, faz com que a previsão de preços de electricidade assuma uma elevada importância. As aplicações da previsão de preços de electricidade variam consoante o horizonte temporal desejado, podendo ser efetuadas previsões a curto, médio e longo prazo.

A capacidade de saber como os preços irão tender no futuro, é extremamente benéfica para todos os participantes e agentes do mercado. As suas estratégias e lucros dependem de uma aposta correta de que o mercado irá "mover-se" para uma direcção ou outra.

Os preços de electricidade apresentam uma elevada volatilidade, sendo essencial para todos os intervenientes no mercado ter acesso a previsões o mais corretas e precisas possível. Apesar de ser praticamente impossível prever a ocorrência de *spikes*¹ no valor dos preços, a utilização de modelos eficientes de previsão pode reduzir consideravelmente as consequências nefastas que estes podem trazer para todos aqueles envolvidos no mercado de energia quer sejam produtores, clientes ou comercializadores de energia.

¹ Ver definição na secção 4.1

1.3 Objetivos

Tal como já foi referido, a realização desta tese, tem como principal objectivo o desenvolvimento e a construção de modelos de previsão de preços de eletricidade a curto prazo, com a finalidade de prever preços para o dia seguinte a tempo das licitações diárias do mercado. A previsão de preços efetuada neste trabalho diz respeito somente ao preços do mercado diário, sendo que o mercado intradiário não se encontra abrangido.

Prevê-se a criação de 3 tipos diferentes de modelos práticos de previsão de preços de eletricidade bem como a criação de um inovador modelo de referência cuja finalidade é ser uma base de comparação para os outros modelos e não só. Através da criação deste modelo de referência, pretende-se compreender melhor a inexplicabilidade associada aos modelos de previsão de preços de eletricidade.

Adicionalmente, um dos modelos exigirá o desenvolvimento de sub-modelos modelos de previsão de consumos, da produção de hídrica, de produção de eólica, da produção de solar e da produção de centrais térmicas (Carvão, Nuclear e Gás Natural).

Através da utilização de redes neuronais e usando o software Matlab, a estratégia de previsão de preços passará pela aprendizagem dos comportamentos históricos dos preços passados e de outras variáveis que se venham a demonstrar influentes para o processo.

1.4 Caracterização do quadro temporal




Figura 1.1: Quadro temporal das previsões.

O quadro temporal das previsões efetuadas encontra-se descrito de seguida e ilustrado na figura 1.1. A previsão do preço $\hat{p}(D-1)h|(D)_t$ é feita para cada uma das 24 horas do dia (D+1) sendo que as previsões são efetuadas diariamente às 00:00h do dia (D). Para os mercados europeus de energia, a obtenção dos preços spot diários é feita às 12:00h do dia (D) sendo que as licitações terão de ser feitas 1 hora antes. Assim, a previsão de preços terá de ser entregue antes da hora

limite de entrega de licitações. Para este trabalho, assume-se que a entrega da previsão é feita na primeira hora do dia (D), sendo que em aplicações práticas, a mesma só é efetuada após a sexta hora de previsão meteorológica.

1.5 Dados e variáveis utilizadas

Para a criação dos diferentes modelos utilizaram-se dados provenientes de diversas fontes, que são de seguida apresentados consoante a sua informação. Assim, os dados fornecidos foram classificados como: dados de produção e consumo, dados de preços de mercado e dados de previsões meteorológicos.

1.5.1 Dados de produção e consumo

Os dados de produção e consumo utilizados nesta tese foram fornecidos pela empresa SmartWatt e compreendem os anos de 2012 e 2013. Tratam-se de dados ibéricos agregados respeitantes às várias produções médias horárias de energia do tipo hídrica, eólica, solar fotovoltaica (que inclui a cogeração e outras produções independentes de energia), termoelétrica (Carvão, Nuclear e centrais de ciclo combinado a Gás Natural) e finalmente dos consumos.

1.5.2 Dados de mercado

Um outro conjunto de dados que à partida será muito importante para a previsão de preços de eletricidade, é o históricos dos mesmos preços de eletricidade para o mercado diário MIBEL. Estes dados são de acesso público e foram obtidos no site da REN mercados.

1.5.3 Dados meteorológicos

Finalmente, os dados meteorológicos usados no desenvolvimento deste trabalho englobam dados de previsão meteorológica, para o dia seguinte, para as seguintes variáveis temperatura média, velocidade de vento média ibérica, direção do vento média ibérica e irradiância média ibérica. Para a obtenção destes agregados de previsão foram realizadas previsões em cerca de 400 pontos geográficos diferentes, sendo agregadas por médias pesadas pela capacidade instalada de cada tipo de fonte de produção e consumo. Estes dados foram também fornecidos pela empresa SmartWatt.

1.6 Estrutura da Dissertação

Esta dissertação é constituída por 6 capítulos, sendo o presente capítulo o introdutório, no qual se apresenta o enquadramento do problema, as motivações para o trabalho, os objetivos e ainda outras informações adicionais acerca dos dados e metodologias utilizadas.

O 2º capítulo é dedicado ao estudo do funcionamento do Mercado Ibérico de Eletricidade. Pretende-se demonstrar o seu modelo de organização bem como todas as operações que decorrem durante o seu funcionamento.

O 3º capítulo é dedicado exclusivamente ao estado da arte relativo a modelos de previsão de preços de eletricidade. Pretende-se demonstrar o funcionamento dos vários tipos de abordagens bem como algumas das suas aplicações. Neste capítulo estão presentes diferentes metodologias, sendo que foi dada uma especial importância aos modelos mais utilizados, nomeadamente os modelos estatísticos e os modelos baseados em inteligência artificial. Foi também feita uma análise mais pormenorizada aos modelos que utilizam redes neuronais, visto que as mesmas foram utilizadas nesta dissertação.

O 4º capítulo, são descritas com bastante detalhe algumas das características mais importantes dos preços de eletricidade tais como a sua volatilidade ou a sazonalidade. Adicionalmente, neste capítulo, é também realizada uma análise dos fatores que influenciam a variabilidade dos preços de eletricidade. Este estudo foi realizado recorrendo a gráficos temporais e *scatter*. Algumas das conclusões apresentadas neste capítulo, referentes à influência dos vários fatores, poderão ser posteriormente comprovadas no capítulo seguinte.

O 5º capítulo é dedicado a análise dos diferentes modelos de previsão contruídos e à sua aplicação. É possível observar as diferentes metodologias utilizadas em detalhe e ainda verificar os resultados obtidos através da sua aplicação. Por último, existe uma secção muito importante onde são comparados os modelos. Serão apresentados esquemas, tabelas e gráficos dos testes efetuados para uma melhor compreensão dos mesmos.

No 6º e último capítulo são apresentadas as conclusões finais relativas a todo o trabalho desenvolvido nesta dissertação e ainda umas pequenas notas acerca de trabalhos futuros.

Capítulo 2

Mercado Ibérico de Eletricidade

Neste capítulo pretende-se demonstrar o modo de funcionamento e estrutura do Mercado Ibérico de Eletricidade (MIBEL).

2.1 Introdução

Atualmente, tem-se assistido a um processo de liberalização dos mercados de energia por toda a Europa. É de vital interesse para a União Europeia que se caminhe na direção de um mercado europeu mais integrado e como tal, vários esforços têm sido feitos com esse objetivo dos quais se destaca o desenvolvimento que vem sendo feito em relação aos vários mercados regionais existentes. O MIBEL é um desses casos tendo surgido da combinação de esforços entre Portugal e Espanha para a criação de um mercado de energia elétrica a nível ibérico. Desde a sua criação até à atualidade, é importante destacar algumas datas que marcaram o percurso de vida do MIBEL até ao momento [59-61]:

- **Novembro, 2001** - celebração do Protocolo de colaboração entre Portugal e Espanha para criação do MIBEL;
- **Outubro, 2004** - Assinatura do acordo em Santiago de Compostela entre Portugal e Espanha;
- **Novembro, 2006** - XXII.^a Cimeira Luso-Espanhola de Badajoz onde se definiu um Plano de Compatibilização Regulatória;
- **Janeiro, 2008** - Assinatura do acordo decidido em Novembro de 2006;
- **Maio, 2014** - Acoplamento do MIBEL aos restantes mercados europeus.

Atualmente, e como em todos os outros mercados de energia elétrica, é possível dividir o MIBEL em três tipos de atividades diferentes, designadamente a produção de energia, o transporte e distribuição e por último a comercialização. Enquanto que a produção e a comercialização de energia elétrica se encontram abertas à concorrência, o processo de transporte e distribuição de

energia baseia-se numa estrutura existente de redes que conduzem a energia elétrica desde a produção até aos consumidores, adquirindo a nomenclatura de monopólios naturais. É sabido que a manutenção de uma estrutura monopolista no caso do transporte e distribuição é economicamente mais eficiente. No entanto, o seu acesso é livre a terceiros, havendo apenas a necessidade de pagamento de uma tarifa. Por outro lado, tanto o ramo da produção como o da comercialização permitem a existência de concorrência, com vista a tornar a gestão e operação dos recursos inerentes a estas atividades mais eficiente. Assim, é possível dividir o mercado em dois tipos: o mercado grossista, associado à atividade de produção de energia elétrica, no qual os produtores de energia garantem a disponibilidade da mesma e os agentes compradores obtêm energia elétrica; e o mercado retalhista, associado ao processo de comercialização de energia, no qual os agentes comercializadores disputam para garantir o fornecimento aos consumidores finais.

2.2 O modelo de organização do MIBEL

2.2.1 Mercado Grossista

O atual mercado grossista do MIBEL compreende uma série de formatos de contratação de energia [59-61]:

- Mercado de contratação à vista (mercado *spot*) que se subdivide em dois tipos, nomeadamente mercados diários e intradiários. É nestes mercados que se apresentam as várias propostas de venda (produção) e compra (comercialização) de energia elétrica para o dia seguinte ao da negociação;
- Mercado de contratação a prazo, onde são estipulados compromissos a futuro de produção e compra de energia elétrica. O mercado a prazo pode realizar liquidação física (venda de energia) ou liquidação financeira;
- Mercado de contratação bilateral, onde é possível ordenar a compra e venda de energia elétrica para diferentes horizontes temporais;
- Mercado de serviços de sistema que funciona em tempo real e é responsável por manter o equilíbrio entre a produção e o consumo de energia elétrica.

2.2.2 Mercado Retalhista

O modo de funcionamento do mercado retalhista baseia-se em duas formas de contratação do fornecimento de energia elétrica [59-61]:

- Contratação em mercado regulado, onde são aplicadas tarifas integrais reguladas;
- Contratação em mercado liberalizado, onde as partes envolvidas têm o poder de definir e acordar as condições de negociação de energia. No entanto, a componente do acesso às redes continua a ser aplicada através de um preço regulado.

Acompanhando o desenvolvimento do mercado liberalizado de energia eléctrica, e visto que a atividade de comercialização se encontra aberta ao mercado, os consumidores possuem liberdade total na escolha do seu fornecedor de electricidade.

2.3 Mercado Diário e Intradiário

Tal como já foi mencionado anteriormente, uma das formas de contratação de energia no mercado grossista consiste na contratação à vista (mercado *spot*) que pode ocorrer no mercado diário ou no mercado intradiário. Como fatores de integração do modelo de funcionamento do MIBEL, foram previstos os dois pólos responsáveis pela gestão dos mercados organizados, nomeadamente, O OMEL (pólo espanhol), responsável pela gestão do mercado diário e intradiário eo OMIP (pólo português), responsável pela gestão dos mercados a prazo. É no mercado diário do MIBEL que ocorre a transação da energia eléctrica que irá satisfazer a procura do dia seguinte ao da negociação. O mercado diário encerra às 10 horas do dia que antecede a data do fornecimento de energia eléctrica. Os resultados provenientes do processo de encontro são posteriormente publicados às 11 horas. No processo de encontro estão incorporadas:

- As posições abertas transferidas do mercado a prazo, para as quais foi solicitada uma entrega física;
- A informação relativa à execução dos leilões regulados, caso a mesma ocorra por meio de entrega física;
- Os resultados dos leilões de capacidade nas interligações.

De seguida, entre as 11 e as 14 horas, e após terem sido incorporados os contratos bilaterais, é obtido o programa diário base de funcionamento (PDBF) para cada um dos sistemas. Posto isto, cabe aos operadores de sistema o trabalho de analisar e resolver possíveis restrições técnicas que possam surgir devido ao processo de encontro do mercado diário e a declaração de contratos bilaterais com vista à obtenção dos respectivos programas diários viáveis provisórios (PDVP).

HORARIO DE LAS SESIONES DEL MERCADO DE ELECTRICIDAD							
	MERCADO DIARIO	MERCADO INTRADIARIO					
		1ª SESIÓN	2ª SESIÓN	3ª SESIÓN	4ª SESIÓN	5ª SESIÓN	6ª SESIÓN
Apertura de sesión		16:00	21:00	1:00	4:00	8:00	12:00
Recepción contratos bilaterales	10:00						
Integración de las posiciones abiertas del mercado a plazo	10:00						
Cierre de sesión	10:00	17:45	21:45	1:45	4:45	8:45	12:45
Casación	11:00	18:30	22:30	2:30	5:30	9:30	13:30
Publicación del programa base de funcionamiento (PBF)	12:00						
Recepción de desagregaciones	12:00	Durante 30 minutos posteriores a la publicación de los resultados de la casación					
Análisis de restricciones	14:00	19:10	23:10	3:10	6:10	10:10	14:10
Publicación del programa diario viable (PVD)	16:00						
Publicación del programa horario final (PHF)		19:20	23:20	3:20	6:20	10:20	14:20
Anotaciones en cuenta para seguimiento de garantías	11:00	19:15	23:15	3:15	6:00	9:40	15:30
HORIZONTE DE PROGRAMACIÓN	24 horas	28 horas	24 horas	20 horas	17 horas	13 horas	9 horas
Periodos horarios		21 - 24	1 - 24	5 - 24	8 - 24	12 - 24	16 - 24

Figura 2.1: Esquema temporal de funcionamento do MIBEL. Fonte: OMEL

O PDV final é depois publicado antes das 16 horas e contém também, o resultado do mercado de regulação secundária. Na figura 2.1, é possível observar as várias sessões que compõem o mercado diário e intradiário e o seu esquema temporal de funcionamento, onde o resultado de cada sessão, uma vez livre de potenciais restrições ocorridas, gera o programa horário final (PHF).

Com o acoplamento do MIBEL aos restantes mercados europeus o esquema temporal de funcionamento do MIBEL sofreu algumas alterações. A figura 2.1 diz respeito ao período anterior a este acontecimento.

2.3.1 Mercado Diário e formação de preços

Desde 1 de Janeiro de 1998 (para o sistema espanhol) e 1 de Julho de 2007 (para o sistema português) que o mercado diário constitui o ponto de encontro entre a oferta e a procura de energia elétrica.

As várias ofertas de venda efetuadas pelos produtores são apresentadas por unidade de produção (podem incorporar condições complexas), para a parte que se encontra isenta de compromissos bilaterais, com especificação da quantidade e preço independentes para cada hora. Por outro lado, todas as ofertas de compra de energia eléctrica que ocorrem no mercado diário não podem integrar condições complexas.

2.3.1.1 Caracterização da curva de oferta

Todas as ofertas apresentadas no mercado diário pelos agentes fornecedores de energia (vendedores) para cada uma das horas do dia seguinte são ordenadas por preço ascendente, formando assim a curva de oferta do mercado para cada hora.

Tanto as centrais nucleares como a produção em regime especial (PRE) surgem habitualmente na parte baixa da curva da zona espanhola, dado que o seu custo de oportunidade é particularmente baixo. Contrariamente ao que se verifica em Espanha, em Portugal os produtores em regime especial não fazem parte do mercado de produção. No entanto, a sua produção é vendida ao comercializador de último recurso, responsável por incorporar a respectiva produção nas suas ofertas de aquisição, contribuindo para uma redução da necessidade de procura.

