

FACULDADE DE ENGENHARIA DA UNIVERSIDADE DO PORTO



FEUP

Previsão probabilística de preços de eletricidade para o mercado diário MIBEL

Luís Miguel Moreira e Ribeiro

PARA APRECIÇÃO POR JÚRI

Mestrado Integrado em Engenharia Electrotécnica e de Computadores

Orientador: Prof. Doutor Cláudio Monteiro

25 de Janeiro de 2016

Resumo

O Mercado Ibérico da Energia Elétrica (MIBEL) consiste num mercado concorrencial, no qual o preço de eletricidade diário e quantidade de energia a ser transacionada está dependente das propostas de venda e compra submetidas pelas empresas geradoras e comercializadores respetivamente.

O sucesso por parte destes agentes do mercado, está bastante dependente da capacidade destes em inferir os riscos reais que as suas estratégias de licitação comportam. Surge desta forma o conceito de previsão probabilística de curto prazo do preço do mercado de eletricidade, que visa determinar os preços do mercado e as incertezas associadas a esse valor.

Este tipo de previsões permite assim aos agentes de mercado terem acesso a informações em relação à dispersão da incerteza, permitindo avaliar o maior ou menor risco que o erro da previsão implicará nas suas decisões, e também em relação à assimetria dos desvios relativamente ao valor real. Esta última constitui uma informação bastante importante para estes, uma vez que os erros de previsão por défice e os erros de previsão por excesso apresentam consequências económicas diferentes.

É neste contexto que se insere o tema da presente dissertação, que visa a criação de modelos de previsão probabilista dos preços de curto prazo para o mercado diário do MIBEL, usando a ferramenta de previsão NW-KDE.

Para que tal fosse possível, foi necessário desenvolver-se uma metodologia que permite a otimização das parametrizações do NW-KDE para cada modelo de previsão. Posteriormente, foram analisados os resultados de cada um dos modelos desenvolvidos, determinando-se o melhor modelo de previsão cujo desempenho foi detalhadamente avaliado, sendo também estudada a influência das diversas variáveis explicadoras ou envolventes que afetam a dispersão e assimetria do erro da previsão.

Desta forma, foi possível determinar as parametrizações ótimas do NW-KDE, para cada modelo de previsão, alcançando-se um modelo que é capaz de prever o preço de eletricidade, para a grande maioria das semanas de teste, com uma baixa dispersão da incerteza e de uma forma fiável. Foi também revelada a influência de várias variáveis na dispersão e assimetria do erro de previsão.

Palavras-chave: Previsão do Preço de Eletricidade, NW-KDE, Preço Diário, Previsão Probabilística

Abstract

The Iberian Electricity Market (MIBEL) consists on a competitive market, where the daily price of electricity and the amount of energy being transacted is dependent from the sell and bid proposals undertaken by producer and commercializing companies.

The success of these market agents is dependent of their ability to predict accurately the risks their auction strategies have. Arises this way, the concept of short-term probability forecast of the electricity market price, which determines the market prices and uncertainty associated to this value.

This type of forecast enables the market agent to have access to information regarding the uncertainty dispersion, which will allow them to evaluate the risk that their forecast error will have in their decisions, and also information regarding the asymmetry of the deviations compared to the real value. This latter case provides very valuable data, since forecasting errors by deficit and by excess present very different economic consequences.

This dissertation is related with the above subject. The main goal is to create short-term probability forecast models for the daily market prices of MIBEL, using the forecasting tool NW-KDE.

For this to become a reality, it was necessary to develop a method that allows the optimization of the NW-KDE parameters for each forecasting model. Subsequently, the results of each of these models were analysed, determining the best forecasting model whose performance was thoroughly evaluated.

Thus, it was possible to determine the optimal parameter setting of NW-KDE, for each forecasting model, creating a model that is capable of predicting the electricity price with a low uncertainty dispersion and in a reliable way, for the great majority of the tested weeks. It was also revealed the influence of many variables on the dispersion and asymmetry of the forecasting error.

Key words: Electricity Price Forecast, NW-KDE, Daily Price, Probability Forecasting

Agradecimentos

Gostaria de agradecer em primeiro lugar ao Professor Cláudio Monteiro pela excelente orientação que me prestou na realização desta dissertação.

Quero de agradecer também à empresa Smartwatt e à Universidade de la Rioja pela disponibilização dos dados que possibilitaram o desenvolvimento deste documento.

A título mais pessoal gostaria ainda de agradecer, à minha família pelo apoio e por me ter dado os alicerces que me permitiram chegar aqui. Ao Zu, Zé e Nuno pelas noites de estudo e companheirismo. Ao Lynx e João Luís, irmãos por afinidade que partilharam comigo casa durante esta etapa da minha vida. Ao Marino pela consciência e pelos conselhos e à Rita por estar sempre presente e disponível para me ajudar.

E por último à Joana por nunca me permitir sentir que estava a ultrapassar as dificuldades sozinho, fazendo dos meus obstáculos os dela, sendo um verdadeiro pilar que nunca me deixou cair.

Luís Miguel Moreira e Ribeiro

*“No power. Just precision. No speed. Just timing.
These are fundamentals. That’s all it takes!”*

Conor McGregor

Conteúdo

Resumo	i
Abstract	iii
Agradecimentos	v
1 Introdução	1
1.1 Enquadramento	1
1.2 Motivação	2
1.3 Objetivos	3
1.4 Estrutura da Dissertação	3
2 Estado da Arte	5
2.1 Introdução	5
2.2 Previsão Determinista do Preço da Eletricidade	5
2.2.1 <i>Time Framework</i>	5
2.2.2 Classificação dos modelos quanto às variáveis utilizadas	6
2.2.3 Avaliação de Desempenho	8
2.2.4 Classificação dos modelos quanto às técnicas matemáticas	10
2.3 Previsão Probabilística do Preço da Eletricidade	15
2.3.1 Intervalos de Previsão	16
2.3.2 Previsão da Densidade	17
2.3.3 Avaliação de Desempenho	23
3 Metodologia	29
3.1 <i>Time Framework</i>	29
3.2 Informação Utilizada	32
3.2.1 Variáveis Cronológicas	32
3.2.2 Variáveis de Preço	33
3.2.3 Variáveis Meteorológicas	33
3.2.4 Variáveis de Produção Elétrica	34
3.2.5 Variáveis de Previsão de Consumo e Produção Elétrica	35
3.2.6 Dados Utilizados	35
3.2.7 Modelos de Previsão	36
3.3 Parâmetros da Ferramenta de Previsão	37
3.4 Metodologia para a Identificação das Parametrizações Ótimas de cada Modelo de Previsão	45
3.4.1 Avaliação dos Modelos no Processo de Parametrização	45

3.4.2	Conclusões Sobre as Consequências Práticas das Parametrizações na Qualidade do Modelo de Previsão	46
3.4.3	Metodologia	48
4	Análise de Resultados	51
4.1	Indicadores de Erro	51
4.1.1	Indicadores da Previsão Determinista (Quantil 50)	51
4.1.2	Indicadores da Previsão Probabilística	53
4.2	Resultados Obtidos para os 23 Modelos de Previsão	55
4.3	Análise do Melhor Modelo de Previsão de cada Grupo	57
4.3.1	Modelo 3 - Variáveis Cronológicas	58
4.3.2	Modelo 6 - Variáveis Cronológicas e Preços	61
4.3.3	Modelo 10 - Variáveis Cronológicas, Preços e Consumos	64
4.3.4	Modelo 14 - Variáveis Cronológicas, Preços, Consumos e Previsões Meteorológicas	68
4.3.5	Modelo 23 - Variáveis Cronológicas, Preços, Consumos, Previsões Meteorológicas e Produções	71
4.4	Influência das Variáveis Explicadoras na Previsão do Melhor Modelo	75
4.4.1	Dia da Semana	76
4.4.2	Hora	77
4.4.3	Preço D	78
4.4.4	Preço D-6	80
4.4.5	Consumo D+1	81
4.4.6	Consumo D-1	82
4.4.7	Eólica D+1	84
4.4.8	Temperatura D+1	85
4.4.9	Hídrica D-1	87
4.4.10	Carvão D-1	88
4.4.11	Gás Natural D-1	90
4.5	Evolução do Preço real e da FDP Prevista do Melhor Modelo	92
5	Conclusões e Trabalhos Futuros	95
5.1	Conclusão	95
5.2	Trabalhos Futuros	96
A	Anexos	99
A.1	Anexo A	99
	Referências	101

Lista de Figuras

2.1	Principais técnicas matemáticas para a previsão de preços de eletricidade	11
2.2	Gráfico de dispersão dos preços do mercado em relação à série histórica da carga	21
2.3	Exemplos de diferentes tipos de cenários de <i>reliability</i> [1]	24
2.4	Exemplo gráfico do cenário de <i>reliability: Points out of Distribution</i>	25
3.1	Processo de concertação de propostas de venda e aquisição	30
3.2	<i>Time Framework</i> das PPE realizadas na presente dissertação, em hora portuguesa [2]	31
3.3	Parte do código da ferramenta NW-KDE para H Dinâmico ligado	38
3.4	Parte do código da ferramenta NW-KDE que calcula a função de kernel	39
3.5	Parte do código da ferramenta NW-KDE que calcula a função de <i>kernel</i> para variáveis cíclicas	39
3.6	Parte do código da ferramenta NW-KDE que contém a condição imposta pelo <i>Nível de Ativação</i>	39
3.7	Gráfico de dispersão dos preços do mercado em relação à série histórica da carga com <i>Nível de Ativação</i>	40
3.8	Parte do código da ferramenta NW-KDE que contém o calculo dos pontos similares Contar X2	40
3.9	Parte do código da ferramenta NW-KDE que contém que calcula o fator multiplicativo	41
3.10	Pontos para o cálculo do fator multiplicativo [3]	41
3.11	Parte do código da ferramenta NW-KDE que calcula a nova largura de kernel . .	41
3.12	Parte do código da ferramenta NW-KDE	42
3.13	Exemplo de diagrama de <i>reliability</i> com um <i>Ajuste</i> de 0,5	43
3.14	Exemplo de diagrama de dispersão com um <i>Ajuste</i> de 0,5	43
3.15	Exemplo de diagrama de <i>reliability</i> com um <i>Ajuste</i> de 1,9	44
3.16	Exemplo de diagrama de dispersão com um <i>Ajuste</i> de 1,9	44
3.17	NMAE para diferentes valores de H de Referência da variável Eólica D-1	47
3.18	Fluxograma da metodologia desenvolvida para a identificação das parametrizações ótimas de cada modelo de previsão	49
4.1	Exemplo gráfico de uma análise de frequência do erro	52
4.2	Exemplo gráfico de uma análise dos erros médios da previsão	52
4.3	Exemplo gráfico de uma análise dos erros médios para as semanas de teste	53
4.4	Exemplo de diagrama de <i>reliability</i> da FDP	54
4.5	Exemplo de diagrama de dispersão	54
4.6	Tabela dos resultados obtidos para cada modelo de previsão	56
4.7	Evolução dos indicadores de erro com os 23 modelos de previsão	57

4.8	Gráfico da frequência do erro do modelo 3	58
4.9	Gráfico dos erro médios do modelo 3	59
4.10	Gráfico dos erros médios para as semanas de teste do modelo 3	59
4.11	Diagrama de reliability da FDP do modelo 3	60
4.12	Diagrama de dispersão do modelo 3	61
4.13	Gráfico da frequência do erro do modelo 6	61
4.14	Gráfico dos erro médios do modelo 6	62
4.15	Gráfico dos erros médios para as semanas de teste do modelo 6	63
4.16	Diagrama de reliability da FDP do modelo 6	63
4.17	Diagrama de dispersão do modelo 6	64
4.18	Gráfico da frequência do erro do modelo 10	65
4.19	Gráfico dos erro médios do modelo 10	65
4.20	Gráfico dos erros médios para as semanas de teste do modelo 10	66
4.21	Diagrama de reliability da FDP do modelo 10	67
4.22	Diagrama de dispersão do modelo 10	67
4.23	Gráfico da frequência do erro do modelo 14	68
4.24	Gráfico dos erro médios do modelo 14	69
4.25	Gráfico dos erros médios para as semanas de teste do modelo 14	69
4.26	Diagrama de reliability da FDP do modelo 14	70
4.27	Diagrama de dispersão do modelo 14	71
4.28	Gráfico da frequência do erro do modelo 23	72
4.29	Gráfico dos erro médios do modelo 23	72
4.30	Gráfico dos erros médios para as semanas de teste do modelo 23	73
4.31	Diagrama de reliability da FDP do modelo 23	74
4.32	Diagrama de dispersão do modelo 23	74
4.33	Evolução dos indicadores de erro com o melhor modelo de previsão de cada grupo	75
4.34	Diagrama de dispersão da previsão com o Dia da semana	76
4.35	Evolução dos erros médios da previsão com o Dia da Semana	77
4.36	Diagrama de dispersão da previsão com a Hora	77
4.37	Evolução dos erros médios da previsão com a Hora	78
4.38	Diagrama de dispersão da previsão com o Preço D	79
4.39	Evolução dos erros médios da previsão com o Preço D	79
4.40	Diagrama de dispersão da previsão com o Preço D-6	80
4.41	Evolução dos erros médios da previsão com o Preço D-6	81
4.42	Diagrama de dispersão da previsão com o Consumo D+1	82
4.43	Evolução dos erros médios da previsão com o Consumo D+1	82
4.44	Diagrama de dispersão da previsão com o Consumo D-1	83
4.45	Evolução dos erros médios da previsão com o Consumo D-1	83
4.46	Diagrama de dispersão da previsão com a Eólica D+1	84
4.47	Evolução dos erros médios da previsão com a Eólica D+1	85
4.48	Diagrama de dispersão da previsão com a Temperatura D+1	85
4.49	Evolução dos erros médios da previsão com a Temperatura D+1	86
4.50	Diagrama de dispersão da previsão com o Mês	86
4.51	Evolução dos erros médios da previsão com o Mês	87
4.52	Diagrama de dispersão da previsão com a Hídrica D-1	88
4.53	Evolução dos erros médios da previsão com a Hídrica D-1	88
4.54	Diagrama de dispersão da previsão com o Carvão D-1	89
4.55	Evolução dos erros médios da previsão com o Carvão D-1	89

4.56	Diagrama de dispersão da previsão com o Gás Natural D-1	90
4.57	Evolução dos erros médios da previsão com o Gás Natural D-1	91
4.58	Evolução do preço do mercado diário real e previsto para a semana 30 de 2012 (Verão)	92
4.59	Evolução do preço do mercado diário real e previsto para a semana 50 de 2012 (Inverno)	93
4.60	Evolução do preço do mercado diário real e previsto para a semana 27 de 2013 (Primavera)	93
4.61	Evolução do preço do mercado diário real e previsto para a semana 42 de 2013 (Outono)	94
A.1	Parametrizações ótimas de cada modelo	100

Lista de Tabelas

2.1	Características dos diferentes horizontes temporais de previsão	6
2.2	Tipos de variáveis explicadoras utilizadas nas PPE de curto prazo	8
2.3	Indicadores de Erro	9
2.4	Base de conhecimento histórico do modelo de previsão	19
2.5	Base de conhecimento futuro do modelo de previsão	20
2.6	Representações de incertezas e respetivas skill score	26
3.1	Variáveis utilizadas nos modelos de previsão	32
3.2	Modelos de previsão desenvolvidos para a previsão probabilística do preço do mercado diário do MIBEL	36

Abreviaturas e Siglas

AE	<i>Absolute Error</i>
APE	<i>Absolute Percentage Error</i>
AR	<i>AutoRegressive</i>
ARCH	<i>AutoRegressive Conditional Heteroskedastic model</i>
ARIMA	<i>AutoRegressive Integrated Moving Average</i>
ARMA	<i>AutoRegressive Moving Avarage model</i>
CRPS	<i>Continuous Ranked Probability Score</i>
CRPSS	<i>Continuous Ranked Probability Skill Score</i>
$\overline{CRPS}$	<i>Average Continuous Ranked Probability Skill Score</i>
DDS	Dia da Semana
DRMSE	<i>Daily Root Mean Square Error</i>
FDP	Função Densidade de Probabilidade
GARCH	<i>Generalized AutoRegressive Conditional Heteroskedastic model</i>
GN	Gás Natural
KDE	<i>Kernel Density Estimator</i>
MA	<i>Moving Average</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MASE	<i>Mean Absolute Scaled Error</i>
MDE	<i>Mean Daily Error</i>
MIBEL	Mercado Ibérico de Eletricidade
MNoE	<i>Mean Negative Error</i>
MPoE	<i>Mean Positive Error</i>
MWE	<i>Mean Weekly Error</i>
NEM	<i>National Electricity Market</i>
NMAE	<i>Normalized Mean Absolute Error</i>
NW-KDE	<i>Nadaraya Watson - Kernel Density Estimator</i>
OMIE	<i>Operador del Mercado Ibérico de Energía</i>
PBF	Programa Diário Viável
PBF	Programa de Base de Funcionamento
PIT	<i>Probability Integral Transform</i>
PPE	Previsão do Preço de Eletricidade
REE	<i>Red Eléctrica de España</i>
REN	Redes Energéticas Nacionais
RMSE	<i>Root Mean Square Error</i>
RMSSE	<i>Root Mean Square Scaled Error</i>
RNA	Redes Neurais Artificiais
SARIMA	<i>Seasonal AutoRegressive Integrated Moving Average</i>
SE	<i>Square Error</i>
SVC	<i>Support Vector Machines</i>
WRMSE	<i>Weekly Root Mean Square Error</i>

Lista de Símbolos

P_h	Preço real para o período de carga h
$\hat{P}_h$	Preço previsto para o período de carga h
σ	Desvio padrão
σ^2	Variância
t	Momento para o qual se pretende prever o valor do preço da eletricidade ou dia seguinte
k	<i>Time-steps</i>
V	Variável explicadora
X	Vetor de variáveis explicadoras
Y	Variável dependente
μ	Valor médio
H	Intervalo multidimensional de ativação do <i>kernel</i>
K	Função de <i>kernel</i>
h_p	Largura da banda do <i>kernel</i>
f	Função densidade de probabilidade
α	Coefficiente de forma da FDP Beta
β	Coefficiente de forma da FDP Beta
F_t	Distribuição da previsão probabilística
G_t	Distribuição real da probabilidade
p_t	Função do PIT
$F_o(x)$	Função <i>Heaviside</i>
τ	Valor do quantil <i>target</i>
y	Valor real do quantil
z	Valor previsto do quantil
i	Índice de intervalos
N	Número de intervalos
$f_{real,i}$	Frequência de valores reais previstos para cada intervalo da FDP estipulado
$f_{ideal,i}$	Frequência ideal de valores reais para cada intervalo da FDP estipulado
Q_x	Quantil x

Capítulo 1

Introdução

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

1.1 Enquadramento

À semelhança de outros agregados de países, também a Península Ibérica possui o seu próprio mercado de energia elétrica, o Mercado Ibérico da Energia Elétrica – MIBEL.

Este resulta de um processo de cooperação desenvolvido pelos Governos de Portugal e Espanha com o objetivo de promoverem a integração dos sistemas elétricos dos dois países e de que com isso adviessem benefícios para os consumidores de ambos os países, num quadro de garantia do acesso a todos os interessados em condições de igualdade, transparência e objetividade. Este processo de cooperação entre os dois países constituiu um contributo significativo não só para a concretização do mercado de energia elétrica a nível Ibérico, mas também, à escala europeia, sendo um passo significativo para uma futura construção do Mercado Interno de Energia (mercado único que agrega todos os mercados da Europa). Após um trabalho de harmonização de condições entre os dois sistemas elétricos ibéricos, este mercado arrancou, finalmente, em toda a sua dimensão em 1 de Julho de 2007.

O MIBEL é constituído por Mercados Diários e Intradiários, sendo que os estudos na presente dissertação incidirão sobre os primeiros. Estes funcionam de uma forma concorrencial, através de leilões diários, nos quais é definido o preço e a quantidade de energia a ser transacionada, através do processo de concertação das propostas de venda e aquisição, propostas essas submetidas pelas unidades geradoras e pelos comercializadores, respetivamente.

O objetivo destes dois agentes do mercado visa a maximização dos seus lucros, objetivo esse que está extremamente dependente das estratégias de licitação que estes definam. Torna-se então extremamente necessário para estes, terem à sua disposição o máximo de informação de qualidade sobre as condições futuras do mercado, de forma a poderem analisar os riscos de diferentes estratégias de licitação e definirem a que melhor serve os seus interesses.

Surge desta forma o conceito de previsão do preço de eletricidade de curto prazo, que consiste na aplicação de ferramentas de previsão para se determinar o preço de mercado num futuro próximo, utilizando informação histórica e informação atual sobre as características do mercado.

1.2 Motivação

A previsão de curto prazo do preço eletricidade do mercado diário é uma ferramenta essencial para os *traders* do mercado energético, uma vez que a qualidade das suas estratégias de licitação, ou seja a maximização dos seus lucros, está altamente dependente da capacidade destes em conseguirem prever as condições futuras do mercado.

A grande maioria dos estudos desenvolvidos sobre previsão do preço de eletricidade do MIBEL optam por uma abordagem determinista, ou seja determinam um único valor esperado para o horizonte de previsão. No entanto, esta abordagem está incompleta, uma vez que não tem em conta o fato dos proveitos que advém das estratégias de licitação dependerem bastante, não só do valor esperado, mas também da dispersão da incerteza e da assimetria dos desvios relativamente ao valor real. Posto isto, é necessária uma nova abordagem para se conseguirem suplantarem as debilidades das previsões deterministas em processos de negócio que usam preços de mercado. Esta nova abordagem corresponde às previsões probabilísticas, que têm a capacidade de quantificar as incertezas associadas ao valor esperado, sendo que quanto maior a dispersão da incerteza da previsão, maior será o risco no processo de negocio. Possuem também a capacidade de determinarem a assimetria da incerteza nos preços, cuja informação é importante uma vez que, erros de previsão por défice podem implicar desequilíbrios financeiros catastróficos para as empresas e erros de previsão por excesso têm consequências bastante menores. Desta feita, estas valências da previsão probabilística proporcionam aos agentes de mercado informações necessárias ao controlo e mitigação de riscos nas suas estratégias de negócio.

Sendo assim, dependendo do processo de negócio, a previsão probabilística poderá ser mais ou menos relevante, mas no geral é uma informação essencial nos processos de decisão, desde que o agente tenha ferramentas e processos capazes de tirar proveito de uma análise e otimização baseada em análise de risco. Justifica-se desta forma a relevância de levar a cabo estudos sobre a previsão probabilística de preços de eletricidade para o mercado diário do MIBEL.

Posto isto, a presente dissertação tem como objetivo estudar ferramentas de previsão probabilística de forma a otimizar o desempenho da avaliação da incerteza, tentando reduzir a dispersão da mesma e tentando garantir que a sua representação é fiável, para que o risco da decisão seja o mais baixo possível e seja realista. Pretende-se também avaliar a influência das diversas variáveis explicadoras ou envolventes que afetam a dispersão e assimetria do erro da previsão, para assim conseguir uma mais eficaz mitigação do risco, de acordo com o contexto que afeta os preços e a previsão.

1.3 Objetivos

A presente dissertação tem como principal objetivo desenvolver modelos de previsão probabilística para o preço de mercado diário do MIBEL, utilizando ferramentas de previsão do tipo NW-KDE, que contenham os seguintes tipos de informação: variáveis cronológicas, preços em dias anteriores, previsão de consumos, consumos em dias anteriores, previsão de produção renovável, previsão de produção termoelétrica. É ainda expectável que se cumpram os seguintes objetivos:

- Adaptação de modelos NW-KDE para a previsão probabilística de preços de eletricidade.
- Otimização da parametrização de modelos de previsão probabilística de preços de eletricidade.
- Analisar os resultados obtidos para cada modelo de previsão, encontrando-se o melhor modelo de previsão probabilística do preço de mercado diário do dia seguinte.
- Avaliar o desempenho do melhor modelo de previsão probabilística do preço de mercado diário do dia seguinte.
- Retirar conclusões quanto ao desempenho da previsão probabilística relativamente à previsão determinista.

1.4 Estrutura da Dissertação

O presente documento encontra-se dividido em 5 capítulos distintos.

O capítulo 1 é um capítulo introdutório, onde é feito o enquadramento e se descrevem as motivações que justificam a relevância da presente dissertação, bem como os objetivos que se esperam alcançar.

