



ESTUDO DE PREÇOS DE ENERGIA NO MERCADO SPOT E FUTUROS NO MIBEL

JOÃO FILIPE OLIVEIRA NASCIMENTO

novembro de 2017

ESTUDO DE PREÇOS DE ENERGIA NO MERCADO SPOT E FUTUROS NO MIBEL

João Filipe Oliveira Nascimento



Departamento de Engenharia Eletrotécnica
Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

2017

Relatório elaborado para satisfação parcial dos requisitos da Unidade Curricular de DSEE -
Dissertação do Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

Candidato: João Filipe Oliveira Nascimento, Nº 1101507, 1101507@isep.ipp.pt

Orientação científica: Manuel Azevedo, mpa@isep.ipp.pt

Empresa: Energia Simples

Supervisão: João Brito, joao.brito@energiasimples.pt



Departamento de Engenharia Eletrotécnica
Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

2017

Esforço, Dedicção, Devoção e Glória.

Agradecimentos

Agradeço à minha família e amigos, pelo apoio demonstrado no decorrer desta longa jornada, que me ajudou a realizar os objetivos a que me propus.

Ao meu orientador, o Professor Manuel Azevedo, pela colaboração e orientação ao longo deste percurso e pela oportunidade de participação neste estágio em ambiente empresarial, na Simples Energia. Assim como também aos seus colaboradores pelo auxílio no desenvolvimento desta dissertação e partilha de conhecimentos.

Agradeço igualmente ao Engenheiro Tiago Pinto do Grupo de Investigação em Engenharia do Conhecimento e Apoio à Decisão (GECAD), e ao Engenheiro Ricardo Araújo, por toda a disponibilidade e contribuição à evolução do trabalho desenvolvido. Tenho também a agradecer ao Engenheiro Cláudio Monteiro e ao Engenheiro Tiago Santos da empresa SmartWatt, pela cedência de dados históricos que auxiliaram a execução do presente estudo.

Um especial agradecimento à minha namorada, por ter ajudado a que nunca me sentisse sozinho nesta viagem, e me ter sempre amparado, sem me deixar desanimar. O teu apoio foi fundamental para a conclusão desta fase académica.

Resumo

A liberalização do mercado elétrico de energia veio alterar o paradigma de um sector cujos modelos de organização eram tradicionalmente monopolistas, sendo maioritariamente propriedade do estado. Esta mudança veio introduzir o fator competitivo no setor, possibilitando a redução dos custos, a melhoria da qualidade e fiabilidade de serviço, e até promover a inovação, no que a novos produtos e serviços diz respeito. Porém, esta também trouxe instabilidade aos preços praticados e um maior risco aos agentes de mercado deste setor.

As características do mercado de energia elétrica pós-liberalização fazem com que a previsão da evolução do preço seja algo muito complexo, mas importante para a proteção dos envolvidos, sejam eles produtores, comercializadores ou consumidores. Com esse objetivo, esta dissertação procura fazer um estudo de preços de energia no mercado spot e futuros no Mercado Ibérico de Eletricidade (MIBEL). Inicialmente, efetuou-se uma recolha e tratamento de dados históricos de produções de energia elétrica por tecnologia e consumos, tal como dados meteorológicos para Portugal e Espanha. Posteriormente, foram avaliados todos os dados obtidos, através do cálculo do coeficiente de *Spearman*, permitindo entender a tendência de variação do preço da energia no MIBEL, face aos restantes valores. Foi também efetuado um estudo da sazonalidade demonstrada, tanto pelo preço da energia elétrica como pela carga verificada nos mercados português e espanhol, uma vez que esta última seria um dos dados que mais influenciou a variação do preço. Posto isto procedeu-se também à construção de modelos para a sua previsão com o intuito de auxiliar na redução do erro obtido para a previsão do preço.

Os modelos de previsão foram desenvolvidos através de um método baseado em inteligência computacional, as Redes Neurais Artificiais (RNA), implementadas através da ferramenta *nntool* do Matlab®. O modelo diário, sendo aquele para o qual se tem dados mais recentes, e um horizonte temporal menor, é aquele para o qual a tolerância ao erro é menor. Este prevê o preço da energia elétrica para as 24 horas seguintes, adaptando-se ao mercado spot, mais concretamente o mercado diário. O modelo semanal, com uma estrutura muito semelhante

ao diário, faz a previsão do preço para as 168 horas seguintes, tendo uma tolerância superior, face aos dados históricos não serem tão recentes, e o horizonte temporal dar mais azo à existência de erros. Quanto ao modelo mensal desenvolvido, por forma a não ter um erro muito elevado (uma vez que se fosse desenhado de forma semelhantes aos anteriores, teria de prever cerca de 720 valores horários), e face à maior dificuldade em obter valores precisos para uma janela temporal mais distanciada (dados meteorológicos para os dias todos do mês seguinte, por exemplo), foi desenhado de forma a prever um valor médio de preço para o mês seguinte, contendo como entradas, por exemplo, valores históricos de preço médio do ano anterior. Devido à necessidade deste tipo de informação, os dados totais obtidos, apesar de exaustivamente recolhidos, não seriam os ideais para previsões de longo prazo minimamente precisas.

A avaliação de desempenho efetuada foi feita através do *Mean Absolute Percentage Error* (MAPE) e do *Absolute Percentage Error* (APE), e concluiu-se que, os modelos de previsão desenvolvidos demonstram uma precisão bastante aceitável. Ainda assim, de forma a potenciar a diminuição do erro foi usado um procedimento com vista a diminuir a dispersão dos resultados e desta maneira ignorar valores que se afastem da média, com o recurso ao desvio padrão dos valores obtidos.

Palavras-Chave

Coefficiente de *Spearman*, MAPE, MIBEL, Modelo de Previsão, Redes Neurais Artificiais.

Abstract

The liberalization of the electric energy market has changed the paradigm of a sector whose organizational models were traditionally monopolistic, being mostly owned by the state. This change has introduced the competitive factor in the sector, making it possible to reduce costs, improve quality and reliability of service, and even promote innovation in new products and services. However, this also brought instability to the prices practiced and a greater risk to the market agents of this sector.

The characteristics of the post-liberalization electricity market make forecasting price developments very complex, but important for the protection of those involved, be they producers, traders or consumers. With this purpose, this dissertation seeks to make a study of energy prices in the spot and futures market in the Iberian Electricity Market (MIBEL). Initially, a collection and treatment of historical data of electricity production by technology and consumption, such as meteorological data for Portugal and Spain, was carried out. Afterwards, all the data obtained were evaluated through the Spearman coefficient, allowing to understand the trend of the price variation of the energy in the MIBEL, compared to the other values. It was also carried out a study of the demonstrated seasonality, as much by the price of the electric power as by the load verified in the Portuguese and Spanish markets, since the load would be one of the data that most influenced the price variation. Therefore, was also constructed models for forecasting, in order to help reduce the error obtained for the price forecast.

Prediction models were developed using the computational intelligence-based method, Artificial Neural Networks (ANN), developed in the *nntool* tool of Matlab®. The daily model, the one for which we have the most recent data, and a shorter time horizon, is the one for which the error tolerance is lower. This provides for the price of electricity for the next 24 hours, adapting to the spot market, more specifically the daily market. The weekly model, with a structure very similar to the daily one, forecasts the price for the next 168 hours, having a higher tolerance, given that the historical data is not so recent, and the time horizon gives rise to more errors. As for the monthly model developed, in order to not have a very

high error (since if it were drawn similarly to the previous ones, it would have to predict about 720 hourly values), and due to the greater difficulty in obtaining accurate values for a time window (meteorological data for all the days of the following month, for example), it was designed to predict an average price for the following month, containing, for example, historical values of average price of the previous year. Due to the need for this type of information, the total data obtained, although comprehensively collected, would not be the ideal for minimally accurate long-term forecasts.

The performance evaluation was performed through the Mean Absolute Percentage Error (MAPE) and Absolute Percentage Error (APE), and it was concluded that the forecast models developed show a very acceptable accuracy. Nevertheless, to maximize the error reduction, a procedure was used to reduce the dispersion of the results and thus to ignore values that deviate from the mean, using the standard deviation of the values obtained.

Keywords

Artificial Neuronal Network, Forecast Model, MAPE, MIBEL, Spearman Coefficient.

Índice

AGRADECIMENTOS	VII
RESUMO	IX
ABSTRACT	XI
ÍNDICE DE FIGURAS	XVII
ÍNDICE DE TABELAS	XIX
SIGLAS E ACRÓNIMOS	XXI
NOTAÇÃO	XXV
1. INTRODUÇÃO	1
1.1. CONTEXTUALIZAÇÃO	1
1.2. OBJETIVOS	3
1.3. CALENDARIZAÇÃO	3
1.4. ORGANIZAÇÃO DO RELATÓRIO	4
2. ESTADO DA ARTE	5
2.1. INTRODUÇÃO.....	5
2.2. EVOLUÇÃO DO SETOR ELÉTRICO.....	6
2.3. MERCADO EUROPEU DE ENERGIA	8
2.4. MERCADO IBÉRICO DE ELETRICIDADE.....	12
2.4.1. Funcionamento do Mercado.....	14
2.4.2. Modelo Organizacional.....	16
2.5. MERCADO SPOT (À VISTA)	17
2.5.1. Mercado Diário	17
2.5.2. Mercado Intradiário	20
2.6. MERCADO A PRAZO (FUTUROS)	21
2.7. MODELOS DE PREVISÃO.....	23
2.7.1. Medidas de Avaliação de Desempenho	25
2.8. CONCLUSÃO.....	26
3. ESTUDO DAS CARACTERÍSTICAS DO PREÇO DA ENERGIA	27

3.1.	INTRODUÇÃO	27
3.2.	RECOLHA E TRATAMENTO DE DADOS	28
3.3.	ANÁLISE DE CORRELAÇÃO	30
3.3.1.	Coeficiente de Spearman	30
3.3.2.	Sazonalidade	31
3.4.	INTERPRETAÇÃO DE RESULTADOS	37
3.5.	CONCLUSÕES	41
4.	PREVISÃO DE PREÇOS DE ENERGIA NO MIBEL.....	43
4.1.	INTRODUÇÃO	43
4.2.	PREVISÃO DE PREÇOS DE ELETRICIDADE.....	44
4.2.1.	Horizonte Temporal	45
4.2.2.	Variáveis Utilizadas	46
4.2.3.	Avaliação de desempenho	48
4.3.	REDES NEURONAIAS ARTIFICIAIS	49
4.4.	PREVISÃO MERCADO SPOT.....	54
4.4.1.	Diário	54
4.5.	PREVISÃO MERCADOS FUTUROS.....	65
4.5.1.	Semanal.....	65
4.5.2.	Mensal	76
4.6.	CONCLUSÕES.....	79
5.	CONCLUSÕES.....	81
5.1.	CONCLUSÕES FINAIS E PRINCIPAIS CONTRIBUTOS	81
5.2.	TRABALHOS FUTUROS	83
	REFERÊNCIAS	85
	ANEXOS.....	87
A.1	DADOS HORÁRIOS.....	87
A.2	DADOS DIÁRIOS E MENSAIS	89
A.3	DADOS METEOROLÓGICOS.....	93
A.4	DADOS DE RADIAÇÃO SOLAR	94

A.5	ANÁLISE DE CORRELAÇÕES.....	95
A.6	MODELO DIÁRIO – ENTRADAS E RESULTADOS	96
A.7	MODELO MENSAL – ENTRADAS E RESULTADOS	102

Índice de Figuras

Figura 1 Calendarização do Estágio Curricular.....	3
Figura 2 Estrutura verticalmente integrada	6
Figura 3 Desafios da regulação do sector energético na Europa.....	11
Figura 4 Modelo acionista do operador de mercado ibérico (OMI) [11].....	14
Figura 5 Curva “Procura vs Oferta” [16].....	18
Figura 6 Formação do preço da energia no mercado diário [16].....	19
Figura 7 Sessões diárias de negociação do mercado intradiário [16].....	20
Figura 8 Gráfico Preço médio horário e valor médio de preço	31
Figura 9 Gráfico Carga média horária e valor médio de carga	32
Figura 10 Gráfico Preço médio por dia da semana.....	33
Figura 11 Gráfico Carga média por dia da semana	33
Figura 12 Gráfico da evolução do Preço e da Carga para os 2 anos em análise	34
Figura 13 Gráfico da evolução da Carga com a temperatura média nos 2 anos em análise.....	35
Figura 14 Gráfico da evolução da Carga com a radiação solar média mensal para os 2 anos em análise.....	35
Figura 15 Gráfico da evolução do Preço com a temperatura média e radiação média solar nos 2 anos em análise.....	36
Figura 16 Exemplo da estrutura de uma rede neuronal na ferramenta nntool do Matlab®.....	52
Figura 17 Metodologia desenvolvida para a escolha do melhor modelo.....	53
Figura 18 Processo de previsão do Preço da Eletricidade no Modelo Diário	60
Figura 19 Correlação dos outputs finais obtidos com os valores reais de preço (Modelo Diário).....	61
Figura 20 Comparação entre os resultados obtidos e valores reais de preço (Modelo Diário)	61
Figura 21 Semana de 19 a 25 de janeiro de 2017, com a comparação entre outputs e valores reais de preço verificados.....	62

Figura 22 Gráfico que combina a comparação dos valores reais com os outputs gerados, e o MAPE médio horário para o total do conjunto de teste	63
Figura 23 Histograma do erro obtido (Modelo diário).....	64
Figura 24 Erro relativo percentual e desvio padrão do mesmo (Modelo diário)	64
Figura 25 Exemplo de um gráfico de regressão, da ferramenta nntool.....	68
Figura 26 Método usado para a previsão do preço da eletricidade com o Modelo Semanal	71
Figura 27 Relação entre as previsões e os valores reais de preço, para o modelo semanal	72
Figura 28 Comparação entre os resultados obtidos e valores reais de preço (modelo semanal)	72
Figura 29 Semana de 19 a 25 de janeiro de 2017, com a comparação dos valores reais de preço e outputs obtidos (modelo semanal)	73
Figura 30 19/01/2017, com valores obtidos e reais, e MAPE médio horário para o conjunto de teste.....	74
Figura 31 Histograma do erro percentual obtido no modelo semanal	74
Figura 32 Erro relativo percentual e desvio padrão para o conjunto de teste (modelo semanal)	75
Figura 33 Método usado para a previsão do preço da eletricidade com o Modelo Mensal	78
Figura 34 Valor real e valores previstos do preço médio para o mês de agosto/2017	79

Índice de Tabelas

Tabela 1 Evolução do enquadramento legislativo europeu até ao Segundo Pacote da Energia [9].....	9
Tabela 2 Indicadores de Erros: Erros Absolutos	25
Tabela 3 Correlações do Preço com dados de Carga e Produções por tecnologia	38
Tabela 4 Correlações do Preço com dados Meteorológicos.....	39
Tabela 5 Correlações do Preço com dados Cronológicos do mesmo	40
Tabela 6 Correlações da Carga com dados Meteorológicos	40
Tabela 7 Correlações da Carga com dados Cronológicos da mesma	41
Tabela 8 Tolerância para os erros de previsão do preço de energia	46
Tabela 9 Resultados do modelos de parametrização criados	55
Tabela 10 Resultados do teste relativo ao número de treinos a usar	55
Tabela 11 Comparação dos erros MAPE entre modelos previsão do preço	58
Tabela 12 Comparação dos erros MAPE entre modelos previsão da carga – Modelo Diário	59
Tabela 13 Modelos de parametrização desenvolvidos.....	66
Tabela 14 Constituição dos modelos de previsão semanal	67
Tabela 15 Resultados dos modelos de previsão semanais	68
Tabela 16 Constituição dos modelos de previsão de carga semanais.....	69
Tabela 17 Resultados dos modelos de previsão de carga semanais	70
Tabela 18 Constituição dos modelos de previsão mensais	77
Tabela 19 Resultados obtidos na avaliação dos modelos de previsão mensais.....	77
Tabela 20 Dados Horários – parte 1	87
Tabela 21 Dados Horários – parte 2	87
Tabela 22 Dados Horários – parte 3	88
Tabela 23 Dados Diários e Mensais – parte 1	89

Tabela 24 Dados Diários e Mensais – parte 2.....	90
Tabela 25 Dados Diários e Mensais – parte 3.....	91
Tabela 26 Dados Diários e Mensais – parte 4.....	92
Tabela 27 Dados Meteorológicos.....	93
Tabela 28 Dados de Radiação Solar.....	94
Tabela 29 Análise da correlação entre a Carga e o Desvio do valor médio de Radiação Solar	95
Tabela 30 Dados de entrada e resultados – Simulações 1 e 2 (Modelo Diário)	96
Tabela 31 Dados de entrada e resultados – Simulações 3 e 4 (Modelo Diário)	97
Tabela 32 Dados de entrada e resultados finais – Simulação 5 (Modelo Diário).....	98
Tabela 33 Gestão do Erro – parte 1 (Modelo Diário).....	99
Tabela 34 Gestão do Erro – parte 2 (Modelo Diário).....	100
Tabela 35 Gestão do Erro e resultados – parte 3 (Modelo Diário)	101
Tabela 36 Dados de entrada e resultados do Modelo Mensal.....	102

Siglas e Acrónimos

ACER	– Agência Europeia de Cooperação dos Reguladores de Energia
AE	– <i>Absolute Error</i>
APE	– <i>Absolute Percentage Error</i>
ARIMA	– <i>Autoregressive Integrated Moving Average</i>
AT	– Alta Tensão
CAE	– Contratos de Aquisição de Energia
CE	– Comissão Europeia
CEER	– <i>Council of European Energy Regulators</i>
CMEC	– Custos de Manutenção do Equilíbrio Contratual
CMVM	– Comissão do Mercado de Valores Mobiliários
CNE	– <i>Comisión Nacional de Energía</i>
CNMV	– <i>Comisión Nacional del Mercado de Valores</i>
CTC	– Custos de Transição para a Concorrência
D	– Dia
DDS	– Dia da Semana
EDP	– Energias de Portugal
EE	– Energia Elétrica
ERGEG	– <i>European Regulators Group for Electricity and Gas</i>
ERSE	– Entidade Reguladora dos Serviços Energéticos

FN	–	Feriado Nacional
GARCH	–	<i>Generalized Autoregressive Conditional Heteroskedasticity</i>
H	–	Hora
ISO	–	<i>Independent System Operator</i>
M	–	Mês
MAE	–	<i>Mean Absolute Error</i>
MAPE	–	<i>Mean Absolute Percentage Error</i>
MAT	–	Muito Alta Tensão
MCD	–	Modelo de Carga Diário
MCM	–	Modelo de Carga Mensal
MCS	–	Modelo de Carga Semanal
MIBEL	–	Mercado Ibérico de Eletricidade
MPD	–	Modelo de Preço Diário
MPM	–	Modelo de Preço Mensal
MPS	–	Modelo de Preço Semanal
NMAE	–	<i>Normalized Mean Absolute Error</i>
OMI	–	Operador de Mercado Ibérico
OMIE	–	Operador de Mercado Ibérico pólo Espanhol
OMIP	–	Operador de Mercado Ibérico pólo Português
OS	–	Operador do Sistema

- OTC – *Over-the-Counter*
- PRE – Produção em Regime Especial
- PRO – Produção em Regime Ordinário
- PURPA – *Public Utilities Regulatory Policies Act*
- REE – Red Eléctrica de España
- REN – Redes Energéticas Nacionais, SGPS, S.A.
- RNT – Rede Nacional de Transporte
- S – Semana

Notação

- T_{méd} – Temperatura média
- Preço (D-1) – Preço 24 horas antes da hora para a qual se pretende prever, em €/MW.h
- Preço (D-2) – Preço 48 horas antes da hora para a qual se pretende prever, em €/MW.h
- Preço (S-1) – Preço 168 horas antes da hora para a qual se pretende prever, em €/MW.h
- Preço (S-2) – Preço 336 horas antes da hora para a qual se pretende prever, em €/MW.h
- Preço (M-1) – Preço médio do mês anterior, em €/MW.h
- Preço (M-2) – Preço médio há 2 meses, em €/MW.h
- Preço (M-12) – Preço médio há 12 meses, em €/MW.h
- Preço (M-13) – Preço médio há 13 meses, em €/MW.h
- Carga (D-1) – Carga 24 horas antes da hora para a qual se pretende prever, em MW.h
- Carga (D-2) – Carga 48 horas antes da hora para a qual se pretende prever, em MW.h

Carga (S-1) – Carga 168 horas antes da hora para a qual se pretende prever, em MW.h

Carga (S-2) – Carga 336 horas antes da hora para a qual se pretende prever, em MW.h

Carga (M-1) – Carga média do mês anterior, em MW.h

Carga (M-2) – Carga média há 2 meses, em MW.h

Carga (M-12) – Carga média há 12 meses, em MW.h

Carga (M-13) – Carga média há 13 meses, em MW.h

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

Anteriormente à liberalização do sector elétrico, os modelos de organização deste mercado baseavam-se em companhias monopolistas, sendo maioritariamente propriedade do estado. Os preços praticados eram estáveis e previsíveis para longos períodos de tempo, fazendo com que os riscos a que os agentes de mercado estavam expostos fossem mínimos. Pós-liberalização, este sector sofreu uma reestruturação, deixando de parte o cenário em que o preço era bastante controlado, para passar a ser extremamente volátil, fruto da dependência do mesmo relativamente a variados fatores. Exemplos destes fatores são as restrições técnicas do sistema elétrico de energia, dependência da procura e a impossibilidade de armazenamento de energia elétrica em grandes quantidades. Tudo isto, faz com que possam ocorrer variações acentuadas no preço da eletricidade.