Por outro lado, as centrais hídricas de albufeira costumam marcar presença na zona alta da curva, visto que o seu custo de oportunidade é elevado em função do preço que espera receber noutro momento no mercado ou em função da tecnologia substituída. Em contrapartida, as centrais hídricas de fio-de-água surgem normalmente na zona baixa da curva, dada a sua incapacidade de armazenamento de água para outras alturas.

Na zona intermédia da curva de oferta situam-se as centrais a gás natural de ciclo combinado e as centrais térmicas a carvão, que são ordenadas tendo em conta os seus rendimentos e as condições dos seus contratos de fornecimento de combustível.

Por último, na zona superior da curva de oferta estão presentes habitualmente as centrais térmicas a fuelóleo, que, para o caso português, tiveram uma grande importância para a cobertura

da procura de energia elétrica durante algumas situações extremas que ocorreram durante o ano, quando uma grande parte da potência hídrica apresentava reservas escassas.

2.3.1.2 Caracterização da curva de procura

Relativamente à curva da procura, a procura correspondente aos fornecimentos regulados costuma aparecer na parte superior da curva. Por outro lado, a zona baixa e a zona intermédia da curva de procura costumam albergar o consumo correspondente às centrais hídricas com bombagem e aos comercializadores para os seus fornecimentos no mercado livre.

De realçar ainda que, desde 1 de Julho de 2008, com o desaparecimento da tarifa integral de alta tensão, se verificou um aumento acentuado na quantidade de energia adquirida pelos comercializadores para os seus fornecimentos em Espanha. Em Portugal, e motivado pela definição de um défice *ex ante*, e pela incorporação, nas tarifas reguladas, de um custo mais elevado ao real para a energia prevista, verificou-se também um aumento das compras por parte dos comercializadores.

2.3.1.3 Preço de equilíbrio do mercado

O preço de equilíbrio do mercado (preço de encontro) em cada hora, é obtido através da interseção entre a curva de oferta (linha azul) e a curva de procura (linha vermelha), como se pode ver na figura 2.2.




Figura 2.2: Obtenção do preço de equilíbrio do mercado. [62]

2.3.2 Mercado Intradiário

O mercado ibérico intradiário foi concebido para funcionar como um mercado de ajustes. O seu objectivo passa por disponibilizar uma adequação entre a oferta e a procura mais precisa e

próxima do tempo real que aquela permitida pelo mercado diário. Desta maneira, resolvem-se possíveis desajustes em sucessivas etapas da programação diária.

No mercado intradiário, e com o objectivo de rectificar as suas posições anteriores, os agentes com uma posição natural vendedora (produtores) também podem comprar energia, e os agentes com uma posição natural compradora (comercializadores) também podem vender energia.

O mercado intradiário do MIBEL confere uma grande flexibilidade à operação dos agentes, permitindo um grau de otimização bastante considerável do portfólio, de acordo com as necessidades de cada agente, numa variedade de horizontes temporais e com as mesmas garantias a nível de transparência e de possibilidades de supervisão que caracterizam o mercado diário.

O mercado intradiário está dividido em enúmeras sessões (6 no total) realizando-se em cada uma delas uma intersecção de índole marginal entre a oferta e a procura. Como se pode ver na figura 2.3, a primeira sessão abrange 28 horas (as últimas 4 no dia D-1 e as 24 do dia D), a segunda sessão abrange 24 horas (24 do dia D), a terceira sessão abrange 20 horas (últimas 20 horas do dia D), a quarta sessão abrange 17 horas (últimas 17 horas do dia D), a quinta sessão abrange 13 horas (últimas 13 horas do dia D) e por último a sexta sessão abrange as últimas 9 horas do dia D.




Figura 2.3: Estrutura por sessões do mercado intradiário do MIBEL. Fonte: OMEL

2.3.3 Separação de mercados

Em determinadas alturas, e visto que se trata de um mercado ibérico, constituído por Portugal e Espanha, existem momentos em que a utilização de interligação entre os dois países excede a sua capacidade. Nestas alturas, é possível presenciar o fenómeno de *market splitting* ou separação de mercados entre os dois países, que passam então a operar individualmente, período este onde se verificam preços específicos para cada um deles. Na figura 2.4 é possível observar a sequência de acontecimentos que leva à ocorrência deste fenómeno. Ainda assim, o spread existente entre os preços horários Espanha-Portugal é bastante reduzido acentuando-se nas horas de vazio e nas horas cheias.




Figura 2.4: Diagrama representativo da ocorrência de *market splitting*. [62]

2.4 Mercado a Prazo

O mercado a prazo tem como objetivo o estabelecimento de contratos de compra e venda de energia eléctrica a longo prazo (semana, mês, trimestre, e ano). Desta maneira, a entidade responsável pela gestão deste mercado, o OMIP, oferece os seguintes instrumentos para estabelecimento dos contratos:

- Contratos Futuro - contratos de compra ou venda de energia para um determinado horizonte temporal, em que o comprador estabelece o compromisso de compra de electricidade num dado período de entrega, comprometendo-se o vendedor a colocar essa mesma electricidade, por um preço determinado, aquando da transacção. Os ganhos e perdas resultantes das

flutuações de preços durante a fase de negociação neste tipo de contratos, são liquidados numa base diária. Segundo o OMIP, os produtos mais transacionados no mercado a prazo são os contratos Futuro

- Contratos Forward - são contratos bastante semelhantes aos contratos Futuro, havendo apenas uma diferença na forma de liquidação dos ganhos e perdas, que nesta situação contratual apenas ocorre durante o período de entrega e numa base mensal;
- Contratos SWAP - contratos em que é feita a troca de posição em preço variável por uma posição de preço fixo ou vice-versa, dependendo do sentido da troca. A sua função passa por fazer a gestão ou toma de risco financeiro, não se verificando entrega física do produto a que se referem, mas apenas a liquidação das margens correspondentes.

Capítulo 3

Estado da Arte

Neste capítulo pretende-se demonstrar as principais metodologias utilizadas na previsão de preços de eletricidade.

3.1 Introdução

Desde que se assistiu ao desregulamento da indústria de energia elétrica, surgiu a necessidade dos seus participantes se encontrarem no mercado de energia para decidir o preço da eletricidade. Devido à sua extrema volatilidade, a previsão de preços de eletricidade (PPE) emergiu como um ramo interessante de investigação na engenharia eletrotécnica/elétrica. A PPE tornou-se então numa ferramenta essencial para as empresas de energia no que diz respeito às decisões a tomar e estratégias de desenvolvimento a seguir.

As aplicações da PPE recaem normalmente sobre três tipos de horizonte temporal, nomeadamente PPE a curto prazo, a médio prazo e ainda a longo prazo. No entanto, não existe um consenso acerca dos limites de cada uma delas. A PPE a longo prazo influencia as decisões a nível da expansão ou melhoramento das redes de transmissão de energia, o aumento da capacidade de geração, o planeamento das redes de distribuição bem como possíveis trocas de energia regionais, na medida em que é utilizada na análise da rentabilidade destes possíveis investimentos e planeamentos mencionados. A PPE a longo prazo é normalmente efetuada e medida em anos. As PPE a médio prazo, normalmente utilizadas para horizontes temporais mensais (alguns dias a alguns meses), são cruciais para cálculos de balanço e avaliação do risco bem como para as negociações de contratos bilaterais entre fornecedores e consumidores. Por último, a PPE a curto prazo engloba previsões de alguns minutos até alguns dias depois, e tem uma influência direta no mercado de energia. Um fornecedor de energia com a capacidade de prever preços spot pode ajustar o seu plano de produção adequadamente para obter o máximo de benefícios (maximização dos lucros). Por outro lado, os consumidores podem criar um plano para maximizar os seus serviços utilizando a energia elétrica adquirida no mercado, ou então usufruir de uma possível capacidade de auto-produção de energia elétrica para se protegerem contra os preços elevados que poderão surgir no

mercado spot. No entanto, a PPE a curto prazo, assume a sua maior importância no mercado spot de propostas diárias (*day ahead spot market*).

Numa altura em que o panorama atual nos fornece um elevadíssimo número de abordagens ao problema da PPE, e considerando as características e o comportamento único da variável preço (aleatoriedade, volatilidade e sazonalidade), torna-se imperativo saber qual a metodologia a utilizar.

3.2 Panorama geral dos modelos de previsão

Com pesquisa efetuada, verificou-se a existência de enúmeros métodos que podem ser aplicados na PPE. A classificação que se segue foi baseada em [3], [4] e [9]. As diferentes abordagens podem ser divididas nas seguintes categorias:

- **Modelos Multi Agente** (*Equilibrium, Game Theoretic, Simulação*);
- **Modelos Fundamentais** (Estruturais);
- **Modelos Quantitativos** (Estocásticos, Forma Reduzida);
- **Modelos Estatísticos** (Séries Temporais, Econométricos);
- **Modelos baseados em Inteligência Artificial** (Redes Neurais Artificiais, *Fuzzy Logic, Neuro-Fuzzy*);

De realçar ainda a existência de modelos híbridos que consistem na combinação de dois ou mais modelos das categorias apresentadas anteriormente.

3.3 Modelos Multi Agente

Este tipo de modelos engloba normalmente dois tipos de abordagens, nomeadamente modelos de custo de produção e ainda um outro grupo de modelos baseado em *game theory*.

3.3.1 Modelos de Custo de Produção

Os modelos de custo de produção têm a capacidade de prever preços a um nível horário (curto-prazo). No entanto, este tipo de modelos tem vindo cada vez mais a perder popularidade na medida em que não são muito úteis para os novos mercados competitivos que foram surgindo. Estes modelos eram apropriados principalmente para os mercados regulados com uma baixa incerteza no preço e uma estrutura estável. Para fazer face a este problema foi criado um novo modelo estratégico de custo de produção. Neste modelo, cada participante do mercado, tenta maximizar os seus lucros, tendo em consideração os seus custos estruturais e as ações esperadas dos seus concorrentes. Esta operação é modelada através de um parâmetro estratégico que representa o declive da função de procura residual para cada nível de produção do gerador. Apesar de serem dotados de

algumas desvantagens, o seu principal trunfo reside na sua elevada velocidade computacional que o torna adequado para análises em tempo real. É possível observar a aplicação deste tipo de método no artigo [1].

3.3.2 *Equilibrium Models*

Este tipo de modelos é utilizado principalmente para a PPE em mercados sem histórico de preços, mas onde se sabem os custos de fornecimento e a concentração do mercado. Existem dois tipos de abordagens que têm sido utilizadas para modelar as estratégias dos participantes do mercado. A primeira consiste na utilização de uma combinação dos modelos de Cournot e Nash na qual a eletricidade é considerada como um bem homogéneo e o equilíbrio do mercado é obtido através das decisões tomadas pelos fornecedores de energia. No entanto, estes modelos, tendem a originar preços mais elevados em relação aos que se verificam na realidade. Em segundo lugar existe o chamado "*supply function equilibrium model*" que requiere a resolução de um conjunto de equações diferenciais. Os modelos de equilíbrio, para além do que foi dito anteriormente, são utilizados principalmente para a obtenção de resultados qualitativos em detrimento de resultados quantitativos. Exigem também um moroso processo computacional de otimização não adequado para situações reais. Não obstante, é necessário definir os participantes, as suas estratégias e a forma como interajem entre si o que representa um claro risco. Desta maneira, este tipo de modelos não é muito adequado para as operações diárias do mercado. Mais informações relativas a esta abordagem podem ser consultadas nos artigos [1-3] e [10-11].




Figura 3.1: Características de entrada e saída de um "*equilibrium model*". [3]

3.4 Modelos Fundamentais

Este tipo de métodos descreve a dinâmica dos preços tendo em conta o impacto de fatores físicos e económicos no preço da eletricidade. A sua utilização numa situação real implica a utilização de uma grande quantidade de dados, sendo que são normalmente utilizados para PPE a

médio-prazo. Na construção destes modelos, é necessário estabelecer algumas condições e suposições acerca de certas interações físicas e económicas presentes no mercado. Como tal, as PPE geradas através deste tipo de modelos são bastante sensíveis a um incumprimento destas condições. Da mesma forma, quanto mais detalhado for o modelo, mais complicada será a otimização dos parâmetros e mais simplificações terão de ser feitas conduzindo a um maior risco na aplicação deste tipo de modelo. Informação adicional acerca deste método pode ser consultada em [4].

3.5 Modelos Quantitativos

Este tipo de modelos, maioritariamente utilizados na área financeira, têm como principal função a caracterização das propriedades estatísticas dos preços de eletricidade. A sua aplicação reside na avaliação de derivados financeiros e na gestão de risco. Esta abordagem requiere o conhecimento de algumas noções financeiras, nomeadamente, o conceito de *Risk Premium* e a diferença entre a previsão de preço spot e preço futuro. *Risk Premium* é a recompensa que se obtém por efetuar um investimento de risco em vez de um investimento sem risco algum. Representa a diferença mínima entre o valor esperado de um investimento que um participante está disposto a fazer e o valor certo (sem risco) ao qual o participante é indiferente. Uma previsão de preço spot representa uma estimativa do valor do preço numa determinada altura no futuro. Por outro lado, o preço futuro representa o preço atual que um comerciante está disposto a pagar hoje pela entrega de eletricidade no futuro ou seja, o valor da previsão de preços spot menos o *risk premium*.

A relação existente entre os preços spot e os preços futuros requiere um cuidado extra aquando da construção do modelo de previsão. Tal como já foi mencionado, os modelos quantitativos são usados para recriar as principais características dos preços de eletricidade em detrimento da obtenção de PPE precisas. Assim, um modelo correto será aquele que conseguir aliar esta capacidade a um esforço computacional reduzido para que o modelo possa ser utilizado em situações reais. Desta maneira, existem duas abordagens que conjugam estas duas necessidades, designadamente os *Jump-Diffusion models* e os *Markov Regime-Switching models*.

3.5.1 *Jump-Diffusion models*

Este tipo de abordagem permite recriar com sucesso a ocorrência de spikes (ver definição na secção 4.1) e ainda a capacidade de *mean-reversion* (capacidade dos preços regressarem ao seu valor normal após a ocorrência de um spike). De uma maneira geral, os modelos *Jump-Difusion* podem ser aplicados na PPE através da seguinte equação diferencial estocástica:

$$dP_t = \mu(P_t, t)dt + \sigma(P_t, t)dW_t + dq(P_t, t) \quad (3.1)$$

W_t - representa um movimento browniano responsável pela criação de pequenas flutuações;

$q(P_t, t)$ - representa o processo da criação de "saltos"(jumps) responsável pela produção de grandes saltos positivos onde (P_t, t) representa uma distribuição de Poisson com a intensidade requerida e a gravidade dos saltos.

$u(P_t, t)$ - utilizado para forçar a mean reversion para um valor constante a longo prazo

$\sigma(P_t, t)$ - representa a volatilidade, normalmente dado por um valor constante.

A questão chave da utilização deste modelo reside na calibração efetuada, ou seja, o processo de estimação dos parâmetros mencionados anteriormente. Adicionalmente também se poderão fazer algumas suposições acerca do comportamento dos preços para a obtenção de um modelo mais rigoroso e que produza resultados válidos. Analisando os artigos [5-7] é possível observar algumas aplicações deste tipo de modelos bem como o uso de modelos híbridos dos mesmos.