No capítulo 2 é abordado o estado de arte do documento, realizando-se uma revisão bibliográfica sobre os dois tipos de previsões que existem, as previsões deterministas e as previsões probabilísticas do preço de eletricidade. Abordando-se os tipos de horizontes temporais que estas previsões podem assumir, a classificação dos modelos quanto às variáveis utilizadas, a classificação dos modelos quanto às técnicas matemáticas utilizadas e como são realizadas as avaliações de desempenho.

No capítulo 3 é descrita a metodologia aplicada. Neste sentido, analisa-se a *Time Framework* das previsões realizadas, a informação utilizada nos vários modelos de previsão desenvolvidos e os parâmetros da ferramenta de previsão, bem como a metodologia para a identificação das parametrizações ótimas para cada modelo de previsão.

No capítulo 4, são analisados os resultados obtidos. Contendo uma descrição dos indicadores de erro utilizados na avaliação dos modelos e os resultados obtidos em cada modelo de previsão, são também analisados os melhores modelos de previsão de cada grupo de modelos, a influência das variáveis explicadoras na previsão do melhor modelo de previsão e a capacidade de previsão deste modelo em 4 semanas distintas.

No capítulo 5, são expostas as conclusões da presente dissertação, bem como possíveis trabalhos futuros.

Capítulo 2

Estado da Arte

2.1 Introdução

O presente capítulo resulta de um estudo bibliográfico cujas principais referências foram os artigos *Electricity price forecasting: A review of the state-of-the-art with a look into the future* [4] e *State-of-the-Art of Electricity Price Forecasting* [5].

Posto isto, neste capítulo irão ser expostos e analisados, todos os fatores teóricos que terão que ser tidos em conta quando se fazem previsões do preço de eletricidade (PPE) deterministas (*Point Forecast* na literatura inglesa) e a previsões probabilística (*Probabilistic Forecast* na literatura inglesa). Sendo que, inicialmente explorar-se-ão as primeiras, onde serão abordados alguns pontos comuns de qualquer um destes dois tipos de previsão (*time framework* e classificação dos modelos quanto às variáveis utilizadas) e por fim as suas técnicas matemáticas e como são realizadas as suas avaliações de desempenho. E posteriormente, serão analisadas as PPE probabilísticas, nomeadamente as suas técnicas matemáticas, avaliações de desempenho e possíveis aplicações no mercado de eletricidade.

2.2 Previsão Determinista do Preço da Eletricidade

2.2.1 Time Framework

Quando se decide fazer uma previsão a primeira coisa que se tem que fazer, após se definir a variável a prever, é definir o horizonte temporal da previsão. Este define-se como sendo o período temporal compreendido entre o momento em que a previsão é efetuada e o instante para o qual se quer prever uma determinada variável.

Em relação a este tema não existe um consenso na literatura da especialidade sobre PPE em relação aos termos que devem ser utilizados para se definirem os diversos horizontes temporais. [4] No entanto é usual falar-se em previsão de longo prazo, médio prazo e curto prazo.

O que separa as previsões destes três tipos de horizontes temporais são, essencialmente, o tipo de técnicas e variáveis de influência que são utilizadas no seu desenvolvimento, as suas aplicações

e avaliações de desempenho (um determinado erro da previsão pode ser aceitável para uma previsão de longo prazo e não ser aceitável para uma de curto prazo). Segundo [6], estes três tipos de previsões definem-se da seguinte maneira:

Previsões de preços de eletricidade de longo prazo - dizem respeito a horizontes de previsão de meses, trimestres ou mesmo anos e são usadas principalmente para análises de aproveitamento de investimentos e planeamento (determinação de novas localizações ou fontes de combustível para as centrais, por exemplo [7]). E enquanto que para as PPE de médio e curto prazo podem ser utilizadas técnicas semelhantes, este tipo de previsões geralmente requer abordagens diferentes.

Previsões de preços de eletricidade de médio prazo - este insere-se em PPE no intervalo temporal que vai desde alguns dias até meses depois. São utilizadas em cálculos de balanços, em planeamentos de expansão da geração e de manutenção, na realocação de recursos e na realização de contratos bilaterais. [8] [9]

Previsões de preços de eletricidade de curto prazo – são as mais comuns. Tratam-se de previsões que vão desde alguns minutos até alguns dias depois e são de extrema importância nas operações diárias dos mercados, por exemplo na preparação de propostas de oferta e compra e na implementação de outras funções de operação de sistemas de potência e em funções de operação de sistemas energéticos. [10] [9] A título de exemplo, uma central que seja capaz de prever o preço a curto prazo da eletricidade pode ajustar o planeamento da sua produção de forma a maximizar o seu lucro. [7] [5]

Um resumo de algumas características destes três horizontes temporais de previsão pode ser visto na Tabela 2.1:

Tabela 2.1: Características dos diferentes horizontes temporais de previsão

<i>Time Framework</i>	Curto Prazo	Médio Prazo	Longo Prazo
Horizonte temporal da previsão	De alguns minutos até dias	De alguns dias até meses	Meses; Trimestres; Anos
Aplicação	Operações diárias dos mercados	Gestão de riscos de novas estratégias	Análise de aproveitamento de investimentos e planeamento
Erros (tolerância)	Baixa	Média	Alta

Todas as previsões efetuadas nesta dissertação serão PPE de curto prazo.

2.2.2 Classificação dos modelos quanto às variáveis utilizadas

Um aspeto chave na PPE (e qualquer tipo de previsão por sinal) é uma boa seleção das variáveis que serão utilizadas como *input* no modelo de previsão. [4] [11] No entanto, este tipo de decisões têm que ser tomadas baseadas em suposições de quem está a fazer a previsão e, onde existem tomadas de decisões humanas, há espaço para a existência de erros. [12] É por isso de extrema importância o pré-processamento, a seleção e a forma como serão organizadas as variáveis que vão ser utilizadas. [2]

Na presente dissertação optou-se por classificar as diferentes variáveis explicadoras em seis classes distintas:

Variáveis cronológicas – O preço de mercado é caracterizado por um comportamento de sazonalidade em termos diários, semanais e mesmo em termos anuais até um certo nível, que se deve essencialmente à variabilidade da intensidade das atividades de negócio, o que leva a que o tempo apresente uma grande relação com o preço do mercado. [4] Posto isto, surgiu a necessidade de se incluírem variáveis deste tipo, que quantificassem e qualificassem esta característica, sendo usual a existência de variáveis referentes à hora, dia, fim-de-semana, mês, ano, feriados e estação do ano, em vários modelos. Estas variáveis são de livre acesso a todos os agentes do mercado.

Variáveis de preço – Estas variáveis são autorregressivas. Dizem respeito aos preços de mercado históricos (de dias até anos atrás) e/ou presentes e existem devido à elevada relação entre os valores futuros do preço com valores conhecidos desta variável no passado e presente. Estas são normalmente facultadas pela maioria dos operadores do mercado, porém a obtenção de valores correspondentes a preços de períodos muito longínquos no passado pode revelar-se bastante difícil.

Variáveis de produção elétrica – As variáveis de produção elétrica, ou exógenas, pretendem representar alguns dos fatores externos que influenciam o mercado dos preços da eletricidade e são variáveis históricas ou presentes. Exemplos de variáveis pertencentes a esta classe são: a geração de energia solar, térmica, eólica, hídrica e nuclear e o consumo de energia. Para as previsões que irão ser feitas ao longo desta dissertação, em relação ao preço da eletricidade no MIBEL, os valores destas variáveis são diariamente fornecidas pelo TSO português REN [13] e pelo TSO Espanhol ([14]), no entanto têm que ser processados de forma a tornar estas duas séries numa só.

Variáveis meteorológicas – Estas consistem em previsões (para o mesmo horizonte temporal da previsão que se pretende fazer) de fatores climatéricos que possam influenciar o preço da eletricidade, nomeadamente a temperatura, irradiância, pluviosidade e velocidade e direção do vento. Estes dados podem ser obtidos através de institutos meteorológicos, no entanto dado o tamanho da Península Ibérica e o fato destes variarem conforme a posição geográfica para onde foram previstos, é necessário ter especial atenção ao seu processamento, para que os valores de diversos pontos geográficos da mesma variável sejam expressos como uma única série que represente essa variável na Península Ibérica.

Variáveis de previsão de consumo e produção elétrica – São as mesmas variáveis da classe das variáveis de produção elétrica, porém representam valores futuros ao passo que as da segunda classe representam valores históricos. Como o próprio nome indica estas só podem ser obtidas através da realização de previsões das mesmas.

Variáveis de restrição – São variáveis históricas que representam a relação das restrições do

sistema, da rede elétrica e do mercado com o preço da eletricidade. Alguns exemplos de variáveis desta classe são: limites das linhas (restrições da rede elétrica), limites de geração e níveis de reserva (restrições do sistema) e limites de energia transacionada (restrições do mercado). Dado que são de difícil acesso, este tipo de variáveis não serão utilizadas nas previsões que serão feitas nesta dissertação.

A escolha do modelo de previsão quanto às variáveis explicadoras que serão utilizadas varia com o horizonte temporal da previsão (curto, médio ou longo), mas também com o período (ano) para o qual se está a fazer a previsão e também com o mercado. O autor de [15] afirmou que, no período entre 2011 e 2012 no mercado do Reino Unido, variáveis explicadoras comumente utilizadas como a geração eólica, consumo e preço do gás não tiveram grande influência no preço da eletricidade, ao passo que picos no preço (ou especulação de) foram responsáveis por 95% da sua variação. [4]

Nas PPE de curto prazo realizadas na presente dissertação foram utilizadas as variáveis explicadoras presentes na Tabela 2.2:

Tabela 2.2: Tipos de variáveis explicadoras utilizadas nas PPE de curto prazo

	Variáveis Cronológicas	Variáveis de Preço	Variáveis Meteorológicas	Variáveis de Produção Elétrica	Variáveis de Previsão de Consumo e Produção Elétrica
<i>Time Framework</i>	-	D ou D-x	D+x	D-x	D+x

2.2.3 Avaliação de Desempenho

Em relação às avaliações de desempenho, não existe uma norma definida e as denominações das medidas de avaliação não são usadas de forma consistente na literatura da especialidade, o que leva a que comparações de previsões de diferentes autores tenham que ser feitas com bastante precaução. [4] No entanto, irão ser abordados nos parágrafos seguintes algumas das medidas de precisão mais utilizadas. Esta explicação teve como base o estudo bibliográfico feito por [4].

Os erros absolutos e erros quadráticos são as medidas de precisão mais comumente utilizadas. A fórmula matemática do primeiro pode ser observada na Tabela 2.3, onde P_h é o preço real e $\hat{P}_h$ o preço previsto para o período de carga h . Através do seu cálculo podem ser construídos histogramas, dos quais se podem retirar vários indicadores estáticos, tais como: BIAS; desvio padrão (σ); variância (σ^2); STD; viés e *skewness*. Além destes indicadores é também possível calcular-se o *mean absolute error* (MAE), onde para previsões horárias o MAE diário é composto pela média de $T=24$ erros absolutos e o semanal por $T=168$.

Tabela 2.3: Indicadores de Erro

		Sigla	Nome	Fórmula
Erros Absolutos	Normais	AE	Absolute Error	$AE_h = P_h - \hat{P}_h $
		MAE	Mean Absolute Error	$MAE_T = \frac{1}{T} \sum_{h=1}^T [P_h - \hat{P}_h]$
	Percentuais	APE	Absolute Percentage Error	$APE_h = \frac{ P_h - \hat{P}_h }{P_h}$
		MDE	Mean Daily Error	$MDE_{24} = \frac{1}{24} \sum_{h=1}^{24} \frac{ P_h - \hat{P}_h }{\bar{P}_{24}}$
		MWE	Mean Weekly Error	$MDE_{168} = \frac{1}{168} \sum_{h=1}^{168} \frac{ P_h - \hat{P}_h }{\bar{P}_{168}}$
		NMAE	Normalized Mean Absolute Error	$NMAE_T = \frac{1}{T} \sum_{h=1}^T \left[\frac{ P_h - \hat{P}_h }{\bar{P}_h} \right]$
		MAPE	Mean Absolute Percentage Error	$MAPE_T = \frac{1}{T} \sum_{h=1}^T \left[\frac{ P_h - \hat{P}_h }{P_h} \right]$
	Escalados	MASE	Mean Absolute Scaled Error	$MASE_T = \frac{1}{T} \sum_{h=1}^T \left[\frac{ P_h - \hat{P}_h }{\frac{1}{T-m} \sum_{l=m+1}^T [P_h - P_{h-m}]} \right]$
Erros Quadráticos	Normais	SE	Square Error	$SE_h = (P_h - \hat{P}_h)^2$
		RMSE	Root Mean Square Error	$RMSE_T = \sqrt{\frac{1}{T} \sum_{h=1}^T [(P_h - \hat{P}_h)^2]}$
		DRMSE	Daily Root Square Error	$DRMSE_{24} = \sqrt{\frac{1}{24} \sum_{h=1}^{24} [(P_h - \hat{P}_h)^2]}$
		WRMSE	Weekly Root Square Error	$WRMSE_{168} = \sqrt{\frac{1}{168} \sum_{h=1}^{168} [(P_h - \hat{P}_h)^2]}$
	Percentuais	RMSPE	Root Mean Square Percentage Error	$RMSE_T = \sqrt{\frac{1}{T} \sum_{h=1}^T \left[\frac{(P_h - \hat{P}_h)^2}{P_h} \right]}$
		DRMSPE	Daily Root Square Percentage Error	$DRMSE_{24} = \sqrt{\frac{1}{24} \sum_{h=1}^{24} \left[\frac{(P_h - \hat{P}_h)^2}{P_h} \right]}$
		WRMSPE	Weekly Root Square Percentage Errors	$WRMSE_{168} = \sqrt{\frac{1}{168} \sum_{h=1}^{168} \left[\frac{(P_h - \hat{P}_h)^2}{P_h} \right]}$
	Escalados	RMSSE	Root Mean Square Scaled Errors	$RMSSE_T = \frac{1}{T-24} \sum_{h=25}^T [(P_h - P_{h-24})^2]$

Porém, visto que erros absolutos são difíceis de comparar para diferentes *datasets*, muitos autores usam medidas baseadas em erros absolutos normalizados: AE_h/REF . Como referência (REF) podem ser utilizados vários tipos de valores, nomeadamente o valor real (P_h) que dará origem ao *absolute percentage error* (APE_h), o preço médio obtido num dia que dará origem ao *mean daily errors* (MDE), o preço médio obtido numa semana que dará origem ao *mean weekly errors* (WMAE) e o preço médio obtido num mês ou a média de um valor de teste.

Do APE_h surge uma das medidas de erro mais popular, o *mean absolute percentage error* (MAPE), que consiste na média de T erros absolutos percentuais. Porém, a utilização do MAPE pode levar a fracas avaliações já que, se os preços de eletricidade forem valores perto de 0, os valores do MAPE serão bastante grandes (independentemente dos valores dos erros absolutos). Por outro lado, se o preço de eletricidade tiver um pico, os valores do MAPE serão pequenos e se os valores dos preços forem negativos, os valores do MAPE serão negativos e difíceis de interpretar.

Embora pouco utilizados na área das PPE, Hyndman and Koehler (2006), depois de terem comparado várias medidas de desempenho e terem chegado à conclusão que elas eram pouco eficientes em muitas situações que ocorriam frequentemente, defendem o uso de *scaled errors* em vez de erros percentuais quando se comparam precisões de previsões em séries de diferentes escalas. Para uma série temporal não sazonal, o *scaled error* usa previsões curto prazo naïve ($m=1$ na equação presente na Tabela 2.3) e para séries temporais sazonais é definido utilizando uma previsão naïve sazonal. O *mean absolute scaled error* (MASE) é definido então pela equação presente na Tabela 2.3, onde se pode definir $m=24$ e $T=168$ para se obter a MASE semanal, ou $m=168$ e T bastante maior que 168 se se pretender ter em conta o efeito “dia útil”/“fim-de-semana”.

Outra abordagem, provavelmente a mais comum, é normalizar o erro absoluto pelo preço médio obtido no intervalo de avaliação. O que nos leva ao diário ou semanal *weighted mean absolute errors* (DMAE e WMAE), também designados por *mean daily errors* (MDE) e *mean weekly errors* (MWE).

Tal como foi referido anteriormente, além dos erros absolutos, também existem os erros quadráticos, sendo a mais utilizada a diária e semanal *root mean square errors* (RMSE, também denominada por DRMSE caso $T=24$ ou WRMSE caso $T=168$). E tal como nas outras medidas baseadas em erros absolutos, a $(P_h - \hat{P}_h)^2$ também pode ser normalizada pela raiz do preço real para se obter a *root mean square percentage error* (RMSPE), pela raiz da média do preço diário (DRMSE), pela raiz da média do preço semanal (WRMSE) ou por $\frac{1}{(T-24)} \sum_{(h=25)}^T (P_h - P_{h-24})^2$ para se obter a sazonal *root mean square scaled error* (RMSSE).

Na presente dissertação serão utilizadas os indicadores de erro NMAE, MPoE e MNeE. Sendo os dois últimos analisados na secção 4.1.1.

2.2.4 Classificação dos modelos quanto às técnicas matemáticas

Da leitura do estado de arte foi possível verificar que existem vários modelos matemáticos para analisar e prever preços de eletricidade, tendo estes sido organizados em três classes (Figura 2.1):



Figura 2.1: Principais técnicas matemáticas para a previsão de preços de eletricidade

Simulações de Mercado: Nesta classe inserem-se os modelos *multi-agent* ou *fundamental*. Estes não são propriamente métodos de previsão mas antes de simulação, já que simulam a operação de um sistema de agentes heterogêneos (centrais, companhias) que interagem entre si e também impactos de fatores físicos e económicos, de forma a alcançarem o valor que se pretende prever. Para se realizar esta operação de simulação é necessário fazer uma previsão multi-modelo, onde se prevê o comportamento de vários agentes do mercado, o que se revela uma tarefa bastante complexa.

Estatísticos: São aplicações diretas das técnicas estatísticas de previsão de carga ou aplicações de modelos econométricos no mercado energético.

Inteligência Computacional: Combinam elementos de aprendizagem, evolução e *fuzziness* para criarem métodos que são capazes de se adaptarem a sistemas dinâmicos complexos e que podem ser considerados “inteligentes” neste sentido.

As previsões que serão feitas no decorrer desta dissertação, sendo de curto prazo, não vão ter em conta variáveis econométricas, pelo que serão abordados apenas os modelos estáticos e computacionais. Posteriormente, será analisado mais aprofundadamente um sub-grupo destes modelos, as técnicas baseadas em séries temporais, onde os modelos estáticos se inserem nas técnicas de regressão linear e os modelos computacionais nas técnicas de heurística não linear.

2.2.4.1 Modelos Estatísticos

Este tipo de modelos surgiram para a PPE através de modelos estatísticos para prever a carga, quando se substituíram, nas variáveis a prever, os consumos por preços e possivelmente os consumos por temperaturas nas variáveis explicadoras. Este foi o primeiro passo dado para a criação de modelos estatístico para a PPE e a partir desse momento vários modelos desta classe foram criados. [4]

Apesar do uso deste tipo de modelos ser bastante questionável para mercados financeiros, em mercados de energia a sua performance é bastante satisfatória. Isto deve-se à influência da sazonalidade nos preços da eletricidade durante períodos normais e em períodos em que não ocorrem picos nos valores, o que leva a que os preços sejam mais previsíveis do que variáveis financeiras que variam “aleatoriamente”. [7]

Este tipo de modelos também são bastante atrativos já que algumas interpretações físicas podem estar ligadas aos seus componentes. As interações entre as variáveis explicadoras são visíveis, ao contrário do que acontece nos modelos de inteligência computacional, o que permite aos engenheiros e operadores de sistema perceberem os seus comportamentos e as torna ideais para definir que modelos se vão aplicar quanto às variáveis utilizadas. Apesar disto, eles são frequentemente criticados devido às suas limitações no que concerne à modelização de comportamentos não lineares entre os preços da eletricidade e as variáveis de influência. Todavia em aplicações práticas a sua performance é comparável.

Os métodos mais populares deste tipo de modelos são: a regressão multivariada (*multivariate regression* na literatura inglesa), as técnicas baseadas em séries temporais e as técnicas de suavização (*smoothing techniques* na literatura inglesa). [7] Contudo, como referido anteriormente na presente dissertação apenas serão analisadas as técnicas baseadas em séries temporais, nomeadamente nas técnicas de séries temporais do tipo AR e ARX e nas do tipo GARCH.

Séries temporais do tipo AR e ARX

A *AutoRegressive Moving Average model* (ARMA) é a técnica baseada em séries temporais padrão, que tem em conta a natureza aleatória e a relação temporal do fenómeno em estudo. Como o próprio nome indica, na técnica ARMA o preço da eletricidade é previsto através da sua relação linear com variáveis autorregressivas (ponto 2.2.2), componente AR (*autoregressive*), e de um termo (futuro) de ruído, componente MA (média móvel ou *moving average* na literatura inglesa). [7]

Esta técnica necessita que a série temporal em estudo seja estacionária, exigindo assim que se verifique a condição de homoscedasticidade, ou seja, que a média seja um valor nulo e a variância e covariância sejam valores constantes [16]. Se tal não se verificar, terá que se proceder à transformação das séries não estacionárias em séries estacionárias. Em 1976, Box and Jenkins, através de diferenciação, criaram um modelo para ultrapassar este obstáculo: o *Autoregressive Integrated Moving Average* (ARIMA) ou modelo Box-Jenkins. É importante ainda referir que se a diferenciação for feita com lags de magnitude maior que 1 em vez de ARIMA passaremos a ter um modelo SARIMA (*Seasonal Autoregressive Integrated Moving Average*) [7]. Em Cuaresma, Hlouskova, Kossmeier e Obersteiner (2004), é possível visualizar a aplicação de variantes de modelos do tipo AR e processos de ARMA na PPE de curto prazo para o mercado alemão EEX e também, em Weron e Misioerek (2005), a aplicação dos modelos do tipo AR na PPE no mercado da Califórnia.

Os modelos do tipo AR são a espinha dorsal de todas as PPE baseadas em séries temporais. [4] No entanto, embora tenham havido várias aplicações deste tipo de modelos na PPE, a maioria dos artigos propõe o uso de técnicas baseadas em series temporais com variáveis exógenas, o que nos leva aos modelos do tipo ARX.

Como já foi analisado no ponto [2.2.2], valores presentes e passados de variáveis exógenas estão relacionadas com os valores do preço da eletricidade e de forma a ser tida em conta esta relação, modelos de séries temporais com variáveis exógenas são utilizados. Este tipo de modelos, do tipo ARX, não são uma classe nova mas antes uma generalização dos modelos do tipo AR,

ou seja o ARMAX, ARIMAX e SARIMAX são generalizações do ARMA, ARIMA e SARIMA respetivamente.

GARCH

Como referido no ponto anterior, os modelos do tipo AR exigem que se verifique a condição de homoscedasticidade e, dado que as séries temporais para a PPE exibem várias formas de não linearidade e não apresentam uma variância constante (heteroscedasticidade), levanta-se aqui uma dificuldade que tem que ser ultrapassada.

Em 1982, pela mão de Engle, foi então criado o *AutoRegressive Conditional Heteroskedastic model* (ARCH) de forma a suplantar este problema e consequentemente, em 1986, Bollerslev criou *Generalized AutoRegressive Conditional Heteroskedastic* (GARCH). No modelo tipo GARCH, a variância condicional depende não só de variáveis autorregressivas mas também da média móvel de variâncias condicionais passadas e tem valores estritamente positivos. [4]

Os modelos do tipo GARCH são interessantes nas previsões de intervalos para o preço da eletricidade (previsões probabilísticas), no entanto para PPE deterministas não são muito eficazes. Este tipo de modelos também é utilizado em técnicas híbridas, a aplicação de um modelo híbrido ARIMA-GARCH pode ser observado em Garcia (2005) e também em Knittel and Roberts (2005) e Tan et al. (2010).

2.2.4.2 Modelos de Inteligência Computacional

Segundo As Duch (2007), a inteligência computacional não é um termo fácil de se definir, é “*a new buzzword that means diferente things to diferente people*”. Todavia, [4] descreveu-o como sendo uma classe bastante diversa de técnicas computacionais inspiradas pela natureza, criadas com o objetivo de resolver problemas, aos quais os métodos tradicionais não conseguem dar uma resposta eficaz.

Modelos computacionais são flexíveis e conseguem lidar com problemas complexos e não lineares, características estas que os afirmam como uma hipótese bastante interessante para PPE curto prazo.