Esta liberalização, e a conseqüente introdução da livre competição no fornecimento de energia, iniciaram os seus avanços no Mercado Elétrico Português em 1995, tendo em vista o aumento da competitividade em relação aos preços praticados e à qualidade do serviço apresentado. Segundo a EDP – Energias de Portugal [1], este processo, em Portugal, desenrolou-se de forma faseada e progressiva, sendo que inicialmente o mercado foi

disponibilizado apenas a consumidores com níveis de tensão e consumos mais elevados, e posteriormente aos restantes, ficando disponível para todos os consumidores em Portugal Continental, em setembro de 2006.

Com esta reestruturação, alguns dos principais elos do Sistema Elétrico Nacional – produção, transporte, distribuição e comercialização de eletricidade – sofreram alterações. A produção de eletricidade, passou a tratar-se de uma atividade totalmente liberalizada e que opera numa lógica de mercado e em regime de livre concorrência, mediante atribuição de uma licença, sendo praticada em regime ordinário ou especial. O transporte de eletricidade, feito através da Rede Nacional de Transporte (RNT) em Alta e Muito Alta Tensão (AT/MAT), e trata-se de uma atividade não liberalizada, atribuída pelo Estado Português, à Redes Energéticas Nacionais (REN). A distribuição de eletricidade, feita pela Rede Nacional de Distribuição, em Alta e Média Tensão, e pelas Redes Municipais de Distribuição, em Baixa Tensão, também não se trata se uma atividade liberalizada. E por fim, a comercialização da eletricidade, que passou a tratar-se de uma atividade liberalizada e que opera em regime de livre concorrência, mediante atribuição de licença, tal como com a produção, numa lógica de mercado.

Existem ainda entidades denominadas por Comercializadores de Último Recurso, cuja atividade é regulada, e que procuram a salvaguarda dos direitos dos consumidores, garantindo-lhes o fornecimento de eletricidade, com tarifas reguladas. Os consumidores podem então optar por celebrar contrato com um comercializador estabelecido no mercado, praticando preços livres em regime de concorrência, ou com um dos comercializadores de último recurso.

Em qualquer dos casos, os fornecedores, normalmente designados por comercializadores, adquirem energia elétrica diretamente aos produtores, ou por meio de bolsas (OMIP, em Portugal, e OMEL, em Espanha) e utilizam as redes de transporte e de distribuição para a fazer chegar aos seus clientes (regime de acesso às redes), sendo a EDP Distribuição a entidade responsável pela entrega da mesma aos clientes ligados às suas redes.

As características do mercado de energia elétrica pós-liberalização fazem a previsão da evolução do preço algo muito complexo, mas importante para a proteção dos agentes envolvidos no mercado, sejam eles produtores, comercializadores ou consumidores.

1.2. OBJETIVOS

Esta dissertação teve como principal objetivo o desenvolvimento de uma ferramenta de software que permita analisar e prever a evolução dos preços no mercado spot e futuros no Mercado Ibérico de Eletricidade. Desta forma foram cumpridas diversas etapas, passando por:

- Extração, tratamento e análise de dados que poderão influenciar o preço da energia elétrica;
- Análise de correlação entre as variáveis recolhidas e o preço;
- Construção de modelos de previsão do preço da energia elétrica para o Mercado Spot e Mercado a Prazo (Futuros).

1.3. CALENDARIZAÇÃO

No âmbito da conclusão da Unidade Curricular de Dissertação do Mestrado em Engenharia Eletrotécnica – Sistemas Eléctricos de Energia (DSEE), foi realizado um estágio na empresa Simples Energia. Esta empresa que se dedica à comercialização de energia elétrica, no mercado liberalizado, pretende satisfazer as necessidades dos consumidores e garantir a preservação e sustentabilidade ambiental. A Simples Energia atua no mercado empresarial e domésticos oferecendo planos tarifários de eletricidade adequados aos clientes, sistemas de gestão e monitorização e promovendo a produção descentralizada renovável.

O estágio nesta empresa decorreu desde o dia 28 de novembro de 2016, até outubro de 2017, como é possível verificar na Figura 1, tendo sido utilizadas as instalações da empresa para o desenvolvimento dos trabalhos levados a cabo ao longo desta dissertação.

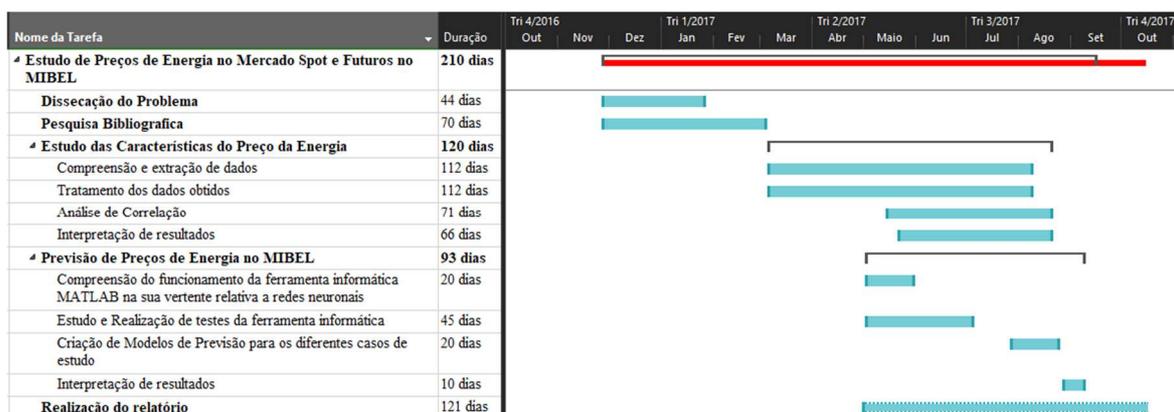


Figura 1 Calendarização do Estágio Curricular

1.4. ORGANIZAÇÃO DO RELATÓRIO

A presente dissertação é composta por 5 capítulos, sendo estes descritos de forma sucinta em seguida.

Capítulo 1: apresentada uma contextualização do tema abordado, a motivação para à qual se realizou este estudo, os objetivos principais a atingir, a calendarização do trabalho desenvolvido e a organização estrutural da tese.

Capítulo 2: apresentação do estado da arte onde são abordados temas como *Smart Grid*, Produção distribuída, Rede de Distribuição, Índices de Avaliação de Fiabilidade nas Redes de Distribuição, Modelo no Trânsito de Potências e Planeamento de uma Rede de Distribuição.

Capítulo 3: análise de diferentes conceitos matemáticos e de otimização fundamentais para a formulação do problema apresentado na tese.

Capítulo 4: aplicação da metodologia analisada para a resolução do problema de planeamento de redes de distribuição a duas redes com diferentes dimensões - rede de testes (13 barramentos) e rede real (180 barramentos).

Capítulo 5: principais conclusões retiradas deste trabalho, principais contributos e propostas para trabalhos futuros na área.

2. ESTADO DA ARTE

2.1. INTRODUÇÃO

Atualmente, o preço do mercado de energia elétrica passou a ser um fator crucial para todos os agentes do setor elétrico, principalmente as empresas produtoras de energia. Com a introdução de uma mudança na estrutura da indústria ao longo destes últimos anos, o setor elétrico sofreu uma conseqüente mutação. Isto afetou o mercado a este setor associado, sendo uma das principais conseqüências a introdução de competitividade ao invés do conceito até à data aplicado – um mercado monopolista. Desta forma, a previsão do preço da energia elétrica, será uma mais valia, podendo ter influência em diversos temas, como transmissão, expansão, melhoria ou aumento da produção, distribuição e planejamento energético, auxiliando, por exemplo, na quantificação dos riscos inerentes a uma dessas decisões e do valor estratégico e da flexibilidade operacional dessas decisões.

Por conseguinte, com o intuito de enquadrar este tema relativo ao estudo dos preços de energia no Mercado Spot e Futuros no Mercado Ibérico de Eletricidade (MIBEL), são apresentados conceitos e ferramentas essenciais para o desenvolvimento desta dissertação. Neste capítulo serão abordados temas como a Evolução do Setor Elétrico, o Mercado

Europeu de Energia, o Mercado Ibérico de Eletricidade, os dois mercados estudados, Mercado Spot e Mercado a Prazo e, por fim, Modelos de Previsão e de Avaliação.

2.2. EVOLUÇÃO DO SETOR ELÉTRICO

Desde a sua origem, no século XIX, a eletricidade e o setor a esta associado sofreram diversas modificações. No princípio e durante várias décadas, os sistemas elétricos de energia (SEE) foram explorados tendo em conta uma estrutura verticalmente integrada e um regime de monopólio natural. Nesse monopólio, a exploração dos três principais componentes do sistema (produção, transporte e distribuição) era efetuada de uma forma centralizada e verticalmente integrada, como se pode verificar na Figura 2. As redes elétricas eram de pequena dimensão, devido essencialmente às limitações de potência e máquinas da época, a produção era controlável e a carga seguia padrões de consumo estáveis. Relativamente à relação com os consumidores, era dispensável a disponibilização de informação aos mesmos e existia pouca interação com os clientes.

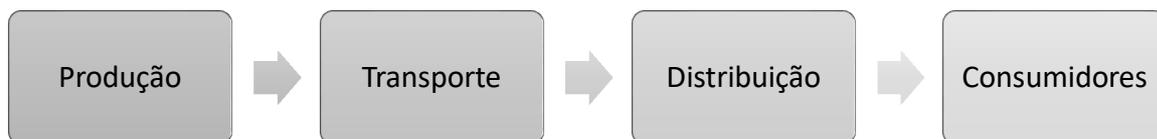


Figura 2 Estrutura verticalmente integrada

O desenvolvimento das interligações entre sistemas elétricos, originou o aparecimento de sistemas regionais, em que o seu principal objetivo seria o aumento da segurança de exploração e operação dos sectores elétricos. As estruturas deste tipo continuaram a vigorar até à década de 70 do século XX uma vez que a economia era pouco volátil, previsível e assente em incrementos elevados e constantes do consumo de eletricidade, taxas de juro e de inflação com baixos valores e estabilidade dos custos das infraestruturas.

A partir da década de 70, conseqüente do primeiro choque petrolífero em 1973, a visão do que seria o melhor modelo de mercado alterou-se. Silva [2] refere que as enormes alterações na economia mundial causaram a incerteza, o risco elevado e a volatilidade nos diversos setores. Este facto, impulsionado pelos avanços tecnológicos e novas metodologias organizacionais, deu lugar ao aparecimento das primeiras experiências de liberalização do

setor elétrico. Novas políticas foram implementadas, consistindo em medidas de substituição da eletricidade por novas fontes de energia, técnicas para um melhor aproveitamento da energia e consideração de questões relacionadas com o ambiente. A indústria do sector elétrico deu então início a um processo de reestruturação e de liberalização – a desverticalização do setor.

Com o objetivo de melhorar a qualidade de serviço e de fornecer energia elétrica aos seus consumidores a preços mais atrativos, este processo de desverticalização assenta na criação de várias empresas produtoras, entidades fornecedoras e comercializadores. Desta forma introduz-se o conceito de competitividade no sistema elétrico - existência de concorrência em diversas áreas, onde nenhuma entidade deverá deter posição monopolista de mercado. Azevedo [3] afirma que esta renovação consentiu o aparecimento de novos agentes a operar no mercado e as empresas, que outrora se encontravam verticalmente integradas, necessitam de se separar por áreas de atividade nomeadamente em produção, transporte e distribuição até à comercialização e mesmo à regulação e operação dos sistemas. As empresas de produção passarão a competir entre si e os consumidores serão livres de escolher o seu fornecedor de energia elétrica. Contudo, para facilitar a competição na produção e no mercado de retalho, é necessário um controlo operacional independente das redes. Para garantir o acesso livre e não discriminatório às redes e a qualidade de serviço é necessário a criação de uma entidade independente, designada por Operador do Sistema¹ (OS).

Passando para uma visão mais abrangente do mercado elétrico, nos Estados Unidos, segundo Harkins [4] em 1978 o congresso aprovou o Public Utilities Regulatory Policies Act (PURPA). Isto promoveu o aparecimento de pequenos produtores independentes e tal como Hauric, Loulou e Savard [5], o PURPA estabeleceu que as empresas integradas se encontravam obrigadas a adquirir toda a energia produzida por esses pequenos produtores. Contudo, esta reestruturação tomou um ritmo lento, pois a inexistência na legislação de

¹ Na literatura anglo-saxónica, Independent System Operator (ISO).

garantias favoráveis para o desenvolvimento de competitividade assim o ditou. Segundo Baptista [6], o setor americano envergou por uma aposta na desregulação e, o que se tem verificado desde 1991, tem sido um aumento considerável dos preços, consumidores sem hábito de mudar de empresas e, além disto, e muito mais grave, ocorrências de colusão entre empresas (Califórnia 2000), picos de preços, falência de alguns distribuidores e apagões.

Pinto et al. [7] afirmam que o movimento de reestruturação iniciado no Chile em 1978, influenciou e teve continuidade em diversos países tendo evoluído para a criação de mercados transnacionais. O governo chileno procedeu a uma reorganização industrial, iniciando uma separação vertical das atividades elétricas de forma a garantir a eficiência no setor. Promoveu também um programa de privatização das sociedades resultantes dessa separação, sem esquecer a criação de uma entidade reguladora das atividades desenvolvidas para cada sector. Assim, desde o início da década de 90, simultaneamente à reestruturação e liberalização do sector elétrico, que ocorreu em diversos Estados membros da União Europeia, assistiu-se ao processo de integração dos mercados nacionais em direção ao futuro Mercado Europeu Interno de energia elétrica. Baptista [4] explica que o precursor do caminho da liberalização no setor energético foi o Reino Unido, com as políticas dos governos conservadores de Thatcher. Trata-se de um marco histórico, devido à aprovação de um novo regulador e a privatização da maioria das ações das empresas do setor elétrico. Ainda na mesma altura, um ambicioso processo de reforma no setor, com uma forte reorganização da indústria e a modificação regulamentar, não privatizando as empresas públicas, acontecia na Noruega.

2.3. MERCADO EUROPEU DE ENERGIA

No decorrer da década de 90, quando a maior parte dos mercados nacionais da eletricidade e do gás natural eram ainda objeto de monopólio, a União Europeia e os Estados-Membros decidiram abrir gradualmente estes mercados à concorrência. O Parlamento Europeu [8] refere que as primeiras diretivas de liberalização – o Primeiro Pacote da Energia – foram adotadas em dezembro de 1996 para a eletricidade e em Junho de 1998 para o gás. Em 2003 ambas foram revogadas pelas segundas diretivas do mercado interno da energia, – Segundo Pacote da Energia – sendo transpostas para o direito nacional pelos Estados-Membros em 2004, entrando em vigor de algumas disposições apenas em 2007, como é possível verificar na Tabela 1.

Tabela 1 Evolução do enquadramento legislativo europeu até ao Segundo Pacote da Energia [9]

	Diretiva 1996		Diretiva 2003
Produção	Monopólio	Autorização (Concurso)	Autorização (Concurso)
Transporte	Monopólio	Acesso Regulado	
Distribuição		Acesso Negociado	Acesso Regulado
		Comprador único	
Comercialização	Monopólio	Livre	Livre
Consumidores	Sem Escolha	Escolha para elegíveis ($\approx 1/3$)	Todos Não- Residenciais (2004)
			Todos (2007)
Comércio Transfronteiriço	Monopólio	Negociado	Regulado
Regulação	Monopólio	Pouco harmonizada	Forte e Harmonizada

Esteves e Braz [9] afirmam que os consumidores industriais e domésticos eram agora livres de escolher os seus fornecedores de gás e eletricidade a partir de um leque mais vasto de concorrentes. Em abril de 2009, foi adotado um Terceiro Pacote da Energia com vista a prosseguir a liberalização do mercado interno da eletricidade e do gás, que altera o segundo pacote e proporciona a base para a realização do mercado interno da energia. Este Terceiro Pacote é constituído por um conjunto de cinco documentos, quatro dos quais alteram as duas Diretivas 2003/54/CE e 2003/55/CE, o Regulamento (CE) 1228/2003, relativo às condições de acesso às redes para comércio transfronteiriço de eletricidade, e o Regulamento (CE) 1775/2005, relativo às condições de acesso às redes de transporte de gás natural. O quinto documento que constitui o Terceiro Pacote é um novo Regulamento europeu que estabelece

a criação da ACER, Agência Europeia para a Cooperação dos Reguladores de Energia². A evolução do enquadramento legislativo Europeu teve um impacto muito significativo na organização das atividades do sector energético nos países europeus. Os mesmos autores [9] apresentam ainda, em tom de resumo, os aspetos mais relevantes para este último o Pacote Europeu de Legislação sobre os Mercados de Eletricidade e Gás.

- Separação efetiva das atividades de transporte em relação à produção e à comercialização;
- Harmonização dos poderes e do grau de independência dos reguladores nacionais;
- Estabelecimento de uma instituição que promova a cooperação entre os reguladores europeus: Agência Europeia para a Cooperação dos Reguladores (Nacionais) da Energia;
- Criação de um mecanismo visando melhorar a coordenação das operações de rede, da segurança do abastecimento e das condições em que se processam as trocas transfronteiriças;
- Criar condições para que haja mais transparência no funcionamento dos mercados energéticos;
- Reciprocidade e aprofundamento da solidariedade.

Existem assim três princípios que orientam toda a atividade de regulação do sector energético na Europa: a competitividade, a segurança do abastecimento e a sustentabilidade. As interações entre estes três princípios levam ao conjunto de desafios apresentados na Figura 3 .

² O Parlamento Europeu [8] afirma que a Agência Europeia de Cooperação dos Reguladores da Energia (ACER) está plenamente operacional desde Março de 2011 (Regulamento (CE) n.º 713/2009). A ACER é principalmente responsável por promover a cooperação entre as entidades reguladoras nacionais a nível regional e europeu e por acompanhar o desenvolvimento da rede e os mercados internos da eletricidade e do gás. Tem igualmente competência para investigar casos de abuso de mercado e para coordenar com os Estados-Membros a aplicação das sanções adequadas. A responsabilidade de aplicar sanções relacionadas com infrações mantém-se, porém, uma competência dos Estados-Membros.



Figura 3 Desafios da regulação do sector energético na Europa

Deste modo, através da análise da Figura 3, a interação entre a competitividade e a segurança de abastecimento orienta as preocupações com a independência da regulação, as perspetivas para os investimentos nas infraestruturas e a necessidade da integração dos mercados. Para o caso da interação entre a segurança de abastecimento e a sustentabilidade, surge a necessidade do desenvolvimento urgente das renováveis, da descarbonização e da eficiência energética. Por último, a interação entre a competitividade e a sustentabilidade justificam as preocupações atuais com as redes inteligentes³, que introduz também o conceito de contadores inteligentes⁴ e a gestão do lado da procura⁵.