3.5.2 Markov Regime-Switching models

O objetivo destes modelos consiste em modelar o comportamento estocástico observado de uma determinada série temporal, em duas ou mais fases ou regimes diferentes recorrendo a processos distintos. Isto significa que os parâmetros de um determinado processo podem mudar durante um certo período de tempo e depois voltar à sua estrutura inicial. Assim, para cada regime, é possível definir processos separados e independentes. O mecanismo de transição entre regimes é determinado por uma variável aleatória.

Por exemplo, o preço spot pode demonstrar uma reduzida ou elevada volatilidade dependendo do regime em que se encontra. Conhecendo as probabilidades de transição entre regimes, é possível, através da aplicação de processos de Markov, calcular a probabilidade de o preço estar a um determinado valor numa determinada altura do tempo.

Assim, esta abordagem tem a vantagem de permitir a modelação correta das variações dos preços spot e principalmente da ocorrência de spikes. A construção de um modelo válido depende primeiramente de uma correta definição da quantidade de estados que se assume que o valor do preço pode tomar. Posteriormente, é necessário também proceder a uma minuciosa calibração para estimação dos parâmetros e definição dos valores limite de cada regime. No entanto, esta abordagem não tem sido ainda muito utilizada para a PPE devido aos fracos resultados que produz. O artigo [8] mostra a aplicação deste modelo sendo que mais informação pode ser encontrada em [4], [16] e [24].

3.6 Modelos Estatísticos

Os modelos estatísticos são baseados na análise de estatísticas geradas pela atividade do mercado. Utilizam vários tipos de informação tais como os preços horários históricos, índices temporais (hora, dia da semana, mês), consumos, temperatura, custo dos combustíveis, valores de importação e exportação de energia entre outros. A característica sazonal dos preços de eletricidade faz com que a utilização de modelos estatísticos consiga produzir resultados muito positivos na PPE durante os períodos em que o preço se mantém normal, sem a ocorrência de spikes. Na

figura 3.2 é possível observar um exemplo de um modelo geral estatístico com as respectivas variáveis de entrada e saída. Como se pode ver, é possível considerar como entradas a produção hídrica, o histórico dos preços, índices temporais, preço dos combustíveis, importações/exportações, histórico do volume transacionado entre outros. Como saídas, este tipo de modelos, permite obter, para além do preço spot de mercado, o intervalo de confiança e ainda análises de volatilidade. No artigo [3] pode ser consultada informação adicional sobre este modelo e ainda resultados da sua aplicação.




Figura 3.2: Exemplo de um modelo estatístico. [3]

3.6.1 Técnicas ARMA, ARIMA

A construção de modelos estatísticos envolve a utilização de vários tipos de técnicas diferentes. A primeira técnica em análise tem em consideração a natureza aleatória dos preços de eletricidade e a sua correlação com o tempo e dá pelo nome de ARMA - *AutoRegressive Moving Average*. Na técnica ARMA(p,q), o preço atual P_t é expresso linearmente em função dos seus valores passados p (parte autoregressiva) e ainda em termos dos seus valores passados de ruído q (moving average part). A abordagem ARMA assume que a série temporal em análise é estacionária. No caso de não se verificar a estacionariedade da mesma é necessário recorrer a um processo de diferenciação.

A abordagem resultante é conhecida como ARIMA sendo que a sua única diferença reside na inclusão de diferenciação na formulação do modelo. Esta técnica pode ainda adotar outro formato, SARIMA - *Seasonal ARIMA*, caso a diferenciação seja efetuada a um lag periódico descontínuo.

Tanto o ARMA como o ARIMA são técnicas importantes para o caso em estudo. No entanto, é sabido que os preços de eletricidade são afetados não só pelos seus valores passados, mas também




Figura 3.3: Série não estacionária



Figura 3.4: Série estacionária (após diferenciação)

por variáveis exógenas futuras tais como perfis de consumo ou condições do tempo. Assim, a inclusão de tais variáveis levou à introdução de novas técnicas, denominadas ARMAX, ARIMAX ou SARIMAX que podem ser definidas através de uma função de transferência. Os modelos que utilizam este tipo de abordagens são também conhecidos como *transfer function models* e *dynamic regression models* havendo no entanto uma grande discrepância na literatura em relação à distinção entre todos eles. No que toca às suas aplicações, estas técnicas têm sido muito utilizadas para a PPE a curto-prazo apresentando resultados muito favoráveis em relação às abordagens standard ARMA e ARIMA. Para analisar mais informações e resultados obtidos através da aplicação destes métodos, é possível consultar os artigos [2] e [12-15].

3.6.1.1 Técnicas AR, ARX-type

O modelo autoregressivo é muito utilizado para a previsão de consumos mas também tem sido usado para a PPE, com resultados positivos. Sendo um subtipo do ARMA e ARMAX, o modelo AR parte do pressuposto que um determinado valor P_t é a combinação linear dos seus valores passados. Assim, é possível utilizar o AR para prever valores futuros de P . Mais informação acerca deste modelo pode ser consultada em [8].

3.6.2 Threshold AR

Este modelo tem um modo de funcionamento semelhante ao descrito em 3.5.2. O *Threshold Autoregressive* assume que os regimes são especificados pelo valor de uma determinada variável v_t relativa a um valor limite (*threshold value*) T . Por outras palavras, isto significa que as séries temporais de preços são divididas em diferentes partes e analisadas individualmente com a respetiva definição dos valores limites de cada uma.

Existe ainda o modelo SETAR (*Self-Exciting TAR*) onde o valor da variável limite é um valor presente na série temporal (neste caso, tratar-se-ia de um valor da série histórica dos preços). Este modelo pode ainda ser modificado de modo a permitir uma transição gradual entre os diferentes regimes, adquirindo a designação de *Smooth Transition AR* (STAR) model. Mais informação pode ser consultada nos artigos [8] e [17].

3.6.3 TARSW with wavelet filter

Este modelo utiliza simultaneamente o TARSW (*Threshold Autoregressive Switching*) com um *Wavelet filter*). O funcionamento deste modelo desenvolve-se através de uma análise dos históricos de preços e consumos em diferentes alturas. O *wavelet filter* é aqui aplicado com vista à diminuição do ruído que poderá influenciar as previsões futuras de preços. O restante processo decorre com aplicação de métodos autoregressivos, permitindo obter resultados com uma boa precisão. No artigo [36] é possível ver a aplicação deste método para um mercado de energia específico onde se utilizou também um processo de comutação para melhorar as previsões obtidas.

3.6.4 GARCH-type

Os modelos ARMA assumem a homoscedasticidade ou seja, uma função de variância e covariância constante. No entanto, as séries temporais de preços spot de eletricidade apresentam um comportamento não linear e uma característica de heteroscedasticidade, com a sua variabilidade futura a depender fortemente de valores passados.




Figura 3.5: Homoscedasticidade




Figura 3.6: Heteroscedasticidade

Sendo assim, surgiu a necessidade de resolver este problema com o aparecimento do modelo ARCH (*AutoRegressive Conditional Heteroskedastic*) proposto por Engle (1982) no qual a variância condicional de uma série temporal era representada por um processo auto-regressivo. Futuramente, Bollerslev (1986) "descobriu" que, ao permitir à variância condicional depender não apenas dos seus valores passados mas também de uma média móvel das variâncias passadas, o modelo resultante permitiria uma representação mais detalhada /minuciosa dos dados surgindo então o modelo GARCH (*Generalized AutoRegressive Conditional Heteroskedastic*).

O modelo GARCH em si próprio não se apresenta como uma solução viável para a PPE a curto prazo. No entanto, se associado com autoregressão ou um modelo mais geral (S)AR(I)MA, pode apresentar-se como uma opção atraente para o problema. O artigo [18] contém uma aplicação do GARCH para a PPE para o dia seguinte.

3.6.5 *Similar-Day Method, exponential smoothing*

O primeiro método - *Similar-Day Method* - consiste na pesquisa de dados históricos pertencentes a dias com características idênticas (*similar*) ao dia que está a ser alvo de previsão. Estas características podem incluir o dia da semana, dia do mês ou condições meteorológicas. Este método também é muito utilizado na PPE para dias especiais, nomeadamente os feriados. Estes dias não seguem a tendência natural do resto dos dias da semana e sua previsão acaba por assentar em dados históricos de feriados passados. Este é também muito utilizado para a previsão de consumos, que seguem uma tendência sazonal a nível semanal.

Exponential Smoothing é um tipo de abordagem que obtém os seus resultados através de uma média móvel exponencialmente ponderada de valores passados. Trata-se de uma abordagem robusta capaz de obter previsões com boa precisão. Estes modelos foram sendo aperfeiçoados ao longo do tempo de modo a permitir a integração de outros componentes, obtendo os seus resultados não só a partir de observações passadas mas também recorrendo a tendências (*smoothed*) e a características sazonais.

Para mais informação acerca destes dois tipos de modelos, é possível consultar [4].

3.7 Modelos baseados em Inteligência Artificial

A obtenção de modelos deste tipo exige a utilização de técnicas designadas como não-paramétricas que, consideram fundamentalmente a relação existente entre as entradas e as saídas (*input-output*) sem explorar os complexos procedimentos de modelação. São ainda capazes de reconhecer e aprender comportamentos e relações complexas e não-lineares que seriam impossíveis recorrendo a métodos convencionais. Isto faz com tenham uma grande e promissora performance quando aplicados à PPE a curto-prazo. É possível dividir estes modelos em duas categorias: ANN (*Artificial Neural Network*) e ainda *Data-mining models*.

3.7.1 *Redes Neurais Artificiais (Artificial Neural Network)*

As redes neurais artificiais baseiam-se em métodos desenhados para recriar o funcionamento do cérebro humano, adquirindo conhecimento através da experiência. Uma rede neuronal é composta por unidades idênticas à que se pode ver na figura 3.7. O modo de funcionamento de cada unidade consiste numa soma ponderada das suas entradas, às quais se adiciona um termo de polarização (termo constante). A sua saída está condicionada pela presença de uma função de ativação ou de transferência que pode ser de vários tipos: linear, sigmóide ou tangente hiperbólica.

A organização das unidades define a arquitectura ou topologia da rede neuronal. Nas redes unidireccionais ou redes de alimentação directa, cujo grafo não apresenta realimentação, as unidades são frequentemente distribuídas em camadas — redes multicamada — uma camada de entrada, uma ou mais camadas intermédias, também denominadas camadas escondidas, e uma camada de saída. As unidades em cada camada podem partilhar as mesmas entradas, mas não são conectadas umas às outras. A camada de entrada tem por objectivo adquirir os dados, sendo os dados




Figura 3.7: Estrutura de uma unidade pertencente a uma rede neuronal. [63]

propagados à camada seguinte sem qualquer processamento. Assim, os dados são processados apenas pelas unidades nas camadas escondidas e na camada de saída.

A topologia de uma rede neuronal unidireccional genérica com três camadas é apresentada na figura 3.8. A rede neuronal considerada é dita completamente interligada, visto que, toda a unidade pertencente a uma determinada camada está ligada a toda a unidade pertencente à camada adjacente.




Figura 3.8: Exemplo de uma rede neuronal. Fonte: ICMC-USP

Na criação de uma ANN, é importante ter em consideração o grau de complexidade da topologia da mesma. Um rede muito complexa, com demasiadas variáveis por exemplo, pode levar um aumento do ruído e consequente incapacidade de obtenção de resultados válidos - incapacidade de generalização dos dados. Em contrapartida, uma rede muito simples poderá resultar numa inaptidão para reproduzir corretamente os dados - sub-ajustamento dos dados. Na criação de uma ANN, é extremamente importante atingir um equilíbrio entre a complexidade e a simplicidade, de modo a capacitar a rede de um poder de processamento de dados credível.

A aplicação prática de redes neurais para a previsão de preços engloba dois processos distintos:

- O processo de treino, onde são utilizados dados históricos existentes, do qual fazem parte os valores das entradas e respectivas saídas. Utilizando estes dados, é então criada a rede de treino sendo que a obtenção de resultados válidos no processo de treino está dependente da qualidade e precisão dos dados utilizados. Na fase de treino é essencial evitar o sobre-treino da rede, isto é, a rede não deverá ser treinada durante um longo período de tempo, sob o risco de deterioração da qualidade das previsões obtidas¹.

- O processo de teste onde, recorrendo a um processo de aprendizagem, a ANN adquire um determinado conhecimento. Este conhecimento é posteriormente utilizado com um conjunto de dados de teste, onde a rede deverá ser capaz de reproduzir com o maior rigor possível dados nunca antes apresentados. O processo de aprendizagem baseia-se no ajuste dos pesos e polarizações existentes em cada iteração com vista à minimização do erro existente entre a saída prevista e a saída real.

As redes artificiais neuronais são uma das abordagens para o qual foram efetuados enúmeros estudos e com um grande número de aplicações no ramo da PPE a curto-prazo. Nos artigos [25-32] é possível observar algumas destas abordagens para diferentes cenários.

3.7.1.1 *Feedforward neural networks*

Nas redes neuronais *feedforward*, as conexões entre as diferentes unidades apresentam uma única direção. Assim, a informação move-se desde os inputs, passado pelas camadas escondidas até aos outputs, não havendo ciclos ou loops, como se pode ver na figura 3.9.




Figura 3.9: Modo de funcionamento feedforward. [64]

¹Normalmente, com o decorrer do processo de otimização durante o treino da rede, o erro de treino diminui, verificando-se também uma diminuição do erro de teste. No entanto, um sobre-treino da rede conduzirá evidentemente a um erro de treino menor, não se verificando o mesmo com o erro de teste que poderá aumentar.

A utilização deste tipo de modelos juntamente com um algoritmo de aprendizagem de retropropagação é uma ótima escolha para endereçar o problema da PPE e é dos mais utilizados em vários estudos. O algoritmo de retropropagação é basicamente um processo de retropropagação dos erros presentes nas camadas de saída diretamente para as camadas de entrada durante o treino da rede. A retropropagação é realmente necessária pois as camadas escondidas da rede não possuem valores alvo, ou seja, as unidades de cada camada deverão ser treinadas de acordo com os erros das camadas anteriores. A camada de saída possui um valor alvo que é usado para se comparar com o valor calculado. À medida que os erros se vão retropropagando pelas unidades da rede, as conexões vão sendo atualizadas e o treino decorrerá até que os erros nas conexões atinjam um valor suficientemente pequeno para ser aceite.




Figura 3.10: Esquema representativo do modo de funcionamento do algoritmo de retropropagação. [66]

3.7.1.2 Recurrent neural networks

Uma rede neuronal recorrente é um tipo de redes neuronais onde as conexões entre as diferentes unidades formam um ciclo direcionado, criando um estado interno na rede que permite que a mesma exiba um comportamento dinâmico temporal como se pode ver na figura 3.11. Ao contrário das redes neuronais feed forward, as recorrentes podem usar a sua memória interna para processar diferentes sequencias de entradas.

3.7.1.3 Fuzzy neural networks

A lógica Fuzzy/difusa é uma generalização da lógica booleana usada no desenvolvimento de circuitos digitais. Segundo a lógica booleana, uma entrada pode assumir os valores 1 ou 0. Segundo uma lógica fuzzy, estão associados a uma entrada vários intervalos cada qual com uma determinada classificação. As redes neuronais difusas apresentam como principal vantagem o facto de não necessitarem de modelos matemáticos no processo que decorre entre as entradas e as saídas. A sua utilização não requer uma extrema precisão das entradas tornando esta abordagem robusta e muito utilizada para a previsão de consumos e preços de eletricidade. Nos artigos [19-21] são mostradas várias aplicações e testes efetuados com redes neuronais Fuzzy.




Figura 3.11: Modo de funcionamento recurrent. [65]

3.7.1.4 *Self-adaptive radial basis function neural network*

Este trata-se de um método evolucionário auto-adaptativo baseado na função radial das redes neurais onde são aplicados algoritmos de enxame FCM *Fuzzy c-means* e de evolução diferencial que são usados para a configuração dos parâmetros de entrada para a rede neuronal. É possível observar a aplicação deste método no artigo [37] onde o histórico do preço foi a única variável de entrada considerada.