Os principais métodos desta classe de modelos são as redes neuronais artificiais, os *support vector machine* (SVC), *data-mining* e computação evolucionária. Contudo, na presente dissertação irão ser analisados apenas os três primeiros métodos.

Redes Neuronais Artificiais

Segundo [17], as redes neuronais artificiais (RNA) são modelos simplificados do sistema nervoso central do ser humano, ou seja, são uma estrutura composta por unidades computacionais extremamente conectadas (neurónios) com capacidade de aprendizagem. Este processo tenta assim simular o comportamento do cérebro humano, já que o seu conhecimento é adquirido através de interações com um ambiente (processo de aprendizagem) e é armazenado nas conexões (sinapses) entre neurónios.

Os neurónios estão organizados num grupo relativamente pequeno de camadas (conectadas entre si) que se situam entre os *inputs* e *outputs* da rede. [4] Às ligações entre neurónios está associado um fator multiplicativo (peso), sendo que durante o processo de aprendizagem o peso das conexões é ajustado até se atingir um determinado objetivo (neste caso, a previsão de determinados valores) ou estado de conhecimento da rede. [17]

Posto isto, a operação de qualquer RNA inicia-se com um processo de treino, onde são fornecidos à rede *inputs* (variáveis de influência) e *targets* (*outputs* ou variáveis que se querem prever, que correspondem aos respetivos *inputs* que foram inseridos), iniciando-se assim o processo de aprendizagem onde a rede vai determinar quais são as melhores relações entre os *inputs* e *outputs*, de forma a que o erro médio quadrático entre os *outputs* produzidos pela rede e os *outputs* reais (*target*) sejam mínimos. [18] O *Back-Propagation* é o algoritmo de aprendizagem mais utilizado nas RNA de PPE e o *Levenberg-Marquardt* o segundo algoritmo mais popular. [4]

De seguida, inicia-se a fase de teste da RNA, onde são aplicados os pesos (descobertos na fase de treino) a um conjunto de *inputs* (com as mesmas características dos *inputs* utilizados na fase de treino) não fornecidos anteriormente à rede, de forma a serem calculados um conjunto de *outputs*, obtendo-se assim os valores da variável que se pretendia prever. Posteriormente procede-se a avaliação de desempenho da rede (através de uma das medidas de avaliação apresentadas no ponto 2.2.3).

Existem vários tipos redes neuronais, sendo estas classificadas mediante a sua arquitetura e algoritmo de aprendizagem, sendo que a primeira diz respeito à maneira como se organizam as ligações entre neurónios e a segunda, como já foi referido, diz respeito à maneira como a rede neuronal ajusta os pesos das suas conexões. [4] Posto isto, existem dois grupos de RNA: as Redes neuronais *feedforward* e as Redes neuronais *feedback* (recorrentes). Na classe das redes neuronais *feedforward* pode-se classificar as redes em três sub-grupos: redes de uma só camada; redes multicamada e redes com função de base radial.

Aplicações de redes neuronais na PPE curto prazo podem ser observadas em [19].

Support Vector Machines

Aquando da aplicação de uma rede neuronal, a determinada altura é necessário proceder-se à otimização de certos parâmetros da rede (número de camadas escondidas, número de neurónios nas camadas escondidas, etc.). Porém, não existe nenhum algoritmo que otimize estes parâmetros automaticamente, sendo necessário muitas vezes alguma experiência, pesquisas bibliográfica sobre o tema e aplicar uma metodologia de “tentativa/erro” para se chegar à otimização ideal, o que se pode revelar bastante moroso. O *Support Vector Machines* (SVM) é uma ferramenta que visa tornar todo este processo mais rápido e menos dependente da experiência do utilizador, sendo por isso considerado como uma evolução das redes neuronais. [20]

Ao contrário das redes neuronais, o SVM faz um mapeamento não linear dos dados (*inputs*) para um espaço dimensional superior (de forma a tornar o sistema linearmente separável) através de uma função de *kernel*, ou seja, organiza os dados em diferentes grupos e, posteriormente aplica funções lineares simples para criar limites de decisão lineares no novo espaço. [20]

O SVM traz então consigo algumas vantagens, já que foi desenhado para otimizar os seus parâmetros em função dos inputs utilizados na fase de treino. E também porque nesta fase é feita uma otimização quadrática que tem apenas uma solução, não apresentando assim várias soluções possíveis, o que ocorre nas redes neuronais devido ao facto dos valores iniciais dos pesos durante o treino serem aleatórios e que tem como consequência uma diminuição da qualidade dos resultados. [20]

A aplicação desta metodologia para PPE pode ser observada em [21].

Data-Mining

Em relação as técnicas de *data-mining*, estas consistem em processos de análise dos *inputs*, com o objectivo de organiza-los em categorias (*clustering*) mediante a identificação de padrões. Esta metodologia ainda não foi muito explorada na PPE, no entanto tem vindo a aumentar de popularidade. A PPE determinista através deste modelo pode ser observada em [21].

2.3 Previsão Probabilística do Preço da Eletricidade

Como referido anteriormente, além do ramo das previsões deterministas (analisadas nos pontos anteriores) existe o ramo das previsões probabilísticas. As primeiras consistem na determinação de um valor absoluto, assumindo assim que se tem um conhecimento exato (ou próximo disso) do que vai acontecer no futuro e as segundas assumem um conjunto de resultados possíveis para esse futuro (assumindo assim que podem haver imperfeições ou incertezas na linha de pensamento). [12]

O objetivo deste tipo de previsões não é encontrar uma desculpa para previsões erradas, mas antes determinar que probabilidades representam melhor um acontecimento a longo prazo. Por outras palavras, se se prevê que a uma determinada hora a probabilidade de acontecer algo (por exemplo o preço da eletricidade ter um determinado valor) é 90%, isto também quer dizer que é de se esperar que 10% das vezes isto não aconteça. [12]

Para certas aplicações, tais como análise de risco ou na licitação com margens de segurança esta classe de previsões é bastante mais interessante do que as deterministas, já que conseguem quantificar a incerteza dos valores previstos. [22] [21] No entanto, como foi referido anteriormente, embora a sua utilização esteja a ser cada vez mais usual nas mais diversas áreas, nas PPE a sua aplicação ainda não foi muito explorada. [4]

Existem vários métodos de representação das incertezas, nomeadamente: funções densidade da previsão, funções de distribuição cumulativa, quanties e intervalos de previsão. Contudo, da análise do estado de arte foi possível concluir que a previsão probabilística do preço da eletricidade é feita essencialmente através de intervalos de previsão e funções de densidade pela grande maioria dos investigadores da especialidade, pelo que ambos serão analisados nos pontos que se seguem.

2.3.1 Intervalos de Previsão

Em termos de PPE, os intervalos de previsão consistem em intervalos estocásticos, que contêm o verdadeiro valor do preço com uma probabilidade previamente atribuída. [21] É importante referir que na literatura da especialidade alguns autores usam o termo intervalo de confiança em vez de intervalo de previsão, o que está errado dado que o segundo termo está associado a um parâmetro de um modelo. [4]

Existem duas principais dificuldades na PPE através deste método. Estas recaem no fato de inicialmente ser necessário fazer uma previsão determinista precisa do PPE e de posteriormente ser necessário fazer uma previsão precisa da variância do preço. A realização precisa da primeira apresenta bastantes obstáculos (já expostas anteriormente nesta dissertação), nomeadamente o fato do preço da eletricidade corresponder a uma série temporal não linear, que é bastante volátil e não pode ser modelizada através de um modelo de séries temporais lineares. A segunda previsão é ainda mais complicada, dado que as variâncias do preço podem variar em relação ao tempo (heteroscedasticidade da série temporal do preço da eletricidade exposta no ponto 2.2.4.1). Para suplantar os obstáculos da previsão deterministas podem ser utilizados alguns dos modelos expostos no ponto 2.2.4, contudo estes modelos não podem ser utilizados diretamente na determinação dos intervalos de previsão pois não têm a capacidade de preverem a variância do preço. [22] De seguida, expõem-se dois trabalhos publicados onde foram aplicados algumas metodologias para a estimação de intervalos de previsão para o PPE.

Em [23], foi testada uma metodologia de previsão no mercado de ISSO *New England* utilizando uma rede neuronal ao qual é aplicada filtro de Kalman alargado (*extended Kalman filter*) no modo desacoplado que funciona como algoritmo de aprendizagem e metodologia para estimação de *prediction intervals*. Posteriormente, de forma a ser diminuído o esforço computacional necessário para a definição dos pesos na RNA, foi aplicada nesta técnica híbrida uma fatorização U-D. Por fim, esta metodologia foi comparada com uma técnica *back-propagation* Bayesiana para determinação dos intervalos, concluindo-se que o método proposto converge mais rapidamente, apresenta previsões mais precisas e com intervalos de previsão mais curtos.

Em [20], o autor testou para o mercado da eletricidade Australiano (NEM) um modelo híbrido baseado em técnicas de *data-mining* e de SVC, fazendo-se a estimação dos intervalos de previsão através do desenvolvimento de uma equação de variância com heteroscedasticidade. No final foram comparados os resultados com os de técnicas do tipo GARCH, concluindo-se que a técnica desenvolvida apresenta uma performance muito superior ao da técnica linear GARCH, sendo que para todas as amostras a diferença entre o parâmetro relativo à confiança estimada e a confiança empírica se encontra entre 1 e 4%. É ainda de salientar que para 95% do intervalo da previsão, o modelo desenvolvido conseguiu fazer uma modelização adequada dos picos do preço de mercado, modelização esta que a metodologia GARCH não alcançou.

2.3.2 Previsão da Densidade

Um dos objetivos da presente dissertação passa pela previsão probabilista dos preços de eletricidade diários no MIBEL, através da determinação das funções de densidade da previsão.

Este tipo de previsão consiste numa estimação da distribuição probabilística dos possíveis valores futuros da variável que se pretende prever. Ela fornece uma completa descrição das incertezas associadas à previsão, contrastando assim com a previsão determinista. [24]

Entre estes dois extremos encontram-se as previsões baseadas em intervalos de previsão (referidas no ponto anterior), porém é bastante mais útil conhecer-se a densidade total da previsão do que apenas um único intervalo de previsão. É, contudo, também bem mais complexo descobrir-se a distribuição da primeira variável do que o valor da segunda. [24]

As duas principais classes de técnicas para se construírem distribuições de previsão, são: aproximações paramétricas e aproximações não paramétricas. [25]

As aproximações paramétricas assumem no início do processo preditivo a forma da curva da densidade da previsão (forma de distribuição Gaussiana ou de distribuição do tipo Beta). Isto traz vantagens, já que a função probabilidade da distribuição da previsão encontra-se exclusivamente dependente de alguns parâmetros característicos da equação da curva adotada. Isto resulta numa estimativa simplificada e em programas computacionalmente menos pesados, contudo pode ter alguns custos em termos eficiência. [25]

Para técnicas de aproximação do tipo não-paramétrica (*distribution-free*) não se fazem nenhuma considerações iniciais relativamente à forma da distribuição da previsão. Neste caso, a modelização das incertezas pode ser alcançada, por exemplo, através de métodos de regressão de quantis (*Quantile regression method* na literatura inglesa) ou através de estimadores de *kernel*, sendo estes últimos objeto de estudo na dissertação a desenvolver. Com este tipo de técnicas têm que se estimar um número mais elevado de densidades ou quanties, do que com as aproximações paramétricas. De seguida, expõem-se dois trabalhos publicados onde foram aplicados algumas metodologias para a estimação da função densidade de probabilidade (FDP) da previsão dos preços do mercado para um horizonte temporal a curto prazo.

Em [26], foi aplicado, para o mercado da Califórnia, um processo, denominado pelos seus autores de *Monte Carlo Simulation*, que consiste na aplicação de uma rede neuronal auxiliar pra definir a relação entre o histórico da carga/reservas (inputs) e o preço de mercado previsto (*output*). E posteriormente, mantendo todas as outras variáveis constantes, são introduzidas variações nos dados de *input* (carga e da reserva), através da multiplicação de todos os dados por um fator que segue uma distribuição normal (média toma o valor de 1 e o desvio-padrão é 0.1 para a carga e 0.15 para a reserva). Obtendo desta forma um conjunto de amostras para a carga e a reserva e, conseqüentemente, para o preço. Este processo foi repetido 2000 vezes, fazendo-se a análise da probabilidade para todas as horas (24 horas), concluindo-se que apesar da carga e da reserva apresentarem uma distribuição normal para todas as horas, o mesmo não se passa com os preços de mercado previstos.

Em [27], foram utilizados dados referentes a uma zona do mercado NORDPOOL (*Western*

Danish) fazendo-se inicialmente, uma aproximação paramétrica de forma a modelizar o desvio-padrão Gaussiano através de um conjunto de formulações de técnicas ARCH/GARCH (os resultados obtidos são utilizados como *baseline*). Posteriormente, foi desenvolvida uma metodologia baseada numa análise não paramétrica da densidade da previsão, através da aplicação da técnica de *quantile-regression* para os quantis confinados a um intervalo de 0.05 a 0.95. Sendo, que a descrição das caudas da função de distribuição é feita através de uma função exponencial aproximada. A performance dos modelos desenvolvidos é comparada com os resultados obtidos para 4 metodologias de referência distintas: densidade marginal empírica dos preços da eletricidade (fatores climáticos definidos por um conjunto de quantis), densidade incondicional Gaussiana (definidos pela média e desvio padrão empíricos dos preços da eletricidade), densidade condicional Gaussiana (média e o desvio padrão determinados através de uma suavização exponencial) e estimador da densidade de *kernel*. De forma a fazer uma comparação da precisão dos resultados obtidos para os diversos modelos testados, os autores utilizam o *average continuous probability score* e *continuous probability score* (CRPSS), que será explicado posteriormente. De todos os modelos de referência utilizados, o KDE foi aquele que se apresentou mais robusto e preciso. Porém, comparativamente com os resultados obtidos para metodologia desenvolvida (*quantile regression* com definição exponencial das caudas) os resultados obtidos pelo KDE apresentam-se fracos. No que concerne ao teste com CRPSS, os modelos apelidados pelo autor de Gaussianos (paramétricos baseados em ARCH/GARCH) apresentaram resultados bastante semelhantes à metodologia desenvolvida de *quantile-regression*, porém através da utilização de um PIT e posterior construção de diagramas de confiança, conclui-se que os modelos Gaussianos falham em obter previsões probabilísticas confiáveis.

2.3.2.1 NW-KDE

Como foi referido no ponto anterior, podem-se aplicar técnicas de aproximação não-paramétricas para modelizar as distribuições de incerteza, utilizando estimadores de *kernel*. Em consequência desde fato, foi criada uma ferramenta de seu nome *Kernel Density Estimator* (KDE), que é um estimador de densidade condicional não-paramétrica onde nenhuma função de regressão paramétrica é assumida. Esta metodologia tem como principal vantagem a limitação dos erros de estimação, erros que resultam da hipótese incorreta da função de regressão assumida. Porém, como foi referido no ponto anterior, à semelhança de outras técnicas não-paramétricas quando comparadas com metodologias paramétricas, necessita de mais informação e de uma capacidade computacional superior. [28]

Baseada na ferramenta KDE, na estimação de Nadaraya-Watson e na distribuição Beta, foi criada uma outra de seu nome *Nadaraya Watson-Kernel Density Estimator* (NW-KDE) [3]. Esta variante é uma evolução do KDE, já que permite estimar diretamente os parâmetros da distribuição de probabilidade em vez de estimar uma distribuição discreta não paramétrica (tornando-a computacionalmente mais rápida) e tem ainda várias funções adicionais (pesos para os casos na base de conhecimento, modelização de variáveis cíclicas, inclusão de realimentação recursiva e parametrização de incerteza). [3]

Este será o *software* de previsão probabilística utilizada na presente dissertação, pelo que nos pontos seguintes irá ser descrito o seu funcionamento.

Organização dos Dados

Antes de se analisarem os processos matemáticos que definem a ferramenta NW-KDE, é necessário explicitar qual o horizonte temporal da previsão e como será organizada a base de dados onde o NW-KDE se irá basear.

Como referido no ponto 2.2.1, o horizonte temporal das previsões feitas na presente dissertação será cada uma das horas do dia seguinte, ou seja $t + k$, onde t é o momento para o qual se pretende prever o valor do preço da eletricidade (dia seguinte neste caso) e k cada um dos *time-steps* utilizados (neste caso será igual a um valor que vai variar de 1 até 24 e que representa a hora do dia). Posto isto, o algoritmo aplicado para determinar a função probabilidade da densidade para cada uma das horas do dia seguinte, terá que um ciclo de 24 iterações, sendo que a previsão é feita para cada um dos *time-steps* de forma independente.

As várias variáveis utilizadas podem-se classificar em dois grupos: as séries dos históricos das variáveis explicadoras (*inputs*) e respetivas variáveis previstas através dessas séries (*targets* ou variáveis dependentes).

Na Tabela 2.4 pode-se visualizar a representação da base histórica que será utilizada na fase de treino. Onde X representa, para cada caso histórico i ($i = 1, \dots, N$), um vetor de j variáveis explicadoras V , a variável x_{ij} corresponde a cada uma das ocorrências relatadas nos casos históricos e Y representa, para cada caso histórico i , um vetor unidimensional de variáveis dependentes.

Tabela 2.4: Base de conhecimento histórico do modelo de previsão

Ocorrências Históricas	Inputs (X_i)					Targets
	V_1	V_2	V_3	$V_{j=(\dots)}$	V_d	
$i=1$	x_{11}	x_{12}	x_{13}	x_{1j}	x_{1d}	y_1
$i=2$	x_{21}	x_{22}	x_{23}	x_{2j}	x_{2d}	y_2
$i=3$	x_{31}	x_{32}	x_{33}	x_{3j}	x_{3d}	y_3
$i=(\dots)$	x_{i1}	x_{i2}	x_{i3}	x_{ij}	x_{id}	y_i
$i=N$	x_{N1}	x_{N2}	x_{N3}	x_{Nj}	x_{Nd}	y_N

Atendendo à Tabela 2.4 podemos representar cada ocorrência história em pares (X_i, y_i) , o que possibilita o conhecimento das condições do passado (X_i) para as quais se obteve determinado valor para a variável dependente (y_i).

Para realizar a previsão de uma determinada variável (Y_{t+k}) dependente no horizonte temporal $t + k$, serão utilizadas séries de variáveis explicadoras futuras que estarão associadas ao mesmo horizonte temporal (X_{t+k}), como é visível na Tabela 2.5.

Tabela 2.5: Base de conhecimento futuro do modelo de previsão

<i>Ocorrências Históricas</i>	<i>Inputs (X_i)</i>					<i>Targets</i>
	V_1	V_2	V_3	$V_{j=(\dots)}$	V_d	Y_i
$t+1$	$x_{t+1,1}$	$x_{t+1,2}$	$x_{t+1,3}$	$x_{t+1,j}$	$x_{t+1,d}$	y_{t+1}
$t+2$	$x_{t+2,1}$	$x_{t+2,2}$	$x_{t+2,3}$	$x_{t+2,j}$	$x_{t+2,d}$	y_{t+2}
$t+3$	$x_{t+3,1}$	$x_{t+3,2}$	$x_{t+3,3}$	$x_{t+3,j}$	$x_{t+3,d}$	y_{t+3}
$t+k$	$x_{t+k,1}$	$x_{t+k,2}$	$x_{t+k,3}$	$x_{t+k,j}$	$x_{t+k,d}$	y_{t+k}
$t+24$	$x_{t+24,1}$	$x_{t+24,2}$	$x_{t+24,3}$	$x_{t+24,j}$	$x_{t+24,d}$	y_{t+24}

Processo de Extração de Similaridades

O processo de extração de similaridade é uma fase essencial para a obtenção de resultados de boa qualidade, já que é nesta fase que se vão relacionar os dados históricos com os dados no momento da previsão. Neste processo vão ser atribuídos pesos às condições verificadas no passado (X_i), mediante a sua semelhança com as condições verificadas no momento da previsão (X_{t+k}). Esta atribuição de pesos será realizada através de uma função de *kernel* baseada na curva da distribuição de *Gauss*, dada pela seguinte equação:

$$f(x, \mu, \sigma) = e^{\frac{-(x-\mu)^2}{2\sigma^2}} \quad (2.1)$$

Onde o parâmetro μ corresponde ao valor médio e σ à variância da distribuição, respetivamente. Adaptando a equação 2.1 de acordo com a nomenclatura adotada até este ponto, obtém-se a expressão a partir da qual o NW-KDE concretiza o processo de pesagem, para cada dimensão j :

$$f(x_{ij}, x_{t+k,j}, \sigma_j) = e^{\frac{-(x_{ij}-x_{t+k,j})^2}{2\sigma_j^2}} \quad (2.2)$$

Como se pode depreender através da análise da equação 2.2, o valor médio passará a ser a variável explicadora $x_{t+k,j}$ (ou seja o filtro está centrado nesse valor), analisando-se de seguida a distância a que as variáveis históricas x_{ij} se encontram desse valor. E, dado que o *kernel* utilizado é uma função exponencial negativa, quanto menor essa distância maior será o valor da função, logo maior será o peso dado à amostra em análise. Atingindo-se assim o objetivo de atribuir pesos de maior magnitude às condições históricas mais semelhantes às condições para as quais as previsões estão a ser feitas.

É importante ainda referir que o valor da variância definirá a largura do *kernel*, sendo que esta tem que ser suficientemente apertada para que y_i , seja razoavelmente constante no intervalo multidimensional H de ativação do *kernel*. [11]

Na gráfico da Figura 2.2 é possível visualizar o processo de extração de similaridade do KDE, onde os pontos representam ocorrência história (X_i, y_i), onde X_i neste caso são cargas e y_i preços de mercado.




Figura 2.2: Gráfico de dispersão dos preços do mercado em relação à série histórica da carga

Observando o gráfico da Figura 2.2 é possível depreender que o *kernel* toma a forma de uma curva de distribuição de Gauss e é centrado na variável explicadora futura, X_{t+k} , que neste caso tem então o valor 38.000 MWh. E, posteriormente, o algoritmo atribui um peso a cada ocorrência histórica, mediante a proximidade da sua variável explicadora histórica, X_i , em relação à variável explicadora futura. Garantindo-se assim que quanto menor a distância entre X_i e X_{t+k} , maior será o valor correspondente na curva de Gauss utilizada como filtro e consequentemente maior será o peso da amostra na determinação da função probabilidade da densidade.

Função de Distribuição *Beta* e formulação do modelo baseado em *NW-KDE*

Aplicando a metodologia denominada por KDE é possível determinar-se a função densidade condicional de Y condicionado por x_{t+k} , descrita na equação 2.3

$$\hat{f}(y|X = x_{t+k}) = \sum_{i=1}^N \left[K(y, y_i, h_p) \cdot \prod_{j=1}^d K(x_{t+k,j}, x_{ij}, H_j) \right] \quad (2.3)$$

Onde K corresponde à função de *kernel* (responsável pela atribuição de pesos a cada uma das amostras, ponto tal) centrada em x_{t+k} (caso futuro) e x_i é o caso histórico representando o valor central da vizinhança no intervalo H (intervalo multidimensional de ativação do *kernel* ou largura de banda). A variável y é um qualquer caso no espaço da variável dependente Y e h_p é a largura da banda do *kernel* aplicado à variável dependente.

A partir da aplicação desta equação é possível obter a função da densidade probabilística da variável Y , sendo essa função representada sob a forma de um histograma da estimativa suavizada da densidade (amostras discretas).