Desta maneira, o mercado europeu de energia caracteriza-se fundamentalmente pela liberdade de investimento e comércio em todo o espaço comunitário; pelo acesso regulado

³ Na literatura anglo-saxónica, *Smart Grids*. Uma rede inteligente trata-se de um sistema evoluído que faz a gestão da procura de eletricidade de forma sustentável, fiável e económica³. É desenvolvida de forma a facilitar a integração de todos os envolvidos, sincronizando a informação em tempo real, [27].

⁴ Na literatura anglo-saxónica, *Smart Metering*. Um contador inteligente é um dispositivo eletrónico que regista o consumo de energia eléctrica em intervalos de uma hora ou menos e comunica essa informação de forma a ser previamente tratada, [28].

⁵ Na literatura anglo-saxónica, *Demand Side Management*. A gestão do lado da procura trata de uma ampla gama de ações que podem ser tomadas pelo cliente, tendo em conta o seu contador de eletricidade, em relação a condições particulares dentro do sistema, [29]

às infraestruturas, dentro das quais as redes de transporte e de distribuição e terminais de gás natural liquefeito; e pela liberdade de escolha de fornecedor atribuída a todos os consumidores.

Com a criação deste mercado único, Esteves e Braz [9] assumem que a cooperação entre autoridades reguladoras nacionais tem um papel fundamental, sobretudo nas questões relativas ao comércio transfronteiriço de energia e no que toca à partilha de informação e de boas práticas. Em março de 1997, as autoridades reguladoras nacionais de Portugal, Espanha e Itália deram início a uma cooperação informal através de reuniões periódicas e da organização de grupos de trabalho conjuntos. No ano seguinte, organizam o Fórum Europeu de Regulação de Eletricidade (Fórum de Florença) e, em setembro de 1999, o Fórum Europeu de Regulação de Gás Natural (Fórum de Madrid), onde se reúnem os principais intervenientes europeus dos dois sectores. Estas experiências de cooperação entre os reguladores de energia europeus permitiram criar, em março de 2000, o Conselho dos Reguladores Europeus de Energia (CEER), através de um memorando de entendimento entre as autoridades reguladoras de energia de países europeus. Em seguida, após a adesão de mais cinco países, em junho de 2003, o CEER torna-se numa associação sem fins lucrativos. A experiência positiva do trabalho desenvolvido pelo CEER leva a que, por decisão da Comissão Europeia (CE) de novembro de 2003, seja instituído o Grupo de Reguladores Europeus de Eletricidade e de Gás Natural (ERGEG), órgão formal de consulta da CE. Envolvendo autoridades reguladoras nacionais de energia de vinte e nove países (os vinte sete da União Europeia, a Noruega e a Islândia), prevê-se uma nova evolução da estrutura associativa dos reguladores de energia europeus com a proposta da CE para a criação da ACER, prevista no 3º Pacote Europeu de Legislação sobre os Mercados de Eletricidade e Gás e anteriormente referida. No caso de Portugal e Espanha, respetivamente, a Entidade Reguladora dos Serviços Energéticos (ERSE) e a “Comisión Nacional de Energía” (CNE) assumem a responsabilidade de regular unicamente o sector da energia.

2.4. MERCADO IBÉRICO DE ELETRICIDADE

Em meados da década 90, após a liberalização dos setores elétricos de Portugal e Espanha, acompanhou-se a tendência europeia de criação de mercados regionais de energia elétrica, o que, devido ao inerente aumento de competitividade, veio dar um grande impulso ao desenvolvimento da interligação ibérica. Através de um acordo internacional entre estes dois

países, a ERSE [10] refere que de forma a aproveitar as sinergias dos dois países no sentido de criar um mercado único para a eletricidade na península ibérica, o “Protocolo de colaboração entre as Administrações Espanhola e Portuguesa para a criação do Mercado Ibérico de Eletricidade (MIBEL)”, assinado a 14 de novembro de 2001. O referido Protocolo tem como obrigatoriedade a regulação do mercado, sendo para isso designados a Entidade Reguladora dos Serviços Energéticos ⁶ (ERSE) e a Comissão do Mercado de Valores Mobiliários ⁷ (CMVM) como reguladores portugueses e Comissão Nacional de Energia⁸ (CNE) e a Comissão Nacional do Mercado de Valores⁹ (CNMV) no que diz respeito à representação espanhola. Depois de uma análise aos sistemas elétricos português e espanhol, tanto a ERSE como a CNE [10], consideraram pertinentes os seguintes pontos:

- A inexistência de desequilíbrios estruturais entre os sistemas. Os dois sistemas apresentam dimensões distintas (o sistema elétrico Espanhol é cerca de cinco vezes superior ao sistema Português), contudo as estruturas são idênticas e facilitam a implementação do MIBEL;
- O aumento elevado do consumo de Energia Elétrica (EE) de ponta conduz a investimentos relevantes numa nova capacidade de produção;
- O elevado crescimento do investimento subsidiado, de forma direta ou indireta, numa nova capacidade de produção de EE através de fontes de energia renováveis e de instalações de cogeração, ou seja, nas unidades de Produção em Regime Especial (PRE);
- A necessidade de considerar e conciliar as regras de recuperação dos investimentos dos produtores em regime ordinário, certificando-se de que a recuperação dos custos de transição para um ambiente de mercado não introduz distorção na concorrência entre produtores, nem a formação dos preços de energia no mercado;
- Panorama empresarial caracterizado por quatro grandes grupos, EDP, Endesa, Iberdrola, Unión Fenosa, obrigando à implementação de mecanismos de controlo e

⁶ Inicialmente ERSE era denominada como Entidade Reguladora do Sector Elétrico, sendo que a partir de 2002 foi alterada a sua designação para Entidade Reguladora do Sector Energético, devido a inserção da regulação do setor de gás natural. [30]

⁷ Tendo como missão a supervisão e regulação dos mercados de valores mobiliários e instrumentos financeiros derivados, os chamados “mercados bolsistas”, a CMVM foi criada no decorrer de 1991, sendo reformulada em 2008, [31].

⁸ A CNE surge no fim da década de 90 direcionada para a regulação do setor elétrico e hidrocarbonetos líquidos e gasosos, [32].

⁹ A CNMV é responsável pela supervisão e inspeção do mercado de valores espanhóis, bem como a atividade dos seus agentes. Surgiu em 1988, tendo uma reformulação em 2002, [33].

atuação adequados, bem como incentivos ao desenvolvimento da concorrência entre eles, dando ainda a possibilidade de entrada de novos operadores no mercado;

- A necessidade de aumento das capacidades de interligação entre Portugal e Espanha, não esquecendo a de Espanha-França, visto as capacidades de interligação serem insuficientes ao desenvolvimento do MIBEL, assim como do mercado interno de energia da União Europeia.

2.4.1. FUNCIONAMENTO DO MERCADO

Com a implementação do modelo funcional e organizacional das entidades de gestão do MIBEL, os governos português e espanhol necessitavam de um Operador de Mercado Ibérico (OMI), que teria como base as duas holdings acionistas, como mostra a Figura 4.

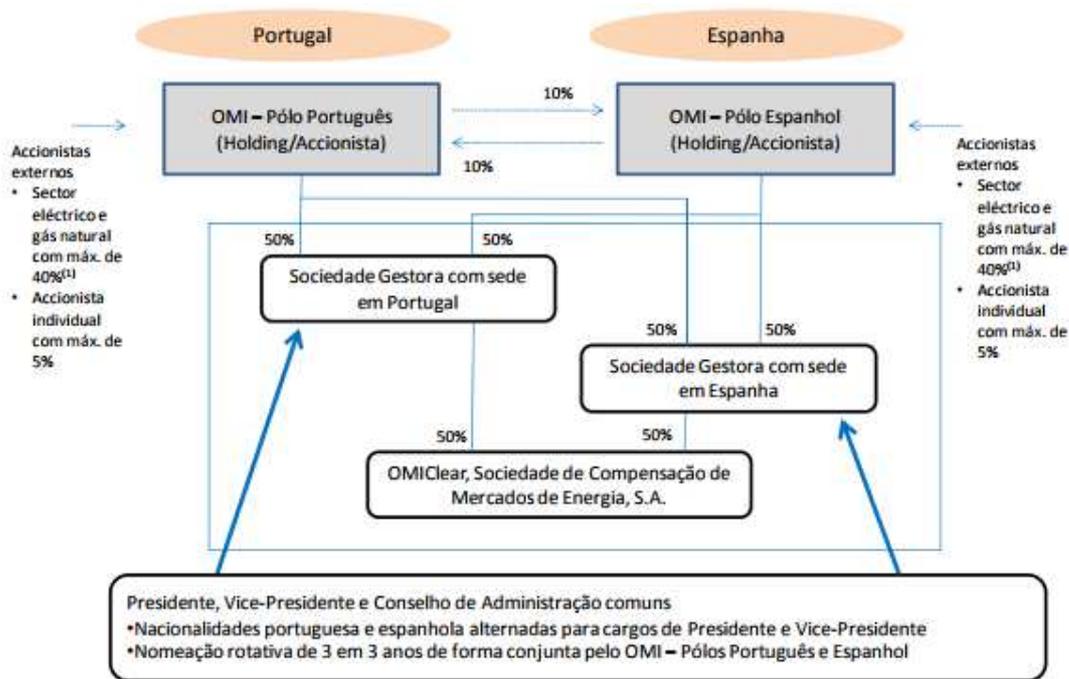


Figura 4 Modelo acionista do operador de mercado ibérico (OMI) [11]

O Operador de Mercado Ibérico do pólo Português (OMIP) e a do pólo espanhol, a OMIE, com sede nos respetivos países, estabelecem compromissos relativos à produção e compra de energia elétrica do respetivo mercado. O OMIP gere o mercado a prazo (mercado futuro) e não carece de liquidação física, existindo a possibilidade apenas da ocorrência de liquidação financeira. Em relação ao OMIE, este gere o mercado spot, compreendendo as transações do mercado diário e intradiário, com base na legislação atualmente em vigor, em Espanha [11].

Conforme o Acordo de Santiago [12], em termos empresariais, ambas as entidades gestoras dos mercados organizados deterão, em igual proporção, 50% da sociedade participada OMIClear –Sociedade de Compensação de Mercados de Energia S.A..

Existe ainda um mercado específico de contratação bilateral, em que os agentes compram e vendem EE, para diversos horizontes temporais. Outro mercado a atuar no MIBEL é o mercado específico para contratação de serviços, tais como as reservas secundárias e as terciárias, de forma a, simultaneamente com a energia primária, contribuir para a garantia de equilíbrio entre a produção e consumo em tempo real.

Uma vez que se avançava para um mercado concorrencial na produção de energia elétrica da península ibérica, os Contratos de Aquisição de Energia (CAE) revelavam-se um problema para o funcionamento do mercado pretendido, tornando-se uma barreira para a entrada de novos produtores no mercado. Amaral [13] refere que os CAE representavam contratos que obrigavam os produtores englobados no Sistema Elétrico de Serviço Público a manterem uma relação comercial em regime de exclusividade com a entidade concessionária da rede nacional de transporte. Através de contratos de vinculação de longo prazo, esta relação comercial era vinculada, nos quais eram reconhecidos os proveitos expectáveis dos produtores.

Para anular estes contratos, seria preciso pagar aos produtores vinculados detentores dos CAE a denúncia dos mesmos. Os custos decorrentes da denúncia destes contratos designam-se Custos de Transição para a Concorrência (CTC), no caso espanhol, e Custos de Manutenção do Equilíbrio Contratual (CMEC), para Portugal. Através de acordos, estes custos são naturalmente necessários para honrar com os promotores os compromissos outrora assumidos – como aquando da construção das centrais – e consistem em pagamentos fora de mercado. Ribeiro [14] diz que pretendem também minorar o impacto da liberalização do setor elétrico ao nível da produção, ou seja, permitir que as empresas praticamente não sejam afetadas, no curto prazo, por reduções dos preços ligados à concorrência estabelecida pelo mercado. No entanto, tanto os CTC como os CMEC representam apenas uma fase tendo como função assegurar uma transição suave para o ambiente de mercado livre.

A segurança de abastecimento na Península Ibérica é considerada como sendo um dos pontos cruciais para o sucesso de implementação do MIBEL. Como tal coloca-se a questão

fundamental: é necessário averiguar se o mercado será capaz de fornecer aos investidores, por intermédio de sinais económicos de preços, indicações fiáveis que levem à construção atempada de novas centrais elétricas, para que o abastecimento de energia elétrica nunca seja posto em causa. Mais uma vez, Ribeiro [14] refuta que, caso o mercado seja capaz de fornecer aos investidores os sinais económicos de preços que levem à construção de novas unidades de produção, não deverão ser previstos mecanismos de regulação que dissociem o valor da capacidade de energia elétrica disponível do preço da energia elétrica. Por outro lado, se estes sinais económicos de preços não incentivarem os investidores a construir novas unidades de produção, será necessário reforçar estes sinais através da remuneração pela capacidade de energia elétrica disponível que cada um dos diferentes produtores apresente no mercado. Desta forma, a implementação de um mecanismo de monitorização da margem de reserva do sistema Ibérico é de grande importância para a segurança de abastecimento de eletricidade a curto e longo prazo.

2.4.2. MODELO ORGANIZACIONAL

O modelo organizacional do MIBEL tem como alicerce princípios que implementam a liberdade e igualdade de acesso de todos os agentes ao mercado em condições de transparência e objetividade, para os diferentes níveis de negociação de energia. Desta maneira, Baptista [6] afirma que as principais metas passam por beneficiar os consumidores de eletricidade através de um processo de integração dos respetivos sistemas elétricos, tal como auxiliar no desenvolvimento do mercado de eletricidade nos dois países e aumentar a eficiência económica das empresas do setor elétrico através da livre concorrência. Neste modelo, estão também presentes as preocupações com a segurança de abastecimento e com a implementação de mecanismos de recuperação de custos ociosos detetados. Desta forma, Ribeiro [15] afirma que o modelo organizativo do MIBEL é constituído por: mercado grossista e mercado retalhista.

Mercado Grossista

Este autor refere que o mercado grossista do MIBEL compreende uma série de formatos de contratação de energia, [10]:

- Mercado de contratação à vista ou mercado spot – segmentado em dois tipos de mercados, nomeadamente, os mercados diários e intradiários. É nestes mercados que

se apresentam as várias propostas de venda (produção) e compra (comercialização) de energia elétrica para o dia seguinte ao da negociação;

- Mercado de contratação a prazo – onde são estipulados compromissos a futuro de produção e compra de energia elétrica. O mercado a prazo pode realizar liquidação física (venda de energia) ou liquidação financeira;
- Mercado de contratação bilateral – onde é possível ordenar a compra e venda de energia elétrica para diferentes horizontes temporais;
- Mercado de serviços de sistema – funciona em tempo real e é responsável por manter o equilíbrio entre a produção e o consumo de energia elétrica.

Mercado Retalhista

Seguindo o progresso do mercado liberalizado de energia, e uma vez que a atividade de comercialização se encontra aberta ao mercado, os consumidores possuem liberdade total na escolha do seu fornecedor de eletricidade. Neste caso, o modo de funcionamento do mercado baseia-se em duas formas de contratação do fornecimento de energia elétrica, [10]:

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

2.5. MERCADO SPOT (À VISTA)

Como suprarreferido, o mercado spot é dividido em dois mercados distintos: mercado diário e intradiário. Este mercado é gerido pelo Pólo espanhol, responsável pela gestão dos mercados organizados do MIBEL, OMIE.

2.5.1. MERCADO DIÁRIO

É no mercado diário do MIBEL que ocorre a transação da energia elétrica que irá satisfazer a procura do dia seguinte ao da negociação. Segundo a ERSE [16], este mercado forma preço para cada uma das 24 horas de cada dia e para todos os dias de cada ano. A hora de negociação é determinada pela hora legal espanhola. Este mercado funciona através do cruzamento de ofertas, quer de compra quer de venda, por parte dos diversos agentes registados para atuar naquele mercado, indicando cada oferta o dia e a hora a que se reporta, o preço e a quantidade de energia correspondentes.

O preço é então encontrado através da ordenação de forma crescente do preço das ofertas de venda – curva de oferta – e de forma decrescente do preço das ofertas de compra – curva de

procura – para uma mesma hora. O preço de mercado, apresentado na Figura 5, é o preço mínimo que garante que a oferta satisfaz a procura.

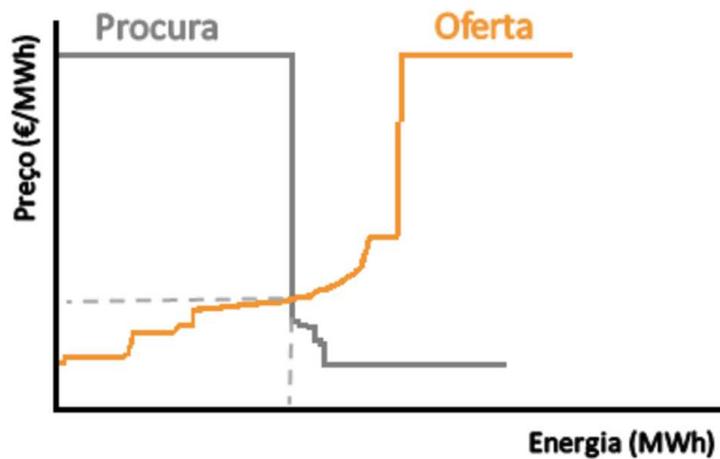


Figura 5 Curva “Procura vs Oferta” [16]

As regras de funcionamento deste mercado são definidas pelo próprio operador do mercado. Assim sendo, o funcionamento do mercado diário em que participam os agentes portugueses implica que, segundo a ERSE [16], todos os compradores paguem um mesmo preço e todos os vendedores recebam esse mesmo preço, no que se designa como modelo de preço marginal único.

Uma vez que este mercado compreende conjuntamente Portugal e Espanha, torna-se pertinente prever a possibilidade de as capacidades de interligação comercialmente disponíveis entre os dois países não suportarem os fluxos transfronteiriços de energia que o cruzamento de ofertas em mercado determinaria. A Figura 6 demonstra como se forma o preço neste mercado, tendo em conta as regras presentemente aplicadas.

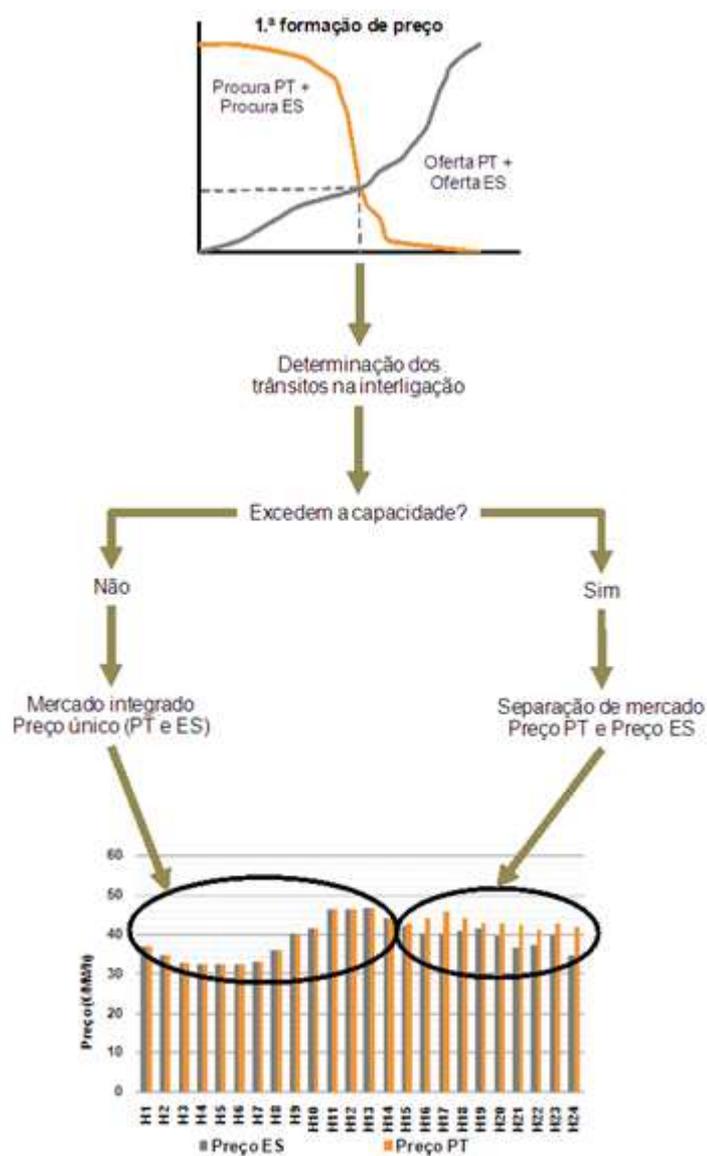


Figura 6 Formação do preço da energia no mercado diário [16]

Todas as vezes que tal situação ocorrer, as regras atuais de mercado ditam que se dividam as duas áreas de mercado correspondentes a Portugal e Espanha e que se encontrem preços específicos para cada uma delas. Este mecanismo é designado como separação de mercados – *market splitting*. O motivo para a qual ocorre a separação de mercados (e correspondentes *spreads*¹⁰ de preço) justifica-se através de uma variedade de fatores, desde a organização

¹⁰ Diferença entre o preço de compra (procura) e venda (oferta), [17].

estrutural da produção em cada uma das áreas, insuficiência das capacidades de interligação ou comportamento dos agentes. A supervisão, ao atuar, pretende diminuir o número de ocorrências de situações de separação de mercados e, em particular, garantir que estas não se atribuam a comportamentos anti concorrenciais dos agentes.