3.7.1.5 *Redes neurais em cascata*

Este modelo tem um grande número de aplicações na PPE para o dia seguinte. Utilizando as redes neurais como base, este método recorre também a um algoritmo com capacidade de filtragem dos valores das variáveis de entrada com uma elevada correlação com as saídas. Assim, é possível eliminar as variáveis de entrada de menor relevância e posteriormente as variáveis de entrada redundantes, diminuindo o erro e o ruído introduzido pelas mesmas. O artigo [38] mostra a aplicação deste método onde as variáveis de entrada consideradas foram o histórico de preços e consumos.

3.7.1.6 *Support vector machines*

Support vector machines é uma abordagem recente, criada a partir de outros modelos tradicionais existentes. Trata-se também de uma técnica robusta usada para resolver problemas de regressão e classificação através da análise de dados e reconhecimento de padrões/tendências. Este método utiliza mapeamento não-linear dos dados para um espaço dimensional específico, sendo

que a obtenção de resultados válidos está dependente da precisão do kernel escolhido. No artigo [34], é possível analisar uma aplicação desta abordagem.

3.7.2 *Data-mining models*

Existem vários tipos de técnicas de *Data-mining* usadas para interpretação e dedução de dados. As mais utilizadas são: *Bayesian categorization method* [34-35], *closest k-neighborhood categorization*, *reasoning based categorization*, *genetic algorithm based categorization*. Para uma melhor compreensão deste tipo de metodologia, é possível analisar o artigo [33] e adicionalmente [4] e [9].

3.8 Aplicações

A presente secção têm como objetivo enumerar várias aplicações de alguns modelos e técnicas previamente descritos para o mercado Ibérico e também para o mercado de eletricidade espanhol.

No artigo [40] é utilizada uma rede neuronal *feedforward* de três camadas treinada com o algoritmo de Lavenberg-Marquardt de modo a obter PPE para o dia seguinte. É avaliada a precisão das previsões obtidas e são mostrados resultados para o mercado de eletricidade espanhol e californiano (dados de 2002). Uma abordagem mais completa utilizando redes neuronais é possível ser vista nos artigos [50] e [56]. O desenvolvimento de redes neuronais é aqui testado para a obtenção de PPE a curto prazo para o mercado de eletricidade espanhol utilizando dados de 2001/2002.

No artigo [41] é possível verificar a utilização de uma metodologia híbrida inteligente baseada na *wavelet transform* e que utiliza um conjunto de redes neuronais e lógica fuzzy com vista à obtenção de PPE a curto prazo para o mercado espanhol (dados de 2002).

No artigo [43] é construído um modelo de PPE para o dia seguinte utilizando a técnica ARIMA anteriormente descrita. Mais uma vez, o mercado analisado é o espanhol sendo utilizados dados referentes ao ano de 2000. O artigo [45] contém uma abordagem semelhante ao problema, utilizando também técnicas ARIMA para a obtenção de PPE para o dia seguinte. A utilização deste tipo de técnicas pode ainda ser vista no artigo [53] onde foi aplicada para o mercado Ibérico.

O artigo [44] mostra a aplicação de redes neuronais, a análise de séries temporais e ainda a utilização de um filtro *wavelet* para a obtenção de PPE para o mercado de eletricidade espanhol (dados de 2002). É efetuada a comparação entre as diferentes abordagens e analisada a precisão e performance individual de cada modelo utilizado.

Analisando o artigo [46] é possível observar uma série de aplicações de diferentes abordagens ao mercado de eletricidade espanhol (dados de 2007 e 2008). Os métodos utilizados incluem o *Double Seasonal ARIMA*, *Exponential Smoothing with Double Seasonality*, modelos de regressão dinâmica e de regressão periódica dinâmica bem como uma abordagem com redes neuronais. Pretende-se analisar a performance dos diferentes modelos bem como a influência da produção de energia eólica e do dia da semana na PPE para o dia seguinte.

No artigo [47] é estudada a utilização e aplicação do método GARCH para a obtenção de PPE para o dia seguinte, para o mercado espanhol e californiano.

Outros artigos incluem abordagens de *Input/Output Hidden Markov Models* [51], a utilização de modelos econométricos [52], *Weighted Nearest Neighbors Techniques* [54], *Hybrid PSO-ANFIS approach* [57] e ainda métodos funcionais não-paramétricos [58].

Capítulo 4

Características e fatores de influência dos preços MIBEL

Neste capítulo apresentam-se alguns factos e características importantes dos preços de eletricidade bem como os fatores que mais influenciam a variabilidade dos mesmos. Adicionalmente serão apresentados gráficos com dados do mercado MIBEL de 2012 e 2013 para sustentar algumas das afirmações.

4.1 Picos nos preços (*Price Spikes*)

Uma das características mais notória dos preços de eletricidade é a sua extrema volatilidade. Isto significa que, ao longo do ano, se podem verificar variações bruscas nos preços spot às quais, vulgarmente se dá o nome de *spikes* ou *jumps*. Nas figuras 4.1 e 4.2 podemos comprovar a característica volátil que distingue os preços de eletricidade e ainda observar alguns dos *spikes* mais relevantes que ocorreram durante os anos de 2012 e 2013 no mercado MIBEL.




Figura 4.1: Perfil horário de preços spot do MIBEL com identificação de spikes relevantes durante o ano 2012

Apesar de estar representado na figura 4.2 a ocorrência de spikes no final do ano de 2013, não se trata de facto de spikes mas sim de um caso especial de preços elevados que será motivo de estudo mais à frente neste capítulo.




Figura 4.2: Perfil horário de preços spot do MIBEL com identificação de spikes relevantes durante o ano 2013

De uma maneira geral, os spikes dos preços podem ser definidos como os valores dos preços que ultrapassam um determinado limite por um curto período de tempo. A intensidade com que os spikes ocorrem não é homogênea durante o tempo e acontece habitualmente durante os períodos de maior consumo de eletricidade. No caso do mercado ibérico, a maior ocorrência de spikes verifica-se durante o Inverno, como podemos ver nas figuras 4.1 e 4.2. No entanto, é importante realçar que estes spikes têm normalmente uma amplitude temporária na ordem das horas. Os preços spot podem aumentar consideravelmente e regressar passado pouco tempo depois ao seu valor anterior, sem que nada o faça prever. Na figura 4.3 podemos observar a ocorrência de um spike, no qual se verifica um aumento no valor do preço na ordem das dezenas de euros em apenas poucas horas.

Os spikes são responsáveis por grande parte da variação dos preços spot e algumas empresas não estão preparadas para lidar com este tipo de situação. O risco inerente de um possível surgimento de spikes pode ser muito prejudicial para uma empresa que pode ver os seus lucros desaparecerem num curto espaço de tempo. Apesar de os spikes não ocorrerem com grande frequência, é necessário assegurar algum tipo de proteção contra possíveis variações dos preços de eletricidade.

A natureza volátil dos preços de eletricidade é uma consequência direta da incapacidade de armazenar eletricidade. A eletricidade que será entregue a uma determinada hora, não pode ser substituída por eletricidade que esteja disponível um pouco antes ou depois. Como não existe ainda um processo de armazenar elevadas quantidades de energia, a mesma terá de ser consumida à medida que é produzida. Assim, variações bruscas no consumo (causadas por condições climáticas adversas juntamente com falhas de energia ou da rede de transmissão) podem levar à ocorrência de spikes.




Figura 4.3: Spike ocorrido em Maio de 2013

4.1.1 O que origina os spikes?

A resposta à pergunta reside na forma como o valor dos preços de eletricidade é obtido, através da conjugação entre a oferta (produção) e a procura (consumo) de energia elétrica. Quando o consumo é elevado, e uma grande parte da energia elétrica provém de fontes de energia expensivas, basta que haja um pequeno aumento no consumo para que o valor dos preços suba consideravelmente. Assim, quando o consumo diminui, o preço pode descer rapidamente ao seu valor normal, visto que os meios de produção que implicam mais custos já não são necessários. Da mesma maneira, mesmo que o consumo se mantenha constante, os spikes podem aparecer, caso os meios de produção mais baratos sejam retirados de serviço. Existem vários fatores que influenciam a oferta de energia elétrica, entre os quais se destacam: a flutuação dos preços dos combustíveis, retirada de serviço de centrais (devido a operações de manutenção ou avarias que possam surgir), constrangimentos ao nível da rede de transmissão e ainda a utilização do poder de mercado.




Figura 4.4: Esquema que mostra a oferta de energia com duas curvas de consumo hipotéticas. Mostra também o preço spot, dado pela interseção entre a oferta e o consumo. [4]

No entanto, o principal motivo que origina o aparecimento de spikes consiste nas estratégias de licitação usadas pelos participantes no mercado. Como a eletricidade é um bem necessário para a sociedade, muitos destes agentes no mercado acabam por pagar praticamente qualquer preço para assegurar um fornecimento de energia elétrica contínuo e suficiente. Assim, alguns destes agentes colocam com alguma regularidade ordens de compra, ao preço máximo permitido, pela quantidade

de eletricidade que esperam necessitar para uma determinada hora. Como os fornecedores de energia estão cientes deste tipo de estratégias, estes colocam as suas ofertas adequadamente, com o objetivo de maximizar os seus lucros.

4.2 Sazonalidade

As flutuações sazonais no fornecimento e no consumo de energia elétrica traduzem-se num comportamento sazonal dos preços de eletricidade, particularmente nos preços spot. Se analisarmos o perfil dos preços spot para o mercado MIBEL a uma escala anual, verifica-se a existência de preços mais elevados durante os meses de Inverno e preços mais baixos durante os meses de Verão como podemos ver na figura 4.5.




Figura 4.5: Evolução do preço da eletricidade para o MIBEL (2010-2013)

Existem ainda mais duas situações onde se pode verificar também a característica sazonal dos preços spot, nomeadamente se analisarmos a evolução dos preços a nível semanal e também a um nível diário. Na figura 4.6 podemos ver a variação semanal dos preços de eletricidade onde se verifica que os preços de eletricidade são de facto mais elevados durante os dias úteis da semana (Segunda a Sexta) em relação aos valores verificados durante o fim-de-semana. Tal se deve ao facto de grande parte das empresas, negócios, lojas, etc, se encontrarem fechados ao Sábado e ao Domingo. A razão pela qual se escolheram duas semanas de duas estações do ano distintas serve para ilustrar a diferença de preços entre o Verão e o Inverno mencionada anteriormente.

Adicionalmente, podemos comprovar a correlação existente entre o dia da semana e os preços analisando o gráfico scatter da figura 4.7. A linha de tendência mostra-nos de facto o que já foi dito anteriormente, ou seja, que os preços de eletricidade são mais elevados durante a semana (dias úteis representados por 2,3,4,5,6) quando comparados com o fim-de-semana (1 e 7) e feriados (8).

Por último, resta-nos analisar a evolução dos preços a nível diário. Mais uma vez, recorrendo a um gráfico scatter podemos constatar a correlação existente entre os preços de eletricidade e a hora do dia. Na figura 4.8 podemos observar a tendência dos preços ao longo de 24 horas, que




Figura 4.6: Evolução do preço da eletricidade durante duas semanas distintas

atingem os seus valores mais elevados em duas alturas diferentes do dia. O primeiro pico verifica-se durante a manhã, numa altura em que normalmente as pessoas se levantam e se dirigem para o seus trabalhos. O segundo pico dá-se ao final da tarde quando as pessoas saem dos trabalhos e chegam a casa.




Figura 4.7: Correlação existente entre o preço da eletricidade e o dia da semana.

A sazonalidade é uma característica muito importante dos preços de eletricidade e pode ser observada em diferentes escalas temporais. Ficou comprovado que o dia da semana e a hora do dia são duas variáveis com uma forte influência nos preços de eletricidade do MIBEL, e como tal, a sua inclusão em modelos de PPE deve ser obrigatória para a obtenção de resultados válidos. Muitos modelos de PPE utilizam também o mês do ano como variável de entrada para explicar a




Figura 4.8: Correlação existente entre o preço da eletricidade e a hora do dia.

diferença de preços existente de Janeiro a Dezembro. No entanto, muita desta informação acaba por estar "contida" na variável temperatura e como tal, por vezes o seu uso é desnecessário.

4.3 Fatores Meteorológicos

4.3.1 Temperatura

No que toca a PPE a curto-prazo, e para além dos fatores temporais, são as condições meteorológicas que têm a maior influência para a obtenção de boas previsões. Existem vários tipos de variáveis que podem ser incluídas, mas a temperatura é sem dúvida uma das mais importantes.




Figura 4.9: Correlação existente entre o preço da eletricidade e a temperatura. Dados de temperatura registados às 9 horas da manhã de todos os dias de 2013

Os preços spot sofrem variações consoante as mudanças de temperatura como se pode ver no gráfico scatter da figura 4.9. Os preços são mais elevados quando se registam temperaturas baixas (5°C) ou temperaturas elevadas ($> 20^{\circ}\text{C}$). A utilização de sistemas de aquecimento (Inverno) e arrefecimento/ar condicionado (Verão) traduz-se num aumento do consumo de energia elétrica e consequente aumento dos preços de eletricidade.

A variável temperatura desempenha um papel fundamental em qualquer modelo de PPE pois, para além do que foi mencionado anteriormente, contém ainda informação relativa à sazonalidade das estações do ano e explica o comportamento dos preços ao longo dos diferentes meses. Com uma forte componente sazonal, esta variável apresenta-se como um bom indicativo não só para a previsão de preços mas também para a previsão de consumos e previsão de produção solar fotovoltaica.

4.3.2 Vento

As energias renováveis e mais concretamente a energia eólica, representam uma grande fatia no mix produtivo da Península Ibérica. Atualmente, esta é região a nível Europeu, com maior consumo de energia proveniente da produção eólica. Utilizando como matéria prima a força do vento, esta fonte de energia apresenta um custo do MWh bastante mais reduzido quando comparado com as outras.

Estas características fazem do vento um fator preponderante nos preços de eletricidade no MIBEL. Apesar de na Península Ibérica as velocidades do vento apresentarem normalmente valores medianos, existem várias barragens equipadas com bombagem que permitem a utilização e armazenamento de energia eólica excedentária.




Figura 4.10: Correlação existente entre o preço da eletricidade e a velocidade do vento. Dados relativos ao ano 2013 - MIBEL

Analisando a figura 4.10, é visível a relação existente entre o preço e a intensidade do vento. Ventos mais fortes aumentam a produção de energia eólica, tendo como consequência direta uma redução nos preços de eletricidade e vice-versa. Assim, para o MIBEL, a intensidade do vento é dos fatores mais importantes que influenciam a variabilidade dos preços de eletricidade, podendo até ser considerado como o fator meteorológico mais determinante.

À partida, a conclusão que se retira é que a variável velocidade do vento é uma variável crucial e que deve fazer parte de qualquer tipo de modelo de PPE que se utilize caso se queira produzir boas previsões de preços.

4.4 Consumo

O consumo está diretamente relacionado com o preço da eletricidade, na medida em que apresenta também uma sazonalidade diária e semanal. De facto, como podemos ver na figura 4.11, o consumo segue exatamente a mesma tendência dos preços de eletricidade, isto, à medida que o consumo aumenta, os preços aumentam também. Da mesma maneira, verifica-se também uma tendência semelhante de redução dos preços de eletricidade nos casos em que o consumo é menor. Como já foi mencionado anteriormente, existem casos raros onde se verificam preços anormalmente elevados que se devem a uma falta de geração ou a um excesso anormal de consumo.