Esta pode, no entanto, ser transformada numa função contínua, sendo utilizada para este efeito uma aproximação paramétrica baseada na distribuição *Beta*:

$$f(y_{t+k}, \alpha, \beta) = \frac{x^{\alpha-1} \cdot (1-x)^{\beta-1}}{B[\alpha, \beta]} \quad (2.4)$$

Onde $B[\alpha, \beta]$ faz referência a uma constante de normalização que assegura que f é uma função densidade de probabilidade e x é um valor compreendido num intervalo $[0,1]$. Já α e β são os parâmetros positivos da função de distribuição Beta e são definidos para cada um dos *time-steps* de forma independente (tal como é de esperar, visto que a previsão é feita de forma independente para cada uma das horas do dia seguinte), da seguinte forma: [29]

$$\alpha = \frac{(1-\mu) \cdot \mu^2}{\vartheta} - \mu \quad (2.5)$$

$$\beta = \frac{1-\mu}{\mu} \cdot \alpha \quad (2.6)$$

Onde μ e ϑ correspondem à média e variância de $f(Y|X = x_{t+k})$. No entanto, os resultados obtidos pelo KDE não fornecem resultados relativamente à média e à variância da densidade (previsão determinística) da função probabilidade da densidade, assim recorre-se às formulações de Nadaraya-Watson de forma a calcular estas duas grandezas probabilísticas. Esta abordagem permite a estimação do valor esperado de uma determinada função densidade condicional na vizinhança de um caso do vetor de variáveis explicadoras [3]:

$$\mu(y|X) = \int y \cdot (y|x) dp = \frac{\int y \cdot f(y,x) dp}{\int f(y,x) dp} \quad (2.7)$$

Usando estimativas, chega-se à equação 2.8:

$$\mu(y|X = x_{t+k}) = \frac{\sum_{i=1}^N y_i \cdot \prod_{j=1}^d K(H_j^{-1}(x_{ij} - x_{t+k,j}))}{\sum_{i=1}^N \prod_{j=1}^d K(H_j^{-1}(x_{ij} - x_{t+k,j}))} \quad (2.8)$$

Que, tirando partido da relação $K(x_{t+k,j}, x_{ij}, H_j) = K(x_{ij}, x_{t+k,j}, H_j)$, pode ser representada pela equação 2.9:

$$\mu(y|X = x_{t+k}) = \frac{\sum_{i=1}^N y_i \cdot \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, H_{t+k,j}))}{\sum_{i=1}^N \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, H_{t+k,j}))} \quad (2.9)$$

Determinada a expressão que permite o cálculo do valor da média pesada da densidade, facilmente se calcula a variância da densidade (equação 2.10):

$$\vartheta(y|X = x_{t+k}) = \mu(y^2|X = x_{t+k}) - \mu(y|X = x_{t+k})^2 \quad (2.10)$$

Substituindo a equação 2.9 em 2.10 determina-se a equação que permite o cálculo da variância da densidade a utilizar na dissertação a desenvolver.

$$\vartheta(y|X = x_{t+k}) = \frac{\sum_{i=1}^N y_i^2 \cdot \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, H_{t+k,j}))}{\sum_{i=1}^N \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, H_{t+k,j}))} - \left(\frac{\sum_{i=1}^N y_i \cdot \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, H_{t+k,j}))}{\sum_{i=1}^N \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, H_{t+k,j}))} \right)^2 \quad (2.11)$$

É importante referir que com esta metodologia h_p (equação 3.8), não é utilizado, o que simplifica a parametrização do modelo.

Com o cálculo de μ e ϑ e respetiva substituição nas equações 2.5 e 2.6 torna-se possível a modelização dos parâmetros α e β , construindo-se posteriormente com recurso à equação (3.9) uma função de distribuição Beta que permite a análise da distribuição probabilística da densidade dos preços do mercado de uma forma contínua.

Parametrização da Entrada Recorrente

Na PPE a variabilidade entre instantes de tempo é uma informação importante, que deve ser tida em conta no modelo de previsão. À semelhança das redes neuronais recorrentes, no NW-KDE para a PPE a uma determina hora (y_{t+k}) será utilizado como *input* a previsão do preço na hora anterior (y_{t+k-1}). Ou seja, o valor deste *input* (V_{ar}) de cada caso histórico i , terá o valor normalizado da variável dependente do caso histórico anterior (y_{i-1}). Para esta nova variável vai ser preciso definir uma largura de banda, H , sendo que um H demasiado apertado implicará que estará a ser dada muita importância ao valor do preço na hora anterior, o que resulta numa previsão mais suavizada, no entanto pode-se estar a mapear situações raras do histórico.

2.3.3 Avaliação de Desempenho

Em termos de avaliação de desempenho de previsões probabilísticas, esta pode-se definir como a avaliação de duas propriedades: *reliability* e *sharpness*.

A *reliability* (ou *calibration*) diz respeito à consistência estatística entre distribuições de previsão e observações. Esta revela a capacidade da previsão probabilística de corresponder eficazmente a uma avaliação a longo prazo, ou seja, (utilizando um exemplo anteriormente aplicado) se se prevê que a uma determinada hora a probabilidade do preço da eletricidade ter um determinado valor é 90%, é espectável que a longo prazo, para casos semelhantes, 90% das vezes o preço da eletricidade tenha esse valor. [25] [30] Uma maneira de quantificar esta propriedade é através do uso de histogramas de ranking como proposto por Talagrand *et al.* (1997), que são utilizados para avaliar previsões de conjuntos discretos [31].

Já para previsões contínuas pode ser utilizado a *probability integral transform* (PIT), que é descrita segundo a equação 2.12:

$$p_t = F_t(x_t) \quad (2.12)$$

Onde F_t representa a distribuição da previsão probabilística e x_t é um número aleatório da função G_t , que representa a distribuição real da probabilidade (numa previsão perfeita $F_t = G_t$) e é um conceito hipotético. Se a previsão for a ideal e F_t contínuo, p_t terá uma distribuição uniforme, sendo assim possível avaliar a previsão. No entanto, Hamill (2011) demonstrou-se que, embora seja verdade que uma distribuição calibrada demonstra uma PIT uniforme, uma PIT uniforme não implica necessariamente uma distribuição calibrada, provando que este método de avaliação tem as suas falhas. [32] [31]

Existem 4 cenários possíveis quando se realiza a calibração de uma previsão:

Underdispersed Forecast – O histograma terá a forma de U. Como o nome indica, a Função Densidade de Probabilidade apresenta uma dispersão baixa, o que provoca uma elevada frequência de casos reais previstos nos extremos da distribuição e uma baixa frequência na zona central. Uma possível solução para melhor este tipo de previsões é atuar sobre o α e β (equações 2.5 e 2.6) da distribuição, diminuindo os seus valores.

Overdispersed Forecast – O histograma terá a forma de uma lomba. A Função Densidade de Probabilidade apresenta uma dispersão elevada, o que provoca uma elevada frequência de casos reais previstos na zona central da distribuição. Uma possível solução para esta situação passa por se aumentar os valores de α e β da distribuição.

Calibrated Forecast – Previsão ideal, onde a Função Densidade de Probabilidade apresenta uma distribuição uniforme e consegue acompanhar a frequência de casos reais. Neste tipo de situações não é necessário atuar-se sobre α e β , já que estes já possuem os valores ótimos.

Points out of Distribution – Este tipo de situações só podem ocorrer caso a distribuição seja limitada (o que é caso para as previsões efetuadas na presente dissertação) e, nesta situação, a distribuição é incapaz de caracterizar parte dos valores reais.

Uma representação gráfica das 3 primeiras situações expostas, pode ser visível na Figura 2.3.




Figura 2.3: Exemplos de diferentes tipos de cenários de *reliability* [1]

Na Figura 2.4, é possível visualizar-se uma representação gráfica da quarta situação. Para este efeito foi escolhido um exemplo de um diagrama de avaliação do *reliability* utilizado na presente dissertação para se avaliar esta característica. É necessário referir que este tipo de diagramas foi escolhido em detrimento dos PIT, uma vez que são mais fáceis de interpretar. A sua construção e os seus componentes encontra-se descrita na secção 4.1.2.




Figura 2.4: Exemplo gráfico do cenário de *reliability*: *Points out of Distribution*

A *sharpness* representa a capacidade do modelo em prever acontecimentos de uma forma precisa, em vez de os prever com incertezas demasiado elevadas, isto é, previsões que têm uma distribuição uniforme e que de pouca utilidade são para quem tomará decisões baseadas nestas. Ao contrário da *reliability* esta propriedade é avaliada independentemente da comparação dos valores obtidos na previsão com os valores reais, mas antes pela observação das concentrações das distribuições probabilísticas da previsão (quanto mais concentradas, ou seja menos dispersas as distribuições mais precisa é a previsão). [25] [30]

Em Bremnes (2004) é proposto o uso de gráficos do tipo diagramas de caixas (*box plot* na literatura inglesa) para avaliar esta propriedade, este tipo de gráficos são denominados na bibliografia de especialidade por diagramas de *sharpness*. [32]

Em [28] foi proposta a avaliação do *sharpness* através de um indicador que represente a média das distâncias entre quanties da FDP, expressão 2.13. Indicador esse que será utilizado na presente dissertação para se avaliar a dispersão das FDP.

$$\bar{\delta}_k^\alpha = \frac{1}{N} \sum_{i=1}^N \delta_{i,k}^\alpha \quad (2.13)$$

Onde:

$$\delta_{t+k|t}^\alpha = \hat{q}_{t+k|t}^{1-\alpha/2} - \hat{q}_{t+k|t}^{\alpha/2} \quad (2.14)$$

Em [32] é então definido como objetivo para se obter uma previsão com uma boa performance, a maximização da *sharpness* da distribuição da previsão, condicionada pela *reliability*, ou seja, diminuir ao máximo as incertezas da previsão sem pôr em risco a fiabilidade da mesma. Afirmando assim que a qualidade da previsão probabilística não pode ser avaliada apenas por uma destas propriedades, mas antes pelas duas em conjunto. E, é neste contexto, que se inserem as *skill score* que consistem num único critério de avaliação que contém informação relativa às propriedades *reliability* e *sharpness*. Estas são definidas para que a previsão com melhor qualidade tenha a melhor pontuação e têm como principal vantagem a compactação de informação, porém, a contribuição de cada uma das suas propriedades é impercetível. [25] [28]

Algumas das medidas de pontuação mais utilizadas nas diversas representações de incertezas podem ser vistas na Tabela 2.6:

Tabela 2.6: Representações de incertezas e respetivas skill score

Representação das Incertezas	Skill Score
Funções de Densidade Probabilística	Logarithmic Score
Funções de Distribuição Comutativa	CRPS
Quanties	Tick; Check Loss Score; Pinball Loss Function
Intervalos	Interval Score

As *logarithmic score* são bastante sensíveis a eventos extremos (picos de valores), no entanto, a *continuous ranked probability score* (CRPS) já é mais robusta a lidar com estes casos. [25] Desta última surgem ainda as medidas *average continuous ranked probability score* ($\overline{CRPS}$) e a *continuous ranked probability skill score* (CRPSS), sendo a equação 2.15 a expressão que define a primeira. [27]

$$\overline{CRPS} = \frac{1}{N} \sum_{i=1}^N CRPS_i \quad (2.15)$$

Onde CRPS é definido pela equação 2.16.

$$CRPS = \int_{-\infty}^{\infty} (\hat{F} - F_o(x))^2 dx \quad (2.16)$$

Onde $F_o(x)$ corresponde à função *Heaviside* e pode ser expressa pela equação 2.17.

$$F_o(x) = H(x - x_o) = \begin{cases} 0, & \text{Se } x - x_o < 0 \\ 1, & \text{Se } x - x_o \geq 0 \end{cases} \quad (2.17)$$

Já o CRPSS para um determinado modelo pode ser expresso pela equação 2.18.

$$CRPSS = 1 - \frac{\overline{CRPS}_{model}}{\overline{CRPS}_{ref}} \quad (2.18)$$

Onde o $\overline{CRPS}_{model}$ é o valor médio do CRPS do modelo a ser avaliado e o $\overline{CRPS}_{ref}$ é o valor médio do CRPS de um modelo de referência escolhido.

Por último, a *pinball loss function* e os *interval score* são medidas utilizadas para avaliar as previsões feitas através de quanties e intervalos, respetivamente. Sendo que a função que define a primeira é a equação 2.19.

$$L_r(y, z) = \begin{cases} (y - z)\tau & \text{Se } z \leq y \\ (z - y)(1 - \tau) & \text{Se } z > y \end{cases} \quad (2.19)$$

Onde τ é o quantil *target*, y é o valor real e z o quantil previsto.

Capítulo 3

Metodologia

Neste capítulo pretende-se fazer uma descrição do trabalho desenvolvido ao longo da presente dissertação.

Posto isto, inicialmente será feita uma descrição da *time framework* utilizada nas PPE do mercado diário do MIBEL e uma exposição dos diferentes tipos de variáveis que serão utilizadas como inputs nos vários modelos de previsão. Posteriormente, será feita uma análise dos vários parâmetros da ferramenta utilizada para se realizarem as PPE deterministas e probabilísticas, o NW-KDE. Após esta análise, serão descritos os pressupostos definidos com o intuito de se tentar evitar o comprometimento da eficácia das previsões deterministas em detrimento das previsões probabilísticas (e vice-versa) que foram efetuadas para cada modelo, bem como a metodologia utilizada para se atingirem as parametrizações ótimas que permitem os melhores resultados para cada modelo.

Antes de se proceder às descrições referidas no paragrafo anterior, é importante mencionar que a presente dissertação é uma continuação do trabalho realizado em [2], pelo que, foram recriados aqui os modelos efetuados na mesma dissertação (23 modelos que serão expostos mais à frente) mas desta feita utilizando a ferramenta NW-KDE, ferramenta essa que permitiu a obtenção dos valores médios dos preços (previsões determinista) e de funções de densidade dos preços (previsões probabilísticas). Posto isto, os tipos de variáveis explicadoras e respetivos valores que foram utilizados nos vários modelos de previsão, bem como o espaço temporal para o qual se efetuaram as PPE, foram os mesmos. Os resultados obtidos para as previsões deterministas efetuadas em [2] serão ainda utilizadas como referência para as previsões deterministas realizadas na presente dissertação.

3.1 *Time Framework*

De forma a se compreender a *time framework* definida para as PPE que se realizaram é imperativo perceber-se quem são os intervenientes e todo o processo em que assenta o mercado diário da eletricidade do MIBEL, pelo que de seguida se fará uma breve descrição destes dois aspetos.

O mercado diário da eletricidade consiste então em leilões diários, leilões esses que têm como intervenientes quatro tipos de agentes: as empresas produtoras (ou unidades geradoras), os compradores (ou comercializadores), o operador do mercado e o operador do sistema.

Este processo inicia-se com a submissão por parte das empresas produtoras para cada hora h do dia $D+1$, da quantidade de energia (em MW) que estão dispostas a fornecer ao mercado e o preço mínimo (em €/MW) a que aceitam fazer essa transação e com a submissão por parte dos comercializadores (também para cada hora do dia $D+1$) da quantidade de energia que necessitam de adquirir e o preço máximo que estão dispostos a pagar por essa aquisição.

É importante ainda referir que as propostas de venda de energia podem integrar um conjunto de condições de cariz técnico e económico (condição de invisibilidade, graduação da cara, entradas mínima e paragem programada), sendo denominadas por propostas de venda complexas. [2]

Estas propostas têm que ser submetidas à entidade responsável pela gestão do mercado diário do MIBEL, o Operador del Mercado Ibérico de Energía (OMIE), sendo que o prazo final para a submissão destas propostas (referentes a cada hora h do dia $D+1$) é as 12h CET do dia D . Após o final deste prazo o operador do mercado dá início à ordenação das propostas e realiza um despacho centralizado baseado em preços [33], processo este designado por concertação de propostas. Por outras palavras, para cada hora do dia $D+1$ (ou seja este processo é realizado 24 vezes por dia), o OMIE organiza as propostas em duas curvas, uma curva de oferta (curva crescente com 25 lanços no máximo) que diz respeito às propostas de venda e uma curva de procura (curva decrescente com 25 lanços no máximo) que representa as propostas de aquisição. Posteriormente o OMIE une estas duas curvas (gráfico da Figura 3.1) e as coordenadas do ponto de intersecção corresponderão à quantidade de energia que será transacionada naquela hora e ao preço marginal do mercado (preço de custo de qualquer transição de energia naquela hora). Como se pode concluir observando o gráfico da Figura 3.1 todas as propostas que se encontrarem à direita do ponto de intersecção não são correspondidas.




Figura 3.1: Processo de concertação de propostas de venda e aquisição

Após a realização da concertação de propostas por parte do operador de mercado para as 24h

do dia D+1, este envia, até às 13h CET, os resultados provisórios que obteve para o operador do sistema (REN em Portugal e REE em Espanha), que conjuga estas transações de energia com as transações de energia referentes aos contratos bilaterais (contratos negociados diretamente entre empresas produtoras e comercializadores, sem irem a mercado) de forma a obter o Programa de base de Funcionamento (PBF), programa este que é publicado antes das 14h CET do dia D.

Até às 16h CET, o operador do sistema pública o Programa Diário Viável (PDV) que resulta da análise das restrições técnicas da rede e contratações de serviços auxiliares, sendo que entre as 14h CET e as 16h CET este tem a capacidade de alterar despachos oriundos da atividade do mercado diário para que os critérios de segurança do sistema sejam cumpridos. Caso estas alterações não solucionem os problemas que possam pôr em risco a segurança das redes, ocorre um processo denominado de *market splitting*. Neste processo, o mercado do MIBEL divide-se em dois, num mercado Português e num mercado Espanhol, tendo cada um destes o seu próprio preço, em que o preço do país exportador será o preço da proposta feita pela última unidade geradora despachada e o preço do país importador corresponderá ao máximo dos preços obtidos nos dois encontros de ofertas correspondentes a ambas as zonas [2].

Após a descrição de todo o processo de formação dos preços de eletricidade do MIBEL, pode-se então passar à descrição da *Time Framework* definida para as PPE da presente dissertação.

Visto que as propostas de compra e venda para o dia D+1 têm que ser submetidas até às 11h GMT do dia D, é necessário que o processo preditivo seja finalizado umas horas antes desta hora limite para que as entidades que vão utilizar este recurso tenham tempo de construir as suas propostas baseando-se nestes novos dados. Posto isto, definiu-se para a presente dissertação (tal como para [2], que todas as PPE do MIBEL para cada hora h do dia D+1, tanto as deterministas (valor médio do preço) como as probabilísticas (funções de densidade do preço) seriam realizadas às 0h GMT do dia D, tal como se pode observar na Figura 3.2.




Figura 3.2: *Time Framework* das PPE realizadas na presente dissertação, em hora portuguesa [2]

3.2 Informação Utilizada

Como referido anteriormente, a presente dissertação é uma continuação do trabalho desenvolvido em [2], pelo que os 23 modelos de previsão desenvolvidos bem como as variáveis explicadoras utilizadas em cada um desses modelos serão as mesmas. Estas consistem em 17 variáveis, variáveis essas cujas séries de valores se encontram acessíveis às 0h do dia D, momento em que é efetuada a previsão, para que os modelos possam ser utilizados em situações reais. Estas variáveis dividem-se em quatro horizontes temporais diferentes em relação ao dia em que se processam os modelos (D), que são: a semana anterior (D-6), dia anterior (D-1), o próprio dia (D) e dia seguinte (D+1). E, tendo em conta as classificações feitas em (tal), pertencem a 5 classes distintas: Variáveis Cronológicas; Variáveis Meteorológicas; Variáveis de Produção Elétrica e Variáveis Previstas Elétricas. Na Tabela 3.1 são apresentadas as 17 variáveis e as respetivas classes e horizontes temporais.

Tabela 3.1: Variáveis utilizadas nos modelos de previsão

	Variáveis Cronológicas	Variáveis de Preço	Variáveis Meteorológicas	Variáveis de Produção Elétrica	Variáveis de Previsão de Consumo e Produção Elétrica
<i>Time Framework</i>	-	D; D-6	D+1	D-1; D-6	D+1
Variáveis	Hora; Dia da Semana	Preço D; Preço D-6	Temperatura D+1; Vento D+1; Irradiância D+1	Consumo D-1; Consumo D-6; Eólica D-1; Hídrica D-1; Cogeração/ Solar D-1; Carvão D-1; Nuclear D-1; Gás Natural D-1	Consumo D+1; Eólica D+1

Apresentadas as 17 variáveis utilizadas, passar-se-á à análise mais aprofundada das mesmas.

3.2.1 Variáveis Cronológicas

Como referido no subcapítulo 2.2.2, as variáveis cronológicas apresentam uma relação com o preço do mercado devido ao comportamento de sazonalidade em termos diários e semanais desta variável. Foram por isso utilizadas duas variáveis pertencentes a esta classe de variáveis: a hora e o dia da semana (DDS). Para a primeira foi definido que a primeira hora do dia seria a hora 0 e a última seria a hora 23, um dia completo terá então 24 horas quantificadas. Em relação à segunda variável foi estipulado o valor 1 para a segunda-feira, o valor 2 para a terça-feira, o valor 3 para a quarta-feira, o valor 4 para a quinta-feira, o valor 5 para a sexta-feira, o valor 6 para o sábado, o

valor 7 para o domingo e o valor 8 para os feriados (Portugueses e Espanhóis). A estas variáveis corresponde um horizonte temporal adimensional.

3.2.2 Variáveis de Preço

No que diz respeito a esta classe de variáveis, foram utilizadas as variáveis o preço de mercado do dia em que é feita a previsão (Preço D) e preço da semana anterior (Preço D-6), estas variáveis foram utilizadas, já que (como explicitado no subcapítulo 2.2.2) existe uma elevada relação entre os valores futuros do preço e os valores conhecidos desta variável no passado e presente. Estas variáveis foram obtidas através das publicações diárias dos resultados para o mercado diário do MIBEL, realizadas pelo operador do sistema Português (REN) [13]. É ainda necessário clarificar que nas situações em que ocorreu *market splitting*, foram utilizados os preços de mercado correspondentes ao mercado Português.

3.2.3 Variáveis Meteorológicas

As 3 variáveis meteorológicas utilizadas na presente dissertação correspondem a previsões para o dia D+1, das variáveis temperatura (temperatura D+1), velocidade do vento (vento D+1) e irradiância (irradiância D+1). Correspondendo estas variáveis a previsões, estas não são séries de valores reais, mas antes estimativas que divergirão portanto dos respetivos valores reais das mesmas (terão um certo grau de erro associadas a si). A utilização das variáveis vento D+1 e irradiância D+1 é pertinente, já que contêm informação explicadora referente à geração eólica e fotovoltaica. E dado o grau de complexidade mais elevado em se preverem este tipo de produções quando comparadas com as previsões das variáveis meteorológicas, estas variáveis podem-relevar-se ideais para se poderem retirar conclusões em relação à influência destas formas de geração no preço. Já em relação à variável temperatura D+1, esta foi utilizada nos modelos de previsão dada a sua elevada relação com o consumo do dia D+1 (variável essa que por sua vez se encontra bastante relacionada com o preço). Esta relação existe devido ao aumento de utilização de máquinas de arrefecimento ou aquecimento quando se verificam grandes variações de temperatura. Utilizando esta variável, introduzimos assim nos modelos informação relativa aos consumos do dia D+1, o que pode vir a revelar-se interessante para previsão do preço de mercado.

Conforme explicado no subcapítulo 2.2.2, dado o tamanho das Península Ibérica e o fato destas variáveis dependerem da posição geográfica para onde foram previstas, estas tiveram que ser processadas para que os diversos pontos geográficos de uma determinada variável possam ser expressos como uma única série que represente essa variável na Península Ibérica. Posto isto, em relação à variável vento D+1, foi realizada uma média pesada das previsões de 750 parques eólicos (de acordo com a potência instalada destes parques) distribuídos por Portugal e Espanha. Realizando um processo semelhante em relação à variável irradiância. Em relação à temperatura D+1, foi realizada uma média pesada das previsões meteorológicas de 250 locais de elevada concentração demográfica tendo em conta a procura de eletricidade destes locais.

As séries de valores das previsões meteorológicas destas 3 variáveis para Portugal e Espanha são provenientes da empresa Smartwatt e da Universidade de la Rioja, respetivamente.

3.2.4 Variáveis de Produção Elétrica

Através da visualização do gráfico da Figura 3.1, pode-se concluir que dois aspetos que têm bastante influência na formação dos preços são a quantidade de energia requerida pelos comercializadores e a quantidade de energia que as empresas geradoras estão dispostas a fornecer. As variáveis que pertencem a esta classe contêm informação histórica referente a estes dois aspetos. O consumo do dia anterior (variável consumo D-1) e o consumo da semana anterior (consumo D-6) possuem informação referente à quantidade de energia que os comercializadores necessitam de adquirir e também em relação à quantidade de energia que as empresas geradoras estarão disponíveis para fornecer uma vez que estas fazem o planeamento do seu despacho tendo por base os consumos. Por outro lado, as variáveis eólica D-1 (variável que representa as produções das centrais eólicas do dia anterior), hídrica D-1 (que representa as produções das centrais hídricas no dia anterior), cogeração/solar D-1 (que representa as produções agregadas das unidades de cogeração e parques fotovoltaicos no dia anterior), carvão D-1 (que representa as produções das centrais térmicas a carvão no dia anterior), a nuclear D-1 (que representa as produções das centrais nucleares no dia anterior) e a gás natural D-1 (que representa as produções das centrais térmicas de ciclo combinado no dia anterior) contêm informação mais específica em relação à quantidade de energia que as empresas geradoras estarão dispostas a vender.