2.5.2. MERCADO INTRADIÁRIO

ERSE [16] define o mercado intradiário do MIBEL como uma plataforma complementar ao mercado acima definido. Aqui é onde se transaciona eletricidade para ajustar as quantidades transacionadas no mercado diário, compreendendo 6 sessões diárias de negociação. Cada uma das sessões de mercado intradiário forma preço para as horas objeto de negociação em cada sessão e são apresentadas na Figura 7.



Figura 7 Sessões diárias de negociação do mercado intradiário [16]

Através da análise da Figura 7, [16]:

- A primeira sessão de intradiário forma preço para as 4 últimas horas do dia de negociação e para as 24 horas do dia seguinte ao da negociação.
- A segunda sessão de intradiário forma preço para as 24 horas do dia seguinte ao da negociação.
- A terceira sessão de intradiário forma preço para as 20 horas compreendidas entre a hora 5 e a hora 24 do dia seguinte ao da negociação.
- A quarta sessão de intradiário forma preço para as 17 horas compreendidas entre a hora 8 e a hora 24 do dia seguinte ao da negociação.
- A quinta sessão de intradiário forma preço para as 13 horas compreendidas entre a hora 12 e a hora 24 do dia seguinte ao da negociação.
- A sexta sessão de intradiário forma preço para as 9 horas compreendidas entre a hora 16 e a hora 24 do dia seguinte ao da negociação.

Desta maneira e identicamente ao mercado diário, o mercado intradiário cobre todas as horas do dia (com a especificidade própria de cada sessão) e todos os dias de cada ano. O funcionamento do mercado intradiário, mais uma vez semelhante ao mercado diário, está assente na sujeição de ofertas, de compra e de venda, por parte dos diversos agentes registados para atuar no mercado diário, indicando cada oferta por sessão o dia e a hora a que se reporta, o preço e a quantidade de energia correspondentes.

2.6. MERCADO A PRAZO (FUTUROS)

O mercado a prazo é um mercado organizado que oferece instrumentos de gestão de risco sob a forma de derivados e a entidade responsável pela sua gestão é o OMIP. Os instrumentos transacionados no OMIP tratam-se de contratos de compra e venda de energia para um determinado período no futuro (semana, mês, trimestre e ano), de acordo com regras específicas deste mercado. O tipo de instrumentos transacionados varia com as necessidades de gestão de risco e de troca de eletricidade pelos diferentes agentes. Desta forma, o OMIP disponibiliza três contratos diferentes: Futuro, *Forward* e SWAP. Segundo a ERSE [17], o contrato futuro trata-se de um contrato padronizado¹¹ de compra ou venda de energia para um determinado horizonte temporal, em que o comprador se compromete a adquirir eletricidade no período de entrega e o vendedor se compromete a colocar essa mesma eletricidade, a um preço determinado no momento da transação. Este contrato tem liquidações diárias (margens) entre o preço de transação e a cotação de mercado (a futuro) de cada dia. Os agentes compradores e vendedores não se relacionam diretamente entre si, cabendo à câmara de compensação a responsabilidade de liquidar as margens diárias e o contrato na data ou período de entrega. Relativamente ao contrato *Forward*, este também é um contrato padronizado de compra ou venda de energia para um determinado horizonte temporal, em que o comprador se compromete a adquirir eletricidade no período de entrega e o vendedor se compromete a colocar essa mesma eletricidade, a um preço determinado no momento da transação. Ao contrário do anterior, não tem liquidações diárias das margens durante o período de negociação, sendo a margem liquidada integralmente nos dias de

¹¹ (volume nominal e notação de preço)

entrega física ou financeira. Em relação aos agentes compradores e vendedores, mais uma vez, estes não se relacionam diretamente entre si, cabendo novamente à câmara de compensação a responsabilidade de liquidar as margens diárias e o contrato na data ou período de entrega. Por último, os Contratos SWAP. Mais uma vez um contrato padronizado, em que se troca uma posição em preço variável por uma posição de preço fixo, ou vice-versa, dependendo do sentido da troca. Este tipo de contratos destina-se a gerir ou tomar risco financeiro, não existindo, por isso, entrega do produto subjacente, mas apenas a liquidação das margens correspondentes.

A ERSE [17] afirma que, no OMIP, os produtos mais transacionados e, por isso, mais comuns são os contratos Futuro. A padronização de um contrato derivado sobre eletricidade significa que se impõe a predefinição da dimensão de cada contrato (nominal), a unidade em que se expressa o preço e o valor mínimo de variação do preço (*tick*), bem como as condições de entrega. O nominal dos contratos Futuro listados pelo OMIP é de 1 MW, podendo existir dois tipos de produto: o produto base – *Baseload* – que oferece a mesma quantidade de energia para todas as horas de um determinado período; ou o produto pico – *Peakload* – que oferece a mesma quantidade de energia para as 16 horas de pico (da hora 9 à hora 24) dos dias úteis constantes de um determinado período.

No que toca ao referencial de preços para liquidação dos contratos, é possível optar por produtos com áreas de entrega distintas dentro do MIBEL, ou seja Portugal ou Espanha, sendo o preço spot de cada país a referência de liquidação. Os produtos transacionados neste mercado poderão ainda ter 2 tipos de liquidação: física, onde existe uma entrega física de eletricidade, designadamente através da sua oferta no mercado diário; ou financeira – *Cash settlement* – havendo a liquidação meramente financeira das posições em aberto (vendedoras e compradoras).

No OMIP, existe ainda a possibilidade de se efetuarem liquidações de operações em “mercado ao balcão” ou OTC (*Over-the-Counter*) já firmadas entre as partes, sendo o mercado organizado a assumir o risco de crédito das contrapartes (com a gestão das necessárias garantias). A negociação no mercado a prazo pode processar-se a dois níveis distintos: em contínuo, dentro do horário de negociação definido no Regulamento de Negociação; ou em leilão, realizando-se atualmente sessões específicas de leilão nas 4

primeiras quartas-feiras de cada mês, existindo obrigações de compra para os comercializadores de último recurso ibéricos.

Os agentes que participam no mercado e podem ser membros do mercado a prazo do MIBEL tratam-se das seguintes entidades:

- Intermediários financeiros, que disponham de capacidade e competência de negociação, bem como de recursos suficientes para exercer as funções a que estão sujeitos;
- Produtores em regime ordinário;
- Comercializadores;
- Outros agentes do sector elétrico.

2.7. MODELOS DE PREVISÃO

Nas últimas décadas têm sido propostos diversos modelos de previsão de preço da energia elétrica, contudo ainda não existe um consenso em relação ao método que deve ser usado para cada um dos três tipos de horizontes temporais – curto, médio e longo prazo. Neste subcapítulo serão abordadas algumas das técnicas de previsão existentes: modelos estatísticos, modelos multiagente e modelos baseados em inteligência computacional.

Modelos Estatísticos

Estes modelos concebem previsões de preços de energia elétrica a partir de uma combinação entre valores históricos do preço e/ou de valores atuais ou históricos de outras variáveis, tais como consumo, produção, meteorológicas entre outras. Loureiro [18] destaca neste âmbito técnicas de séries temporais e modelos GARCH (*Generalized autoregressive conditional heteroskedasticity*). As primeiras, as séries temporais, são muito utilizadas para previsões a curto prazo. No que se refere à ordem das observações, nos modelos de regressão linear é irrelevante para a análise, enquanto que para as séries temporais, a ordem dos dados é indispensável. A metodologia usada na previsão de séries temporais é designada por modelos de ARIMA. Estes modelos são construídos a partir de modelos autorregressivos (AR), modelos integrativos (I) e modelos de média móvel (MA). O formato do modelo matemático é descrito na equação 1.

$$\begin{aligned}
 (1 - B)^d (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p) (1 - \phi_1 B^7) X_1 &= \\
 = \delta + (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_q B^q) (1 - \phi_1 B^{30}) a_1 &
 \end{aligned}
 \tag{1}$$

Em relação aos modelos GARCH, estes tratam-se da generalização dos modelos ARCH propostos por Bollerslev, em 1986. A diferença entre estes modelos é a componente adicional referente à variância condicional nos instantes anteriores. Uma vantagem do GARCH é a possibilidade de ser utilizado para descrever a volatilidade com menos parâmetros do que um modelo ARCH, [19]. Desta forma, o modelo GARCH é definido através das equações 2 e 3.

$$r_t = \sqrt{h_t} \varepsilon_t, \quad 2$$

$$h_t = \alpha_o + \sum_{i=1}^p \alpha_i r_t^2 + \sum_{i=1}^q \beta_j h_{t-j} \quad 3$$

$$\alpha_o > 0, \alpha_i > 0, \beta_j \geq 0$$

Modelos Multiagente

Moreira [15] afirma que os modelos multiagente apresentam uma flexibilidade bastante importante para a análise do comportamento do mercado do setor elétrico. Contudo focam-se mais numa análise qualitativa do que quantitativa. Desta maneira permitem, por exemplo, compreender o que influencia a variação dos preços, contudo, quando se pretendem resultados quantitativos precisos, como no contexto abordado nesta tese, revelam fragilidades. Têm sido pouco utilizados e normalmente são-no como componentes de modelos híbridos.

Modelos baseados em Inteligência Computacional

Segundo Ribeiro [14], a inteligência computacional não tem uma definição consensual. No entanto, este descreve-o como uma classe bastante diversa de técnicas computacionais criadas com o objetivo de resolver problemas, aos quais os métodos tradicionais não dão uma resposta eficaz. Estes modelos são capazes de lidar com problemas complexos e não lineares. Um dos principais métodos desta classe são as redes neuronais artificiais (RNA). Esta técnica utilizada para previsão é utilizada tanto a curto como longo prazo, daí ser o modelo de previsão aplicado nesta dissertação. Os modelos de RNA são uma simplificação do sistema nervoso central do ser humano, isto é, tratam-se de uma estrutura composta por unidades computacionais extremamente conectadas – os chamados neurónios – com capacidade de aprendizagem. Tenta então simular o comportamento do cérebro humano, ao adquirir conhecimento através de interações com o ambiente e armazenando-o nas conexões

entre neurónios. Existem vários tipos de redes neuronais, podendo estas ser classificadas consoante a sua arquitetura e algoritmo de aprendizagem. A primeira diz respeito à forma como estas organizam as ligações entre neurónios e a segunda à maneira como a rede neuronal ajusta os pesos das suas conexões. No capítulo 4 este tema será aprofundado.

2.7.1. MEDIDAS DE AVALIAÇÃO DE DESEMPENHO

No que toca à avaliação da performance do modelo de previsão, 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. Contudo, na Tabela 2 são apresentadas algumas das medidas de precisão mais utilizadas em relação a erros absolutos.

Tabela 2 Indicadores de Erros: Erros Absolutos

	Sigla	Nome	Formula
Normais	AE	<i>Absolute Error</i>	$AE_h = P_h - \hat{P}_h $
	MAE	<i>Mean Absolute Error</i>	$MAE_T = \frac{1}{T} \sum_{h=1}^T [P_h - \hat{P}_h]$
Erros Absolutos	APE	<i>Absolute Percentage Error</i>	$APE_h = \frac{ P_h - \hat{P}_h }{P_h}$
	NMAE	<i>Normalized Mean Absolute Error</i>	$MAE_T = \frac{1}{T} \sum_{h=1}^T \left[\frac{ P_h - \hat{P}_h }{\bar{P}_h} \right]$
Percentuais	MAPE	<i>Mean Absolute Percentage Error</i>	$MAPE_T = \frac{1}{T} \sum_{h=1}^T \left[\frac{ P_h - \hat{P}_h }{P_h} \right]$

Os erros absolutos, a par dos erros quadráticos, são as medidas de precisão mais comumente utilizadas. Para a análise da Tabela 2, considera-se que P_h é o preço real e \hat{P}_h o preço previsto para o período h . Segundo Ribeiro [14], os erros absolutos são difíceis de comparar para

diferentes *datasets*, daí diversos autores preferirem medidas baseadas em erros absolutos normalizados - AE_h/REF , onde REF é considerado um valor de referência. Pode-se utilizar vários tipos de valor de referência, nomeadamente o valor real (P_h) dando origem ao *absolute percentage error* (APE_h) e, caso se opte pela média de um valor de teste, *normalized mean absolute error* (NMAE). A partir do APE_h surge uma das medidas de erro mais populares, o *Mean Absolute Percentage Error* (MAPE), utilizado então nesta dissertação para a avaliação do desempenho dos modelos de previsão criados. Esta medida será abordada de forma mais detalhada no capítulo 4. Através do seu cálculo podem ser construídos histogramas, dos quais se podem retirar vários indicadores estáticos, tal como o desvio padrão.

2.8. CONCLUSÃO

Ao longo deste capítulo, foram retratados temas como a evolução do setor do elétrico, desde a monopolização para um modelo concorrencial, influenciando assim o funcionamento dos mercados. Apresentou-se ainda o modelo organizacional e o funcionamento do MIBEL, tal como os mercados neste inseridos e estudados nesta dissertação: mercado spot (à vista) e mercado a prazo (futuros). Em seguida, foram apresentados diversos modelos de previsão e métodos utilizados para a avaliação do desempenho, onde os utilizados nesta dissertação tratam-se das redes neuronais – muito utilizadas neste tipo de modelo de previsão – e o MAPE.

3. ESTUDO DAS CARACTERÍSTICAS DO PREÇO DA ENERGIA

3.1. INTRODUÇÃO

Um dos aspetos mais cruciais no que toca à previsão do preço da eletricidade é uma boa seleção de variáveis de entrada para o modelo a ser utilizado. Contudo, uma vez que estas decisões têm que ser tomadas tendo como base suposições e onde existe tomada de decisão humana, há espaço para a existência de erros. É portanto de extrema importância o pré-processamento, a seleção e a forma como serão organizadas as variáveis que vão ser utilizadas.

Desta forma procedeu-se à recolha e tratamento de dados que poderiam influenciar o valor do preço da energia elétrica. A volatilidade e a sazonalidade do preço são aspetos mencionados neste capítulo, tendo sido efetuado um estudo sobre estas características. São também analisados os dados tratados nesta fase, por forma a perceber a influência que estes têm na maneira como o preço da energia elétrica evolui, sendo interpretados os resultados.

3.2. RECOLHA E TRATAMENTO DE DADOS

O conjunto dos dados tratados no decorrer deste trabalho, incluem, dados referentes ao preço da energia elétrica, produções de energia por tecnologia e consumos, no Mercado Ibérico de Eletricidade (MIBEL), assim como dados Meteorológicos para a Península Ibérica, durante um período temporal de dois anos.

Numa primeira fase, os dados disponíveis de produções e consumos de energia para Portugal, na fonte que os providenciava¹², apenas permitia obter os ficheiros Excel que abrangiam o intervalo temporal de 01 de julho de 2016 a 30 de junho de 2017. Esta informação estava disponível fornecendo dados relativos aos diagramas de consumo registados em Portugal, relativamente a dados de consumo, importação/exportação e quantidade de energia produzida por tipo de tecnologia, em períodos de quinze minutos. Posteriormente, após contacto com a empresa Smartwatt, empresa de serviços que fornece soluções para sistemas de energia, foram obtidos os restantes dados referentes ao período de 01 de julho de 2015 até 30 de junho de 2016, por forma a obter pelo menos 2 anos inteiros de dados, para melhorar a eficácia dos modelos de previsão a construir, no que diz respeito a previsões de longo prazo (pelo menos um mês).

Quanto ao mesmo tipo de informação relativa a Espanha, foi possível adquirir esses valores na página da internet da Red Eléctrica de España (REE), que disponibiliza o mesmo tipo de informação que a congénere portuguesa, mas em períodos de 10 minutos e com outras divisões por tipo de tecnologia de produção de energia. Isto levou a uma diferente abordagem e daí a uma adaptação dos dados que eram recolhidos em ambas as fontes, para que os dados pudessem ser tratados em conjunto. Essa adaptação passou por agrupar os dados dos tipos de tecnologia, de maneira a fazer um modelo único, agrupando conjuntos em que isso fosse exequível, como por exemplo, agrupar os diferentes tipos de energia de Produção em Regime

¹² Informação recolhida a partir do *website* do Centro de Informação da REN - Redes Energéticas Nacionais, SGPS, S.A

Ordinário (PRO) de energia térmica, num só grupo, somando a energia produzida em cada um. Desta maneira, somou-se a energia produzida a carvão, gás natural e fuel. Outro ajuste necessário, passou pelo tratamento dos dados que estavam de 15 em 15 minutos no caso português, e de 10 em 10 minutos, no caso espanhol, para dados de hora a hora.

Isto levou ao desenvolvimento de dois documentos em Excel, um para os dados de origem portuguesa, outros para os espanhóis, que serviam de *template* para fazer o tratamento dos dados e adaptação ao modelo final, apresentado as produções e consumos somados consoante os grupos pré-estabelecidos. O modelo final, apresentava assim os resultados para: Nuclear, Produção em Regime Ordinário (PRO) Térmica, Hídrica, Eólica, Fotovoltaica, Produção em Regime Especial (PRE) Térmica, Saldo Importador e Carga. A energia hídrica foi considerada em conjunto pois os dados espanhóis não faziam diferenciação entre PRE Hidráulica e PRO Hidráulica, ao contrário dos portugueses, em que os dados separavam Albufeiras, Fios de Água e PRE Hidráulica. Outro pressuposto tido em conta neste tratamento foi a soma dos dados espanhóis de ligação balear com o seu saldo importador. Uma demonstração dos dados recolhidos e tratados de forma a serem apresentados de hora a hora, encontra-se no Anexo A.1.

Relativamente ao preço real da energia elétrica, foi obtido por meio do *website* do Operador de Mercado Ibérico – Pólo Espanhol S.A. (OMIE). Quanto aos dados meteorológicos usados nesta dissertação, foram recolhidos na página de internet da *Weather Underground*, tendo sido escolhidos 28 pontos referentes à Península Ibérica (5 em Portugal e 23 em Espanha), de maneira distribuída, situados em aeroportos públicos e militares, por serem apenas estes os pontos com dados históricos disponíveis. A informação útil recolhida para cada um desses pontos, passou por dados de precipitação; temperaturas mínimas, médias e máximas; e intensidade, rajadas e direção do vento. Mais tarde, foi utilizada a média de todos estes valores para cada dia, de modo a obter valores médios representativos da Península Ibérica. Uma amostra dos dados tratados no que concerne a dados meteorológicos, pode ser consultada no Anexo A.3.

Outra informação tida em conta foi a radiação solar, obtida no *website* PVGIS, tratando-se de dados médios para cada mês, representativos de valores históricos dos últimos anos. Não se tratam dos valores reais dos últimos dois anos, porém, acrescentam dados importantes e bem representativos da realidade, sendo este sítio da *internet* usado para fazer cálculos para

instalação de painéis fotovoltaicos. O Anexo A.4 apresenta os dados considerados para esta informação.