Figura 4.11: Correlação existente entre o preço da eletricidade e o consumo. Dados relativos ao mês de Janeiro de 2013 - MIBEL

Nas figuras 4.12 e 4.13 é possível analisar mais uma vez a influência que o consumo tem sobre a variabilidade dos preços. Segundo as linhas de tendência de ambos os gráficos scatter, verifica-se novamente uma incidência de preços mais elevados quando se registam também consumos elevados.




Figura 4.12: Relação entre a variável consumo D (MW) e o preço real




Figura 4.13: Relação entre a variável consumo D-6 (MW) e o preço real

4.5 Preço D e Preço D-6

Muitos modelos de previsão utilizam como únicas variáveis de entrada o histórico dos preços de eletricidade não considerando qualquer tipo de variáveis exógenas na sua implementação. Assim, tentou-se perceber de que maneira é que as variáveis do preço do dia (D) e do dia (D-6) influenciam a previsão de preços para o dia (D+1) e qual a sua relação com esta variável de saída que se pretende obter.

De facto, analisando as figuras 4.14 e 4.15, verifica-se a existência de uma relação quase linear entre ambas. A tendência é de que se o preço do dia anterior é elevado, então o preço do dia seguinte será também ele elevado. Claro está que esta relação nunca poderia ser totalmente linear ou então cair-se-ia num cenário em que o preço se manteria constante ao longo do tempo!

No capítulo 4 irá proceder-se à construção de um modelo deste tipo para se tentar perceber a sua performance no que toca à previsão de preços de eletricidade. Mais conclusões sobre estas variáveis e este assunto serão apresentadas no capítulo seguinte.




Figura 4.14: Relação entre a variável preço D e o preço real




Figura 4.15: Relação entre a variável preço D-6 e o preço real

4.6 A influência do despacho

O despacho tem uma influência vital na variabilidade dos preços de eletricidade. De seguida são feitas algumas análises de diferentes cenários de despacho verificados durante o ano de 2013 e a sua influência no preço da eletricidade.

4.6.1 Caso de estudo - Janeiro e Fevereiro de 2013

Nas figuras 4.16 e 4.17 é possível ver a energia colocada em mercado diário (MIBEL) para os meses de Janeiro e Fevereiro de 2013 de acordo com a sua proveniência. É apresentada ainda a variação do preço médio aritmético ao longo do mês. Tratando-se de dois meses que decorrem durante o Inverno, é possível desde já, observar uma elevada volatilidade dos preços para estes períodos de tempo. De facto, uma rápida análise permite-nos ver uma elevada discrepância no valor dos preços de eletricidade durante o mês de Janeiro que oscilaram entre os 20 Eur/MWh e os 70 Eur/MWh.

Durante o mês de Janeiro, a Península Ibérica apresentou um mix energético bastante alargado. Na figura 4.16 podemos ver que todas as fontes mais importantes de energia elétrica foram utilizadas. O peso da energia produzida a partir do regime especial foi grande situando-se nos 60% do mix de geração mensal. Esta componente teve valores particularmente mais elevados a partir da terceira semana do mês de Janeiro, resultando numa consequente diminuição do preço.

A energia produzida a partir de centrais hídricas foi muito reduzida para um mês de Inverno representando 12% do mix de geração total. De acordo com dados recolhidos em [39] no seguimento do que vinha a acontecer no final de 2012, o mês de janeiro caracterizou-se por ser um mês bastante seco o que levou a que os níveis de armazenamento de água apresentassem valores baixos. A quantidade de energia produzida a partir da tecnologia hídrica origina um comportamento do preço de mercado semelhante ao da produção em regime especial. Analisando o gráfico da figura 4.16, verifica-se que quando a percentagem de hídrica aumenta, o preço desce e quando a percentagem de hídrica é menor, o preço é maior.

Assim, e visto que o mês de Janeiro foi um mês atípico em termos meteorológicos, coube ao Carvão (15%) e às CCGT (7%) uma maior fatia no mix de geração mensal. Estas tecnologias têm custos marginais mais elevados que têm tendência a aumentar com o aumento da energia produzida provocando um aumento do preço de eletricidade no mercado diário.

A produção nuclear manteve-se praticamente constante ao longo do mês, pelo que estes gráficos não permitem perceber a sua importância no preço da energia.

No mês de Fevereiro, o preço médio aritmético foi de 45,04 Eur/MWh, ligeiramente menor quando comparado com o de Janeiro (50,50 Eur/MWh). Existem várias razões que explicam esta diminuição, entre as quais se destacam um aumento da produção de hídrica de 12% para 15% e um ligeiro, mas significativo aumento da produção de nuclear de 3% para 5% do mix de geração mensal como podemos ver na figura 4.17. O aumento da utilização destes dois tipos de tecnologias teve como consequência direta, uma menor necessidade da produção através do Carvão (desceu de 15% para 13%) e das CCGT (desceram de 7% para 4%).




Figura 4.16: Energia colocada em mercado diário e preços médio diário para o mês de Janeiro de 2013




Figura 4.17: Energia colocada em mercado diário e preços médio diário para o mês de Fevereiro de 2013

4.6.2 Caso de estudo - Março e Abril 2013

Os meses de Março e Abril de 2013 são aqui alvo de análise devido a algumas particularidades que caracterizaram o valor dos preços do mercado diário dos mesmos. Em primeiro lugar, realça-se uma grande diminuição no preço médio aritmético em ambos os meses quando comparados com Janeiro ou Fevereiro. O preço médio aritmético em Março foi de 26.67 Eur/MWh e em Abril foi de 18,17 Eur/MWh.

Analisando a figura 4.18 é possível verificar que estes dois meses apresentaram uma percentagem muito baixa de geração de energia a partir do Carvão e das CCGT o que, como já foi dito anteriormente, tem como consequência direta uma diminuição do preço de mercado diário.

Por se tratarem de dois meses bastante chuvosos com níveis de precipitação elevados, a componente hídrica aumentou consideravelmente quando comparada com Janeiro e Fevereiro. Assim, analisando-se os gráficos das figuras 4.19 e 4.20, verifica-se que o preço de mercado tende a diminuir quando a quantidade de energia produzida a partir da hídrica sobe, e a aumentar quando esta quantidade de energia diminui.

Apesar do papel relevante que o aumento de produção hídrica teve na diminuição dos preços de eletricidade, também a energia nuclear desempenhou uma função importante para que tal acontecesse. Consultando a figura 4.18 é possível verificar que houve um aumento da produção de energia nuclear durante estes dois meses. De facto, a energia nuclear, por ser uma energia barata, tem como influência uma diminuição no preço de mercado diário.

A importância da energia nuclear pode ainda ser comprovada se verificarmos que, alguns dos aumentos abruptos nos preços verificados em Março e Abril coincidiram exatamente com uma diminuição visível da produção de energia nuclear representada nos gráficos a cor preta. Esta influência encontra-se bastante evidenciada no gráfico 4.20 que representa o mês de Abril sendo que o défice de produção de energia nuclear foi imediatamente compensado pela entrada em serviço de centrais a carvão e algumas de CCGT.

	Janeiro	Fevereiro	Variação	Março	Abril	Variação	Julho	Agosto	Variação	Dezembro
Nuclear	3%	5%	2%	7%	12%	5%	4%	4%	0%	6%
Carvão	15%	13%	-2%	4%	2%	-2%	22%	22%	0%	20%
CCGT	7%	4%	-3%	1%	1%	0%	9%	9%	0%	9%
Hídrica	12%	15%	3%	26%	28%	2%	11%	9%	-2%	10%
PRE	60%	61%	1%	59%	56%	-3%	51%	53%	2%	53%
Outros	3%	2%	-1%	3%	1%	-2%	3%	3%	0%	2%

Figura 4.18: Percentagem de energia colocada em mercado diário e variações entre diferentes meses do ano de 2013.




Figura 4.19: Energia colocada em mercado diário e preços médio diário para o mês de Março de 2013




Figura 4.20: Energia colocada em mercado diário e preços médio diário para o mês de Abril de 2013

4.6.3 Caso de estudo - Julho e Agosto de 2013

A análise que se segue é feita para os meses de Julho e Agosto, dois meses de Verão. Em condições normais, os meses de Verão caracterizam-se por serem mais secos e apresentarem temperaturas mais elevadas em relação ao resto do ano, o que acaba por ter habitualmente como consequência, a diminuição da utilização de recursos hídricos para a produção de eletricidade.

De facto, analisando a figura 4.18, verificou-se que a percentagem de hídrica produzida durante estes meses foi relativamente baixa (11% e 9%). Como consequência, verificou-se um aumento da energia produzida a partir do carvão e das CCGT sendo que se verificaram os valores mais elevados de produção de eletricidade, a partir destes recursos (22% tanto em Julho como em Agosto).

Mais uma vez, a produção em regime especial acaba por ter a maior fatia no mix de geração mensal. No entanto, nos meses de Verão, a PRE não se encontra "monopolizada" pela produção eólica, havendo um aumento significativo da produção de solar fotovoltaico como é possível ver nas figuras [4.21-4.23] que representam a PRE durante um dia do mês de Agosto para Espanha.




Figura 4.21: Produção de Solar FV



Figura 4.22: Produção Eólica




Figura 4.23: Restante PRE

No que diz respeito à produção nuclear, a mesma manteve-se praticamente constante ao longo destes dois meses não tendo influência na variação dos preços de eletricidade.

É importante destacar também o caráter mais estável dos preços de eletricidade que apresentam apenas algumas variações que coincidem com os fins-de-semana onde o consumo é relativamente menor. De facto, como se poderá constatar mais à frente, a previsão dos preços de eletricidade para os meses de Verão é mais eficiente havendo uma maior facilidade na obtenção de boas previsões para este período.




Figura 4.24: Energia colocada em mercado diário e preços médio diário para o mês de Julho de 2013




Figura 4.25: Energia colocada em mercado diário e preços médio diário para o mês de Agosto de 2013

4.6.4 Caso de estudo - Preços elevados verificados durante o mês de Dezembro de 2013

Durante o mês de Dezembro de 2013, o preço da eletricidade no MIBEL atingiu o seu valor mais elevado em 10 anos ao chegar aos 93 euros/MWh. O preço médio aritmético durante este mês foi de 63,51 euros/MWh, valor este muito elevado quando comparado com o mês anterior (41,87 euros/MWh - Novembro 2013) e o mês seguinte (33,15 euros/MWh - Janeiro 2014).




Figura 4.26: Evolução do mercado diário - Preços médios diários e renda de congestionamento (Dezembro 2013, MIBEL)

O facto de o mês de Dezembro ter sido um mês muito frio, onde se registaram temperaturas mais baixas que o habitual, aliado ao facto de ter sido um mês com muito pouco vento provocou um aumento do consumo de energia e uma redução da oferta de energia "barata", tendo-se verificado uma subida drástica nos preços da eletricidade. No entanto, esta situação foi agravada devido à diminuição da produção de energia nuclear durante este mês. Esta diminuição da produção de energia nuclear não teria sido um problema, não fosse o facto de a mesma ter sido programada. A paragem programada de algumas centrais nucleares espanholas diminuiu em quase 4 GW a oferta de nuclear de aproximadamente 8 GW totais sobre uma procura (Consumo) de 30-35 GW.

Apesar de ter sido um mês particularmente bom para a produção de hídrica, o preço a pagar pela mesma acabou por ser bastante elevado. A diferença entre encerrar o mercado a 90 euros ou a 40 euros significa alguns milhões de euros a mais que vão diretamente para os bolsos das empresas produtoras de energia. Com o aumento da produção de energia nuclear, sensivelmente a partir de dia 22 de Dezembro (figura 4.27), verificou-se uma diminuição drástica no valor do preços de eletricidade (figura 4.26) para valores abaixo dos 10 euros/MWh.

Em jeito de conclusão, se o mercado funciona de forma eficiente, os preços normais da eletricidade para o MIBEL deveriam rondar os 40-45 euros. No entanto, a ocorrência de incidentes, o clima e principalmente o poder de mercado que se encontra concentrado em poucos produtores de energia, não permitem que tal aconteça.

Mais informações sobre este assunto podem ser consultadas nos seguintes artigos: [67-69]




Figura 4.27: Energia colocada em mercado diário (Dezembro 2013, MIBEL)

Capítulo 5

Modelos de previsão de preços MIBEL

No presente capítulo, é possível observar uma análise detalhada do processo de construção dos vários modelos de previsão de preços que foram utilizados ao longo deste trabalho. Adicionalmente, apresentam-se os resultados dos testes efetuados e algumas observações acerca dos mesmos.

Tal como já foi mencionado na secção 2.3.1, o preço é definido através de propostas de oferta e procura de energia, sendo estas mesmas propostas executadas em intervalos de tempo a nível horário. Assim, todos os modelos foram construídos utilizando dados de produção e consumo horários referentes ao mercado Ibérico.

A obtenção de todos os resultados foi possível recorrendo à criação de redes neuronais através da utilização do software MatLab. Todas as redes neuronais foram criadas utilizando um algoritmo de retropropagação de Levenberg-Marquardt. Como tal, esta metodologia envolve a utilização de dados de treino e dados de teste. Como se pode ver na figura 5.1, os dados de treino compreendem a totalidade do ano de 2012 ao passo que os dados de teste correspondem ao ano de 2013 (até 30 de Novembro).




Figura 5.1: Diagrama do conjunto de dados utilizado

A ferramenta utilizada no Matlab exige ainda alguns considerações adicionais. Cada vez que se cria uma nova rede neuronal, os resultados obtidos são sempre diferentes devido a duas características aleatórias deste programa: tanto os pesos iniciais dos neurônios, como o conjunto de teste interno do matLab são escolhidos aleatoriamente no início de cada treino. Assim, para a obtenção

de resultados confiáveis e para permitir retirar conclusões concretas acerca dos vários modelos, utilizou-se uma prática comum na área das redes artificiais neuronais, denominada de "Ensemble averaging". Este processo consiste na criação de várias redes neuronais e na combinação dessas mesmas redes para produzir um único modelo. Geralmente, um ensemble (conjunto) de modelos tem uma performance melhor do que qualquer um dos modelos individuais pois os erros dos modelos individuais tendem a diminuir consideravelmente.

Para avaliar a precisão desta abordagem de redes neuronais à previsão de preços de eletricidade, é utilizado um critério que avalia os resultados comparando-os com o valor dos preços de eletricidade que se verificam na realidade. Como tal, é usado o MAPE - *mean absolute percentage error* - que é obtido através da seguinte expressão:

$$MAPE = \frac{100}{N} \sum_{h=1}^N \frac{|\hat{p}_h - p_h|}{\bar{p}} \quad (5.1)$$

$$\bar{p} = \frac{1}{N} \sum_{h=1}^N p_h \quad (5.2)$$

onde $\hat{p}_h$ e p_h representam respetivamente a previsão do preço e o preço de eletricidade real a uma determinada hora h , $\bar{p}$ representa o preço médio real do período de tempo da previsão e N o número de horas previstas. De seguida, apresenta-se passo por passo, a metodologia utilizada para a obtenção do erro MAPE de um exemplo de modelo.

Tabela 5.1: Passo 1 - Aquisição das 5 previsões individuais para obtenção do modelo *ensemble*.

Hora	Previsão 1	Previsão 2	Previsão 3	Previsão 4	Previsão 5	Ensemble
0:00	X ₁	X ₂	X ₃	X ₄	X ₅	X ₆ = Média [X ₁ ,X ₅]
1:00	Y ₁	Y ₂	Y ₃	Y ₄	Y ₅	Y ₆ = Média [Y ₁ ,Y ₅]
2:00	Z ₁	Z ₂	Z ₃	Z ₄	Z ₅	Z ₆ = Média [Z ₁ ,Z ₅]
...	...	...	...	...	...	...

Tabela 5.2: Passo 2 - Cálculo do erro de cada modelo individual para obtenção do erro *ensemble*.