Optou-se por representar estas 6 variáveis de geração em séries distintas, em vez de uma única série que as representasse a todas (produção total), uma vez que as diferentes unidades geradoras instaladas na Península Ibérica têm custos marginais de produção diferentes, custos estes que influenciam o preço de energia presentes nas propostas por parte das empresas geradoras. É também usual verificar-se que, nas horas em que as produções das centrais de geração com custos menores (centrais hídricas e parques eólicos por exemplo) é mais elevada, existe um menor número de propostas por parte das centrais com custos mais elevados (centrais térmicas de ciclo combinado por exemplo) concertadas no processo de formação do preço, ou seja, nestas horas haverá um número mais elevado de propostas de venda de energia com um preço mais baixo, pelo que o ponto de intersecção do gráfico da Figura 3.1 vai baixar (no eixo dos y) o que levará a uma diminuição do preço de mercado.

Posto isto, é expectável que a utilização de variáveis distintas para cada tipo de geração possuam uma informação mais rica no concerne a formação dos preços de mercado, ao contrario da utilização de uma variável de produção total.

Todas as variáveis pertencentes a esta classe utilizadas na presente dissertação, foram obtidas através das publicações diárias no centro de informações do operador do sistema Português (REN) [13] e do operador do sistema Espanhol (REE) [14].

3.2.5 Variáveis de Previsão de Consumo e Produção Elétrica

As variáveis utilizadas que pertencem a esta categoria são o consumo D+1 e a eólica D+1. A importância do consumo nos preços de mercado já foi abordado anteriormente e dado que o erro associado a esta previsão é de cerca de 2%, a utilização desta variável nos modelos torna-se bastante pertinente. Em relação à variável eólica D+1, o seu erro é de cerca de 20%, no entanto justifica-se a sua utilização com o facto da produção dos parques eólicos estarem dependentes de condições atmosféricas (vento), pelo que o uso de séries históricas relativas à produção eólica pode não se afigurar como a melhor opção, já que os seus despachos dificilmente apresentam um padrão ao longo do tempo, dada a grande volatilidade que esta variável apresenta provocada pela sua dependência em relação ao vento.

Com a produção fotovoltaica acontece uma situação semelhante à produção de origem eólica, dada a sua dependência de determinadas condições atmosféricas (nebulosidade). No entanto para esse caso não se realizou o estudo da pertinência dessa variável nos modelos de previsão, dado que esse tipo de produções pouca influência exercessem no comportamento do preço no mercado diário para o dia seguinte, já que pouco contribuem para a colmatar necessidades energéticas na Península Ibérica. Pelo que se considerou suficiente a utilização da variável irradiância D+1, que contém informações referentes a este tipo de produções nos modelos de previsão.

À semelhança das variáveis de produção elétrica, também este tipo de variáveis são publicadas diariamente pelo operador de sistema Português (REN) [13] e pelo operador de sistema Espanhol (REE) [14].

3.2.6 Dados Utilizados

Em relação aos dados que constituem a série de valores de cada uma das 18 variáveis (17 variáveis explicadoras e 1 variável dependente) que serão utilizadas na construção dos modelos de previsão, estes correspondem aos valores das mesmas, para cada hora do dia, no espaço temporal que vai desde o dia 2 de Fevereiro de 2012 até dia 4 de Dezembro de 2013. Posto isto, a base de dados utilizada na presente dissertação contém 16.872 horas para cada uma das 18 variáveis utilizadas.

Como explicitado no subcapítulo 2.3.2.1, a ferramenta NW-KDE necessita da definição de um conjunto de variáveis explicadoras que definem as condições verificadas no momento da previsão (denominadas de *inputs* e um conjunto de ocorrências históricas (denominadas de *historical*). As 16.872 horas foram então divididas da seguinte forma:

- *Inputs*: Todas as horas da semana 5, 10, 15, 20, 25, 30, 35, 40, 45 e 50 do ano de 2012 e da semana 2, 7, 12, 17, 22, 27, 32, 37, 42 e 47 do ano de 2013. O que corresponde a 3360 horas no total.
- *Historical*: Todas as horas não utilizadas no conjunto *Inputs*, entre dia 2 de Fevereiro de 2012 e dia 4 de Dezembro de 2013. O que corresponde a 13.512 horas.

3.2.7 Modelos de Previsão

Uma lista dos modelos de previsão desenvolvidos em [2] e como tal desenvolvidos também na presente dissertação pode ser observado na Tabela 3.2. Tal como na dissertação referida anteriormente, também na presente foram divididos os modelos em 5 grupos distintos.

Tabela 3.2: Modelos de previsão desenvolvidos para a previsão probabilística do preço do mercado diário do MIBEL

Grupos de Var.	Modelo	Hora	DDS	Preço D	Preço D-6	Consumo D-1	Consumo D-6	Consumo D+1	Temperatura D+1	Vento D+1	Irradiância D+1	Eólica D+1	Eólica D-1	Hídrica D-1	Cogeração/solar D-1	Carvão D-1	Nuclear D-1	Gás Natural D-1
Grupo 1	D1	X																
	D2		X															
	D3	X	X															
Grupo 2	D4	X	X	X														
	D5	X	X		X													
	D6	X	X	X	X													
Grupo 3	D7	X	X	X	X	X												
	D8	X	X	X	X		X											
	D9	X	X	X	X			X										
	D10	X	X	X	X	X		X										
Grupo 4	D11	X	X	X	X	X		X	X									
	D12	X	X	X	X	X		X		X								
	D13	X	X	X	X	X		X			X							
	D14	X	X	X	X	X		X	X	X								
Grupo 5	D15	X	X	X	X	X		X	X	X		X						
	D16	X	X	X	X	X		X	X			X						
	D17	X	X	X	X	X		X	X			X	X					
	D18	X	X	X	X	X		X	X			X		X				
	D19	X	X	X	X	X		X	X			X			X			
	D20	X	X	X	X	X		X	X			X				X		
	D21	X	X	X	X	X		X	X			X					X	
	D22	X	X	X	X	X		X	X			X						X
	D23	X	X	X	X	X		X	X			X		X		X	X	X

3.3 Parâmetros da Ferramenta de Previsão

Como já referido anteriormente a ferramenta utilizada na realização das PPE da presente dissertação foi o NW-KDE, cujos princípios base foram descritos na secção 2.3.2.1. No entanto, é importante referir que antes de se poder proceder ao processamento da previsão existe um conjunto de parametrizações que têm que ser definidas, encontrando-se a eficácia da previsão extremamente depende da capacidade do utilizador em conseguir identificar o conjunto de parametrizações ótimas para o problema em questão. Inicialmente apresentar-se-á uma explicação sucinta de cada parâmetro e posteriormente clarificar-se-á a influência destes no processamento da ferramenta e nas formulações matemáticas apresentadas em 2.3.2.1.

Os parâmetros são então os seguintes:

- Nível de Ativação
- H de Referência
- H da Variável Recursiva
- H Dinâmico
- H Dinâmico V
- Pontos
- Variável Cíclica
- Fator de Ajuste

Nível de Ativação: é um valor entre 0 e 1 que define um limite mínimo que uma variável histórica tem que atingir quando lhe é aplicada o filtro do *kernel*, de forma a ser contabilizada como um ponto similar.

H de Referência: corresponde ao valor da largura de *kernel* (ou largura de banda). A escolha de um H de magnitude diminuta, conduz a situações em que o número de pontos similares encontrados é também diminuto, o que tem como consequência uma curva densidade pouco suavizada verificando-se a existência de muitos picos. Por outro lado se este parâmetro se apresentar excessivamente elevado verifica-se uma concentração baixa dos dados, pelo que a curva da densidade é caracterizada por se encontrar suavizada em demasia, não representando de forma satisfatória a densidade real dos resultados (possibilidade de incorrer em situação de *under* ou *over fitting*).

H da Variável Recursiva: como o nome indica, tem uma função semelhante ao parâmetro *H de Referência*, mas desta feita corresponderá apenas à largura do *kernel* que será aplicado à variável recursiva. É definido para esta variável que o parâmetro *H Dinâmico V* da mesma é sempre 0

(está desligado).

H Dinâmico: Corresponde a um mecanismo de ajuste dinâmico da largura de banda, aplicando um valor de H diferente para cada caso previsto, dependendo da densidade de pontos similares ao caso de estudo. Terá o valor de 1 caso se pretenda ativar o dinâmico geral e 0 caso contrário.

H Dinâmico V: só tem influência na previsão caso o parâmetro H Dinâmico esteja ligado e corresponde ao dinâmico de cada variável. Se tiver o valor 1, a variável terá o dinâmico ligado e se tiver o valor 0, o dinâmico estará desligado para essa variável.

Pontos: número médio de pontos similares que o utilizador pretende que o filtro de *kernel* considere para cada variável. Esta parametrização só terá influência na previsão caso o parâmetro H Dinâmico e o parâmetro H Dinâmico V de alguma das variáveis estejam ativos.

Variável Cíclica: terá o valor de 1 caso a variável seja cíclica (por exemplo a variável hora) e terá o valor 0 caso contrário.

Fator de Ajuste: é um fator multiplicativo que é aplicado aos parâmetros α e β (equações 2.5 e 2.6) e que terá como consequência uma variação das concentrações da função distribuição de probabilidade.

Passando à análise da influência das parametrizações no processamento da ferramenta, na imagem 3.3 é possível observar parte código da ferramenta, que é computado caso parâmetro H Dinâmico esteja ligado.

```

If V_ciclicas(i) Then
    Kern1 = Exp(-((V_historico(j, i) - (V_inputs(k, i) - intervalX)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
    Kern2 = Exp(-((V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
    Kern3 = Exp(-((V_historico(j, i) - (V_inputs(k, i) + intervalX)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
    prodf = (Kern1 + Kern2 + Kern3)
    V_prodF1(j) = V_prodF1(j) * prodf
Else
    prodf = Exp(-((V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
    V_prodF1(j) = V_prodF1(j) * prodf
End If
If prodf > fracselect Then
    contarX1 = contarX1 + 1
    ReDim Preserve V_index2(1 To contarX1)
    V_index2(contarX1) = j
End If

```

Figura 3.3: Parte do código da ferramenta NW-KDE para H Dinâmico ligado

Dividindo a imagem 3.3 em diferentes fases, a linha de código representada na Figura 3.4, corresponde à equação 2.2, que contém o cálculo da função *kernel* (prodf) caso a variável a ser computada não tenha a parametrização *Variável Cíclica* ativada. A função *kernel* dependerá do valor histórico da variável a ser computada ($V_{historico}$), do valor no momento da previsão da mesma variável (V_{inputs}) e do parâmetro H de Referência (V_h) desta variável. Sendo que quanto maior

a similaridade entre o valor histórico da variável e o valor da variável no momento da previsão, maior será o valor da função de *kernel* (como já explicitado no subcapítulo tal).

```
prodf = Exp(-(V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
```

Figura 3.4: Parte do código da ferramenta NW-KDE que calcula a função de kernel

Caso a variável a ser computada seja cíclica (Variável Cíclica com valor 1), então o cálculo da função de *kernel* será o presente na Figura 3.5.

```
Kern1 = Exp(-(V_historico(j, i) - (V_inputs(k, i) - intervalX)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
Kern2 = Exp(-(V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
Kern3 = Exp(-(V_historico(j, i) - (V_inputs(k, i) + intervalX)) ^ 2) / (2 * (V_h(k, i)) ^ 2))
prodf = (Kern1 + Kern2 + Kern3)
```

Figura 3.5: Parte do código da ferramenta NW-KDE que calcula a função de *kernel* para variáveis cíclicas

Este será calculado através da soma de 3 componentes: Kern1, Kern2 e Kern3, onde a componente Kern2 apresenta a mesma equação da função *kernel* calculada caso a variável a ser computada não fosse cíclica. As outras componentes possuem uma nova variável, intervalX (que corresponde à diferença entre o valor máximo histórico da variável e o valor mínimo histórico), de forma a terem em conta a natureza cíclica da variável no cálculo da função de Kernel. Caso fosse utilizada apenas a função Kern2 e à variável $V_{historico}$ correspondesse, por exemplo, o valor mínimo da variável a ser computada (0 se a variável a ser computada fosse a hora) e à variável V_{inputs} correspondesse o valor máximo (23 para o caso de ser a hora), então a função de *kernel* (prodf) seria bastante inferior ao que deveria ser na realidade, já que dada a natureza cíclica da variável estes 2 pontos são bastante similares.

Na Figura 3.6 é possível verificar a condição para que o valor histórico da variável a ser computada seja contabilizado como um ponto similar.

```
If prodf > fracselect Then
    contarX1 = contarX1 + 1
```

Figura 3.6: Parte do código da ferramenta NW-KDE que contém a condição imposta pelo *Nível de Ativação*

Onde a variável fracselect representa o parâmetro *Nível de Ativação* definido pelo utilizador e ContarX1 representa o número de pontos similares encontrados.

O valor histórico da variável só é contabilizado como um ponto similar caso a respetiva função *kernel* seja superior ao *Nível de Ativação*, ou seja, só a partir de determinado grau de similaridade definido pelo utilizador é que o valor da variável histórica pode ser considerado como um ponto similar. Este processo pode ser visualizado no gráfico da Figura 3.7, sendo que para este caso a linha vermelha representa o parâmetro *Nível de Ativação* e os pontos vermelhos os pontos que cumprem a condição da Figura 3.6 e que por isso são contabilizados como pontos similares.




Figura 3.7: Gráfico de dispersão dos preços do mercado em relação à série histórica da carga com *Nível de Ativação*

Isto implica que da equação 2.9 não entram no somatório todos os casos históricos, entrando só para o cálculo da média (e por consequência da variância) apenas os casos históricos que cumprem a condição da equação 3.1.

$$K(x_{ij}, x_{t+k,j}, H_{t+k,j}) > \text{Nível de Ativação} \quad (3.1)$$

Posteriormente, é calculado um novo número de pontos similares (ContarX2), Figura 3.8.

```

If V_ciclicas(i) Then
    Kern1 = Exp(-((V_historico(j, i) - (V_inputs(k, i) - intervalX)) ^ 2) / (2 * (V_h(k, i) / (V_hdin(i) + 1)) ^ 2))
    Kern2 = Exp(-((V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i) / (V_hdin(i) + 1)) ^ 2))
    Kern3 = Exp(-((V_historico(j, i) - (V_inputs(k, i) + intervalX)) ^ 2) / (2 * (V_h(k, i) / (V_hdin(i) + 1)) ^ 2))
    prodf = (Kern1 + Kern2 + Kern3)
    V_prodf2(j) = V_prodf2(j) * prodf
Else
    prodf = Exp(-((V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i) / (V_hdin(i) + 1)) ^ 2))
    V_prodf2(j) = V_prodf2(j) * prodf
End If
If prodf > fracselect Then
    contarX2 = contarX2 + 1

```

Figura 3.8: Parte do código da ferramenta NW-KDE que contém o cálculo dos pontos similares Contar X2

O cálculo de ContarX2 é bastante semelhante ao cálculo de ContarX1, sendo que a única diferença se encontra na introdução, no cálculo da função *kernel* (VprodF2), da variável V_{hdin} , que corresponde ao parâmetro *H Dinâmico V* da variável a ser computada. Posto isto, caso o parâmetro *H Dinâmico V* da variável a ser computada esteja desligado então ContarX2 será igual ao ContarX1.

Calculadas as variáveis ContarX1 e ContarX2, caso a primeira variável seja superior à segunda é calculado um fator multiplicativo (hfator), segundo a fórmula presente na Figura 3.9 e cuja origem pode-se tornar perceptível através da observação da Figura 3.10.

```

If contarX1 > contarX2 Then
    hfator = 0.5 * (pontos + contarX1 - 2 * contarX2) / (contarX1 - contarX2)
    If hfator > 10 Then hfator = 10
Else
    hfator = 1
End If
If hfator < 0.1 Then hfator = 0.1

```

Figura 3.9: Parte do código da ferramenta NW-KDE que contém que calcula o fator multiplicativo

Onde a variável *Pontos* corresponde ao parâmetro *Pontos* definido pelo utilizador. Sendo que as outras linhas de código limitam o valor máximo do hfator a 10 e o valor mínimo a 0,1 e definem que o hfator será 1 caso o contarX1 não seja superior ao contarX2, ou seja, caso o parâmetro *H Dinâmico V* da variável a ser computada esteja desligado.




Figura 3.10: Pontos para o cálculo do fator multiplicativo [3]

Após o cálculo do fator multiplicativo, é calculada uma nova largura de *kernel* para a variável a ser computada, Figura 3.11.

```

For i = 0 To ninputs
    If V_hdin(i) = 1 Then
        V_h(k, i) = V_h(0, i) * hfator
    Else
        V_h(k, i) = V_h(0, i)
    End If

```

Figura 3.11: Parte do código da ferramenta NW-KDE que calcula a nova largura de kernel

Isto significa que na equação 2.9, a variável $H_{t+k,j}$ corresponderá ao *H de Referência* definido pelo utilizador multiplicado pelo hfator (fator multiplicativo esse que será igual para todas as variáveis), o que garantirá que a variável *N* (da mesma equação) passará a ser a variável *Npontos* cujo valor tenderá a aproximar-se do valor do parâmetro *Pontos* também definido pelo utilizador.

A largura de *kernel* será então dinâmica e estará ajustada para cada ponto do conjunto de teste. Passando μ e ϑ (equações 2.9 e 2.11) a serem expressas pelas equações 3.2 e 3.3.

$$\mu(y|X = x_{t+k}) = \frac{\sum_{i=1}^{NPontos} y_i \cdot \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, Hdin_{t+k,j}))}{\sum_{i=1}^{NPontos} \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, Hdin_{t+k,j}))} \quad (3.2)$$

$$\vartheta(y|X = x_{t+k}) = \frac{\sum_{i=1}^{NPontos} y_i^2 \cdot \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, Hdin_{t+k,j}))}{\sum_{i=1}^{NPontos} \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, Hdin_{t+k,j}))} - \left(\frac{\sum_{i=1}^{NPontos} y_i \cdot \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, Hdin_{t+k,j}))}{\sum_{i=1}^{NPontos} \prod_{j=1}^d (K(x_{ij}, x_{t+k,j}, Hdin_{t+k,j}))} \right)^2 \quad (3.3)$$

Onde:

$$Hdin_{t+k,j} = H_{t+k,j} \times H_{fator}$$

Regressando à análise do código da ferramenta, utiliza-se então esta nova largura de banda para se calcular o novo número de pontos de similares (que corresponde à variável C na Figura 3.12, que posteriormente serão usados no cálculo de μ e ϑ (equações 2.9 e 2.11) e tornando-se assim possível a modelização dos parâmetros α e β (equações 2.5 e 2.6, utilizando-se posteriormente a equação 2.4 para se construir uma função de distribuição *Beta* que permite a análise da distribuição probabilística da densidade dos preços do mercado de uma forma contínua.

```

For Each j In V_index()
  If V_ciclicas(i) Then
    Kern1 = Exp(-(V_historico(j, i) - V_inputs(k, i) - intervalX) ^ 2) / (2 * (V_h(k, i) ^ 2))
    Kern2 = Exp(-(V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i) ^ 2))
    Kern3 = Exp(-(V_historico(j, i) - (V_inputs(k, i) + intervalX)) ^ 2) / (2 * (V_h(k, i) ^ 2))
    prodf = (Kern1 + Kern2 + Kern3)
    V_prodf(j) = V_prodf(j) * prodf
  Else
    prodf = Exp(-(V_historico(j, i) - V_inputs(k, i)) ^ 2) / (2 * (V_h(k, i) ^ 2))
    V_prodf(j) = V_prodf(j) * prodf
  End If
  If prodf > fracselect Then
    c = c + 1
    ReDim Preserve V_index2(1 To c)
    V_index2(c) = j
  End If

```

Figura 3.12: Parte do código da ferramenta NW-KDE

Caso o parâmetro *H Dinâmico* esteja desligado, então só será computada a parte do código presente na Figura 3.12, deixando as larguras de *kernel* de serem dinâmicas, ou seja estarão apenas dependentes do parâmetro *H de Referência* definido para cada variável e serão independentes do parâmetro *Pontos* definido pelo utilizador. Nesse caso as equações das variáveis μ e ϑ serão 2.9 e 2.11.

Em relação ao parâmetro *Fator de Ajuste*, este parâmetro terá como consequência um melhoramento da qualidade da previsão caso se estejam a verificar situações de *underdispersed forecast* e *overdispersed forecast* (Figura 2.3). Sendo que, caso esteja a ocorrer o primeiro caso serão atribuídos valores compreendidos 0 e 1 a este parâmetro, uma vez que uma diminuição dos valores de α e β provoca um aumento da dispersão da FDP, aumentando a frequência de casos reais previstos

na zona central. Já para o segundo caso, este parâmetro terá valores maiores que 1, uma vez que um aumento dos valores α e β provocam uma diminuição na dispersão do FDP, o que provoca um aumento da frequência de casos reais previstos nos limites da distribuição.

Nas Figuras 3.13 e 3.15 é possível a visualização de diagramas de *reliability* (diagramas cuja construção será explicada no subcapítulo 4.1.2), onde na Figura 3.15 é visível um modelo de previsão em que é aplicado um *Fator de Ajuste* de valor 1,9 e na Figura 3.13 o mesmo modelo com um "Fator de Ajuste" de 0,5.

Nas Figuras 3.14 e 3.16 é possível visualizar os gráficos dispersão dos mesmos modelos. Como se pode observar, as dispersões encontram-se mais concentradas para o primeiro caso do que no segundo.




Figura 3.13: Exemplo de diagrama de *reliability* com um Ajuste de 0,5




Figura 3.14: Exemplo de diagrama de dispersão com um Ajuste de 0,5




Figura 3.15: Exemplo de diagrama de *reliability* com um *Ajuste* de 1,9




Figura 3.16: Exemplo de diagrama de dispersão com um *Ajuste* de 1,9

Resta ainda referir que, ao longo do vasto conjunto de simulações que foram realizadas, foram sendo descobertas algumas fragilidades na versão inicial da ferramenta que estava a ser utilizada, pelo que lhe foram melhoradas algumas componentes, nomeadamente, a parte do código referente ao parâmetro *Nível de Ativação* e ao *H da Variável Recursiva* (as partes do código expostas anteriormente já incluem estas modificações) e foram criados também os parâmetros *H Dinâmico V*.

3.4 Metodologia para a Identificação das Parametrizações Ótimas de cada Modelo de Previsão

3.4.1 Avaliação dos Modelos no Processo de Parametrização

Visto que o NW-KDE é uma ferramenta criada recentemente, não existia nenhuma metodologia para determinar as parametrizações ótimas de um determinado modelo de previsão. No entanto, antes de se analisar a metodologia criada na presente dissertação é necessário expor-se a forma como foram avaliados os modelos ao longo deste processo de parametrização, tendo sido utilizados 2 indicadores de erro para o efeito. O indicador de erro NMAE (exposto no subcapítulo 2.2.3), equação 3.4, para definir o erro associado ao Quantil 50 previsto e foi criado também o indicador de erro *reliability* (exposto no subcapítulo tal), equação 3.5, que define o erro associado à previsão das incertezas (quanto mais próximo de 100 melhor estão modelizadas as incertezas).

$$NMAE_T = \frac{1}{T} \sum_{(h=1)}^T \left[\left| \frac{P_h - \hat{P}_h}{\bar{P}_h} \right| \right] \quad (3.4)$$

$$Reliability = \left(1 - \frac{\frac{1}{N} \sum_{i=1}^N |f_{real,i} - f_{ideal,i}|}{\frac{1}{N-2}} \right) \times 100 \quad (\%) \quad (3.5)$$

Onde:

i – Índice dos intervalos definidos para o estudo, $i \in 1, \dots, N$.

N – Número de intervalos considerados. Neste caso $N=22$, sendo 20 intervalos da FDP e 2 intervalos extra, representativos dos pontos não contidos na distribuição.

$f_{real,i}$ – Frequência de valores reais previstos para cada intervalo da FDP estipulado.

$f_{ideal,i}$ – Frequência ideal de valores reais para cada intervalo estipulado (idealmente 5% para cada intervalo da FDP e 0% para os intervalos).

Com o intuito de não se comprometer a eficácia das previsões dos valores médios do preço (previsões do Quantil 50) em detrimento das previsões das incertezas (e vice-versa), dado que por vezes com a diminuição NMAE ocorria um aumento do *reliability*, foi estabelecido como *benchmark* os valores do NMAE obtidos na dissertação [2].