3.3. ANÁLISE DE CORRELAÇÃO

Com o intuito de aumentar a precisão da previsão a efetuar, envergou-se por uma análise de correlação das variáveis recolhidas com o preço da eletricidade. Desta maneira e ao avaliar o grau de relacionamento entre variáveis, é possível descobrir com precisão, o quanto uma variável interfere no resultado de outra. As técnicas associadas à Análise de Correlação representam uma ferramenta fundamental de aplicação nas Ciências Sociais e do comportamento, da Engenharia e das Ciências naturais. Existem diversos critérios de avaliação desta relação, alguns próprios para variáveis que seguem uma distribuição normal e outros para variáveis que não seguem uma distribuição teórica conhecida. Vários trabalhos envergam pela utilização do Coeficiente de correlação de *Pearson*. [20] [21]. No entanto, existem situações em que a relação entre duas variáveis não é linear, ou uma delas não é contínua, ou as observações são selecionadas aleatoriamente. Em situações como estas, outras alternativas de coeficientes deverão ser aplicadas. O método escolhido para estudar a correlação das diferentes variáveis presentes nos dados recolhidos em relação ao preço foi o Coeficiente de *Spearman*.

3.3.1. COEFICIENTE DE SPEARMAN

Este método, também conhecido por Coeficiente de correlação ordinal de *Spearman*, mede a força de ligação entre duas variáveis, sendo tanto maior quanto mais monótona seja a evolução relativa destas, atingindo os valores máximos de +1 ou -1, caso sejam direta ou inversamente proporcionais, respetivamente. O valor indicativo da correlação é representado por ρ , e encontra-se apresentada na Equação 4:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad 4$$

O coeficiente de *Spearman*, ordena os valores das variáveis x_i e y_i separadamente, onde i representa o valor dos postos 1, 2, 3, ..., n . Em seguida é calculada a diferença, d_i , dos postos de x_i e y_i , e o quadrado deste valor (d_i^2). O número de amostras é representado por n .

3.3.2. SAZONALIDADE

Na análise aos dados recolhidos, de 1 de julho de 2015 até 30 de Junho de 2017, correspondentes ao Mercado Ibérico de Electricidade (MIBEL), foram identificados padrões sazonais de variabilidade entre estes, fossem diários, semanais ou anuais.

Padrões diários são facilmente identificáveis ao analisar o modo como varia o preço da energia elétrica ao longo do dia, estando relacionados com a atividade humana e, naturalmente, com o consumo da mesma.

Esta relação pode ser verificada nos gráficos seguintes, Figura 8 e Figura 9, que comparam a relação destas características ao longo do dia.

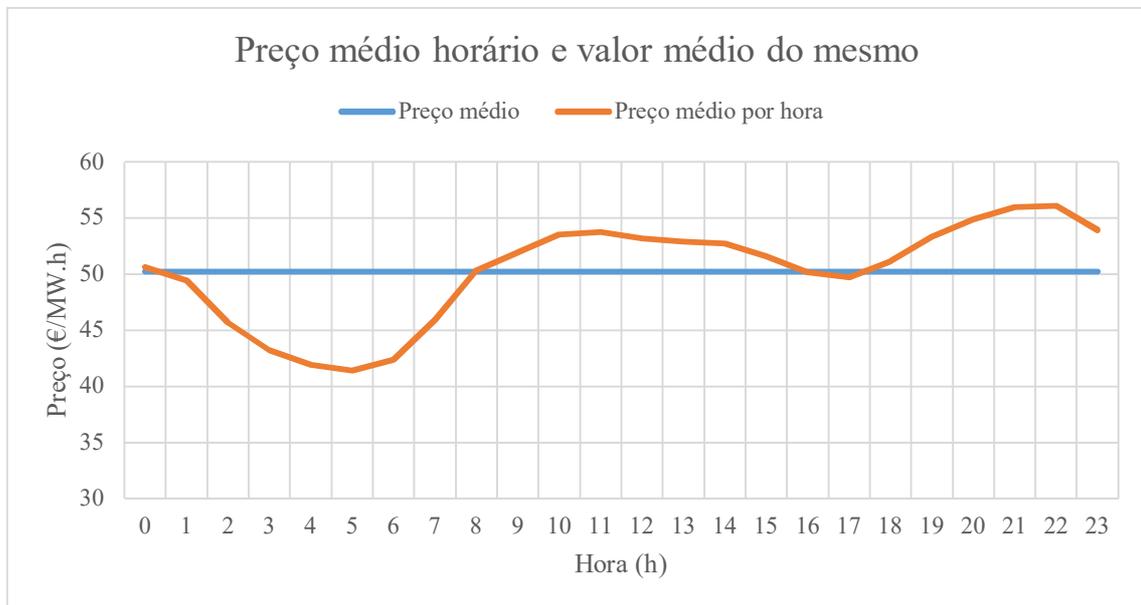


Figura 8 Gráfico Preço médio horário e valor médio de preço

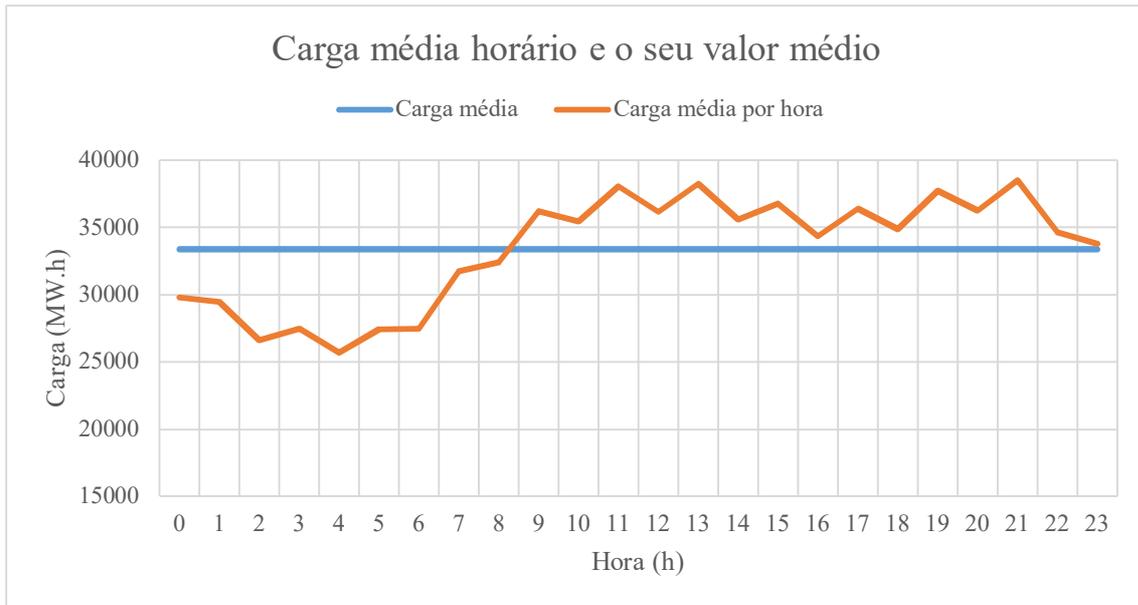


Figura 9 Gráfico Carga média horária e valor médio de carga

Conforme se consegue perceber pelos gráficos apresentados, o preço e a carga variam de maneira equivalente, sendo o mínimo facilmente identificável entre as 2 e as 7 da manhã, e o máximo entre as 9h e as 14h, e entre as 19h e as 23h, para ambos.

Também é possível identificar padrões de variação do preço ao longo da semana, identificando-se que este normalmente é superior às terças, quartas e quintas, e tem os seus valores mínimos habitualmente aos fins-de-semana (Sábado e Domingo). Ao analisar os gráficos seguintes, Figura 10 e Figura 11, percebe-se também que, mais uma vez à semelhança do que acontecia com os padrões evolutivos do preço ao longo do dia, a carga acompanha a evolução do preço.

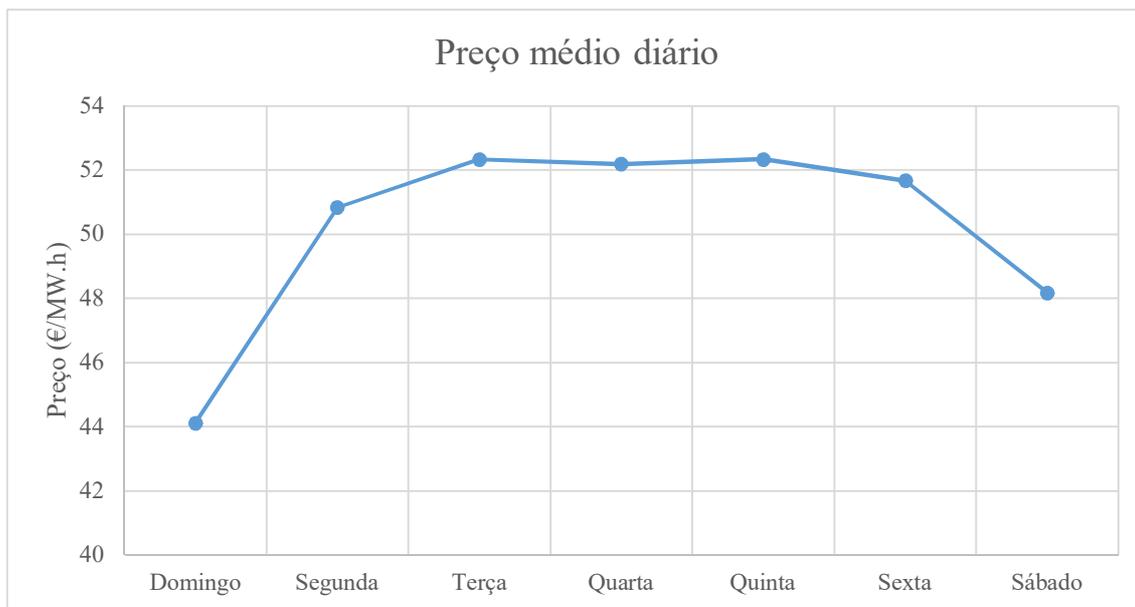


Figura 10 Gráfico Preço médio por dia da semana

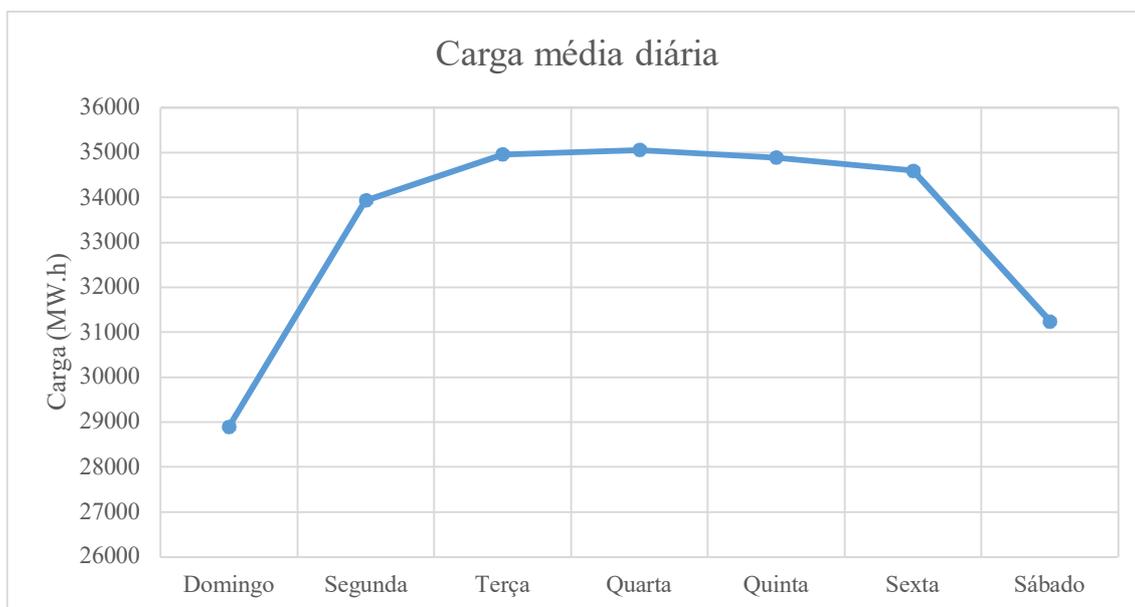


Figura 11 Gráfico Carga média por dia da semana

Em seguida avalia-se a sazonalidade anual do preço e da carga. Esta evolução de preço e carga, podem ser observadas no gráfico seguinte, Figura 12, que contém o desenvolvimento destas duas variáveis para o período de julho de 2015 a junho de 2017. O gráfico contém ainda duas linhas verticais contínuas, a azul, que indicam o primeiro mês de cada ano, ajudando a compreender a transição de um ano para o seguinte, e ainda, barras de erro de desvio padrão da carga, para auxiliar na percepção de picos máximos e mínimos dos dados.

Estes pressupostos serão também utilizados nos gráficos apresentado em seguida neste capítulo

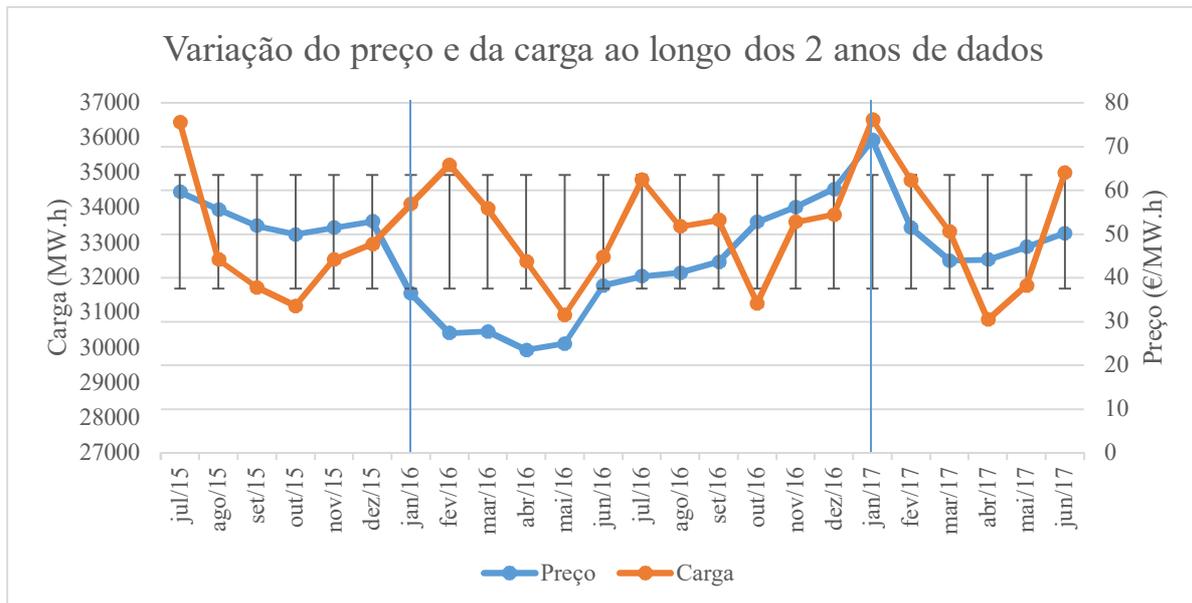


Figura 12 Gráfico da evolução do Preço e da Carga para os 2 anos em análise

Quanto à sazonalidade anual, não se consegue perceber um padrão claro de evolução. Isto pode dever-se à quantidade de dados, que apesar de ser um período de dois anos, pode não ser a mais adequada para este tipo de avaliação. Pelo menos no que toca ao preço, que toma valores mais altos no Verão de 2015, tem uma tendência a diminuir no Inverno e no Verão seguintes, para no Inverno de 2016/2017 obter um pico máximo.

Uma vez que há uma proximidade tão grande entre a variação de preço e carga, pelo menos no que diz respeito à sazonalidade diária e semanal, a carga demonstra ser uma variável a ter em conta para auxiliar na previsão do preço da energia. Esta possibilidade torna-se mais exequível, visto a carga não ser tão volátil como o valor do preço, e depender de menos variáveis, o que faz com que a sua previsão seja mais simples. Desta maneira, prevê-se que sejam obtidos valores mais precisos na sua previsão.

Pode-se, no entanto, notar um padrão evolutivo na carga, pela maneira como evolui com os valores de temperatura média ($T_{méd}$) verificados. Esta obtém valores máximos habitualmente nos picos de Verão e de Inverno. Isto pode também ser observado na Figura 13, em que é apresentada a evolução da carga em relação ao desenvolvimento de valores de temperatura média, ambos os valores relativos a valores para a Península Ibérica.

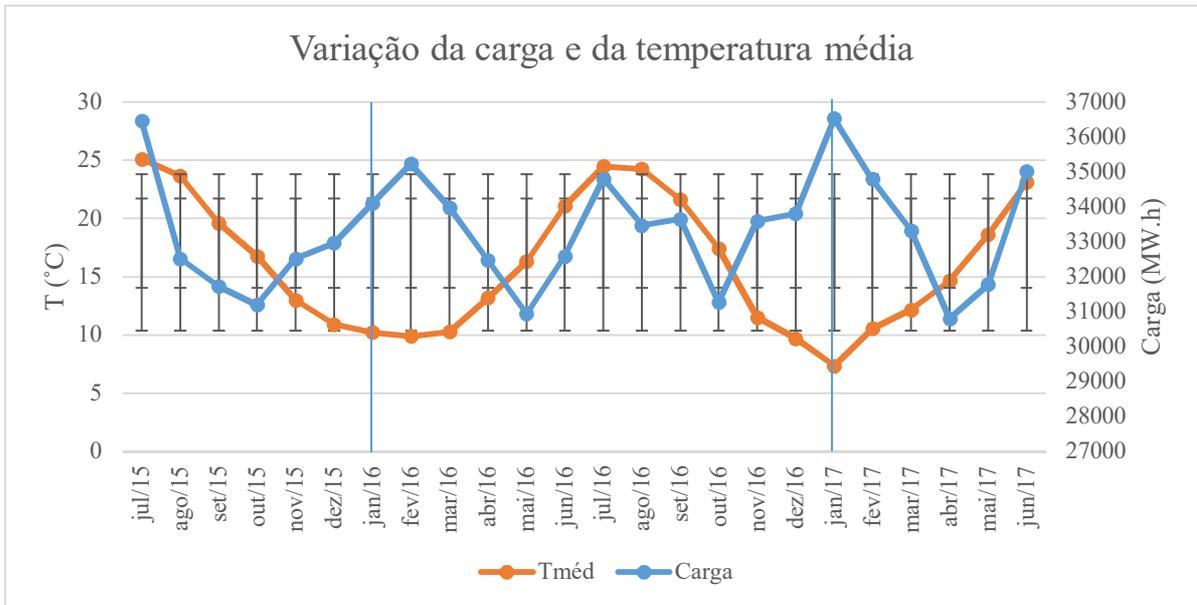


Figura 13 Gráfico da evolução da Carga com a temperatura média nos 2 anos em análise

Pode-se então concluir que quanto mais afastado é o valor da temperatura, do seu próprio valor médio (16,09°C para os dados recolhidos), maior é o valor da carga, levando, ao que tudo indica, a ter uma correlação significativa. Outra característica que varia de certa forma de acordo com a temperatura média, podendo ter também uma ligação ao processo evolutivo da carga, é a radiação solar. Em seguida, pode-se observar a Figura 14 em que é apresentada a variação da carga e da radiação solar, ao longo da janela temporária dos dados avaliados.