Hora	Erro 1	Erro 2	Erro 3	Erro 4	Erro 5	Ensemble
0:00	Ph-X ₁	Ph-X ₂	Ph-X ₃	Ph-X ₄	Ph-X ₅	ε ₁ = Média [Ph-X ₁ , Ph-X ₅]
1:00	Ph-Y ₁	Ph-Y ₂	Ph-Y ₃	Ph-Y ₄	Ph-Y ₅	ε ₂ = Média [Ph-Y ₁ , Ph-Y ₅]
2:00	Ph-Z ₁	Ph-Z ₂	Ph-Z ₃	Ph-Z ₄	Ph-Z ₅	ε ₃ = Média [Ph-Z ₁ , Ph-Z ₅]
...	...	...	...	...	...	...

O último passo consiste na obtenção direta do MAPE através da aplicação direta da equação 5.1.

5.1 Modelo de Referência

Na previsão de preços de eletricidade, existem muitos fatores não explicáveis que são responsáveis pela sua volatilidade e pelo aparecimento de grandes desvios. Estes fatores não nos permitem saber se o erro resultante da aplicação de um modelo de previsão é derivado de um problema do próprio modelo ou se se trata de um problema do mercado em si.

Assim, para tirar algumas conclusões, foi criado um primeiro modelo que utiliza as produções reais da própria hora para explicar o preço de eletricidade. O objetivo deste modelo é que o mesmo seja usado como um modelo de referência para explicar o erro da previsão e detetar possíveis comportamentos atípicos do mercado.

Teoricamente, este modelo deveria explicar perfeitamente o valor do preço. No entanto, existirá um erro resultante que está relacionado com o facto de o preço estar a responder a outros fatores que não estão incluídos nas entradas. Este fenómeno é o que se deve entender por inexplicabilidade, e o objetivo aqui passa também por perceber quais as alturas do ano em que esta é maior.

O modelo de referência criado utiliza como variáveis de entrada valores horários de produção Hídrica, Eólica, Solar + Cogeração, Nuclear, Carvão e Gás Natural todos eles para o dia D+1 e ainda o Consumo para o dia D+1. Adicionalmente é composto ainda pela Hora e Dia da Semana bem como o preço de eletricidade do dia D. A saída que se pretende obter é o preço de eletricidade para o dia D+1.

5.1.1 Aplicação do Modelo de Referência

Inicialmente foram efetuados alguns testes em relação as variáveis de produção térmica (carvão, nuclear e gás natural) para se obter o melhor modelo possível. Assim, foram construídos 3 modelos diferentes com: as produções térmicas desagregadas (3 variáveis), a produção nuclear separada das produções de carvão+gás natural (2 variáveis) e as produções térmicas agregadas (1 variável). Efetuando os testes de cada um destes casos com as restantes variáveis de entrada previamente mencionadas, obtiveram-se os seguintes resultados de erro MAPE anual:

Tabela 5.3: Indicadores de MAPE anuais das previsões individuais e dos *ensembles* - modelo de referência

	Ensamble	Melhor Previsão	Previsão 1	Previsão 2	Previsão 3	Previsão 4	Previsão 5
M1 - Todas as variáveis desagregadas	15.55%	16.88%	18.73%	17.70%	17.24%	16.88%	17.09%
M2 - Nuclear, Carvão e Gás Natural Agregadas	16.74%	16.55%	19.73%	19.66%	16.55%	21.91%	18.10%
M3 - Carvão e Gás Natural Agregadas	16.63%	17.47%	19.55%	19.63%	17.47%	17.55%	18.39%

Analisando a tabela 5.3 é possível verificar que a melhor solução encontrada foi o modelo com as variáveis de Carvão, Nuclear e Gás Natural desagregadas que registou um MAPE de 15.55%




Figura 5.2: Diagrama representativo das variáveis de entrada e saída do modelo de referência

Nesta fase, interessa então saber em que alturas é que o modelo de referência se desvia mais dos valores reais. Estes desvios, já apelidados de inexplicabilidade, variam consoante a hora, o dia da semana e a estação do ano.

De acordo com a figura 5.3, os desvios são maiores em duas fases distintas do dia. Primeiro, entre as 5h e as 9h da manhã e depois entre as 18h e as 20h da tarde.

A um nível semanal, verifica-se que os desvios são maiores principalmente ao fim de semana tendo-se também verificado desvios elevados às quartas e quintas feiras durante todo o ano como se pode ver na figura 5.4.

Finalmente, a nível das estações do ano, verificou-se, à exceção do Verão, que as mesmas apresentam percentagens de desvios semelhantes sendo que o maior valor se verificou no Inverno como é possível ver na figura 5.5.




Figura 5.3: Representação dos desvios médios dos preços em função da hora do dia




Figura 5.4: Representação dos desvios médios dos preços em função do dia da semana




Figura 5.5: Representação dos desvios médios dos preços em função da estação do ano

5.2 Modelo 1 - Modelo Multivariável Direto

O objetivo deste modelo é a previsão de preços de eletricidade para o dia seguinte em tempo útil para as licitações diárias no mercado. Ao contrário da análise efetuada para o modelo de referência, a criação deste modelo tem como objetivos o estudo da influência das diferentes variáveis para a construção de modelos de previsão. De igual importância, e após ter sido encontrado o melhor modelo de previsão, pretende-se fazer uma análise quantitativa dos resultados obtidos para posterior comparação com outros modelos.

Para se perceber melhor a influência das diferentes variáveis foi adotada uma metodologia de trabalho que consiste em testar inicialmente o modelo com todas as variáveis disponíveis e posteriormente ir retirando uma a uma e analisar a variação do MAPE obtido. Na tabela 5.4, encontra-se um resumo de todos os MAPES obtidos durante a fase de testes. É possível ver os MAPES das previsões individuais, o melhor MAPE individual obtido para cada modelo (representado na coluna "Best") e ainda os MAPES referentes aos ensembles.

Tabela 5.4: Indicadores de MAPE anuais das previsões individuais e dos *ensembles* para os diferentes modelos - modelo multivariável direto

Modelo	Variáveis	Ensamble	Best	P1	P2	P3	P4	P5
M1	Todas as variáveis (produção térmica agregada, incluindo "Nuclear, "Carvão" e "Gás Natural")	16.8%	17.3%	17.3%	21.1%	18.4%	19.8%	18.9%
M2	Todas as variáveis ("Nuclear" desagregada do "Carvão" e "Gás Natural")	17.9%	18.5%	20.9%	18.5%	20.3%	23.3%	21.0%
M3	M1, sem a variável "Preço (D) "	18.6%	19.1%	19.1%	22.7%	21.8%	20.3%	23.3%
M4	M1, sem a variável "Preço (D-6) "	17.7%	18.7%	23.8%	19.6%	19.9%	18.7%	19.5%
M5	M1, sem a variável "Hora"	18.1%	19.5%	22.7%	19.5%	21.9%	20.9%	19.5%
M6	M1, sem a variável "Dia da Semana"	17.8%	18.6%	18.7%	18.6%	20.2%	23.1%	20.2%
M7	M1, sem a variável "Consumo (D-1) "	18.3%	20.1%	20.4%	20.1%	20.5%	21.6%	22.0%
M8	M1, sem a variável "Consumo (D-6) "	18.4%	20.7%	22.0%	24.0%	21.1%	20.7%	23.0%
M9	M1, sem a variável "Hídrica (D-1) "	19.5%	20.2%	22.8%	20.2%	20.3%	23.8%	21.1%
M10	M1, sem a variável "Solar + Cogeração (D-1) "	18.2%	18.2%	18.2%	19.6%	22.7%	22.5%	20.3%
M11	M1, sem a variável "Solar + Cogeração (D-6) "	18.6%	18.2%	22.2%	22.1%	22.7%	21.6%	18.2%
M12	M1, sem a variável "Temperatura (D+1) "	18.5%	18.6%	23.1%	18.6%	19.7%	23.2%	20.8%
M13	M1, sem a variável "Velocidade do Vento (D+1) "	24.0%	24.5%	29.6%	31.9%	26.8%	26.7%	24.5%
M14	M1, sem a variável "Térmica N,C,CC (D-1) "	17.6%	18.6%	22.0%	18.6%	19.6%	22.6%	19.7%
M15	M1, sem a variável "Térmica N,C,CC (D-6) "	17.7%	18.4%	18.4%	21.0%	21.3%	20.8%	22.2%

Para uma melhor compreensão dos resultados obtidos é possível observar na tabela 5.5 os resultados dos MAPES por ordem ascendente dos ensembles e do melhor caso das previsões individuais.

Como se pode constatar, o melhor modelo obtido foi o M1, que apresentou um MAPE anual de 16.83%. Este modelo, teve o melhor desempenho tanto na totalidade das previsões individuais como nos modelos ensemble. No outro extremo é fácil observar que o modelo com o desempenho mais fraco foi o M13, modelo que foi construído sem a variável "Velocidade do Vento".

Tabela 5.5: Indicadores de MAPE anuais das previsões individuais e dos *ensembles* para os diferentes modelos por ordem ascendente - modelo multivariável direto

Ensemble		Best	
M1	16.83%	M1	17.26%
M14	17.62%	M11	18.16%
M4	17.66%	M10	18.17%
M15	17.73%	M15	18.37%
M6	17.80%	M2	18.47%
M2	17.90%	M6	18.57%
M5	18.11%	M14	18.58%
M10	18.24%	M12	18.64%
M7	18.28%	M4	18.70%
M8	18.37%	M3	19.10%
M12	18.47%	M5	19.49%
M11	18.55%	M7	20.09%
M3	18.63%	M9	20.24%
M9	19.48%	M8	20.73%
M13	24.00%	M13	24.53%

Estes resultados vêm comprovar o que já foi dito na secção 4.3.2 em relação à influência do Vento. De facto, conclui-se que a velocidade do vento é uma variável muito importante em qualquer tipo de modelo de previsão de preços deste tipo. Apesar de ser uma variável baseada em previsões meteorológicas (que pode acrescentar alguma imprevisibilidade ao modelo), a mesma apresenta-se como um indicativo de elevada qualidade no que toca à produção de energia eólica.

É neste sentido que esta variável adquire ainda mais importância na medida em que, como já foi explicado em "Influência do despacho", a produção em regime especial e mais concretamente a produção eólica apresenta uma enorme influência na variabilidade dos preços de eletricidade. Retirando-se a variável "Velocidade do Vento" do modelo M1 foi possível verificar um acréscimo bastante elevado no erro MAPE, de aproximadamente 8 pontos percentuais o que reforça ainda mais a importância desta variável.




Figura 5.6: Comparação entre os modelos M1 e M13 para uma semana de Fevereiro/2013

Para finalizar, na figura 5.6, é possível ver a comparação entre os modelos M1 e M13 durante

uma semana do mês de Fevereiro de 2013 onde a PRE foi particularmente elevada. Mais uma vez, fica comprovado o fraco comportamento de modelos sem a variável vento na previsão de preços de eletricidade para cenários com elevada PRE (com grande componente eólica). O mesmo modelo M13 acaba por ter um desempenho muito melhor em cenários onde a percentagem de PRE é menor como nos meses de Agosto ou Setembro.

Em relação às restantes variáveis, destaque para o modelo M9 que, sem a variável da produção Hídrica do dia anterior, viu o erro MAPE aumentar também. Semelhante à análise anterior, é possível ver na figura 5.7 que o modelo M9 apresenta um fraco desempenho em cenários de despacho com elevada produção hídrica.




Figura 5.7: Comparação entre os modelos M1 e M9 para uma semana de Abril/2013

5.2.1 Aplicação do Modelo Multivariável Direto - Melhor Caso

Nesta fase pretende-se apresentar os resultados obtidos para o melhor caso, o modelo M1, cujas variáveis de entrada e saída podem ser vistas na figura 5.8.

Tabela 5.6: Indicadores de MAPE semanais, mensais e anual - - modelo multivariável direto

	MAPE Semanal	MAPE Mensal	MAPE Anual
Janeiro	14.0%	21.4%	16.83%
Fevereiro	23.1%	17.4%	
Março	20.7%	30.4%	
Abril	96.8%	19.1%	
Maio	12.4%	15.0%	
Junho	14.0%	16.1%	
Julho	11.3%	9.7%	
Agosto	6.9%	10.3%	
Setembro	8.1%	12.6%	
Outubro	9.6%	14.1%	
Novembro 1	21.9%	19.9%	
Novembro 2	17.5%		

Como podemos ver na tabela 5.6, este modelo apresentou uma performance satisfatória ao longo do ano. O pior MAPE mensal registado foi em Março, que se revelou um mês complicado para a previsão de preços (ver secção 4.6.2). É de realçar também a melhor performance verificada durante os meses de Verão e Outono em comparação com o Inverno e a Primavera. De facto, como já foi mencionado, é durante o Inverno e a Primavera que a volatilidade dos preços é maior dificultando a tarefa da previsão. Ao mesmo tempo, é durante este período que se verifica uma maior existência de fatores inexplicáveis que afetam a variabilidade dos preços. Durante os meses de Verão e Outono, os cenários de despacho são mais constantes conduzindo a um preço constante ao longo destas alturas.

Os indicadores MAPE semanais da tabela 5.6 referem-se à primeira semana de cada mês (Novembro 1 e Novembro 2 são a primeira e a última semana do mês respetivamente). O MAPE semanal do mês de Abril apresenta um valor de MAPE extremamente elevado de 96.8%. No entanto, trata-se de um caso excecional visto que o MAPE mensal para esse mesmo mês acaba por ser de 19.1%.




Figura 5.8: Diagrama representativo das variáveis de entrada e saída do modelo 1.

Nos Anexos, secção 8.1 é possível observar a performance demonstrada por este modelo ao longo do ano.

5.3 Modelo 2 - Modelo Autoregressivo

O modelo que se apresenta de seguida é uma abordagem básica e simples ao problema. Utilizando como variáveis de entrada apenas o Preço do dia D e o Preço do dia D-6, esta abordagem tem sido utilizada em inúmeras investigações ao longo dos tempos.




Figura 5.9: Diagrama representativo das variáveis de entrada e saída do modelo 2.

Como podemos ver na tabela 5.7 o MAPE anual obtido para o modelo ensemble foi de 21.32% tendo-se verificado uma solução melhor no decorrer da obtenção das previsões individuais com o valor de 21.08%. Apesar do erro MAPE obtido ser mais elevado quando comparado com o do modelo 1, esta abordagem apresenta como principais vantagens a sua fácil implementação bem como a desnecessidade de uma elevada capacidade computacional. De facto, cada treino de uma nova rede para este modelo demorou entre 5/10 segundos permitindo a obtenção de uma grande quantidade de testes num curto período de tempo.

Tabela 5.7: Indicadores de MAPE semanais, mensais e anual - modelo autoregressivo

	MAPE mensal		MAPE anual	
	Melhor caso	Ensemble	Melhor caso	Ensemble
Janeiro	26.6%	26.3%	21.10%	21.38%
Fevereiro	27.9%	27.2%		
Março	39.3%	41.5%		
Abril	28.2%	30.6%		
Maio	16.2%	16.0%		
Junho	15.0%	14.9%		
Julho	12.1%	12.0%		
Agosto	11.1%	11.1%		
Setembro	16.0%	16.1%		
Outubro	19.5%	19.1%		
Novembro	20.8%	20.8%		

5.4 Modelo 3 - Estruturas de Submodelos

O terceiro modelo desenvolvido prevê a criação de submodelos de previsão de:

- Consumo;

- Produção Hídrica;
- Produção Eólica;
- Produção Solar + Cogeração;
- Produção Térmica (Carvão, Nuclear e Gás Natural).

que irão ser utilizados posteriormente como variáveis de entrada para a criação de um segundo modelo de previsão de preços como se pode ver na figura 5.10. O objetivo aqui é arranjar modelos de previsão o mais simples possíveis mas que ao mesmo tempo consigam produzir resultados satisfatórios. Cada uma destas previsões poderia ser alvo de um estudo intensivo através da criação de modelos complexos sendo que não é isso que se pretende neste trabalho onde o foco está direcionado para a previsão de preços final. Desta maneira, criaram-se os modelos com as variáveis mais importantes de cada um deles como de seguida se explicará.