Estabelecendo-se, sempre que possível, como objetivo do processo de parametrização obter para cada modelo um NMAE com valor igual ou menor ao obtido para o respetivo modelo na dissertação [2] e alcançado esse objetivo, atingir os melhor valores de *reliability* possíveis, não ultrapassando esse limite. Caso não fosse possível alcançar os valores do NMAE de referência, o objetivo passaria a ser apenas a diminuição desse indicador.

3.4.2 Conclusões Sobre as Consequências Práticas das Parametrizações na Qualidade do Modelo de Previsão

Definidos os objetivos e assimilados os conceitos teóricos de cada parâmetro, dada a grande relação entre as parametrizações definidas pelo utilizador e a qualidade da previsão, foi necessário explorar as consequências práticas da variação dos parâmetros na qualidade dos modelos de previsão. Este conhecimento teve então que ser adquirido empiricamente, ou seja, através da realização de inúmeras simulações, retirando-se as seguintes conclusões sobre os aspetos que influenciam a qualidade dos resultados obtidos:

1. Geralmente obtêm-se melhores resultados quando o parâmetro *H Dinâmico* está ligado, no entanto as simulações tornam-se mais morosas. Por exemplo, numa máquina com um processador “Intel(R) Core(TM) i7-6700HQ CPU @ 2.60 GHz” e 8GB de memória RAM, um modelo com 9 variáveis demora cerca de 6 minutos a ser processado quando o *H Dinâmico* está ativo e com este parâmetro desativado o mesmo modelo demora cerca de 3 minutos a ser processado.
2. Não existe uma relação linear entre o valor dado ao parâmetro *H de Referência* de uma certa variável e a qualidade da previsão, este fato pode ser observado na Figura 3.17 onde se pode visualizar os valores do NMAE de um modelo de previsão, à medida que se vai variando o *H de Referência* da variável explicadora eólica D-1. Isto tem como consequência um aumento do número de simulações que o utilizador tem que realizar quando está a otimizar estes parâmetros, já que o fato do erro piorar, por exemplo, quando se aumenta o valor do *H de Referência* de uma determinada variável, não significa que a qualidade da previsão vai continuar a piorar se se continuar a aumentar esse valor (concluindo-se que esse parâmetro da variável está otimizado), pelo contrário, pode vir a melhorar. Posto isto, o processo de otimização dos *H de Referência* consistiu em definir-se um valor inicial para este parâmetro bastante baixo (por exemplo 0,5 para variáveis na ordem de grandeza da hora e 500 para variáveis na ordem de grandeza do consumo), ir incrementando esse valor com um incremento geralmente igual ao valor inicial definido (o valor deste seria ajustado para um valor maior caso a variação do erro fosse demasiado diminuta, já que o processo tornar-se-ia demasiado moroso) e ir-se guardando os valores de erro obtidos para cada simulação. Este processo inicial de incrementação termina quando para um determinado valor de *H de Referência* o erro obtido para o indicador NMAE fosse maior 1%, do que o melhor valor de erro obtido com um determinado valor de *H de Referência* testado em simulações anteriores. Terminado esse processo de incrementação, analisa-se se o valor de parametrização encontrado é o ótimo ou se à volta desse valor existem valores melhores, através de um novo processo de incrementação (por exemplo, caso o incremento utilizado tivesse o valor de 0,5 e o *H de Referência*, a que corresponde um menor erro no primeiro processo de incrementação, tivesse o valor de 2,5, realizava-se um novo processo de incrementação desta feita com um incremento de 0,1, que começaria com o valor inicial do parâmetro em 2,1 e terminaria

com o valor de 2,9). Estes 2 processos de incrementação permitem então que o utilizador encontre sempre o valor de *H de Referência* ótimo para uma determinada variável.




Figura 3.17: NMAE para diferentes valores de *H de Referência* da variável Eólica D-1

3. A ordem pela qual se otimiza o parâmetro *H de Referência* de cada variável influencia a qualidade que se obtém para um determinado modelo de previsão. Por exemplo, num modelo constituído pelas variáveis: V1, V2, V3 e V4. Se se otimizar o *H de Referência* de cada variável pela ordem V1, V2, V3 e V4 obtém-se um determinado erro de previsão e se se otimizar esses parâmetros pela ordem V2, V3, V1 e V4 obtém-se um erro diferente. Posto isto, após várias simulações, chegou-se à conclusão que a melhor ordem de otimização seria iniciar-se este processo pela variável explicadora que apresenta uma maior relação com variável dependente (relação essa avaliada através da análise da linha de tendência de um gráfico que relaciona-se estas duas variáveis), otimizando as restantes variáveis pela mesma ordem de relação (ou seja, da variável que apresenta maior relação para a menor) e deixar a otimização do *H da Variável Recursiva* para último lugar.
4. Realizando-se apenas um ciclo de ajustes de todos os parâmetros *H de Referência*, no final desse ciclo os primeiros *H de Referência* que foram ajustados, já não se encontram otimizados. Este fato tem como consequência um aumento no numero de simulações, já que é necessário realizarem-se tantos ciclos (geralmente 2 para o problema em questão) quanto os necessários até que todos os parâmetros *H de Referência* estejam otimizados (ou seja, até se chegar a um determinado momento em que se se alterar algum destes parâmetros a qualidade da previsão piora).
5. Para cada modelo de previsão (caso o parâmetro *H Dinâmico* esteja ligado), existe um valor ótimo para o parâmetro *Pontos* e para cada valor que o utilizador define para esse parâmetro,

o conjunto de valores ótimos dos parâmetros *H de Referência* são diferentes. O primeiro aspeto significa que quando se está a testar um modelo de previsão (caso o *H Dinâmico* esteja ligado) o utilizador deve testar vários valores para o parâmetro *Pontos*. E para cada um desses testes, tem que otimizar o valor dos *H de Referência* de todas as variáveis.

6. De forma semelhante ao que ocorre no ponto 4, para cada modelo de previsão, existe um valor ótimo para o parâmetro *Nível de Ativação* e para cada valor que o utilizador define para esse parâmetro, o conjunto de valores ótimos definidos para os parâmetros *H de Referência* são diferentes. Este valor ótimo ronda os 0,2 para os modelos desenvolvidos na presente dissertação.

3.4.3 Metodologia

Os pontos representados na Figura 3.18, são descritos a seguir:

1. Define-se o valor 0,2 para parâmetro *Nível de Ativação*. Caso o parâmetro *H Dinâmico* esteja ativo define-se para o parâmetro *Pontos* o valor obtido na parametrização do modelo anterior, sendo que para o modelo 1 e 2 definiu-se 250 como valor deste parâmetro.
2. Utilizam-se as parametrizações ótimas obtidas para o modelo anterior e realiza-se um ajuste do *H de Referência* da variável adicionada no novo modelo. No final desse ajuste faz-se um ajuste de todas as variáveis segundo o processo descrito no ponto 2 da secção anterior e utilizando a ordem definida no ponto 3 da mesma secção. Repete-se este ciclo às vezes que forem necessárias (como descrito no ponto 4 da secção anterior) e no final realiza-se, caso melhore a qualidade do modelo, um ajuste do *Nível de Ativação*. No final deste processo são guardadas as parametrizações e os respetivos valores dos indicadores NMAE e *Reliability*.
3. Definem-se valores bastante elevados para os *H de Referência* de todas as variáveis do modelo. Posteriormente realiza-se um ajuste destas variáveis segundo o processo descrito no ponto 2 da secção anterior e utilizando a ordem definida no ponto 3 da mesma secção. Repete-se este ciclo às vezes que forem necessárias, como descrito no ponto 4 da secção anterior e no final realiza-se, caso melhore a qualidade do modelo, um ajuste do *Nível de Ativação*. No final deste processo são guardadas as parametrizações e os respetivos valores dos indicadores NMAE e *Reliability*.
4. Comparam-se os indicadores de erro obtidos no ponto 2 e no ponto 3 e escolhe-se o melhor conjunto de parametrizações. Caso o parâmetro *H Dinâmico* esteja ligado e ao melhor conjunto de parametrizações corresponda um valor de NMAE superior aos obtidos nesse modelo em [2], altera-se o número do parâmetro *Pontos* e repete-se o processo descrito no ponto 2. Caso o parâmetro *H Dinâmico* esteja desligado, define-se como parametrização ótima a que obteve um menor valor para o indicador de erro NMAE.

Na Figura 3.18, apresenta-se um resumo da metodologia de parametrização descrita nos pontos anteriores.



Figura 3.18: Fluxograma da metodologia desenvolvida para a identificação das parametrizações ótimas de cada modelo de previsão

Para se realizar o processo do ponto 2 são necessárias, aproximadamente, 25 simulações para se parametrizar o *H de Referência* da variável nova do modelo, 11 simulações por variável (incluindo a variável recursiva) para se parametrizarem os *H de Referência* destas e aproximadamente 9 simulações para se parametrizar o parâmetro *Nível de Ativação*.

Em relação ao processo do ponto 3 este necessita de um número mais extensivo de simulações. Sendo necessário para o seu processamento, aproximadamente, 37 simulações por variável (incluindo a variável recursiva) para se parametrizarem os *H de Referência* e aproximadamente 9 simulações para se parametrizar o parâmetro *Nível de Ativação*.

Dado o conjunto extensivo de simulações que é necessário realizar-se para se descobrir o conjunto de parametrizações ótimas, a morosidade do processamento destas simulações (ponto 1 da secção precedente) e visto que existe um tempo limite para a realização da presente dissertação, a partir do modelo 10 foi desligado o *H Dinâmico*. Esta decisão permitiu com que a presente dissertação fosse realizada dentro dos prazos definidos, já que implicou uma diminuição no tempo de processamento de cada simulação e no número de simulações que foram realizadas, visto que

não foi necessário descobrir-se a parametrização ideal para o parâmetro *Pontos* de cada modelo. No entanto, é expectável que esta decisão implique também uma diminuição da qualidade dos resultados, já que, até ao modelo 10, quando o *H Dinâmico* estava ligado obtinham-se modelos com melhor qualidade, do que com este parâmetro desligado.

Capítulo 4

Análise de Resultados

No presente capítulo serão expostos e analisados os resultados obtidos para cada modelo de previsão.

Inicialmente será feita uma explicação dos indicadores de erro que serão utilizados na caracterização dos modelos. Posteriormente serão exibidos os resultados obtidos para os 23 modelos de previsão. De seguida, será feita uma análise gráfica do comportamento dos melhores modelos dos 5 grupos definidos no secção 3.2.7. Por último será analisada, para o melhor modelo, a relação entre as variáveis que o constituem e os valores dos indicadores de erro obtidos no mesmo e será analisada também, graficamente, a relação entre a previsão e os valores reais.

4.1 Indicadores de Erro

4.1.1 Indicadores da Previsão Determinista (Quantil 50)

Serão utilizados 4 indicadores de erro distintos para se avaliarem as previsões obtidas para o Quantil 50 de cada um dos modelos. Estes 4 indicadores correspondem ao NMAE e MAE (secção 2.2.3), o primeiro foi usado para que os resultados obtidos na presente dissertação possam ser comparados com os obtidos em [2] e 2 indicadores que ainda não foram analisados na presente dissertação: média dos valores absolutos das ocorrências com erros negativos.

Mean Positive Error (MPoE) : Média dos valores absolutos das ocorrências de erros positivos da previsão ($\hat{P} - P > 0$) por cada intervalo da escala do real (equação 4.1).

$$MPoE_T = \frac{1}{T} \sum_{h=1}^T \left[\left| \frac{Ph - \hat{P}_h}{\bar{P}_h} \right| \right], \text{ se } \hat{P} - P > 0 \quad (4.1)$$

Mean Negative Error (MNeE): Média dos valores absolutos das ocorrências de erros negativos da previsão ($\hat{P} - P < 0$) por cada intervalo da escala do real (equação 4.2).

$$MNeE_T = \frac{1}{T} \sum_{h=1}^T \left[\left| \frac{Ph - \hat{P}_h}{\bar{P}_h} \right| \right], \text{ se } \hat{P} - P < 0 \quad (4.2)$$

Serão ainda utilizados 3 tipos de gráficos ao longo do presente capítulo, Figura 4.1, 4.2 e 4.3. No primeiro é possível visualizar-se a variação da frequência de ocorrência do erro (subtração entre valor previsto e valor real) ao longo dos vários intervalos de valores que este pode conter. O segundo permite a visualização gráfica da evolução dos indicadores MAE, MPoE e MNeE, ao longo da escala do valor real, bem como a variação da frequência de ocorrências do valor real em cada intervalo representativo da mesma escala. Através da observação do terceiro pode-se analisar a variação dos indicadores MAE, MPoE e MNeE ao longo das várias semanas de teste (secção 3.2.6).




Figura 4.1: Exemplo gráfico de uma análise de frequência do erro




Figura 4.2: Exemplo gráfico de uma análise dos erros médios da previsão




Figura 4.3: Exemplo gráfico de uma análise dos erros médios para as semanas de teste

4.1.2 Indicadores da Previsão Probabilística

Para se avaliarem as previsões de incertezas de cada modelo foram utilizados 2 indicadores numéricos: *reliability* e dispersão (*sharpness*).

O *reliability* (equação 3.5), foi criado para se consolidar num valor numérico a informação contida no gráfico 4.4.

Este gráfico consiste num diagrama que pretende expor o nível de calibração da FDP (secção 2.3.3). Este é construído realizando-se, para cada instante de tempo, uma verificação binária sobre o intervalo da FDP onde se encontra contido o valor do preço real, ou seja, seria atribuído o valor 1 caso se encontre dentro do intervalo dos quantis Q_x e Q_y da FDP e valor 0 caso se encontre fora desse intervalo. Posteriormente, é efetuada uma contagem do número de ocorrências do valor valor para cada intervalo probabilístico da FDP considerado, transformando-se esses valores em percentagens relativas ao número total de pontos do real observados. No gráfico da Figura 4.4, é avaliada então a distribuição de ocorrências previstas para 20 intervalos da FDP, aos quais se acrescentam mais 2 para se representarem o número de pontos reais que não se encontram incluídos nos limites da distribuição probabilística.




Figura 4.4: Exemplo de diagrama de *reliability* da FDP

Como exposto na secção 2.3.3, não basta analisar-se o *reliability* da previsão, é também necessário analisar-se a dispersão (*sharpness*) probabilística da mesma, sendo que para o efeito foi utilizado o gráfico 4.5. Este consiste num diagrama onde são relacionados os valores médios do máximo, mínimo e Quanties 75, 50 e 25 da distribuição probabilística com cada intervalo do valor real.




Figura 4.5: Exemplo de diagrama de dispersão

Com o intuito de se quantificar a informação contida no diagrama de dispersão foi criado um indicador numérico da equação 4.3.

$$Dispersão = \left(\frac{\sum_{i=1}^N Q_{75,i} - Q_{25,i}}{N} \right) \quad (€/MWh) \quad (4.3)$$

Onde:

N – Numero de casos previstos ($N=3360$ na presente dissertação)

i – Intervalo definido da escala do real, $i \in 1, \dots, N$.

$Q_{75,i}$ – Quantil 75 para o caso previsto i .

$Q_{25,i}$ - Quantil 25 para o caso previsto i .

Posto isto uma previsão com um boa performance terá o mínimo valor de dispersão (equação 4.3) possível, condicionado pelo fato de não poder haver uma diminuição do *reliability* (equação 3.5).

4.2 Resultados Obtidos para os 23 Modelos de Previsão

Expostos e analisados os indicadores de erro e gráficos que serão utilizados ao longo do presente capítulo, encontram-se as condições necessárias para se iniciar a análise de resultados obtidos. Na Tabela 4.6 podem-se então observar os resultados obtidos para cada um dos modelos de previsão.

Grupos de Var.	Modelo	Hora	DDS	Preço D	Preço D-6	Consumo D-1	Consumo D-6	Consumo D+1	Temperatura D+1	Vento D+1	Irradiância D+1	Eólica D+1	Eólica D-1	Hídrica D-1	Cogeração/solar D-1	Carvão D-1	Nuclear D-1	Gás Natural D-1	NMAE de [2] (%)	NMAE (%)	MAE (€/MWh)	MPoE (€/MWh)	MNeE (€/MWh)	Reliability (%)	Dispersão (€/MWh)
Grupo 1	D1	X																	22,64	21,31	9,78	12,09	7,25	78,51	13,38
	D2		X																24	22,67	10,40	13,03	7,73	75,25	11,96
	D3	X	X																20,82	19,64	9,01	11,03	7,02	82,51	12,12
Grupo 2	D4	X	X	X															17	16,85	7,73	9,25	6,15	80,61	10,23
	D5	X	X		X														20,45	19,81	9,09	10,30	8,01	79,33	10,65
	D6	X	X	X	X														16,82	16,79	7,70	8,99	6,38	82,38	10,59
Grupo 3	D7	X	X	X	X	X													16,7	16,52	7,58	8,90	6,25	80,92	10,09
	D8	X	X	X	X		X												16,69	16,56	7,60	8,94	6,25	81,86	10,14
	D9	X	X	X	X			X											16,5	16,49	7,57	8,82	6,27	81,21	10,36
	D10	X	X	X	X	X		X											16,32	16,31	7,48	8,58	6,37	82,98	10,40
Grupo 4	D11	X	X	X	X	X		X	X										16,37	16,31	7,48	8,52	6,42	83,61	10,13
	D12	X	X	X	X	X		X		X									12,85	13,43	6,16	6,55	5,77	83,39	8,93
	D13	X	X	X	X	X		X			X								16,4	16,38	7,52	8,62	6,40	83,17	10,17
	D14	X	X	X	X	X		X	X	X									12,59	13,16	6,04	6,42	5,69	84,92	8,23
Grupo 5	D15	X	X	X	X	X		X	X	X		X							11,86	12,66	5,81	6,08	5,55	83,53	8,75
	D16	X	X	X	X	X		X	X			X							11,58	12,31	5,65	5,85	5,48	85,07	8,21
	D17	X	X	X	X	X		X	X			X	X						11,42	12,18	5,59	5,75	5,45	84,47	8,36
	D18	X	X	X	X	X		X	X			X		X					10,86	12,16	5,58	5,76	5,42	85,25	7,76
	D19	X	X	X	X	X		X	X			X			X				11,41	12,28	5,63	5,81	5,48	84,84	8,19
	D20	X	X	X	X	X		X	X			X				X			11,54	12,26	5,62	5,85	5,43	85,75	7,97
	D21	X	X	X	X	X		X	X			X					X		11,43	12,21	5,60	5,78	5,44	84,11	7,81
	D22	X	X	X	X	X		X	X			X						X	11,32	12,25	5,62	5,80	5,45	83,65	8,12
	D23	X	X	X	X	X		X	X			X		X		X	X	X	10,48	12,10	5,55	5,68	5,44	85,64	7,83

Figura 4.6: Tabela dos resultados obtidos para cada modelo de previsão

Pode-se concluir então que o modelo 23 é o modelo que apresenta melhor qualidade, fazendo um balanço de todos os indicadores de erro obtidos para cada modelo. É de salientar ainda que, em termos de previsões deterministas, o NW-KDE conseguiu melhores resultados do que as redes neurais aplicadas em [2], até ao modelo 11, sendo que na grande maioria dos modelos posteriores as previsões obtidas têm pior qualidade. Isto seria expectável, já que até ao modelo 9 o parâmetro *H Dinâmico* estava ativo e para os modelos que seguiram esse parâmetro foi desativado, o que explica a diminuição de qualidade desses modelos. Em anexo, na Figura A.1, podem ser visualizadas as parametrizações ótimas encontradas para cada um dos 23 modelos.

Na Figura 4.7, podem-se visualizar as variações dos indicadores MAE, *reliability* e dispersão ao longo da evolução dos modelos desenvolvidos.




Figura 4.7: Evolução dos indicadores de erro com os 23 modelos de previsão

Como se pode observar, houve uma tendência para o *reliability* aumentar e o MAE e a dispersão diminuírem, ao longo da evolução dos modelos. Concluindo-se que, como seria expectável, a maior parte das variáveis que foram sendo adicionadas continham informação útil.

4.3 Análise do Melhor Modelo de Previsão de cada Grupo

Expostos os resultados obtidos para cada um dos modelos de previsão, serão analisados na presente secção, com o auxílio a representações gráficas os modelos que apresentam melhor qualidade de cada um dos 5 grupos de tipos de modelos: Modelo 3, Modelo 6, Modelo 10, Modelo 14 e Modelo 23.

4.3.1 Modelo 3 - Variáveis Cronológicas

Como se pode observar na Tabela 4.6 este modelo de previsão foi construído apenas com as variáveis cronológicas: DDS e hora.

Visualizando o gráfico da Figura 4.8, pode-se concluir que a maioria (cerca de 70%) dos erros deste modelo apresentam valores entre os -10 €/MWh e 11 €/MWh. Sendo que as frequências de erros entre os intervalos de -6 €/MWh a -2 €/MWh e de -2 €/MWh a 3 €/MWh, se sobressaem ocorrendo ambos aproximadamente 18% das vezes.




Figura 4.8: Gráfico da frequência do erro do modelo 3

Analisando o gráfico da Figura 4.9, verifica-se que a maioria, cerca de 65% dos valores reais do preço são valores compreendidos entre os 39 €/MWh e os 60 €/MWh (o que ocorrerá também para os restantes modelos uma vez os valores reais do preço são sempre os mesmos), sendo que é também neste período que o MAE apresenta valores mais baixos. Verificando-se que os maiores valores do MAE correspondem aos menores valores do preço real, e é também importante referir que no intervalo de preços reais que vai desde os 0 €/MWh aos 47 €/MWh os erros positivos são de maior dimensão e a partir dos 47 €/MWh passam a ser os erros negativos os mais significativos, sendo que para preço reais menores que 26 €/MWh este nunca previu por defeito e a partir dos 60 €/MWh nunca previu por excesso.




Figura 4.9: Gráfico dos erro médios do modelo 3

Já através da observação do gráfico da Figura 4.10, pode-se concluir que as semanas de teste a que correspondem erros mais elevados são as semanas: 15 (Abril) e 50 (Dezembro) de 2012 e 2 (Janeiro), 7 (Fevereiro), 12 (Março), 17 (Abril) e 22 (Maio) de 2013 (com principal destaque para as semanas 12 e 17 de 2013). Sendo que para estas semanas o valor médio dos erros positivos é mais preponderante que o valor médio dos erros negativos, com exceção da semana 2 de 2013. Concluindo-se que o período onde este modelo apresenta um erro maior vai desde Dezembro de 2012 a Maio de 2013. Em relação às semanas para as quais se obtiveram erros com menores valores, estas são: 30 (Julho) de 2012 e 27 (Julho) e 32 (Agosto) de 2013.




Figura 4.10: Gráfico dos erros médios para as semanas de teste do modelo 3

Em relação ao diagrama de *reliability* deste modelo (gráfico da Figura 4.11), pode-se concluir que a FDP apresenta uma calibração relativamente boa, tendo 82,51% de *reliability* (Tabela 4.6). Concluindo-se também que entre o Quantil 0 e o Quantil 5 existe a maior discrepância entre as ocorrências dos valores previstos e as ocorrências dos valores reais, sendo que estes últimos acontecem cerca de 2,2% mais vezes que as ocorrências previstas. Verifica-se também que cerca de 4,8% das ocorrências reais não estão contidas na FDP (3,8% ocorreram abaixo do valor mínimo da FDP e 1% acima do valor máximo), explicações possíveis para esse fato são a falta de variáveis explicadoras históricas semelhantes às variáveis explicadoras do momento da previsão ou variações do preço provocadas por fatores externos, ou seja, fatores que não estão contidos na informação disponibilizada pelas variáveis explicadores do momento da previsão.




Figura 4.11: Diagrama de reliability da FDP do modelo 3

Em termos de dispersão, através da visualização do gráfico da Figura 4.12, depreende-se que este modelo apresenta uma dispersão relativamente elevada e uniforme, tendo o seu indicador numérico o valor 12,12 €/MWh. Os valores previstos para o preço não são capazes de acompanhar os valores reais desta variável, apresentando um crescimento bastante ligeiro, mantendo-se praticamente uniformes.




Figura 4.12: Diagrama de dispersão do modelo 3

4.3.2 Modelo 6 - Variáveis Cronológicas e Preços

O modelo de previsão 6 foi construído com variáveis cronológicas e variáveis de preço: DDS, hora, preço D e preço D-6.

Realizando uma análise do gráfico da Figura 4.13, verifica-se que a maioria dos erros (cerca de 70%) apresentam valores entre os -9 €/MWh e os 8 €/MWh. Sendo também necessário referir que os intervalos de -4 €/MWh a 0 €/MWh e de 0 €/MWh a 4 €/MWh apresentam as frequências que mais se destacam, tendo ambas um valor aproximado de 21%.