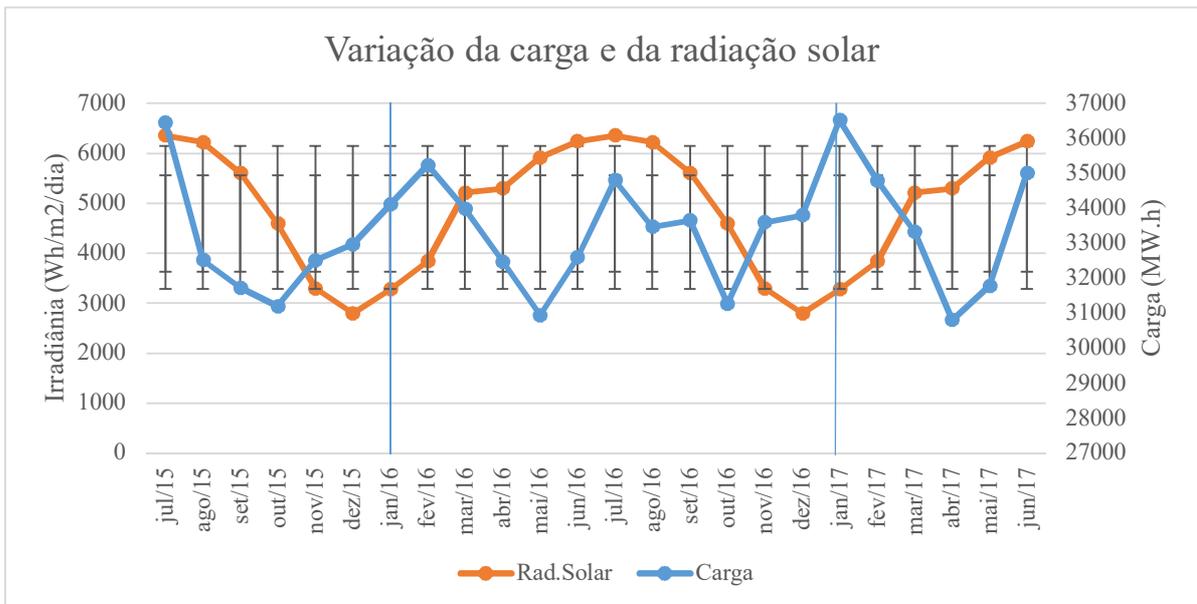


Figura 14 Gráfico da evolução da Carga com a radiação solar média mensal para os 2 anos em análise

Neste caso, embora não se note a mesma correlação entre as duas variáveis através do gráfico, é possível identificar algumas semelhanças em relação à evolução de ambas, com as anteriores na Figura 13, podendo notar que nos picos máximos de radiação solar, a carga também acompanha com os picos máximos, porém nos mínimos relativos a essa variável, os máximos de carga parecem um pouco desfasados. Isto pode dever-se ao facto dos dados recolhidos no que à radiação solar diz respeito, tratarem-se de dados médios representativos de valores históricos do que costuma acontecer nos últimos anos, não sendo informação precisa ou totalmente fidedigna para estes dois anos em análise.

Uma variante da temperatura média e radiação solar que se poderá usar para testar a sua correlação, para inclusão como entrada nos modelos de previsão de carga, é então o desvio das mesmas face aos seus valores médios, uma vez que quanto maior esse valor é, maior também é o valor da carga.

Na Figura 15, é apresentada a evolução da temperatura média, da radiação solar e do preço (temperatura e preço partilham o eixo vertical principal).

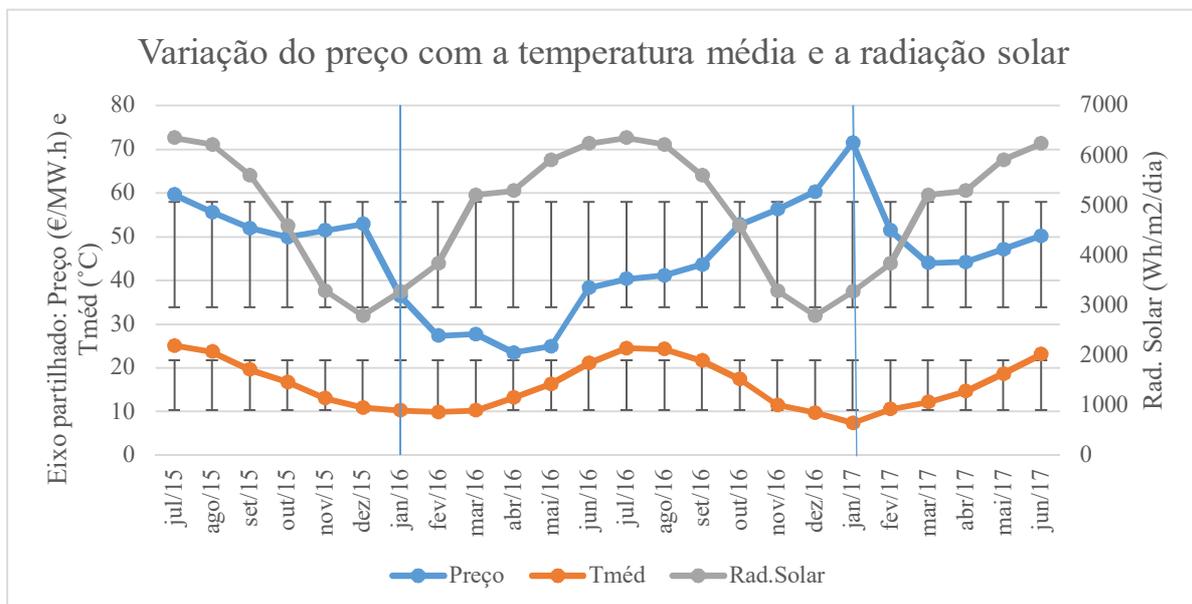


Figura 15 Gráfico da evolução do Preço com a temperatura média e radiação média solar nos 2 anos em análise

Uma vez que a temperatura e a radiação solar têm uma grande correlação entre si, conforme é perceptível no gráfico, no geral variando da mesma maneira, torna mais fácil verificar as alterações destas variáveis face ao preço. Para o primeiro ano, não é clara a compreensão de um padrão nítido na variação destas características (temperatura e radiação solar) relativamente ao preço da energia elétrica. Percebe-se, no entanto, uma correlação negativa (evolução inversamente proporcional) para os dados relativos ao segundo ano. Estes foram os dados usados para os modelos de previsão diário e semanal (01 de julho de 2016 até 30 de junho de 2017), uma vez que seriam previsões de relativo curto prazo. Elegeu-se essa opção uma vez que não seriam necessários dados mais antigos, dada a correlação aparente entre essas variáveis e também devido ao facto de esses dados terem sido obtidos primeiro, face aos do ano anterior.

3.4. INTERPRETAÇÃO DE RESULTADOS

Aqui serão apresentados os resultados obtidos para os dados que foram tratados e testados em relação ao preço e à carga, dada a correlação aparente demonstrada para com o preço, pelo menos a nível diário e semanal de sazonalidade. Uma vez que neste conjunto de dados existe grande diversidade de tipos de variáveis, serão separados de acordo com as suas características. Inicialmente serão apresentados os dados relativos a produções e consumos, para a Península Ibérica.

A notação usada como “(D-1)”, por exemplo, indica o valor da variável referida, 24h antes da hora para a qual se pretende prever (dia-1). Da mesma maneira, “(D-2)” refere-se a 48h antes, e “(S-1)” a 168h antes. No caso de a referência ser “D”, indica que é o valor para o mesmo período para o qual se pretende prever. Inicialmente, em muitas das variáveis aqui testadas, a referência usada é “D” como forma a fazer uma análise prévia se valeria a pena testar para outras referências, uma vez que o valor nesta será, na grande maioria das variáveis, superior a referências prévias, seja 24, 48 ou 168h antes. Na Tabela 3 são apresentados os resultados de coeficiente de *Spearman* obtidos para os dados relativos a produções de energia por tecnologia, e a consumos.

Tabela 3 Correlações do Preço com dados de Carga e Produções por tecnologia

Coefficientes de correlação relativos ao Preço, usando o Coeficiente de Spearman		
Variável testada	Referência cronológica	Valor da correlação em percentagem (ρ)
Carga	D	50,30%
	D-1	38,94%
	D-2	28,64%
	S-1	45,11%
Hidráulica	D-1	31,29%
	D-2	19,00%
	S-1	33,43%
PRO Térmica	D-1	51,88%
	D-2	36,02%
	S-1	51,78%
Eólica	D	-23,30%
MIX1 – Eólica + Fotovoltaica (FV)	D	-22,37%
MIX2 – Eólica + FV + PRE Térm.	D	-20,82%
MIX3 – Eólica + FV + PRE Térm. + Nuclear	D	-24,75%
MIX4 – Hidr. + Eólica + FV + PRE Térm.	D	6,83%
Rácio MIX3/Carga	D-1	-39,73%
	D-2	-22,34%
	S-1	-36,07%

Aqui são apresentadas algumas das variáveis mais preponderantes que foram testadas para a inclusão das mesmas nos modelos de previsão relativos ao preço. Inicialmente testou-se a correlação do mesmo com a carga, visto tratar-se de um dado que poderá ser importante com vista à sua previsão. Como tal, será também testada, da mesma maneira, a relação entre algumas variáveis com a carga consumida, de maneira a construir-se um modelo de previsão da carga para a mesma hora a que se pretende prever o preço, servindo de auxílio, e esperando que melhore as previsões do preço.

Em seguida foram testados alguns grupos de tecnologias energéticas que poderiam ter alguma influência no preço. Uma vez obtido qual o conjunto com uma correlação superior

(MIX3), esse serviu para criar uma nova variável a ser testada: rácio MIX3/Carga. Esta mostrou ser, a par da energia PRO Térmica, uma das que mais influenciavam a evolução do preço, como tal, ambas foram adicionadas para servirem de entradas para os modelos a serem criados.

Inicialmente, conforme se irá verificar no Capítulo 4, as entradas com a referência cronológica “(D-1)”, iriam ser usadas como entradas para os modelos. Porém, após verificar que os dados de consumo e produções para Portugal, apenas estavam disponíveis por volta das 15h do dia seguinte, estes valores foram abandonados e deram lugar aos “(D-2)” ou “(S-1)”, consoante o valor da correlação se revelasse mais preponderante num caso ou no outro. Este valor, habitualmente é maior nas variáveis uma semana antes (168h), dada a importância da sazonalidade semanal, atrás referida.

Também foram avaliados os dados meteorológicos recolhidos para os pontos previamente falados, sendo que estes revelaram ter, no geral, valores mais influentes no desenvolvimento do preço. Junto destes dados, e por se tratarem também de dados meteorológicos, embora de outra fonte e valores mensais ao invés de diários como nos restantes casos, irão ser incluídos os valores de radiação solar. As correlações dos dados falados podem ser verificadas na Tabela 4.

Tabela 4 Correlações do Preço com dados Meteorológicos

Coefficientes de correlação relativos ao Preço, usando o Coeficiente de <i>Spearman</i>		
Variável testada	Referência cronológica	Valor da correlação em percentagem (ρ)
Radiação Solar	D	-83,22%
Temperatura média	D	-57,28%
Vento	D	-34,74%
Precipitação	D-1	-20,96%

Analisando os valores apresentados nesta, percebe-se a importância tanto da radiação solar, como da temperatura, na evolução do preço. Mesmo o vento, demonstra ter mais efeito sobre este, do que a energia eólica produzida. Estes três valores serão então tidos em conta para o modelo de previsão do preço.

Por fim, analisar-se-á a influência que os valores históricos recentes de preço, terão sobre esse mesmo dado. Os valores destes coeficientes de *Spearman* são apresentados na Tabela 5.

Tabela 5 Correlações do Preço com dados Cronológicos do mesmo

Coefficientes de correlação relativos ao Preço, usando o Coeficiente de <i>Spearman</i>		
Variável testada	Referência cronológica	Valor da correlação em percentagem (ρ)
Preço	D-1	76,94%
	S-1	73,79%
	S-2	71,16%

Este valor, conforme seria de esperar, tem uma grande correlação com o preço que se pretende prever, portanto estas serão das principais entradas a serem incluídas nos modelos.

Conforme descrito anteriormente, irá desenvolver-se um modelo de previsão da carga para auxiliar na obtenção de valores precisos de preço. Para isso, avaliou-se também a correlação de alguns dados, com o valor da carga, estando os valores obtidos relativamente às correlações destes dados, apresentados na Tabela 6.

Tabela 6 Correlações da Carga com dados Meteorológicos

Coefficientes de correlação relativos à Carga, usando o Coeficiente de <i>Spearman</i>		
Variável testada	Referência cronológica	Valor da correlação em percentagem (ρ)
Radiação Solar	D	-4,20%
Desvio do valor médio de Radiação Solar	D	72,73%
Temperatura média	D	-4,00%
Desvio do valor médio da Temperatura Média	D	51,64%
Vento	D	15,78%
Precipitação	S-1	-9,33%

Tal como se tinha concluído, aqui é demonstrada a maior percentagem de correlação, em relação à evolução da carga, do desvio dos valores médios de radiação solar e de temperatura

média (“D.Rad.Solar” e “D.Temp.média”, respetivamente), do que dos próprios valores verificados de uma e outra variável. Isto é explicado pela ligação entre estas, e pelo facto de quando ocorrem temperaturas e valores de irradiância mais extremos, há também a necessidade de maiores consumos, para aquecimento/arrefecimento, ou mesmo iluminação.

Mais uma vez, as variáveis históricas irão desempenhar um papel principal na previsão da carga, dando uma ideia da gama de valores mais recentes na Península Ibérica. A sazonalidade semanal da carga é novamente demonstrada ao verificar na Tabela 7 os valores de correlação.

Tabela 7 Correlações da Carga com dados Cronológicos da mesma

Coefficientes de correlação relativos ao Preço, usando o Coeficiente de <i>Spearman</i>		
Variável testada	Referência cronológica	Valor da correlação em percentagem (ρ)
Carga	D-1	81,74%
	D-2	64,90%
	S-1	90,66%
	S-2	86,55%

Nota-se, tal como no caso análogo do preço, uma grande correlação entre os valores disponíveis mais recentes de dados de carga, e os que se pretendem prever com estes. Estas variáveis serão então, mais uma vez, os principais dados a ser usados nos modelos de previsão a aplicar.

Para além das entradas testadas nos quadros apresentados nesta secção, serão também usadas as variáveis cronológicas, devido à variabilidade da carga e do preço consoante a intensidade das atividades de negócio ao longo do dia, semana e, até certo ponto, do ano. Com isto em mente, as variáveis deste tipo a serem utilizadas serão relativas à Hora (H), Dia (D), Dia Da Semana (DDS), Mês (M), Feriados Nacionais (FN) e Sazonalidade (Verão, Inverno ou estações intermédias).

3.5. CONCLUSÕES

Neste capítulo, foram tratados os dados recolhidos, procurando obter um conjunto variado de informação que pudesse ser útil para o objetivo a cumprir. Procurou adaptar-se os dados

para o uso nos diferentes modelos que foram desenvolvidos, e serão falados no capítulo seguinte, consoante o horizonte temporal de cada um. Podem ser consultadas amostras dos dados que foram reunidos para cada modelo, nos Anexos A.1 e A.2. A totalidade da informação recolhida seria demasiado extensa para a sua apresentação integral.

Seguidamente, procedeu-se ao estudo das variáveis do preço e da carga, observando a sazonalidade demonstrada por ambas, fazendo depois a análise dos dados com vista a entender quais teriam uma maior influência no desenvolvimento do valor destas. Essa análise foi feita com o auxílio do coeficiente de *Spearman*, avaliando-se então as variáveis, assim como as referências cronológicas das mesmas, que deveriam ser utilizadas, de um ponto de vista prático e tendo em conta a disponibilidade dos dados no momento da previsão.

Conclui-se que as variáveis com maior coeficiente de *Spearman* relativamente ao valor do preço, para além do valor da carga, são os valores cronológicos da própria variável (tomando valores superiores a 70%), valores meteorológicos de temperatura, vento e radiação solar (cerca de -83%, -35% e -57%, respetivamente) e relativos a produções de energia por tecnologia, sendo a PRO Térmica (52%) e o rácio MIX3/Carga (-36%). Um exemplo dos estudo de correlação efetuados, pode ser consultado no Anexo A.5.

4. PREVISÃO DE PREÇOS DE ENERGIA NO MIBEL

4.1. INTRODUÇÃO

Aqui será explicada a metodologia usada para a aplicação dos três casos de estudo desenvolvidos, sendo eles três modelos de previsão de preço de energia elétrica para três horizontes temporais diferentes: um modelo diário, que prevê o preço da eletricidade para as próximas 24h; um modelo semanal, que faz a previsão do preço para a próxima semana, em valores horários (168); e um modelo mensal, que prevê um valor médio de preço para o mês seguinte. Para todos estes modelos, foram tidas em conta as variáveis estudadas no capítulo 3, sendo usadas as que se julgavam ter mais influência no desenvolvimento do preço da eletricidade.

Para além dos modelos de previsão do preço de mercado, foram também implementados modelos de previsão da carga (para o mesmo horizonte temporal dos modelos de previsão de preço), de forma a mitigar o erro de previsão. Por fim, avaliaram-se os erros dos modelos criados por forma a definir o modelo final, com base na precisão da capacidade de previsão destes, procurou minorar-se o erro e em seguida fez-se uma análise aos valores obtidos.

4.2. PREVISÃO DE PREÇOS DE ELETRICIDADE

Para Azevedo [3], previamente ao processo de reestruturação e liberalização sofrido pelo sector elétrico, habitualmente as variações existentes nas tarifas de energia elétrica eram mínimas e altamente controladas pelo estado ou pelas entidades reguladoras. A evolução dos preços da eletricidade estava muito dependente das políticas praticadas pelos governos, a nível social e industrial, e a previsão da evolução dos preços focava-se sobretudo nos preços dos combustíveis e na evolução tecnológica, sendo que estas normalmente assentavam numa base de longo prazo.

A liberalização, e conseqüente reestruturação deste sector, significou a abertura dos mercados de energia elétrica à livre competição, nos anos noventa, passando a energia a ser comercializada em bolsas (*Pool*) ou mercados organizados, mudando radicalmente a situação vivida até aí. Com isto, um bem que até aí tinha valores estáveis e condicionados, devido à necessidade de manter o sistema em constante equilíbrio, assim como outros fatores, ligados a restrições técnicas do sistema e disponibilidade da produção, por exemplo, estão na base da elevada volatilidade dos preços da energia elétrica. Não só isto, como também a estrutura e a gestão das regras que regem o funcionamento destes mercados, introduzem potenciais fontes de incerteza.

Essa característica do preço da eletricidade, faz com que geradores e distribuidores/retalhistas estejam sujeitos ao risco de preço porque, no caso dos primeiros, por exemplo, vendem a energia a preços variáveis, definidos em *pool*¹³, enquanto os preços dos custos ligados a estes, como combustíveis, podem não variar. Torna-se então de extrema importância, para a definição de estratégias de venda e compra de energia para produtores e consumidores, respetivamente, a previsão do preço de mercado.

¹³ Mercado *spot* centralizado, que administra mecanismos a curto prazo com o objetivo de manter o equilíbrio entre a produção e o consumo, através de ofertas de venda e de compra. Normalmente funciona no dia anterior àquele em que há a entrega física da energia contida nas ofertas.

Desta maneira, uma boa previsão de curto prazo, permitirá a adequação das estratégias, sendo uma ferramenta essencial para os *traders*¹⁴ do mercado energético, por exemplo, por forma a maximizar os seus lucros, no período correspondente. O lucro destes está altamente dependente da capacidade deles em conseguir prever as condições futuras do mercado.

Da mesma forma, possuir uma boa previsão dos preços para médio e longo prazo, permitirá a determinação do *portfolio* de contratos a estabelecer, assim como a energia a ser vendida e/ou comprada no mercado a prazo (futuro), obtendo o melhor resultado possível.

4.2.1. HORIZONTE TEMPORAL

O período temporal compreendido entre os momentos em que a previsão é efetuada e aquele para o qual se pretende prever uma determinada variável, neste caso o preço de energia, é definido como horizonte temporal. Apesar de não haver um consenso quanto aos termos a usar para a definição dos horizontes temporais na literatura relativa à previsão de preço de energia elétrica, Weron [22] afirma que é usual subdividir-se em três tipos de previsão: longo, médio e curto prazo. A separação é feita tendo em conta, essencialmente, o tipo de técnicas e variáveis de influência que são utilizadas no seu desenvolvimento, as suas aplicações e avaliações de desempenho. Tomando como exemplo o erro da previsão: um determinado erro pode ser aceitável para uma previsão de longo prazo (uma vez que existe mais incerteza) e não ser aceitável para uma de curto prazo. Desta maneira, Aggarwal, Saini e Kumar [23] definem este tipo de previsões:

- **Longo Prazo** – a previsão de preço neste horizonte temporal tem em conta períodos de meses, trimestres ou mesmo anos e são usadas principalmente para análises de aproveitamento de investimentos e planeamento. Pode tomar-se como exemplo a determinação de novas localizações ou fontes de combustível para as centrais, tal como referido em [24]. Neste tipo de previsão, normalmente são abordadas técnicas diferentes das de médio e curto prazo.
- **Médio Prazo** – este tipo de previsão encontra-se num intervalo temporal que vai desde alguns dias até meses depois. Normalmente empregues em cálculos de balanços, planeamentos de expansão da produção e de manutenção, na realocação

¹⁴ Tendo em conta a literatura anglo-saxónica, é um indivíduo que se dedica à compra e venda de ativos em mercados financeiros, seja para si ou em nome de outra pessoa.

de recursos e na realização de contratos bilaterais, [25]. A técnica usada para a previsão do preço da energia por vezes é semelhante ao curto prazo.