Figura 5.10: Diagrama representativo das variáveis de entrada e saída do modelo 3.

5.4.1 Previsão do Consumo

A primeira previsão efetuada na construção deste modelo 3 foi a previsão dos consumos. Em relação a esta previsão, existem à partida algumas variáveis que obviamente terão uma acentuada correlação com os consumos. Tal como já foi dito, os consumos têm uma tendência muito semelhante aos preços de eletricidade. Como tal, muito das variáveis que já se provaram ser influentes para a variabilidade dos preços de eletricidade, também o são para a variação dos consumos ao longo do ano.

As variáveis mais importantes em questão são a hora, o dia da semana e a temperatura. Adicionalmente, verificou-se uma ligeira melhoria no MAPE das previsões de consumos obtidas com a adição da variável mês.

Nas figuras [5.11-5.14] é possível observar os gráficos que mostram a correlação entre as variáveis mencionadas e o consumo. Em relação à sua influência, as conclusões são semelhantes ao que já foi dito anteriormente.

Em termos horários, verifica-se um maior registo de consumos elevados nas horas de ponta (10h e 19/20 h) derivado dos hábitos normais de consumo energético no quotidiano. A nível semanal, registam-se os valores mais elevados de consumo durante os dias úteis ao contrário dos fins-de-semana e feriados que registam valores mais reduzidos.




Figura 5.11: Relação entre o consumo (MW) e a hora do dia




Figura 5.12: Relação entre o consumo (MW) e o dia da semana

A nível mensal, verifica-se que os consumos são efetivamente mais elevados durante o Inverno e o Verão. Finalmente, em relação à temperatura, é possível constatar a sua forte influência na variabilidade dos consumos. De facto, temperaturas baixas ou temperaturas elevadas resultam num aumento do consumo.




Figura 5.13: Relação entre o consumo (MW) e o mês




Figura 5.14: Relação entre o consumo (MW) e a temperatura (°C)

5.4.2 Previsão da produção Eólica

A previsão de produção eólica realizada para o modelo 3 conta com a presença de apenas duas variáveis, a velocidade do vento e a direção do vento. Para esta previsão, é primordialmente a velocidade do vento que permite a obtenção de resultados válidos, com a direção do vento a melhorar ligeiramente as previsões obtidas. No entanto, há que ter em consideração que a previsão de produção eólica é um problema que exige uma abordagem mais complexa e profunda do que a que

foi realizada neste trabalho. Existem muitas particularidades associadas à previsão de produção eólica que nunca poderiam ser resolvidas com a construção de um modelo tão simples como este. Mais uma vez, reitera-se que o objetivo aqui passa pela análise da previsão de preços final em detrimento destas previsões.

Como recurso primário do qual a produção eólica depende totalmente, o vento é uma variável importantíssima para a previsão desta produção. Quanto maior é a velocidade do vento, maior é a produção eólica como se pode ver analisando o gráfico da figura 5.15 onde podemos ver que existe uma relação quase diretamente proporcional entre estas duas variáveis. Em relação à direção do vento, observando o gráfico da figura 5.16 é possível constatar a sua reduzida influência neste modelo de previsão. Ainda assim, a mesma foi utilizada como variável de entrada por se verificar uma ligeira melhoria do MAPE para este previsão.




Figura 5.15: Relação entre a produção eólica (MW) e a velocidade do vento (m/s).




Figura 5.16: Relação entre a produção eólica (MW) e a direção do vento (°).

5.4.3 Previsão da produção Hídrica

Durante a realização deste trabalho, encontrou-se um problema relativo à construção do modelo de previsão de hídrica. De facto, tal como a previsão de produção eólica, a previsão de produção hídrica apresenta-se como uma matéria complexa e incapaz de se resolver no âmbito desta dissertação, estando no entanto a decorrer uma dissertação em paralelo específica para a previsão hídrica [70]. Habitualmente, um modelo de previsão hídrica necessita de previsões separadas de mini-hídrica, hídrica de albufeira e ainda de centrais de fio de água.

A solução alternativa para esta dissertação passou então pela utilização de dados reais de produção hídrica para o período em questão. No entanto, a utilização de dados reais seria o mesmo que estar a utilizar uma previsão perfeita o que resultaria numa viciação dos resultados do modelo de previsão de preços. Assim, procedeu-se à introdução de um erro artificial na série de dados para modelizar um erro de 20% através da seguinte expressão:

$$H_m = H_r \times (1 + 0.2 \times rand()) \quad (5.3)$$

em que, H_m representa o valor de produção hídrica modificado, H_r representa o valor de produção hídrica real e $rand()$ representa uma função de geração de números aleatórios compreendidos

entre -1 e 1.

Desta maneira, foi possível utilizar como entrada no modelo de previsão de preços, uma hipotética previsão de produção hídrica afetada com um erro de 20% sem que o modelo final apresentasse resultados viciados.

5.4.4 Previsão da produção Solar + Cogeração

Em relação a previsão de produção solar + cogeração verificou-se ser possível a obtenção de resultados relativamente razoáveis, utilizando apenas duas variáveis de entrada. Utilizando como recurso primário a presença de luz solar, uma das variáveis que à partida iria ter um papel importante na construção deste modelo seria a irradiância média ibérica. De facto, é fácil de observar na figura 5.17 a relação existente entre a irradiância e a produção de energia solar. Valores mais altos de irradiância, que se verificam normalmente ao início da tarde, coincidem com as alturas em que a produção solar é mais elevada.

Relativamente à temperatura, verifica-se uma tendência semelhante, isto é, de acordo com a figura 5.18, a produção de solar é mais elevada quando se registam temperaturas mais elevadas.




Figura 5.17: Relação entre a produção solar + cogeração (MW) e a irradiância (W/m²).




Figura 5.18: Relação entre a produção solar + cogeração (MW) e a temperatura (°C).

5.4.5 Previsão da produção de Carvão, Nuclear e Gás Natural

Relativamente ao modelo de previsão das térmicas, optou-se por agregar as produções e efetuar uma previsão do valor agregado de nuclear, carvão e centrais de ciclo combinado a gás natural. A razão para tal prende-se no facto de existir uma maior dificuldade em prever a produção de carvão e gás natural individualmente. Assim, com a produção térmica agregada, obtiveram-se melhores resultados de MAPE, que permitiram a sua utilização no modelo de previsão de preços final.

As variáveis escolhidas para esta previsão foram a hora do dia, o dia da semana e o valor agregado de produção térmica do dia anterior e da semana anterior. Em relação às duas primeiras, é possível observar a sua influência nas figuras 5.19 e 5.20. A nível horário, verifica-se uma maior produção deste tipo de energia durante as horas de ponta. Durante a semana verifica-se que maiores valores de produção são registados durante os dias úteis, que acabam também por coincidir com as alturas da semana de maior consumo.




Figura 5.19: Relação entre a produção térmica agregada (MW) e a hora




Figura 5.20: Relação entre a produção térmica agregada (MW) e o dia da semana

Finalmente, para melhorar as previsões obtidas, utilizaram-se as variáveis de produção térmica do dia anterior e da semana anterior. Dada a inexistência de uma variável que funcionasse como um bom indicador para a produção térmica, foi necessário então recorrer a estas duas variáveis. O erro MAPE melhorou consideravelmente como se poderá ver na secção seguinte.




Figura 5.21: Relação entre a produção térmica agregada (MW) e a produção térmica agregada do dia anterior (MW)




Figura 5.22: Relação entre a produção térmica agregada (MW) e a produção térmica agregada da semana anterior (MW)

5.4.6 Aplicação do Modelo 3 - Estruturas de Submodelos

Através da aplicação dos diferentes modelos de previsão mencionados anteriormente, ao conjunto de treino e teste disponível, obtiveram-se os indicadores de MAPE anuais que se podem ver na tabela 5.8. Para a construção do modelo de previsão de preços foram utilizados como entrada os resultados do modelo ensemble de cada previsão da tabela 5.8, com exceção para a previsão de hídrica.

Finalmente, utilizando como variáveis de entrada todas as previsões efetuadas, obteve-se a previsão de preços de eletricidade final. O erro MAPE obtido no modelo de ensemble foi de 25.37% como se pode ver na tabela 5.9.

Apesar de apresentar bons resultados para os meses de Verão, este modelo acaba por não produzir boas previsões durante os restantes meses do ano como se pode ver nos anexos - secção

Tabela 5.8: Indicadores de MAPE anuais de teste para os submodelos - modelo estruturado

Modelo	Ensemble	Best	P1	P2	P3	P4	P5
Previsão de Consumos	4.73%	4.75%	4.80%	4.75%	4.99%	5.11%	5.07%
Previsão de produção Eólica	24.27%	24.23%	24.68%	24.34%	24.42%	24.44%	24.23%
Previsão de produção Solar + Cogeração	13.70%	13.66%	13.83%	13.66%	13.68%	13.72%	13.71%
Previsão de produção Térmica	17.22%	16.88%	17.28%	16.88%	18.01%	17.62%	17.50%

Tabela 5.9: Indicadores de MAPE anuais de teste - modelo estruturado

Modelo	Ensemble	Best	P1	P2	P3	P4	P5
Previsão de Preços	25.37%	25.17%	26.41%	25.17%	26.83%	26.53%	26.53%

8.3. Certamente que um trabalho mais profundo e exaustivo sobre cada uma das previsões individuais resultaria num modelo capaz de produzir melhores resultados. Este modelo poderia ainda ser melhorado caso se efetuassem previsões individuais de todas as produções térmicas e ainda se adicionasse uma previsão relativa à importação de energia no MIBEL.

5.5 Comparação dos modelos

Nesta secção pretende-se comparar as diferentes performances dos modelos construídos analisando a evolução do erro MAPE a um nível diário, semanal e mensal para o ano de 2013.

Como se pode ver na figura 5.23, foi o modelo de referência que apresentou os melhores resultados ao longo do dia. No entanto, verificou-se uma situação algo estranha na medida em que o modelo multivariável direto apresentou melhores resultados em algumas horas do dia (5h-7h e 18h-19h). A razão para tal reside na existência de um *bias*¹ reduzido no modelo de referência que provoca uma fraca generalização dos dados de teste em algumas situações. Esta situação verifica-se pois existe uma diferença notável entre os preços verificados em 2012 e 2013, onde a média aritmética anual foi de 47.23 Eur e 43.04 Eur respetivamente. Por ser menos dependente do preço anterior, a alteração de comportamentos entre o conjunto de dados de treino (insample) e o conjunto de dados de teste (outsample) torna o modelo de referência mais sensível. Não obstante, uma possível utilização de um modelo de ajuste ao modelo de referência resultaria certamente numa diminuição do erro MAPE do mesmo, deixando de se verificar este comportamento anómalo.

Voltando à análise da figura 5.23, é possível então verificar que o modelo multivariável (M1) apresenta melhores resultados em relação aos modelos regressivo (M2) e estruturado (M3). Por sua vez, e apesar de ser sem dúvida o pior modelo, o M3 apresentou em algumas horas do dia melhores resultados que o M2. Em relação à variabilidade do MAPE ao longo do dia, destaque apenas para um registo de valores mais elevados durante as horas de ponta como seria de esperar.

Passando para a análise semanal (figura 5.24), verifica-se novamente um comportamento semelhante, com o modelo de referência a apresentar obviamente os valores mais baixos de MAPE ao longo da semana (exceptuando ao Sábado) sendo que o modelo M1 se apresenta novamente como o melhor modelo de entre os três restantes. Destaque ainda para o modelo M2 que se revela algo inconstante em função do dia da semana. De facto, constata-se que o mesmo apresenta bons resultados para as quartas feiras, mas por outro lado um fraco desempenho na obtenção de previsões aos sábados. De realçar ainda um desempenho menos forte na obtenção de boas previsões de preços durante o fim de semana, regra geral para todos os modelos.

Relativamente à análise mensal (figura 5.25), são várias as conclusões que se podem retirar. Em primeiro lugar, verifica-se que nos meses de Verão (Julho, Agosto e Setembro) e mesmo durante Outubro, todos os modelos apresentaram resultados positivos e bastante semelhantes entre si. De facto, qualquer um dos 3 modelos (M1, M2 e M3) poderia ser utilizado para a obtenção de boas previsões durante este período de tempo. É nos restantes meses que se verifica o poder e a capacidade individual de cada modelo.

¹De acordo com o dilema *bias*/variância, um modelo deverá ser treinado até que atinja um elevado erro de treino, mas sem que haja perda do poder de generalização dos dados de teste. O ideal seria escolher um modelo capaz de reconhecer com precisão as características e particularidades dos dados de treino e ao mesmo tempo ter uma boa capacidade de generalização face a dados desconhecidos (dados de teste). No entanto, é praticamente impossível recriar estas duas coisas. Assim, modelos com um *bias* igual a zero representam com precisão os dados de treino mas têm uma capacidade de generalização baixa face a dados de teste, resultando numa variância elevada. Por outro lado, modelos que generalizam bem os dados de teste apresentam tipicamente uma variância baixa mas possuem um *bias* elevado.




Figura 5.23: Indicadores de MAPE dos diferentes modelos em função da hora do dia




Figura 5.24: Indicadores de MAPE dos diferentes modelos em função do dia da semana

Começando por falar do modelo M2, destaca-se a boa performance demonstrada pelo mesmo em comparação com o M1 desde Maio até Novembro, tendo até obtido resultados melhores durante o mês de Maio! No entanto a fragilidade deste modelo vem ao de cima durante os meses de Fevereiro, Março e Abril verificando-se um deterioramento considerável das previsões para este período quando comparado com o M1. A razão para tal, reside no facto de a variabilidade dos preços de eletricidade apresentar uma forte dependência dos fatores meteorológicos durante estes meses, mais concretamente da velocidade do vento como já foi comprovado. Ora, como se pode constatar, o "calcanhar de Aquiles" do modelo M2 consiste precisamente numa inexistência




Figura 5.25: Indicadores de MAPE dos diferentes modelos em função do mês

de variáveis meteorológicas no mesmo. Utilizando apenas o histórico de preços, verifica-se uma dificuldade tremenda por parte deste modelo em obter previsões corretas durante estes três meses sendo mesmo ultrapassado pelo modelo M3. De resto, esta é a única altura em que o M3 consegue ser melhor do que um dos seus "rivais" apresentando-se nos restantes meses como a pior solução para a previsão de preços.

Assim, o modelo multivariável acaba por reclamar para si o troféu de melhor modelo de previsão entre os três modelos construídos, reforçando a sua posição ao apresentar o melhor MAPE anual entre os três como se pode ver na tabela 5.10.

Tabela 5.10: Indicadores de MAPE anuais para os diferentes modelos construídos

	Modelo Referência	Modelo 1	Modelo 2	Modelo 3
MAPE anual	15.55%	16.83%	21.38%	25.37%

Por último resta apenas apresentar os perfis das previsões de preços obtidas pelos diferentes modelos.