Figura 4.13: Gráfico da frequência do erro do modelo 6

Através da visualização do gráfico da Figura 4.14, pode-se concluir que, à semelhança do modelo 3, o período em que os valores do MAE são mais diminutos corresponde ao intervalo que inclui a maioria das ocorrências dos preços reais (entre os 34 €/MWh e os 60 €/MWh) e que os maiores valores do MAE correspondem aos menores valores do preço real. Relativamente às médias dos erros positivos e negativos, no intervalo que compreende os preços reais de 0 €/MWh a 43 €/MWh, os erros médios positivos são mais significativos e nos restantes intervalos os erros médios negativos passam a ser os que apresentam maior significado. É necessário acrescentar ainda que, para os intervalos de 0 €/MWh a 13 €/MWh, este modelo prevê sempre por excesso e para os intervalos de 73 €/MWh a 86 €/MWh prevê sempre por defeito.




Figura 4.14: Gráfico dos erro médios do modelo 6

Observando o gráfico da Figura 4.15, verifica-se que os erros com valores mais elevados correspondem as semanas de 15 (Abril), 45 (Novembro) e 50 (Dezembro) de 2012 e 2 (Janeiro), 12 (Março), 17 (Abril) de 2013 (com destaque para a semana 12 de 2013). Destas semanas referidas anteriormente só na semana 2 de 2013 é que o valor médio dos erros negativos são superiores aos valores médios dos erros positivos. Relativamente às semanas que apresentam erros menores, estas são: 25 (Junho), 30 (Julho) e 40 (Setembro) de 2012 e 32 (Agosto) de 2013, sendo que apenas na semana de 2013 é que os erros médios positivos foram mais significativos. É necessário ressaltar ainda que para a maioria das semanas ocorreu uma diminuição do MAE relativamente aos valores obtidos no modelo 3.




Figura 4.15: Gráfico dos erros médios para as semanas de teste do modelo 6

Relativamente ao diagrama de *reliability* (gráfico da Figura 4.16), este modelo tem uma FDP ligeiramente menos calibrada que a FDP do modelo 3, apresentando um *reliability* de 82,36% (Tabela 4.6). Conclui-se também que, à semelhança do modelo 3, que contém apenas variáveis cronológicas, entre o Quantil 0 e o Quantil 5 existe a maior discrepância entre as ocorrências dos valores previstos e as ocorrências dos valores reais, sendo que estes últimos acontecem cerca de 2,3% mais vezes que as ocorrências previstas. Depreende-se ainda que cerca de 5,4% das ocorrências reais não estão contidas na FDP, das quais 3,4% ocorreram abaixo do valor mínimo da FDP e 2% acima do seu valor máximo.




Figura 4.16: Diagrama de reliability da FDP do modelo 6

Analisando o gráfico da Figura 4.17, conclui-se que este modelo apresenta uma dispersão melhor que o modelo 3 (o que seria expectável visto que o seu indicador de dispersão tem o valor de 10,59 €/MWh), apresentando uma distribuição ligeiramente mais concentrada e menos uniforme. Verifica-se também uma ligeira diminuição das incertezas com o aumento dos valores dos preços reais e, relativamente aos valores previstos estes acompanham melhor os valores reais, apresentando um crescimento mais acentuado, o que seria expectável dada a grande relação entre o preço e as suas variáveis históricas.




Figura 4.17: Diagrama de dispersão do modelo 6

4.3.3 Modelo 10 - Variáveis Cronológicas, Preços e Consumos

O presente modelo de previsão utiliza as seguintes variáveis explicadoras: DDS, hora, preço D, preço D-6, consumo D-1 e consumo D+1.

Como se pode observar no gráfico da Figura 4.18, a maioria dos erros (cerca de 75%) estão compreendidos entre os -9 €/MWh e os 10 €/MWh. Sendo também necessário referir que os intervalos de -4 €/MWh a 0 €/MWh e de 0 €/MWh a 5 €/MWh apresentam as frequências que mais se destacam, com os valores de 26% e 22%, respetivamente.




Figura 4.18: Gráfico da frequência do erro do modelo 10

Visualizando o gráfico da Figura 4.19, conclui-se que, à semelhança do modelo 3 (variáveis cronológicas) e 6 (variáveis cronológicas e preços), o intervalo que compreende a maior percentagem de preços reais é também o período para o qual os valores do MAE são mais baixos e o período para o qual os valores do MAE são mais elevados correspondem aos menores valores do preço real. Relativamente às médias dos erros positivos e negativos, de forma análoga ao que ocorreu no modelo 6, no intervalo que compreende os preços reais de 0 €/MWh a 43 €/MWh, os erros médios positivos são mais significativos e nos restantes intervalos os erros médios negativos passam a ser os que apresentam maior significado. Em relação aos intervalos em que se prevê apenas por excesso e apenas por defeito, no intervalo que vai desde os 0 €/MWh a 9 €/MWh acontece a primeira situação e para os intervalos de 77 €/MWh a 86 €/MWh ocorre a segunda.




Figura 4.19: Gráfico dos erro médios do modelo 10

Analisando o gráfico da Figura 4.20, é perceptível que os erros com valores mais elevados correspondem as semanas de 15 (Abril) e 45 (Novembro) de 2012 e 12 (Março) de 2013 (com destaque para a semana 12 de 2013, à semelhança do modelo 3 e 6). Sendo que, para estas 3 semanas, só na semana 45 de 2012 é que o valor médio dos erros negativos é mais significativo. Por outro lado, as semanas que apresentam menores erros são as semanas 30 de 2012 e 32 de 2013, às quais corresponde os meses de Julho e Agosto, respetivamente.




Figura 4.20: Gráfico dos erros médios para as semanas de teste do modelo 10

Através da visualização do gráfico da Figura 4.21, o presente modelo apresenta uma FDP mais calibrada que as FDP dos modelos analisados nas secções anteriores, à qual corresponde um *reliability* de 82,98%. À semelhança dos modelos anteriores, também para os Quantiles 0 e o 5 da FDP, existe a maior discrepância entre as ocorrências dos valores previstos e as ocorrências dos valores reais, visto que os valores reais acontecem cerca de 2,4% mais vezes que as ocorrências previstas. É possível concluir-se ainda que cerca de 2,8% das ocorrências reais ocorrem abaixo do valor mínimo da FDP e aproximadamente 2,3% acima do seu valor máximo.




Figura 4.21: Diagrama de reliability da FDP do modelo 10

Analisando o gráfico da Figura 4.22, conclui-se que este modelo apresenta um diagrama de dispersão semelhante ao modelo 6, sendo que através do recurso ao indicador numérico de dispersão é possível concluir que este modelo é ligeiramente melhor, apresentando uma dispersão de 10,49 €/MWh. Em relação aos valores previstos, estes também acompanham ligeiramente melhor os valores reais, apresentando um crescimento mais acentuado.




Figura 4.22: Diagrama de dispersão do modelo 10

Pode-se então concluir que com a introdução dos consumos, dada a sua elevada influência no processo de formação dos preços de mercado, houve uma ligeira diminuição do valor médio dos erros e das incertezas e um ligeiro aumento do *reliability*.

4.3.4 Modelo 14 - Variáveis Cronológicas, Preços, Consumos e Previsões Meteorológicas

Este modelo de previsão foi construído com as variáveis: DDS e hora, preço D, preço D-1; consumo D-1; consumo D+1; temperatura D+1 e vento D+1.

Visualizando o gráfico da Figura 4.23, conclui-se que a maioria dos erros (cerca de 73%) deste modelo têm valores compreendidos entre os -7 €/MWh e 7 €/MWh. Sendo que a frequência de erros do intervalo entre -2 €/MWh e 2 €/MWh é a que mais se destaca, ocorrendo aproximadamente 33% das vezes.




Figura 4.23: Gráfico da frequência do erro do modelo 14

À semelhança dos 3 modelos analisados anteriormente, observando o gráfico da Figura 4.24, depreende-se que é no intervalo em que a maior percentagem de valores reais se encontra (entre os 39 €/MWh e os 60 €/MWh), que o MAE apresenta valores mais diminutos e que os maiores valores do MAE correspondem aos menores valores do preço real. É também importante mencionar que no intervalo de preços reais que vai desde os 0 €/MWh até aos 34 €/MWh, os erros positivos têm maior significado e, a partir dos 34 €/MWh, passam a ser os erros negativos os mais significativos, sendo que no intervalo de preço reais que vai desde os 82 e os 86 €/MWh, este modelo nunca previu excesso.




Figura 4.24: Gráfico dos erros médios do modelo 14

Partindo da visualização do gráfico da Figura 4.25, verifica-se que a semana de teste a que correspondem erros mais elevados é a semana 12 (Março) de 2013, destacando-se claramente das restantes. As semanas em que ocorrem menos erros são: 25 (Junho), 30 (Julho) e 35 (Agosto) de 2012 e 32 (Agosto) de 2013, ou seja durante o período de Verão. É possível concluir também que houve uma redução do erro em quase todas as semanas de teste, relativamente ao modelo 10 (variáveis cronológicas, preços e consumos).




Figura 4.25: Gráfico dos erros médios para as semanas de teste do modelo 14

Em relação ao diagrama de *reliability* deste modelo (gráfico da Figura 4.26), pode-se concluir que a FDP apresenta uma calibração melhor que a dos 3 modelos avaliados anteriormente, tendo 84,92% de *reliability*. Concluindo-se ainda que, entre o quantil 0 e o quantil 5, continua a existir uma grande discrepância entre as ocorrências dos valores previstos e as ocorrências dos valores reais, sendo que estes últimos acontecem cerca de 1,4% mais vezes que as ocorrências previstas. No entanto, é importante ainda ressaltar que, além deste intervalo, também o intervalo entre o quantil 15 e 20 apresenta uma discrepância de 1,4% entre as ocorrências previstas e as reais, sendo que neste caso as ocorrências reais acontecem menos 1,4% das vezes. Verifica-se também que, cerca de 2,7% das ocorrências reais ocorreram abaixo do valor mínimo da FDP e 3,1% acima do valor máximo, o que perfazem um total de aproximadamente 5,8% de ocorrências reais que não estão contidas na FDP.




Figura 4.26: Diagrama de reliability da FDP do modelo 14

Em termos de dispersão, através da visualização do gráfico da Figura 4.27, depreende-se que este modelo apresenta uma dispersão bastante melhor do que a dos 3 modelos anteriores, apresentando uma distribuição mais concentrada e menos uniforme, o que é corroborado pelo seu indicador numérico de dispersão, tendo este o valor de 8,23 €/MWh. Verifica-se também uma intensificação da diminuição das incertezas para valores maiores de preço, relativamente aos modelos analisados anteriormente. Os valores previstos para o preço acompanham de forma melhor o crescimento dos valores reais desta variável, relativamente ao modelo 10.




Figura 4.27: Diagrama de dispersão do modelo 14

Verifica-se então que com a introdução das variáveis meteorológicas, principalmente a velocidade do vento, que está bastante relacionada com o valor das produções dos parques eólicos (cuja geração tem um grande impacto nos preços), este modelo apresenta uma grande melhoria em termos de performance.

4.3.5 Modelo 23 - Variáveis Cronológicas, Preços, Consumos, Previsões Meteorológicas e Produções

O presente modelo de previsão é o modelo mais complexo dos 5, utilizando uma maior variedade de variáveis explicadoras, sendo estas as seguintes: DDS, hora, preço D, preço D-6, consumo D-1, consumo D+1, temperatura D+1, eólica D-1, hídrica D-1, carvão D-1, nuclear D-1 e gás natural D-1.

Como se pode observar no gráfico da Figura 4.28, a maioria dos erros (cerca de 84%) estão compreendidos entre os -10 €/MWh e os 10 €/MWh. Sendo também necessário referir que os intervalos de -5 €/MWh a 0 €/MWh e de 0 €/MWh a 5 €/MWh apresentam as frequências que mais se destacam, com os valores de 31% e 30%, respetivamente.




Figura 4.28: Gráfico da frequência do erro do modelo 23

Visualizando o gráfico da Figura 4.29, conclui-se que, à semelhança dos 4 modelo precedentes, o intervalo que compreende a maior percentagem de preços reais é também o período para o qual os valores do MAE são mais baixos, verificando-se também que os maiores valores do MAE correspondem aos menores valores do preço real. Relativamente às médias dos erros positivos e negativos, de forma análoga ao que ocorreu no modelo 14 (variáveis cronológicas, preços, consumos e variáveis meteorológicas), no intervalo que compreende os preços reais de 0 €/MWh a 34 €/MWh, os erros médios positivos são mais significativos e nos restantes intervalos os erros médios negativos passam a ser os que apresentam maior dimensão. É possível também depreender que para o intervalo de 82 €/MWh a 86 €/MWh o modelo nunca prevê por excesso.




Figura 4.29: Gráfico dos erro médios do modelo 23

Analisando o gráfico da Figura 4.30, é perceptível que os erros com valores mais elevados correspondem às semanas de 15 (Abril) de 2012 e 2 (Janeiro) e 12 (Março) de 2013 (com um grande destaque para a semana 12 de 2013, à semelhança dos outros 4 modelos). Sendo que, para estas 3 semanas, só na semana 12 de 2013 é que o valor médio dos erros positivos é mais significativo. Por outro lado, de forma análoga ao que ocorreu no modelo 14, as semanas que apresentam menores erros são: 25 (Junho), 30 (Julho) e 35 (Agosto) de 2012 e 32 (Agosto) de 2013, ou seja no período de Verão. Relativamente ao modelo 14, em cerca de 9 semanas de teste, houve uma diminuição dos valores de erro, sendo que na grande maioria das restantes semanas os valores do MAE mantiveram-se iguais.




Figura 4.30: Gráfico dos erros médios para as semanas de teste do modelo 23

Em relação ao diagrama de *reliability* deste modelo (gráfico da Figura 4.31), pode-se concluir que este apresenta a FDP mais calibrada dos 4 modelos avaliados anteriormente, tendo 85,64% de *reliability*. Concluindo-se ainda que entre o quantil 0 e o quantil 5 deixou de existir a grande discrepância entre as ocorrências dos valores previstos e as ocorrências dos valores reais, que se verificava nos outros 4 modelos. No entanto, no intervalo entre o quantil 90 e o quantil 100, passa a ser o intervalo em que ocorre a maior discrepância entre as ocorrências dos valores reais e dos valores previstos, sendo que os valores reais acontecem cerca de 2% mais vezes que os valores previsto. E, de forma semelhante ao que ocorria no modelo 14, o intervalo entre o quantil 15 e 20 apresenta uma discrepância de cerca de 1,3% entre as ocorrências previstas e as reais, sendo que neste caso as ocorrências reais acontecem menos 1,3% das vezes. Verifica-se também que cerca de 5,3% de ocorrências reais não estão contidas na FDP (frequência de valor inferior à obtida no modelo 14), sendo que 2,4% das ocorrências reais ocorreram abaixo do limite mínimo da FDP e 2,9% acima do limite máximo.




Figura 4.31: Diagrama de reliability da FDP do modelo 23

Analisando o gráfico da Figura 4.32, verifica-se que este modelo apresenta a melhor dispersão de todos modelos analisados, apresentando uma distribuição com um bom nível de concentração e pouco uniforme, sendo que o seu indicador numérico de dispersão tem o valor de 7,83 €/MWh. À semelhança dos modelos anteriores, com exceção do modelo 3 (variáveis cronológicas), as incertezas são maiores para valores do preço real menores.

Em relação aos valores previstos, estes também acompanham ligeiramente melhor os valores reais, relativamente ao modelo 14.

Em suma, este modelo apresenta um salto de qualidade em relação ao modelo 14, isto deve-se à introdução das variáveis de produção, uma vez que as variações das produções de origem renovável e não renovável têm uma grande influência na variação do preço e das incertezas.




Figura 4.32: Diagrama de dispersão do modelo 23

Após esta análise pormenorizada dos melhores modelos de cada grupo e através da visualização do gráfico da Figura 4.33, é possível concluir-se que a informação explicadora acrescentada em cada grupo de modelos foi útil, verificando-se uma diminuição dos valores dos erros médios e das incertezas e um aumento do *reliability* e que a semana para a qual os modelos apresentaram maior dificuldade de previsão foi a semana 12 de 2013. Este fato pode ser explicado por uma grande volatilidade do preço real nessa semana, provocada por uma grande variabilidade nas produções eólicas e hídricas, o que fez com que o NW-KDE não conseguisse encontrar muitas situações no passado (valores das variáveis explicadoras históricas) semelhantes às que ocorreram nessa semana.




Figura 4.33: Evolução dos indicadores de erro com o melhor modelo de previsão de cada grupo

4.4 Influência das Variáveis Explicadoras na Previsão do Melhor Modelo

Na presente secção será analisada a forma como variam os erros da previsão determinista (quantil 50) e as incertezas previstas pelo modelo 23, com cada uma das variáveis explicadoras utilizadas na construção deste modelo.

4.4.1 Dia da Semana

Visualizando o gráfico da Figura 4.34, pode-se concluir que o preço D+1 vai diminuindo ao longo da semana, atingindo os seus valores mínimos ao domingo e que o contrário acontece com a incerteza, sendo ligeiramente superior no fim-de-semana. Analisando o gráfico da Figura 4.35, depreende-se que o erro vai variando ao longo da semana, mas existe uma ligeira tendência para ir aumentando ao longo da mesma. Este atinge os seus valores máximos ao domingo, sendo o segundo dia da semana que apresenta um maior erro a sexta-feira e a quinta-feira o dia da semana em que os erros são mais baixos.




Figura 4.34: Diagrama de dispersão da previsão com o Dia da semana

Ao domingo e à sexta-feira os valores médios dos erros positivos são de maior dimensão e nos restantes dias da semana os valores médios dos erros negativos são os mais significativos. Em suma pode-se depreender que ao fim-de-semana, período em que o consumo é menor, os erros são superiores e existe uma maior incerteza.




Figura 4.35: Evolução dos erros médios da previsão com o Dia da Semana

4.4.2 Hora

Através da observação do gráfico Figura 4.36, verifica-se que o preço previsto vai variando ao longo do dia, atingindo os seus valores mínimos por volta das 4h (altura em que a incerteza é ligeiramente maior, verificando-se uma maior dispersão) e os seus valores máximos por volta das 21h, existindo uma ligeira tendência para este ir aumentando ao longo do dia.




Figura 4.36: Diagrama de dispersão da previsão com a Hora

Em relação ao gráfico Figura 4.37, é possível depreender-se que, à semelhança da variável DDS, os erros são maiores para o momento em que os valores do preço previsto são mais baixos, ou seja às 4h. E existe uma ténue tendência para o erro ir diminuindo ao longo do dia, atingindo o seu valor mínimo as 23h. Das 0h às 17h valores dos erros por excesso são mais significativos e das 17h às 23h são mais significativos os valores dos erros por défice. Pode-se então concluir que em períodos do dia em que o consumo e os preços são mais elevados (horas de ponta) os erros e a dispersão da incerteza são menores, aumentando para as horas de vazio.




Figura 4.37: Evolução dos erros médios da previsão com a Hora

4.4.3 Preço D

Analisando o gráfico da Figura 4.38, é possível concluir que existe uma relação quase linear entre o valor previsto e o preço D, com os valores do preço previsto a subirem à medida que os valores do preço do dia anterior aumentam, no entanto é necessário mencionar que em valores extremos de preço, existe uma ligeira suavização, já que os valores do preço previsto não acompanham os valores do preço do dia anterior. A incerteza é maior para valores extremos da variável explicadora, principalmente para valores diminutos.




Figura 4.38: Diagrama de dispersão da previsão com o Preço D

Por sua vez, observando-se o gráfico Figura 4.39 depreende-se que os erros atingem o seu máximo para o período em que os valores da variável preço D se encontram no intervalo entre 26 €/MWh e 30 €/MWh e que os valores do erro diminuem para os intervalos de valores da variável explicadora, que ocorrem com maior frequência, atingindo o seu mínimo para intervalo que compreende os valores de 52 €/MWh a 56 €/MWh. É ainda visível que valores de preço do dia anterior pequenos (com exceção de valores menores que 17 €/MWh, que são pouco frequentes e que por isso não têm grande significado) os erros por excesso são mais significativos, uma vez que geralmente ocorre uma diminuição do preço. Já para valores elevados do preço do dia anterior, ocorre o contrário, passando os erros por défice a ser os de maior dimensão.




Figura 4.39: Evolução dos erros médios da previsão com o Preço D

4.4.4 Preço D-6

Partindo da visualização do gráfico da Figura 4.40, conclui-se que esta variável apresenta uma relação com preço previsto inferior à relação da variável explicadora preço D, ainda assim verifica-se que, com o aumento dos valores desta variável explicadora há um aumento dos valores do preço previsto. Concluindo-se também que a incerteza é maior para valores menores desta variável.




Figura 4.40: Diagrama de dispersão da previsão com o Preço D-6

Através da análise gráfica da evolução dos erros médios, gráfico da Figura 4.41 depreende-se que, à semelhança do que aconteceu para a variável preço D, os valores do erro diminuem nos intervalos de valores da variável explicadora que ocorrem com maior frequência, atingindo o seu mínimo no intervalo de 59 €/MWh a 63 €/MWh. Por sua vez os erros máximos ocorrem para os valores mínimos do preço da semana anterior, intervalo de 0 €/MWh a 5 €/MWh, o que pode implica que em algumas situações, esta variável pode estar a influenciar negativamente a performance do modelo.

É necessário ainda referir que para valores dos preços D-6 maiores que 50 €/MWh e no intervalo que compreende os valores de 9 €/MWh a 14 €/MWh, os valores médios dos erros negativos são mais significativos e nos restantes intervalos de valores os valores médios dos erros positivos apresentam maior dimensão.




Figura 4.41: Evolução dos erros médios da previsão com o Preço D-6

4.4.5 Consumo D+1

Analisando o gráfico das Figuras 4.42 e 4.43, verifica-se que a presente variável apresenta, como seria expectável, uma relação praticamente linear com o preço previsto, sendo que à medida que os valores desta aumentam, também aumentam os valores do preço previsto. Em relação aos erros médios, estes são maiores para valores de consumo menores, atingindo o seu pico máximo para o intervalo de 23654 MWh a 25073 MWh e atinge o seu valor mínimo para o intervalo dos valores de consumo que ocorrem com mais frequência (de 36425 MWh a 37844 MWh), intervalo esse onde se verifica também uma ligeira diminuição das incertezas.

Para valores menores que 30749 MWh e para o intervalo que vai desde 30749 MWh e 32168 MWh, os erros por excesso são os de maior dimensão e para os outros intervalos de valores os erros por défice são os mais significativos. Pode-se então concluir que para horas de vazio e de ponta existe um aumento das incertezas e que para as primeiras, onde ocorre uma diminuição do preço, os erros por excesso do modelo são mais significativos e nas segundas, com o aumento do preço, ganham dimensão os erros por défice.




Figura 4.42: Diagrama de dispersão da previsão com o Consumo D+1




Figura 4.43: Evolução dos erros médios da previsão com o Consumo D+1

4.4.6 Consumo D-1

Através da observação do gráfico da Figura 4.44, depreende-se que esta variável apresenta uma relação com os valores previstos inferior à variável consumo D+1, não acompanhando tão bem o aumento do preço previsto.




Figura 4.44: Diagrama de dispersão da previsão com o Consumo D-1




Figura 4.45: Evolução dos erros médios da previsão com o Consumo D-1

Observando também o gráfico da Figura 4.45 depreende-se que existe um aumento dos valores médios do erro (e também das incertezas) quando ocorrem consumos d-1 com valores extremos (valores elevados ou valores diminutos) e uma diminuição para valores mais intermédios. O erro médio máximo verifica-se para o intervalo de consumo d-1 de 24901 MWh a 26327 MWh e o erro mínimo para o intervalo de consumo d-1 de 32029 MWh a 34880 MWh. Em relação à maior dimensão dos valores dos erros médios positivos ou dos valores dos erros médios negativos, esta vai alternando à medida que os valores da variável explicadora vão aumentando, sendo que se

pode apenas depreender, que para valores de consumo d-1 maiores que 42008 MWh, a dimensão dos valores dos erros médios negativos é maior.

4.4.7 Eólica D+1

Visualizando os gráficos das Figuras 4.46 e 4.47, verifica-se que os valores do preço previsto vão diminuindo e que os valores do erro e as incertezas vão aumentando, à medida que os valores das produções dos parques eólicos aumentam. Uma possível explicação para este aumento de incertezas prende-se com a grande volatilidade deste tipo de produções.