- **Curto Prazo** – tipo de previsão mais comum. Vão desde alguns minutos até alguns dias depois e são de extrema importância nas operações diárias dos mercados. A título de 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, [25].

Nesta tese, e de acordo com esta definição, apenas foi estudado o mercado a médio prazo (previsão do preço da energia elétrica para uma semana e um mês) e a curto prazo (previsão do preço para um dia). Nos estudos efetuados, as tolerâncias usadas para os erros de previsão do preço da energia são resumidas na Tabela 8, sendo que as previsões a médio prazo se encontram no meio termo, dependendo do horizonte temporal considerado, consoante esteja próximo do seu mínimo (uns dias) ou do seu máximo (entre um a vários meses).

Tabela 8 Tolerância para os erros de previsão do preço de energia

	Curto Prazo	Longo Prazo
Tolerância do erro	Baixa	Alta

Esta baixa tolerância aos erros nos modelos de previsão de preço de curto prazo, prende-se com o facto de os dados históricos obtidos para este serem mais recentes, e haver mais informações disponíveis, como por exemplo, no que diz respeito a dados de previsões meteorológicas. Estes factos ajudam a aumentar bastante a precisão destes modelos, que por norma possuem um horizonte temporal de previsão que vai de alguns minutos até uns dias, havendo então uma menor flexibilidade quanto aos valores de erro obtidos neste caso.

Para os modelos de prazo mais alargado, em que o horizonte temporal considerado pode ir desde uns dias (no caso de médio prazo) até anos (para o longo prazo), o grau de incerteza associado é tão mais elevado quanto maior é o horizonte temporal, dado a falta de muitos dos dados anteriormente mencionados, disponíveis para os de curto prazo. Isto prende-se também pela necessidade de, por vezes, se ter que prever mais variáveis, menos voláteis que o preço, de forma a auxiliar na previsão principal que se pretende fazer, o que aumentará o erro e a incerteza quanto às variáveis em questão.

4.2.2. VARIÁVEIS UTILIZADAS

Na análise dos dados recolhidos e tratados com vista à realização da presente dissertação, classificaram-se e agruparam-se as seguintes variáveis com vista a facilitar o estudo das mesmas:

Variáveis cronológicas

Estas referem-se ao comportamento apresentado pela carga e pelo preço, demonstrando características sazonais diárias, semanais e até mesmo anuais. São incluídas com o objetivo de quantificar e qualificar estas características, tratando-se de referenciar hora, dia, dias da semana (DDS), Mês, feriados nacionais (FN) e sazonalidade.

Variáveis de preço/carga

Variáveis autorregressivas, tratando-se de valores históricos de preço e/ou carga, sejam do dia, semana, mês, ou até de há 12 ou 13 meses atrás, no caso dos modelos de previsão mensal. São importantes na previsão de valores futuros, havendo uma relação estreita normalmente entre esses valores e os dados a prever.

Variáveis de produção elétrica e consumos

Os dados deste tipo que foram recolhidos, apesar de se tratarem de fatores externos, influenciam o mercado de preços de energia elétrica. Estes tratam-se de variáveis que afetam, de maneira positiva ou negativa o preço, consoante o tipo de tecnologia energética.

Variáveis meteorológicas

São variáveis de previsão de fatores climatéricos para o horizonte temporal para o qual se pretende prever o preço/carga. Estes dados, podem ser recolhidos em *websites*, e tratam-se de valores de temperatura, pluviosidade, irradiância, velocidade e direção do vento. Dada a extensão da Península Ibérica, obrigou à recolha destes valores para diversos pontos (na tese em questão foram 28) geograficamente distribuídos, de modo a obter uma média fidedigna dos mesmos. Os pontos a partir dos quais foram recolhidos os dados foram: Porto, Faro, Beja, Montijo e Bragança para Portugal; e Salamanca, Badajoz, Burgos, Córdoba, Albacete, Madrid, Granada, Barcelona, Coruña, Vigo, León,

Santander, Vitória, San Sebastián, Reus, Valência, Alicante, Almería, Sevilha, Saragoça, Maiorca, Valladolid e Ibiza no caso de Espanha.

Variáveis de previsão de carga

Consistem em valores previstos de carga, segundo modelos idealizados para esse efeito, com o objetivo de auxiliar os modelos de previsão do preço a aumentar a sua precisão, ao fornecer mais dados que sirvam de entrada aos mesmos.

4.2.3. AVALIAÇÃO DE DESEMPENHO

Quanto à precisão das previsões de preço, e carga quando necessário, nesta dissertação recorreu-se ao *Mean Absolute Percentage Error* (MAPE) para a avaliação de desempenho dos mesmos. Este indicador permite ter uma ideia da precisão da previsão, comparando a média dos erros absolutos percentuais de cada *output*, com os respetivos valores reais. Este é calculado utilizando a equação 5:

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \frac{|V.Real_i - Output_i|}{V.Real_i} \right) \quad 5$$

Nesta expressão, n corresponde ao número de períodos considerados. O MAPE foi utilizado na avaliação dos modelos de previsão desenvolvidos, fazendo a comparação dos valores reais das variáveis a prever, com os *outputs* resultantes das simulações para cada momento do horizonte temporal de previsão. A construção deste método baseia-se nas fórmulas representadas nas equações 6-9.

$$Erro\ Absoluto = |V.Real - Output| \quad 6$$

$$Erro\ Relativo = \left(\frac{V.Real - Output}{V.Real} \right) \quad 7$$

$$Erro\ Percentual = \left(\frac{V.Real - Output}{V.Real} \right) \times 100\% \quad 8$$

$$Erro\ Absoluto\ Percentual = \left(\frac{|V.Real - Output|}{V.Real} \right) \times 100\% \quad 9$$

Erro Absoluto e Erro (Relativo) Percentual, respetivamente equações 6 e 8, são a base da construção do MAPE que, tal como o próprio nome indica, é o “erro médio absoluto percentual” (em português). O Erro Absoluto Percentual (equação 9) é uma adaptação desses dois outros indicadores, que foram utilizados para auxiliar na análise aos valores previstos, e como cálculos parciais. Este é também normalmente conhecido por *Absolute Percentual Error* (APE) na língua inglesa.

Ainda se recorreu ao uso de medidas de dispersão, como medida de gestão do erro, de forma a identificar e minimizar o mesmo. Após calcular a média e o desvio padrão dos *outputs* para cada período, nos modelos selecionados finais, procedeu-se à construção de um intervalo, ao somar e subtrair o valor do desvio padrão resultante, ao valor médio obtido para cada momento (horas nos modelos diário e semanal, meses no mensal). Em seguida, os valores de *outputs* que não integrassem o intervalo criado, não se incluíam no cálculo final da média, cujo valor foi então considerado para valor previsto final para o momento em questão. Este processo foi repetido para os três modelos desenvolvidos conforme será explicitado nos mesmos. O objetivo deste processo foi diminuir a dispersão dos valores previstos, ignorando os valores que se afastassem demasiado da média, e desta maneira, diminuir a amplitude dos valores, uma vez que é preferível trabalhar com valores com uma variância menor. As fórmulas destas medidas de dispersão podem ser consultadas nas Equações 10-12.

$$\textit{Amplitude} = H = x_{\text{máx}} - x_{\text{mín}} \quad 10$$

$$\textit{Variância} = \sigma^2 = \frac{\sum(x_i - \bar{x})^2}{n} \quad 11$$

$$\textit{Desvio Padrão} = \sigma = \sqrt{\sigma^2} \quad 12$$

4.3. REDES NEURONAIS ARTIFICIAIS

O cérebro humano é um fascinante processador composto de aproximadamente 10 biliões de neurónios. A área da Inteligência Artificial (*Artificial Intelligence* – A.I.) nasce do fascínio de perceber e modular o cérebro humano, de forma a copiar a capacidade de pensar do mesmo. As Redes Neurais Artificiais (RNA), *Artificial Neural Networks* na literatura inglesa, procuram imitar o funcionamento do cérebro humano, tratando-se de modelos simplificados do sistema nervoso central, segundo Cortez e Neves [26]. Estas, através da sua

estrutura composta por unidades computacionais conectadas entre si (neurónios), possuem capacidade de aprendizagem e de armazenamento de conhecimento nas conexões (também designadas por sinapses). As RNA baseiam-se em modelos matemáticos, e têm sido aplicadas à previsão de preços em ambiente de mercado liberalizado, sendo este método aliás, o método de previsão de preços mais comum na literatura. Este método, que funciona por meio de um algoritmo de aprendizagem (sendo *Back-Propagation* e *Levenberg-Marquardt* os dois algoritmos mais comuns), segundo Ribeiro [14], pode ser explicado afirmando que o processo inicial é o de treino, em que são fornecidos à rede *inputs* (variáveis que irão influenciar os resultados) e *targets* (valores a prever, e que correspondem aos valores de *inputs* fornecidos). Neste processo, a rede determina quais as melhores relações entre os dados fornecidos, de forma a que o valor da função de *performance* selecionada seja mínimo, relativamente aos *outputs* produzidos pela rede, e os *outputs* reais (*targets*). A fase seguinte deste processo é a fase de teste em que a rede, após adaptar os pesos das conexões por forma a atingir os valores pretendidos na fase de treino, aplica esses mesmos pesos a um novo conjunto de *inputs* com as mesmas características dos anteriores, não tendo sido anteriormente fornecidos à rede, de maneira a serem calculados novos *outputs*, da variável que se pretendia prever. O desempenho deste processo é depois avaliado, recorrendo a um dos indicadores de avaliação de desempenho apresentados no capítulo 2, e falado com mais detalhe no ponto 4.2.3, o MAPE.

Este foi também o método escolhido para cumprir os objetivos propostos ao longo desta dissertação. Desta maneira, esta propõe-se à criação de modelos de previsão de preço no mercado ibérico de eletricidade (MIBEL), para ambos os mercados existentes: o mercado *spot*, ou à vista, e mercados futuros. Para o primeiro, desenvolveu-se um modelo de previsão, que tem como *output* o valor do preço da eletricidade no MIBEL, para as 24h seguintes ao momento da previsão. Para os mercados a prazo, construíram-se dois modelos diferentes de previsão, um semanal, que prevê os valores horários do preço para as próximas 168 horas (uma semana), e um mensal, que prevê um valor médio dessa mesma variável, para o mês seguinte.

Para realizar as previsões propostas, recorreu-se então às RNA, através do *software* Matlab®. Inicialmente procedeu-se a um teste inicial, para escolher a ferramenta deste *software* que seria utilizada para treinar e simular as redes neuronais que se iriam desenvolver. Este teste

foi feito com o propósito de procurar diminuir o erro dos modelos em questão, sendo que foram definidos dois métodos: no primeiro recorria-se à ferramenta *nftool* (*neural fitting tool*) para a criação das redes com que se iria testar o modelo, e em seguida usava-se essa mesma rede já criada noutra ferramenta do mesmo *software*, o *nntool* (*neural network tool*), para a simulação dos resultados; no segundo método, tanto a criação das redes, como a sua simulação, seriam feitos no *nntool*. Para cada um dos métodos foram gerados 5 *outputs*, com 5 treinos antes das simulações, sendo depois calculado o MAPE de cada simulação, assim como a média destas.

Foi utilizada uma rede de teste, que consistia numa semelhante às utilizadas para o modelo diário, mas que na prática não seria viável, devido à necessidade de previsão de muitas variáveis. Embora com uma diferença pequena, o método com um erro mais reduzido, sendo o selecionado, foi o método 2 (3,52% face a 3,77% do método 1). Todas as simulações e redes geradas posteriormente, foram criadas segundo este mesmo método, com o algoritmo *feedforward backpropagation*, em que o fluxo de informação ocorre de forma unidirecional, progredindo dos neurónios de entrada, para os de saída. De acordo com a arquitetura selecionada para todas as redes desenvolvidas nesta dissertação, tratam-se de redes multicamada, ou *multi-layer perceptrons*, sendo que neste tipo de redes existe uma camada escondida (*hidden layer*) que contém um número variável de neurónios, sendo este um facto que torna este tipo de redes muito usadas. Utilizaram-se redes com duas camadas, sendo que, não havendo uma regra universal para a seleção do número de neurónios na camada escondida, a regra que se usou define a utilização de $3 \times n + 2$ neurónios, sendo n o número de *inputs* da rede. Na Figura 16, pode ver-se um exemplo da aplicação desta regra a uma rede criada com 11 entradas, sendo que, aplicando a regra mencionada, o número de neurónios na *hidden layer* é de 35.

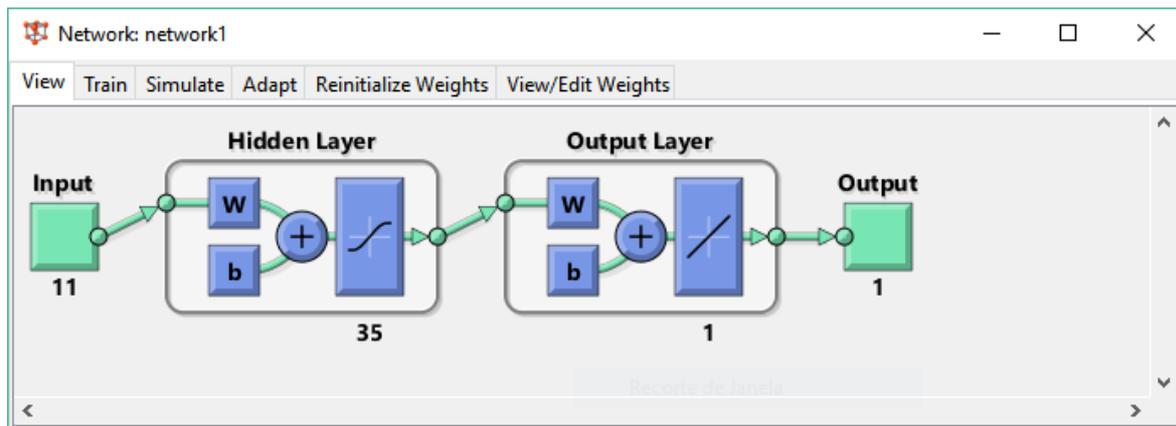


Figura 16 Exemplo da estrutura de uma rede neuronal na ferramenta *nntool* do Matlab®

Nos restantes parâmetros a definir nas redes, utilizou-se como função de treino a *Levenberg-Marquardt backpropagation*, e como funções de adaptação de aprendizagem e de performance, a *learngdm* (*gradient descent with momentum weight and bias learning function*) e a *mse* (*mean-squared error*), respetivamente. Na camada 1 (*hidden layer*) empregou-se a função *tansig* como função de transferência, e na camada 2 (*output layer*) a função *purelin*.

Para recorrer à avaliação das redes a ser construídas, os dados recolhidos e tratados para a construção das mesmas foram divididos. No caso dos modelos diário e semanal, os dados a ser usados foram os dados correspondentes à janela temporal de 01 de julho de 2016 até 30 de junho de 2017. Estes dados foram distribuídos de forma a que a sua divisão fosse de cerca de 85% para os dados de treino, e 15% para os dados de teste. Desta forma, os dados de treino serviriam para treinar as redes neuronais de forma a “ensiná-la” como se havia de comportar, face aos dados apresentados. Este processo de aprendizagem seria depois simulado, com os dados correspondentes aos 15%, representantes dos dados de teste. A repartição feita resultou na escolha aleatória de 8 semanas (cerca de 15,34% da amostra total de 365 dias) para serem testadas, fornecendo os dados de entrada à rede, mas não os dados de *output* esperados. As 8 semanas do conjunto de teste escolhidas foram as seguintes:

- 23 de agosto 2016 até 29 de agosto 2016
- 19 de setembro de 2016 até 25 de setembro de 2016
- 6 de janeiro de 2017 até 12 de janeiro de 2017
- 13 de maio de 2017 até 19 de maio de 2017
- 17 de novembro de 2016 até 23 de novembro de 2016
- 19 de janeiro de 2017 até 25 de janeiro de 2017
- 12 de fevereiro de 2017 até 18 de fevereiro de 2017
- 30 de novembro de 2016 até 6 de dezembro de 2016

Estes conjuntos de treino e teste designados foram utilizados nos modelos diário e semanal. Para o modelo mensal criado, isso não foi possível dada a tipologia das variáveis usadas no mesmo. Nesse modelo, a janela temporal de dados a ser usada, envolveu dados de 01 de julho de 2015, até 30 de junho de 2017, sendo que mais tarde foram obtidos dados para os 2 meses seguintes, julho e agosto de 2017. Isto ocorreu, uma vez que devido às características deste modelo, as variáveis foram adaptadas a valores mensais, e o conjunto de treino continha valores desde agosto de 2016 até julho de 2017, devido às variáveis escolhidas como entrada, pois envolviam entradas com a referência cronológica “(M-12)” e “(M-13)” (12 e 13 meses antes, respetivamente). O conjunto de teste pelo qual se optou foi então o mês de agosto de 2017, de forma a ter uma referência face aos valores do ano anterior, uma vez que os dados recolhidos não seriam os ideais para fazer previsões deste tipo. Um esquema da metodologia desenvolvida para a escolha do melhor modelo para cada um dos horizontes temporais tidos em conta, é apresentado na Figura 17.

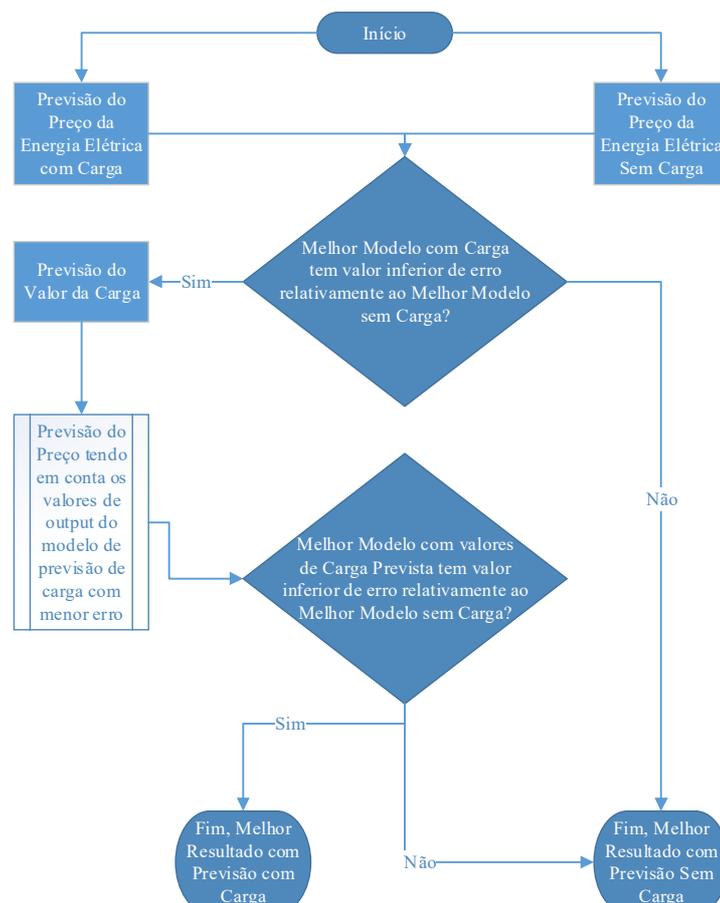


Figura 17 Metodologia desenvolvida para a escolha do melhor modelo

Para implementar todos os casos de estudo desta dissertação, foi utilizado um computador com um processador Intel (R) Core (TM) i7-4710HQ CPU @ 2.50 GHz 2.50 GHz, 8 GB de RAM e com um sistema operativo Windows 10 Home 64-Bit.