Figura 5.26: Perfis das previsões de preços para a primeira semana do mês de Janeiro




Figura 5.27: Perfis das previsões de preços para a primeira semana do mês de Março




Figura 5.28: Perfis das previsões de preços para a primeira semana do mês de Maio




Figura 5.29: Perfis das previsões de preços para a primeira semana do mês de Julho




Figura 5.30: Perfis das previsões de preços para a primeira semana do mês de Agosto




Figura 5.31: Perfis das previsões de preços para a primeira semana do mês de Novembro

Capítulo 6

Conclusões e trabalhos futuros

O principal objetivo deste trabalho passava pela criação e desenvolvimento de diferentes modelos de previsão de preços de eletricidade. No que diz respeito aos modelos construídos, existem algumas conclusões a retirar:

A criação de um modelo de referência apresenta-se como uma ideia inovadora, com o objetivo de compreender a inexplicabilidade associada aos modelos de previsão e perceber em que alturas é que a mesma é mais elevada. Por muito bons que alguns modelos de previsão possam ser, existirá sempre um erro de previsão associado a fatores e causas que não dependem dos inputs dos modelos e que ocorrem com mais frequência em determinadas alturas do dia, da semana e do mês. Este modelo serviu também como base de comparação para os outros modelos desenvolvidos neste trabalho.

O modelo multivariável direto (M1) revelou ser a melhor abordagem ao problema em comparação com os restantes. Apresentando um conjunto de variáveis considerável (13 variáveis), trata-se de um modelo com alguma exigência a nível computacional com os treinos das redes a demorarem entre 2 a 5 minutos. No entanto, os resultados obtidos a partir do mesmo foram bastante satisfatórios, concluindo-se que este será um modelo de previsão de preços a ter em conta.

Em relação ao modelo autoregressivo (M2), apesar de ser um modelo minimalista (com apenas 2 variáveis de entrada), o mesmo demonstrou ser eficiente e provou até ser a melhor solução durante o mês de Maio de 2013. No entanto, este modelo acabou por demonstrar algumas fragilidades em alturas do ano onde as variáveis meteorológicas detinham uma importância maior. De qualquer das maneiras, apresenta-se como uma solução de fácil implementação e com exigências computacionais mínimas com os treinos das redes a demorarem entre 10 a 30 segundos.

Finalmente, em relação ao modelo estruturado (M3), resta realçar que o mesmo se apresentou como a pior solução entre os três. A utilização deste modelo prevê a realização de pequenas previsões de consumos e de várias produções relevantes sendo que estas previsões por si só seriam motivo de estudo e exigiriam um aprofundamento maior do que aquele dado neste trabalho. No desenvolvimento deste modelo adoptou-se uma estratégia de criação de modelos simples com a finalidade de perceber a influência dos mesmos na previsão de preços de eletricidade para o MIBEL. Existem vários trabalhos desenvolvidos que se concentram apenas neste modelo e que

obtiveram melhores resultados em relação a estes. Independentemente, dos resultados obtidos neste trabalho, o modelo estruturado, sendo alvo de maior escrutínio no que toca aos submodelos de previsão, será obviamente capaz de produzir melhores resultados.

Adicionalmente, foi feita uma análise das características dos preços de eletricidade bem como das variáveis que influenciam a sua variabilidade. A volatilidade dos preços de eletricidade para o mercado MIBEL deve-se em grande parte à influência de variáveis meteorológicas, mais precisamente da velocidade do vento. De facto, num cenário onde a produção de energia eólica tem vindo a ganhar muito terreno face às restantes, a existência ou não de vento tem uma forte influência na quantidade de energia proveniente da PRE (eólica). Cenários onde a produção eólica é elevada resultam num decréscimo dos preços de eletricidade e vice-versa. Da mesma maneira, também a produção de nuclear e de hídrica têm um grande influência na variabilidade dos preços MIBEL.

6.1 Trabalhos Futuros

Esta dissertação apresenta um trabalho inovador de desenvolvimento de modelos de previsão de preços de eletricidade, onde há agora um conjunto de ideias que merecem destaque. Mais concretamente, os desenvolvimentos futuros sugeridos pela autor são:

- Aplicação de um modelo de ajuste ao modelo de referência com vista a melhorar o erro MAPE;
- Utilização de outro tipo de variáveis (não disponíveis durante a realização desta dissertação) tais como previsões de preços de combustíveis, no modelo multivariável e autoregressivo e aumentar o conjunto de dados de treino;
- Integrar modelos de previsão de consumos e de produção mais sofisticados no modelo estruturado;

Capítulo 7

Bibliografía

- [1] Battle, Carlos., Barquín, J., A strategic production costing model for electricity market price analysis, 2005
- [2] D. W. Bunn, Forecasting Loads and Prices in Competitive Power Markets, 2000
- [3] Li, G., Liu, C., Lawaree, J., Gallanti, M. and Venturini, A., State-of-the-Art of Electricity Price Forecasting, 2005.
- [4] Weron, Rafal, Modeling and forecasting electricity loads and prices: a statistical approach, 2006
- [5] S. Deng, Stochastic Models of Energy Commodity Prices and Their Application: Mean-Reversion with Jumps and Spikes, 1998
- [6] Blanco, C., Soronow, D., Jump Diffusion Processes – Energy Price Processes Used for Derivatives Pricing and Risk Management, 2004
- [7] Meyer-Brandis, T., Tankov, P., Multi-factor jump-diffusion models of electricity prices.
- [8] Misiorek, A., Trueck, S., Weron, R., Point and Interval Forecasting of Spot Electricity Prices: Linear vs. Non-Linear Time Series Models, 2006
- [9] Aggarwal, S., Saini, L. and Kumar, A., Electricity price forecasting en deregulated markets: A review and evaluation, 2008
- [10] Bajpai, P, Singh SN. Bidding and gaming in electricity market: an overview and key issues, 2004
- [11] Hu Z, Yang L, Wang Z, Gan D, Sun W, Wang K. A game theoretic model for electricity markets with tight capacity constraints, 2008
- [12] Contreras J, Santos JR. Short-term demand and energy price forecasting, 2006
- [13] Contreras J, Espinola R, Nogales FJ, Conejo AJ. ARIMA models to predict nextday electricity prices, 2003
- [14] Zhou M, Yan Z, Ni Y, Li G. An ARIMA approach to forecasting electricity price with accuracy improvement by predicted errors, 2004
- [15] Zhou M, Yan Z, Ni YX, Li G, Nie Y. Electricity price forecasting with confidence interval estimation through an extended ARIMA approach, 2006

- [16] Haldrup, N. and Nielsen, M.Ø. A regime switching long memory model for electricity prices, 2006
- [17] Marquez M., Munoz P., Martí-Recober, and Acosta L., Threshold volatility models: forecasting performance
- [18] Garcia RC, Contreras J, Akkeren M, van Garcia JBC. A GARCH forecasting model to predict day-ahead electricity prices, 2005
- [19] Niimura T, Ko Hee-Sang, Ozawa K. A day-ahead electricity price prediction based on a fuzzy-neuro autoregressive model in a deregulated electricity market, 2002
- [20] Amjady N. Day ahead price forecasting of electricity markets by a new fuzzy neural network, 2006
- [21] Hong YY, Lee Chuan-Fang. A neuro-fuzzy price forecasting approach in deregulated electricity markets, 2005
- [23] Kyoung-jae Kim, Financial time series forecasting using support vector machines, 2003
- [24] Gonzalez AM, San Roque AM, Garcia-Gonzalez J. Modeling and forecasting electricity prices with input/output hidden Markov models, 2005
- [25] Georgilakis PS. Market clearing price forecasting in deregulated electricity markets using adaptively trained neural networks, 2006
- [26] Mandal P, Senju T, Funabashi T. Neural networks approach to forecast several hour ahead electricity prices and loads in deregulated market, 2006
- [27] Li C, Wang S. Next-day power market clearing price forecasting using artificial fish-swarm based neural networks, 2006
- [28] Gao F, Cao X, Papalexopoulos A. Forecasting power market clearing price and quantity using a neural network method, 2000
- [29] Wang A, Ramsay B. A neural network based estimator for electricity spot pricing with particular reference to weekend and public holidays, 1998
- [30] Yamin HY, Shahidepour SM, Li Z. Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets, 2004
- [31] Szkuta BR, Sanabria LA, Dillon TS. Electricity price short-term forecasting using artificial neural networks, 1999
- [32] Gareta R, Romeo LM, Gil A. Forecasting of electricity prices with neural networks, 2006
- [33] Lu X, Dong ZY, Li X. Electricity market price spike forecast with data mining techniques, 2005
- [34] Wu W, Zhou J, Mo L, Zhu C. Forecasting electricity market price spikes based on Bayesian expert with support vector machine, 2006
- [35] Li E, Luh PB. Forecasting power market clearing price and its discrete PDF using a Bayesian-based classification method, 2001
- [36] Stevenson, M., Filtering and Forecasting Spot Electricity Prices in the Increasingly Deregulated Australian Electricity Market, 2001

- [37] K. Meng, Dong, Z. Y., Wong, K. P., Self-adaptive radial basis function neural network for short-term electricity price forecasting, 2009
- [38] N. Amjady and A. Daraeepour, Design of input vector for day-ahead price forecasting of electricity markets, 2009.
- [39] Website do instituto português do mar e da atmosfera - <https://www.ipma.pt/pt/index.html>.
- [40] J.P.S. Catalão, S.J.P.S. Mariano, V.M.F. Mendes, L.A.F.M. Ferreira, Short-term electricity prices forecasting in a competitive market: A neural network approach, 2007
- [41] J.P.S. Catalão, H.M.I. Pousinho, V.M.F. Mendes, Short-term electricity prices forecasting in a competitive market by a hybrid intelligent approach, 2011
- [42] J. P. S. Catalão, H. M. I. Pousinho and V. M. F. Mendes, Hybrid Wavelet-PSO-ANFIS Approach for Short-Term Electricity Prices Forecasting, 2011
- [43] Javier Contreras, Rosario Espínola, Francisco J. Nogales, and Antonio J. Conejo, ARIMA Models to Predict Next-Day Electricity Prices, 2003
- [44] Antonio J. Conejo, Javier Contreras, Rosa Espynola, Miguel A. Plazas, Forecasting electricity prices for a day-ahead pool-based electric energy market, 2005
- [45] Antonio J. Conejo, Miguel A. Plazas, Rosa Espínola and Ana B. Molina, Day-Ahead Electricity Price Forecasting Using the Wavelet Transform and ARIMA Models, 2005
- [46] Alberto Cruz, Antonio Munoz, Juan Luis Zamora, Rosa Espinola, The effect of wind generation and weekday on Spanish electricity spot price forecasting, 2011
- [47] Reinaldo C. Garcia, Javier Contreras, Marco van Akkeren, and João Batista C. Garcia, A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices, 2005
- [48] Carolina García-Martos, Julio Rodríguez, María Jesús Sánchez, Forecasting electricity prices and their volatilities using Unobserved Components, 2011
- [49] Carolina García-Martos, Julio Rodríguez, María Jesús Sánchez, Modelling and forecasting fossil fuels, CO₂ and electricity prices and their volatilities, 2013
- [50] Raquel Gareta, Luis M. Romeo, Antonia Gil, Forecasting of electricity prices with neural networks, 2006
- [51] Alicia Mateo González, Antonio Muñoz San Roque, and Javier García-González, Modeling and Forecasting Electricity Prices with Input/Output Hidden Markov Models, 2005
- [52] Virginia González, Javier Contreras and Derek W. Bunn, Forecasting Power Prices Using a Hybrid Fundamental-Econometric Model, 2012
- [53] João Lagarto, Jorge de Sousa Member, Álvaro Martins and Paulo Ferrão, Price forecasting in the day-ahead Iberian electricity market using a conjectural variations ARIMA model, 2012
- [54] Alicia Troncoso Lora, Jesús M. Riquelme Santos, Antonio Gómez Expósito, José Luis Martínez Ramos, and José C. Riquelme Santos, Electricity Market Price Forecasting Based on Weighted Nearest Neighbors Techniques, 2007
- [55] M. Pilar Muñoz, Cristina Corchero and F.-Javier Heredia, Improving Electricity Market Price Forecasting with Factor Models for the Optimal Generation Bid, 2013

- [56] G.J. Osório, J.C.O. Matias, J.P.S. Catalão, Electricity prices forecasting by a hybrid evolutionary-adaptive methodology, 2014
- [57] H.M.I. Pousinho, V.M.F. Mendes, J.P.S. Catalão, Short-term electricity prices forecasting in a competitive market by a hybrid PSO–ANFIS approach, 2012
- [58] Juan M. Vilar, Ricardo Cao, Germán Aneiros, Forecasting next-day electricity demand and price using nonparametric functional methods, 2012
- [59] CMVM, ERSE, CNMV, CNE, Descrição do Funcionamento do MIBEL, 2009
- [60] website da ERSE - Entidade Reguladora dos Serviços Energéticos - www.erse.pt/pt/Paginas/home
- [61] website do MIBEL, www.mibel.com/index.php?lang=pt
- [62] Gil, João, *Análise e Previsão da Evolução do Custo da Electricidade em Portugal*, 2010
- [63] Catalão, J., Mariano, S., Mendes, V., Ferreira, L., *Previsão dos Preços da Energia Eléctrica através de Redes Neurais Artificiais*, 2007
- [64] website da Tribal Engineering, <http://www.tribalengineering.com/technology/artificial-neural-ictl.aspx>
- [65] Szkola, J., Pancerz, K., Warchol, J., *Recurrent Neural Networks in Computer-Based Clinical Decision Support for Laryngopathies: An Experimental Study*, 2011
- [66] Mansing, G., Bhausahab, K., Sominath, S., Ashok, B., *Indian stock market prediction using neural network technique*, 2014
- [67] Monforte, C., *El Gobierno elimina los incentivos a los parques eólicos anteriores a 2004*, 04-02-2014
- [68] Eficiencia Energetica Ipsom, *El precio de la electricidad se desinfla*, 27-02-2014
- [69] Eficiencia Energetica Ipsom, *Incidencias en las nucleares elevan el precio de la electricidad por las nubes*, 12-12-2013
- [70] Seifert, V., *Previsão de produção hídrica para agregados regionais despacháveis*, 2014

Capítulo 8

Anexos

8.1 Resultados do Modelo 1

Os gráficos que se seguem mostram a comparação entre as previsões obtidas com o modelo 1 e o preço real para a primeira semana de cada mês do ano.




Figura 8.1: Janeiro




Figura 8.2: Fevereiro




Figura 8.3: Março




Figura 8.4: Abril




Figura 8.5: Maio




Figura 8.6: Junho




Figura 8.7: Julho




Figura 8.8: Agosto




Figura 8.9: Setembro




Figura 8.10: Outubro




Figura 8.11: Primeira semana de Novembro




Figura 8.12: Última semana de Novembro

Figura 8.13: Previsões obtidas com o modelo multivariável

8.2 Resultados do Modelo 2

Os gráficos que se seguem mostram a comparação entre as previsões obtidas com o modelo 2 e o preço real para a primeira semana de cada mês do ano.




Figura 8.14: Janeiro




Figura 8.15: Fevereiro




Figura 8.16: Março




Figura 8.17: Abril




Figura 8.18: Maio




Figura 8.19: Junho




Figura 8.20: Julho




Figura 8.21: Agosto




Figura 8.22: Setembro




Figura 8.23: Outubro




Figura 8.24: Primeira semana de Novembro




Figura 8.25: Última semana de Novembro

Figura 8.26: Previsões obtidas com o modelo autoregressivo

8.3 Resultados do Modelo 3

Os gráficos que se seguem mostram a comparação entre as previsões obtidas com o modelo 3 e o preço real para a primeira semana de cada mês do ano.




Figura 8.27: Janeiro




Figura 8.28: Fevereiro




Figura 8.29: Março




Figura 8.30: Abril




Figura 8.31: Maio




Figura 8.32: Junho




Figura 8.33: Julho




Figura 8.34: Agosto




Figura 8.35: Setembro




Figura 8.36: Outubro




Figura 8.37: Primeira semana de Novembro




Figura 8.38: Última semana de Novembro

Figura 8.39: Previsões obtidas com o modelo estruturado