Figura 4.46: Diagrama de dispersão da previsão com a Eólica D+1

Observando o gráfico da Figura 4.47, é possível ainda depreender-se que para valores de produção eólica menores que 6811 MWh e no intervalo que compreende os valores de 12810 MWh a 14523 MWh os valores médios dos erros negativos são ligeiramente mais significativos, verificando-se que para os restantes intervalos os valores médios dos erros positivos são os mais preponderantes. Uma causa provável deste acontecimento é que quando existe um aumento das produções dos parques eólicos, o preço tem tendencia a diminuir mas o modelo não é capaz de se adaptar instantaneamente a esta mudança, errando por excesso.




Figura 4.47: Evolução dos erros médios da previsão com a Eólica D+1

4.4.8 Temperatura D+1

Partindo da visualização do gráfico da Figura 4.48, conclui-se que os valores previstos vão aumentando ligeiramente com o aumento da temperatura, com excepção do intervalo que compreende as temperaturas que vão de 1 °C a 3 °C, no entanto, observando a Figura 4.49 depreende-se que é uma situação que ocorreu com muita pouca frequência pelo que não tem grande significado. As incertezas também vão diminuindo para valores maiores de temperatura.




Figura 4.48: Diagrama de dispersão da previsão com a Temperatura D+1




Figura 4.49: Evolução dos erros médios da previsão com a Temperatura D+1

Analisando o gráfico da Figura 4.49 observa-se que o erro vai diminuindo com a temperatura. Esta diminuição dos valores do erro e das incertezas com o aumento da temperatura pode ser explicado observando as Figuras 4.50 e 4.51, uma vez os meses que correspondem ao Verão (em que as temperaturas apresentam valores mais altos), são os meses em que há menos produção renovável (produção bastante volátil), o que provoca uma diminuição dos valores de erro e incertezas, neste período.




Figura 4.50: Diagrama de dispersão da previsão com o Mês




Figura 4.51: Evolução dos erros médios da previsão com o Mês

4.4.9 Hídrica D-1

Ao contrário do que seria expectável, analisando o gráfico da Figura 4.52, verifica-se que à medida que as produções hídricas aumentam, os valores do preço previsto também aumentam. Por sua vez, observando-se o gráfico da Figura 4.53 depreende-se que os valores do erro diminuem para os intervalos de valores das produções hídricas que ocorrem com mais frequência e aumentam para os intervalos de valores que ocorrem com menos frequência, com excepção para os intervalos de produções maiores que 9710 MWh, que ocorrem com pouca frequência, e para os quais se verifica uma diminuição do erro. Relativamente aos valores médios dos erros negativos e dos positivos, estes têm valores bastante próximos para os valores de produção hídrica menores que 6254 MWh, sendo que a partir deste valores os valores médios dos erros positivos são mais significativos.

Observando a Figura 4.53 depreende-se que para valores altos de produção hídrica existe uma grande diferença entre os valores médios dos erros por excesso (MPoE) e os valores médios do erro (NMAE), o que indica que é uma zona em que a incerteza é bastante elevada (o que seria expectável para este tipo de produção de características bastante voláteis). Visto que, na Figura 4.52 este efeito não é visível, pode-se concluir que a incerteza para elevados valores de produção hídrica não está a ser bem modelizada.




Figura 4.52: Diagrama de dispersão da previsão com a Hídrica D-1




Figura 4.53: Evolução dos erros médios da previsão com a Hídrica D-1

4.4.10 Carvão D-1

Observando os gráficos das Figuras 4.54 e 4.55, depreende-se que há um aumento dos valores previstos para o preço e uma diminuição dos valores dos erros médios e das incertezas, à medida que as produções das centrais térmicas a carvão aumentam, com exceção das produções maiores que 10662 MWh, valores esses que ocorrem com uma frequência bastante baixa e que por isso não têm grande significado. Sendo ainda necessário referir que no intervalo de 795 MWh a 1314 MWh ocorre uma diminuição do erro. Para valores mais diminutos de produção, os erros médios

positivos são bastante significativos (até a 4430 MWh) e para praticamente todos os outros, valores de produção os erros médios negativos são ligeiramente mais significativos.




Figura 4.54: Diagrama de dispersão da previsão com o Carvão D-1




Figura 4.55: Evolução dos erros médios da previsão com o Carvão D-1

Conclui-se então que para valores de produção das centrais térmicas a carvão baixos, o mercado fica com um maior nível de stress (aumentando os valores de erro e a incerteza), provocado pelo um aumento das produções renováveis. Este aumento de produções renováveis provoca ainda uma diminuição nos preços o que faz com que os erros por excesso sejam mais significativos neste período.

4.4.11 Gás Natural D-1

Por observação dos gráficos das Figuras 4.56 e 4.57, pode-se concluir, à semelhança do que ocorria para as centrais térmicas a carvão, que há uma tendência para os valores previstos do preço aumentarem e os valores dos erros médios diminuírem, à medida que as produções das centrais térmicas de ciclo combinado aumentam, com exceção das produções maiores que 11463 MWh (produções que ocorrem com baixa frequência e que por isso não têm grande significado). Salientando-se também que para valores menores de produção, os erros médios positivos são mais significativos (até a 4787 MWh) e para maiores valores de produção os erros médios negativos apresentam uma maior dimensão.




Figura 4.56: Diagrama de dispersão da previsão com o Gás Natural D-1

No entanto, é necessário referir-se que o efeito da diminuição de produção deste tipo de centrais térmicas (e consequente aumento de produção de renováveis), tem um impacto menor no erro do preço previsto em relação às homônimas a carvão, uma vez que apresentam valores de produção bem mais diminutos.




Figura 4.57: Evolução dos erros médios da previsão com o Gás Natural D-1

4.5 Evolução do Preço real e da FDP Prevista do Melhor Modelo

Na presente secção serão expostos 4 gráficos, da Figura 4.58 à Figura 4.61, com o intuito de se poder analisar a capacidade de previsão do melhor modelo em cada estação do ano, tendo-se escolhido duas semanas de cada ano de teste: semanas 30 e 50 de 2012 e 22 e 42 de 2013.

No gráfico da Figura 4.58, pode-se observar a evolução do preço real (linha preta) e da FDP ao longo da semana 30 de 2012 (Verão), verificando-se que na maioria das horas a FDP conseguiu modelizar bastante bem as incertezas, encontrando-se o real sempre bastante próximo do valor médio da FDP (quantil 50) e dentro do intervalo que vai desde o quantil 90 ao quantil 10.




Figura 4.58: Evolução do preço do mercado diário real e previsto para a semana 30 de 2012 (Verão)

Relativamente à semana 50 de 2012 (Inverno), semana esta que apresenta variações de preço mais acentuadas relativamente à semana analisada precedentemente, conclui-se observando o gráfico da Figura 4.59, que a FDP apresenta uma boa capacidade preditiva neste período, com exceção das 20h do dia 10 de Dezembro, em que a FDP não foi capaz de prever o preço. Nessa hora o real encontra-se ligeiramente fora da distribuição, apresentando o valor de 79,05 €/MWh e sendo o valor máximo da distribuição, para essa hora, 78,04 €/MWh.




Figura 4.59: Evolução do preço do mercado diário real e previsto para a semana 50 de 2012 (Inverno)

No que concerne à semana referente à Primavera, semana 22 de 2013, visualizando o gráfico da Figura 4.60, verifica-se que o melhor modelo de previsão também consegue modelizar bem as incertezas para este período do ano, com exceção feita às 10h do dia 1 de Junho, hora essa em que o preço real tem o valor de 8 €/MWh e o valor mínimo previsto para o preço dessa hora, pela FDP, é 9,12 €/MWh.




Figura 4.60: Evolução do preço do mercado diário real e previsto para a semana 27 de 2013 (Primavera)

Analisando o gráfico da Figura 4.61, depreende-se que, embora a FDP consiga modelizar bem as incertezas do preço para a esmagadora maioria das horas, esta é a semana que apresenta mais falhas de previsão, não conseguindo prever-se o valor real do preço em 5 horas distintas. A FDP não consegue conter o preço real nas horas 8 e 9 do dia 13 de Outubro, onde os preços reais apresentam os valores de 72,43 €/MWh e 75 €/MWh, respetivamente, e, por sua vez os valores máximos previstos pela FDP são 72,09 €/MWh e 74,65 €/MWh, respetivamente. Falha também, ligeiramente, nas horas 1, 2 e 4 do dia 16 de Outubro, onde os valores máximos previstos para essas horas eram 58,01 €/MWh para as duas primeiras e 54 €/MWh para a última, e os valores reais foram 59,2 €/MWh, 58,6 €/MWh e 56 €/MWh, respetivamente.

Conclui-se então que o melhor modelo consegue modelizar bastante bem as incertezas de semanas de diferentes estações do ano, apresentando algumas falhas pontuais, falhas essas que são em maior número na semana 42 de 2013 (Outono). É de salientar também que as previsões probabilísticas tem um desempenho superior às previsões deterministas, uma vez que existem vários períodos em que o quantil 50 (previsão determinista) diverge significativamente do valor de preço real e a FDP consegue prever estes valores do real.




Figura 4.61: Evolução do preço do mercado diário real e previsto para a semana 42 de 2013 (Outono)

Capítulo 5

Conclusões e Trabalhos Futuros

No presente capítulo verifica-se se os objetivos propostos foram cumpridos e apresenta-se um resumo das conclusões retiradas no capítulo 4. Posteriormente, são ainda apresentados possíveis trabalhos futuros que poderão dar continuidade ao estudo sobre as previsões do preço de mercado diário do MIBEL.

5.1 Conclusão

A presente dissertação teve como principal objetivo desenvolver modelos de previsão probabilística para o preço de mercado diário do MIBEL, utilizando ferramentas de previsão do tipo NW-KDE.

Posto isto, inicialmente foi necessário estudar-se a influência teórica e posteriormente prática da variação dos parâmetros da ferramenta NW-KDE na qualidade dos modelos de previsão, sendo que ao longo deste processo foram feitas algumas melhorias na ferramenta, e com este conhecimento adquirido foi possível desenvolver-se uma metodologia para a identificação das parametrizações ótimas de um modelo de previsão.

Foram utilizados os 23 modelos desenvolvidos em [2] modelizando as suas incertezas e otimizadas as parametrizações para cada um dos modelos, utilizando a metodologia desenvolvida anteriormente. Neste processo foram tomadas decisões tendo em conta o tempo disponível para a realização da presente dissertação, existindo a forte possibilidade das parametrizações não estarem totalmente otimizadas para alguns modelos (do modelo 10 ao modelo 23).

Procedeu-se de seguida à análise dos resultados obtidos para cada modelo de previsão. Verificou-se que o melhor modelo de previsão era o 23 que continha 12 variáveis explicadoras: hora, DDS, preço D, preço D-6. Consumo D+1, consumo D-1, temperatura D+1, eólica D+1, hídrica D-1, carvão D-1, nuclear D-1 e gás natural D-1. E conclui-se também que em relação às previsões deterministas efetuadas com o NW-KDE, estas só se inferiorizam às realizadas através de redes neurais, nos modelos em que existe a forte possibilidade das parametrizações não estarem totalmente otimizadas.

Após a divisão dos modelos em 5 grupos diferentes mediante as variáveis explicadoras utilizadas em cada um deles e, avaliando o melhor modelo de cada grupo, conclui-se que a informação explicadora que foi sendo acrescentada em cada grupo de modelos continha informação útil, verificando-se uma diminuição dos erros médios e das incertezas e um aumento do *reliability* dos modelos. A semana para a qual os modelos apresentavam mais dificuldade na previsão do preço era a semana 12 de 2013, isto deve-se ao conjunto diminuto de situações do passado que apresentam características semelhantes às que se verificaram nessa semana, na base de dados utilizada.

Por fim, foi analisada a capacidade de previsão do melhor modelo nas 4 estações do ano, verificando-se que este é capaz de modelizar bastante bem as incertezas do preço para períodos do ano com características distintas. Inferindo-se também que as previsões probabilísticas têm um desempenho superior às previsões deterministas, uma vez que existem vários períodos em que o quantil 50 (previsão determinista) diverge significativamente do valor de preço real e a FDP consegue prever estes valores do real.

Em suma, pode-se concluir que a ferramenta NW-KDE consegue realizar boas previsões probabilísticas do preço de eletricidade a curto prazo, apresentando no entanto algumas fragilidades, nomeadamente, no conjunto extensivo de simulações que o utilizador necessita realizar para encontrar as parametrizações ótimas para cada modelo de previsão, o que aliado à morosidade de processamento das mesmas, torna o processo de parametrização bastante longo. Conclui-se ainda que as previsões probabilísticas podem ser bastante úteis para os agentes de mercado, já que lhes fornece informações novas sobre o comportamento do preço. Podendo então ser utilizadas numa análise económica do modelo de negócios dos *traders* de energia, uma vez que, quando estes estão a definir a sua estratégia de licitação, analisando os riscos (diminuições de lucros ou aumento de prejuízos) que podem ou não suportar e que as diferentes estratégias comportam, estes podem tomar decisões diferentes para situações em que o valor médio do preço é o mesmo (previsão deterministas), mas as previsões apresentam mais ou menos incerteza, diminuindo assim os riscos que vão correr.

Este tipo de previsões são ainda úteis para consumidores que tenham as suas tarifas indexadas ao preço de eletricidades determinarem quando devem aumentar ou diminuir os seus consumos e também na gestão de sistemas de armazenamento de energia, auxiliando na determinação dos períodos em que a energia deve ser armazenada e dos períodos em que estes sistemas devem fornecer energia.

5.2 Trabalhos Futuros

Concluída a presente dissertação, considera-se pertinente o desenvolvimento dos seguintes trabalhos futuros:

- Descobrir as parametrizações ótimas, com o parâmetro *H Dinâmico* ativo, para os modelos compreendidos entre o modelo 10 e o 23.

- Melhorar a ferramenta NW-KDE, tornando menos moroso o processo de parametrização.
- Desenvolvimento de novos modelos de previsão probabilística recorrendo a variáveis não utilizadas na presente dissertação.
- Realizar a previsão probabilística do preço de eletricidade do MIBEL, para diferentes *Time Frameworks*.

Anexo A

Anexos

A.1 Anexo A

Na Figura [A.1](#) pode se visualizar a parametrização ótima de cada modelo de previsão.

Modelo	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23
pontos (>1):	50	240	250	48	20	50	50	50	50														
h dinâmico (0-off; 1-on):	0	1	1	1	1	1	1	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
Nível de ativação (<1):	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,21	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,2	0,201
Partições Y (1 soft; 100 strong):	14,1	16,6	16,6	16,6	16,7	16,6	16,6	16,6	16,6	16,6	16,6	17	17	17	17	13,5	13,2	13,5	13,5	13,5	13,5	13,5	13,6
Expand (0% to 100%):	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
AlfaBeta (1 to 6):	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
h de referência (>0) h :	1,3		1,3	1,3	1,9	1,3	1,3	1,5	1,2	3	3	5,4	3	5,4	5,4	4,5	4,5	4,5	4,5	4,5	4,5	4,5	4,5
Tipo (0-linear; 1-cíclica) h :	1		1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
hdinâmico V (0-não; 1-sim):	0		0	0	0	0	0	0	0														
h de referência (>0) dds :		1	0,9	2	2,2	2,2	2,2	2,2	1,9	1,9	1,9	1,6	1,9	1,6	2,7	1,6	1,6	1,9	3,1	2,8	2,1	1,8	2,1
Tipo (0-linear; 1-cíclica) dds:		1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1	1
hdinâmico V (0-não; 1-sim):		1	1	1	1	1	1	1	1														
h de referência (>0) preço D :					33	14	39	30	31	31	3,7	3,7	3,6	3,7	3,6	3,6	5,9	5,9	5,9	5,6	5,6	5,9	6,3
Tipo (0-linear; 1-cíclica) preço D:					0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1
hdinâmico V (0-não; 1-sim):					1	1	1	1	1	1													
h de referência (>0) preço D-6 :						32	61	62	61	7,9	7,9	5,6	7,9	5,6	5,6	5,3	6	6	5,3	4,7	5,5	6,2	5,5
Tipo (0-linear; 1-cíclica) preço D-6:						0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
hdinâmico V (0-não; 1-sim):						1	1	1	1	1													
h de referência (>0) consumo D-6 :									54000														
Tipo (0-linear; 1-cíclica) consumo D-6:									0														
hdinâmico V (0-não; 1-sim):									1														
h de referência (>0) consumo D+1:										36000	2650	2650	2100	2650	2100	2100	2100	2200	2100	2100	2100	2100	2100
Tipo (0-linear; 1-cíclica) consumo D+1:										0	0	0	0	0	0	0	0	0	0	0	0	0	0
hdinâmico V (0-não; 1-sim):										1													
h de referência (>0) consumo D-1 :											2800	2800	7700	2800	7700	7700	8400	7500	10000	8200	7900	8100	8100
Tipo (0-linear; 1-cíclica) consumo D-1:											0	0	0	0	0	0	0	0	0	0	0	0	0
hdinâmico V (0-não; 1-sim):											1												
h de referência (>0) Temperatura D+1 :											8				4,8	5,7	7,6	7,6	7,6	7,1	7,1	7,1	7,1
Tipo (0-linear; 1-cíclica) Temperatura D+1:											0				0	0	0	0	0	0	0	0	0
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) Irradiância D+1 :														290									
Tipo (0-linear; 1-cíclica) Irradiância D+1:														0									
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) vento D+1 :												0,93				0,87	0,93						
Tipo (0-linear; 1-cíclica) vento D+1:												0				0	0						
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) eólica D+1 :																2100	1200	1580	1210	1300	1330	1230	1230
Tipo (0-linear; 1-cíclica) eólica D+1:																0	0	0	0	0	0	0	0
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) eólica D-1 :																	3800						
Tipo (0-linear; 1-cíclica) eólica D-1:																	0						
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) hídrica D+1 :																		5700				5700	
Tipo (0-linear; 1-cíclica) hídrica D+1:																		0				0	
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) Cogeração D+1 :																			3700				
Tipo (0-linear; 1-cíclica) Cogeração D+1:																			0				
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) Carvão D+1 :																				6100			5700
Tipo (0-linear; 1-cíclica) Carvão D+1:																				0			0
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) Nuclear D+1 :																					1100		1100
Tipo (0-linear; 1-cíclica) Nuclear D+1:																					0		0
hdinâmico V (0-não; 1-sim):																							
h de referência (>0) Gás D+1 :																						7100	7200
Tipo (0-linear; 1-cíclica) Gás D+1:																						0	0
hdinâmico V (0-não; 1-sim):																							
Ajuste	1,1	1,7	1,4	1,6	1,8	1,5	1,6	1,6	1,5	1,4	1,5	1,6	1,5	1,9	1,6	1,7	1,6	1,9	1,7	1,8	1,9	1,7	1,9

Figura A.1: Parametrizações ótimas de cada modelo

Referências

- [1] Corinna Maria Frei. Probabilistic forecasts of precipitation using quantiles. Master's thesis, University of Heidelberg - Faculty of Mathematics and Computer Science, 2012.
- [2] José P. M. Conde. Previsão de preços de eletricidade no mercado diário e intradiário mibel. Tese de mestrado, Faculdade de Engenharia da Universidade do Porto, 2015.
- [3] Alexandre M. Amaral. Aplicação de heurísticas para otimização de parâmetros de modelos de previsão eólica. Tese de mestrado, Faculdade de Engenharia da Universidade do Porto, 2015.
- [4] Rafał Weron. Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 2014.
- [5] Jacques Lawarree Massimo Gallanti Andrea Venturini Guang Li, Chen-Ching Liu. State-of-the-art of electricity price forecasting. *IEEE*, 2005.
- [6] Lalit Mohan Saini Sanjeev Kumar Aggarwal e Ashwani Kumar. Electricity price forecasting in deregulated markets: A review and evaluation. *Elsevier Ltd.*, 2009.
- [7] Stefan Trueck Adam Misiorek e Rafał Weron. Point and interval forecasting of spot electricity prices: Linear vs. non-linear time series models. *The Berkeley Electronic Press*, 2006.
- [8] Xing Yan e Nurul A. Chowdhury. Midterm electricity market clearing price forecasting using two-stage multiple support vector machine. *Journal of Energy*, 2015.
- [9] Antonio J Conejo Rosario Espínola Francisco J Nogales, Javier Contreras. Forecasting next-day electricity prices by time series models. *IEEE Transactions on Power Systems*, 2002.
- [10] L. Alfredo Fernandez-Jimenez Cláudio Monteiro e Ignacio J. Ramirez-Rosado. Explanatory information analysis for day-ahead price forecasting in the iberian electricity market. *Energies*, 2015.
- [11] Patrick Billingsley. *Probability and Measure*. John Wiley and Sons, 3rd ed. edição, 1995.
- [12] Nate Silver. *The Signal and the Noise*. The Penguin Press, 1st ed. edição, 2012.
- [13] Redes Energéticas Nacionais (REN). Estatística diária. Disponível em <http://www.centrodeinformacao.ren.pt/PT/InformacaoExploracao/Paginas/EstatisticaDiariaDiagrama.aspx>.
- [14] Red Eléctrica de España (REE). Actividades, balance diário. Disponível em <http://www.ree.es/es/actividades/balance-diario>.

- [15] Katarzyna Maciejowska. Fundamental and speculative shocks, what drives electricity prices? *IEEE - 11th International Conference on the European Energy Market (EEM)*, 2014.
- [16] J.N. Fidalgo. Apontamentos da unidade curricular de técnicas para previsão.
- [17] Paulo Cortez e José Neves. *Redes Neurais Artificiais*, 2000.
- [18] V. M. F. Mendes L. F. M. Ferreira J. P. S. Catalão, S. J. P. S. Mariano. Short-term electricity prices forecasting in a competitive market: A neural network approach. *Electric Power Systems Research*, 2007.
- [19] Antonio Muñoz San Roque Alicia Mateo González e Javier García-González. Modeling and forecasting electricity prices with input/output hidden markov models. *IEEE TRANSACTIONS ON POWER SYSTEMS*, 2005.
- [20] T. Downs D.C. Sansom e T.K.Saha. Evaluation of support vector machine based forecasting tool in electricity price forecasting for australian national electricity market participants. *Journal of Electrical & Electronics Engineering*, 2003.
- [21] Z. Xu J.H. Zhao, Z.Y. Dong e K.P. Wong. A statistical approach for interval forecasting of the electricity price. *IEEE Trans on Power Systems*, 2008.
- [22] Rafal Weron e Adam Misiorek. Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models. *International Journal of Forecasting*, 2008.
- [23] Li Zhang e Peter B. Luh. Neural network-based market clearing price prediction and confidence interval estimation with an improved extended kalman filter method. *IEEE Transactions on Power Systems*, 2005.
- [24] Anthony S. Tay e Kenneth F. Wallis. Density forecasting: A survey. *Journal of Forecasting*, 2000.
- [25] Xifan Wang Yao Zhang, Jianxue Wang. Review on probabilistic forecasting of wind power generation. *Renewable and Sustainable Energy Reviews*, 2014.
- [26] Z. Li H.Y. Yamina, S.M. Shahidehpourb. Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets. *International Journal of Electrical Power & Energy Systems*, 2004.
- [27] Henrik Aalborg Nielsen Pierre Pinson, Henrik Madsen. Predictive densities for day-ahead electricity prices using time-adaptive quantile regression. *Energies*, 2014.
- [28] Audun Botterud Jianhui Wang Ricardo J. Bessa, Vladimiro Miranda e Emil M. Constantinescu. Time adaptive conditional kernel density estimation for wind power forecasting. *IEEE*, 2012.
- [29] C. Soares J. Catalão G. Osório J. Rojas et al. B. Santos, C. Monteiro. Report on the mathematical formulation of the different forecasting models and data analysis. *Singular*, 2012.
- [30] Georges Kariniotakis Jérémie Juban, Lionel Fugon. Uncertainty estimation of wind power forecasts: Comparison of probabilistic modelling approaches. *European Wind Energy Conference & Exhibition EWE*, 2008.

- [31] Kim Stenshorne. A framework for constructing and evaluating probabilistic forecasts of electricity prices: A case study of the nord pool market. Master's thesis, Norwegian University of Science and Technology, 2011.
- [32] Adrian E. Raftery Tilmann Gneiting, Fadoua Balabdaoui. Probabilistic forecasts, calibration and sharpness. *Journal of the Royal Statistical Society*, 2007.
- [33] J. P. Tomé Saraiva. Apontamentos da unidade curricular de mercados e qualidade.