4.4. PREVISÃO MERCADO SPOT

Ao longo desta secção será estudado o modelo desenvolvido para este tipo de mercado – o modelo diário. Apresentam-se então os testes que foram efetuados para escolher a melhor parametrização e número de treinos, a construção de modelos para a escolha do melhor conjunto de *inputs* e, finalmente, o processo resultante deste estudo.

4.4.1. DIÁRIO

O Modelo Diário de previsão de Preço, é aquele para o qual há mais informação recente disponível, o que faz com que tenhamos mais variáveis por onde escolher. Isto também faz com a tolerância ao erro seja menor neste modelo, comparativamente ao semanal ou ao mensal, vistos mais à frente. Conforme dito anteriormente no ponto 4.3, o conjunto de teste selecionado, dos dados disponíveis para este modelo (01 de julho de 2016 até 30 de junho de 2017), foram as 8 semanas apresentadas, correspondentes a cerca de 15% dos dados de treino.

Para garantir todos os cuidados a ter em conta para que as previsões realizadas no modelo diário sejam o mais precisas possível, realizaram-se testes suplementares que não foram efetuados de forma tão exaustiva nos restantes modelos. Com isto, antes de proceder ao treino e simulação das redes dos diferentes modelos desenvolvidos, procedeu-se à realização de testes relativos à parametrização ótima a utilizar e ao número de treinos a executar nas simulações deste modelo. Para estes testes, tal como no anterior da ferramenta do Matlab® a utilizar, foi usada a rede de teste. Estes aspetos foram avaliados consoante a posterior análise do resultado do erro MAPE.

O primeiro teste que se efetuou para o modelo diário foi o da parametrização a utilizar no treino das redes, por forma a maximizar a precisão dos modelos a criar. Para esse efeito, foram pensados cinco modelos com diferentes valores de parametrização, fazendo-se variar os valores de nº máximo de verificações de validação sem melhoria de performance (*max_fail*) e de gradiente mínimo de magnitude (valor que se irá tornar muito pequeno à

medida que o treino atinge o mínimo) (*min_grad*). Estes valores são utilizados para finalizar os treinos das redes neuronais, podendo-se tratar de parâmetros críticos, por paragem demasiado prematura dos mesmos.

Cada modelo foi testado cinco vezes, com o intuito de ter mais do que um *output* de maneira a testar mais eficazmente os resultados dos mesmos. Foram então desenvolvidas cinco redes para cada modelo, por forma a perfazer o número de *outputs* desejado, tendo sido executados cinco treinos em cada uma, antes da posterior simulação de resultados destas, que podem ser consultados na Tabela 9.

Tabela 9 Resultados do modelos de parametrização criados

Redes de parametrização	<i>Min_grad</i>	<i>Max_fail</i>	MAPE
Modelo parametrização 1	1e-07	6	3,70%
Modelo parametrização 2	1e-08	30	3,73%
Modelo parametrização 3	1e-08	100	3,49%
Modelo parametrização 4	1e-07	30	3,63%
Modelo parametrização 5	1e-06	100	3,60%

Dos modelos criados e testados, o que obteve um MAPE menor, conforme se pode verificar na Tabela 9, e consequentemente sendo o escolhido, foi o modelo de parametrização 3 com uma percentagem de erro de cerca de 3,49%. Esta foi a parametrização usada para as restantes simulações no modelo de previsão de preço diário.

O teste seguinte a ser desenvolvido foi quanto ao número de treinos a executar, em cada rede, antes de proceder à simulação da mesma. Neste caso, os valores que foram considerados foram de 1, 3 e 5 treinos, tendo sido utilizada, tal como anteriormente nos restantes testes, a rede de teste. Para este teste foram gerados 3 *outputs* para cada caso, estando os resultados relativos ao MAPE de cada um, apresentados na Tabela 10.

Tabela 10 Resultados do teste relativo ao número de treinos a usar

Nº treinos	MAPE
1 Treino	3,68%
3 Treinos	4,22%
5 Treinos	3,79%

Conforme demonstrado na Tabela 10, as redes que se demonstraram mais precisas, neste teste, foram as que se treinaram apenas uma vez, com a parametrização escolhida anteriormente.

Finalizados os testes descritos, como maneira a diminuir ao máximo o erro obtido nas simulações da previsão do preço, procedeu-se então à criação dos modelos a ser desenvolvidos para esse fim, e à posterior análise do erro MAPE para cada um destes. Para o desenvolvimento destes modelos utilizaram-se as variáveis selecionadas com base nos estudos realizados no capítulo 3. Assim, de maneira construtiva, adicionaram-se novas entradas aos modelos prévios. Posteriormente fizeram-se alterações aos modelos anteriores por forma a desenvolver outros que tivessem mais em atenção variáveis com uma correlação positiva ou negativa, respetivamente, os Modelos Preço Diário (MPD) 4 e 5.

A ordem de inclusão das entradas selecionadas nos modelos, foi principalmente baseada no valor da correlação por meio do cálculo do coeficiente de *Spearman*, como referido no capítulo anterior, incluindo também as entradas identificativas quanto ao Dia (D), Hora (H), Mês (M), Dia da Semana (DDS) e Feriados Nacionais (FN). No MPD 01, foram colocadas as entradas consideradas mais significativas na evolução do preço da energia, Preço(D-1) e Preço(S-1) com um valor de coeficiente de *Spearman* de cerca de 0,77 e 0,74, respetivamente. Junto destas variáveis, colocaram-se também a hora e dia para os quais se quer prever o preço. A estas entradas, em seguida, foram adicionadas as restantes variáveis identificativas mencionadas, no segundo modelo.

No terceiro modelo, adicionam-se mais 2 variáveis com uma correlação elevada com o preço da energia elétrica: a radiação solar média (Rad. Solar) para o mês em questão, e a temperatura média (Tméd) verificada nesse dia. Nos dois modelos seguintes, MPD 04 e MPD 05, conforme mencionado, acrescentaram-se em ambos, relativamente ao terceiro modelo, 2 variáveis em cada um: com uma correlação positiva no caso do quarto modelo (0,71 para Preço(S-2) e 0,52 para PRO Térmica(S-1)), e com uma correlação negativa no caso do quinto modelo, uma vez que estas evoluem de maneira inversamente proporcional, face ao valor do preço (rácio MIX3/Carga(S-1) com -0,36, e Vento com -0,35). Nestes dois últimos modelos, optou-se também por retirar a variável correspondente ao mês, das entradas destes, uma vez que se chegou à conclusão que talvez não tivesse uma influência tão

determinante que levasse à sua inclusão, dado que a radiação solar teria mais “peso” do que esta entrada, e sinalizava também a alteração do mês.

Um dos aspetos a ter em conta também na escolha das entradas a utilizar, de um ponto de vista prático, foi a sua disponibilidade para que a previsão pudesse ser feita de um dia para o seguinte, sem a necessidade de se esperar por uma hora mais avançada do mesmo, para que essas informações estivessem disponíveis. Com isto em conta, foi decidido não utilizar os dados de Carga do dia anterior ao da previsão, no caso do modelo de previsão desta, abordado em seguida. Já que esses dados, embora para Espanha estivessem disponíveis quase imediatamente, para Portugal só estavam disponíveis para *download*¹⁵ na plataforma para o efeito, mais de 12h depois. Isto levou a optar-se antes pela entrada Carga(D-2) (valor da carga na Península Ibérica, 48h antes do valor a prever) ao invés de Carga(D-1) (o mesmo valor, 24h antes).

A distribuição das variáveis pelos modelos criados para a previsão de preço para o Mercado Diário, foi a seguinte:

- MPD 01: Preço(D-1) + H + D + Preço(S-1)
- MPD 02: variáveis anteriores + DDS + Mês + FN
- MPD 03: variáveis anteriores + Rad. Solar + T_{méd}
- MPD 04: variáveis anteriores + Preço(S-2) + PRO Térmica(S-1) – Mês
- MPD 05: MPD 03 + rácio MIX3¹⁶/Carga(S-1) + Vento – Mês

Por forma a testar a influência do valor da carga na previsão a realizar do preço da energia elétrica, fizeram-se outros 5 modelos, iguais aos anteriores, mas com a inclusão do valor real da carga verificada:

- MPD 06: Preço(D-1) + H + D + Preço(S-1) + Carga
- MPD 07: variáveis anteriores + DDS + Mês + FN
- MPD 08: variáveis anteriores + Rad. Solar + T_{méd}
- MPD 09: variáveis anteriores + Preço(S-2) + PRO Térm.(S-1) – Mês
- MPD 10: MPD 08 + rácio MIX3/Carga(S-1) + Vento – Mês

¹⁵ Proveniente da literatura anglo-saxónica, significa transferir dados ou ficheiros de um servidor remoto para um computador local

¹⁶ Tal como mencionado anteriormente no capítulo 3, trata-se da soma da energia verificada de Eólica, Fotovoltaica, PRE Térmica e Nuclear, para um determinado momento

Em seguida procedeu-se então ao treino e simulação das redes neuronais criadas através destes modelos, sendo que foram desenvolvidas cinco redes para cada um dos modelos, por forma a que se obtivessem 5 *outputs* diferentes em cada um dos casos, avaliando-se o erro para cada rede e fazendo-se a média em seguida. Esta comparação de erros entre os diferentes modelos, com e sem carga, pode ser verificada na Tabela 11.

Tabela 11 Comparação dos erros MAPE entre modelos previsão do preço

Modelos sem Carga		Modelos com Carga	
MPD 01	9,77%	MPD 06	9,59%
MPD 02	9,49%	MPD 07	9,97%
MPD 03	11,28%	MPD 08	10,66%
MPD 04	10,73%	MPD 09	10,78%
MPD 05	9,56%	MPD 10	8,34%

Conforme se pode verificar, o modelo que obteve um valor mais reduzido de MAPE foi o MPD 02, nos que não incluíam o valor da carga, e o MPD 10, nos que incluíam esse mesmo valor. Uma vez que o valor de erro em MPD 10, ainda foi mais reduzido que em MPD 02, há então a necessidade de testar o modelo de previsão da carga, para acompanhar o desenvolvimento deste. De assinalar, que nem sempre um modelo é mais preciso por ter mais variáveis na sua constituição, conforme é exemplo o modelo sem carga aqui selecionado, o MPD 02, que é dos que possui menos variáveis de todos os desenvolvidos. Para o modelo de previsão da carga, criaram-se, conforme mencionado no capítulo 3, duas novas variáveis criadas de propósito para este, que revelaram ter uma maior correlação do que as variáveis base. Estas foram o desvio da temperatura média e o desvio da radiação solar (D.Tméd e D.Rad.Solar, respetivamente), e explicam-se pelo aumento no consumo da carga, nos períodos em que tanto a temperatura, como a radiação solar, são mais extremas, ou seja, nos seus picos positivos e negativos, atingidos por norma no Verão e no Inverno, nesta ordem.

Sendo assim foram criados 5 modelos com as seguintes características, de modo a prever a carga no MIBEL (denominados de MCD – Modelo de Carga Diário):

- MCD 01: H + D + Carga(S-1)
- MCD 02: variáveis anteriores + DDS + Mês + FN
- MCD 03: variáveis anteriores + Carga(S-2) + Carga(D-2)
- MCD 04: variáveis anteriores + D.Rad.Solar + D.Tméd
- MCD 05: MCD 02 + D.Rad.Solar + Carga(S-2)

A construção destes modelos, seguiu a lógica dos modelos desenvolvidos para a previsão do preço, sendo apenas de mencionar que em MCD 05, utilizaram-se as variáveis do modelo MCD 02, e adicionaram-se apenas as entradas dos modelos posteriores a este que tinham maior correlação, sendo elas Carga(S-2) no caso de MCD 03, e D.Rad.Solar no caso de MCD 04.

Nestes modelos seguiram-se novamente os procedimentos que foram testados previamente quanto ao método a usar, parametrização e número de treinos. Os resultados obtidos nesta simulação podem ser consultados na Tabela 12:

Tabela 12 Comparação dos erros MAPE entre modelos previsão da carga – Modelo Diário

Modelo	MAPE
MCD 01	5,26%
MCD 02	5,29%
MCD 03	4,03%
MCD 04	4,10%
MCD 05	6,74%

O modelo que obteve um MAPE menor foi o MCD 03, com 4,03%. As médias dos valores de carga obtidos para cada hora nas simulações deste, foram então utilizadas como entrada, ou *input*, para testar o modelo MPD 10, de modo a verificar se o erro obtido usando o valor previsto de carga compensaria. Isto foi feito com o intuito de comparar face ao uso do melhor modelo sem o valor da carga nas suas entradas (MPD 02).

Mais uma vez, a simulação desta nova rede (MPD 10 com previsão de carga) foi efetuada tendo em conta os critérios determinados anteriormente, e com 5 *outputs*. A média do erro obtido nestas simulações resultou num MAPE de cerca de 9,32%. Conforme expectável, este valor de erro é superior em relação ao valor obtido para MPD 10 com o valor real de carga. Isto justifica-se, pois a própria previsão da carga tem um erro associado. No entanto este valor mantém-se abaixo do MAPE do melhor modelo sem utilização da carga ($MAPE_{MPD\ 02} = 9,49\%$), fazendo com que estes sejam os modelos selecionados para a previsão do preço no mercado diário.

Finalmente recorreu-se e ao processo explicitado no ponto 4.2.3, para proceder à gestão do erro. Aplicando o dito processo conseguiu-se obter uma redução do erro do modelo final,

que baixou dos 9,32%, para os 8,24%. Na Figura 18 pode ser consultado o resumo do método levado a cabo para a previsão do preço da energia elétrica no modelo diário desenvolvido, e também do valor final de erro que se obteve.

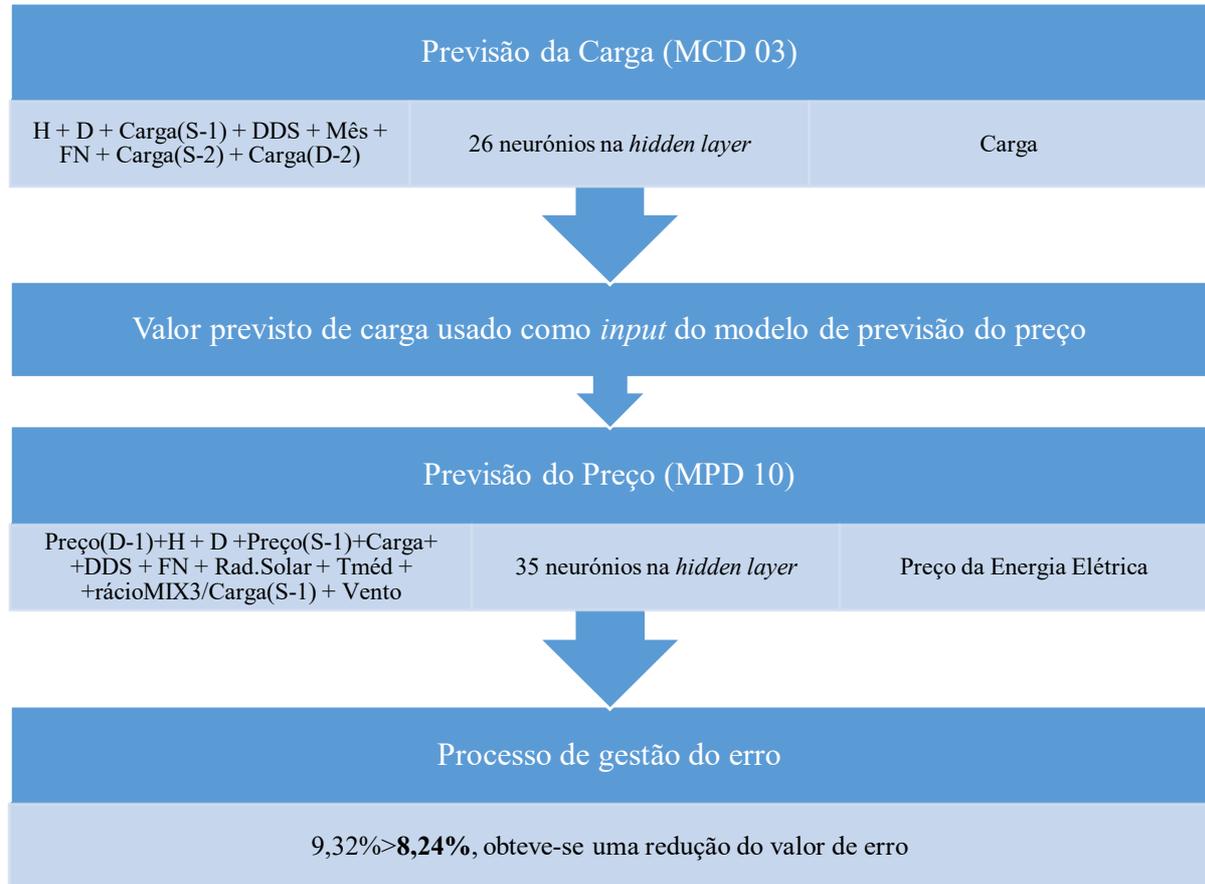


Figura 18 Processo de previsão do Preço da Eletricidade no Modelo Diário

Por fim, calculou-se o coeficiente de *Spearman* dos resultados finais obtidos com os valores reais de preço, e também se recorreu a uma demonstração gráfica desta correlação. O valor obtido foi de 90,54%, e a Figura 19 mostra o gráfico que correlaciona estas duas variáveis.

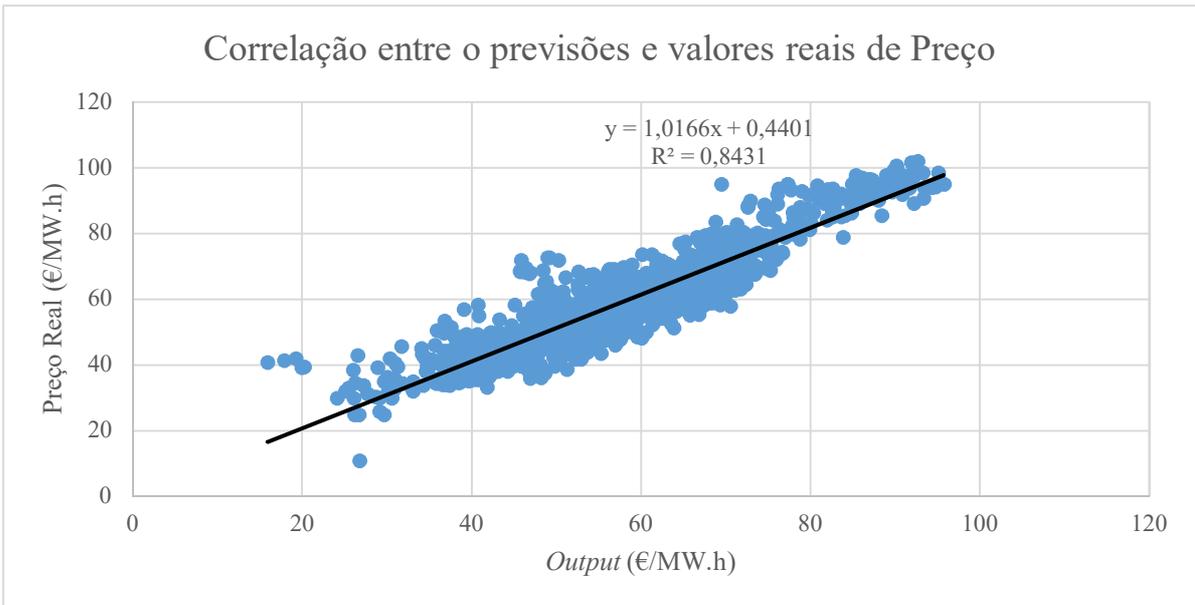


Figura 19 Correlação dos *outputs* finais obtidos com os valores reais de preço (Modelo Diário)

A correlação dos dados calculada desta maneira não obteve um resultado tão promissor como quando calculada através do coeficiente de *Spearman*, no entanto possui um valor bastante aceitável (cerca de 0,84). Em seguida, compararam-se os *outputs* com os valores reais de preço, para a totalidade do conjunto de teste, através do gráfico da Figura 20.

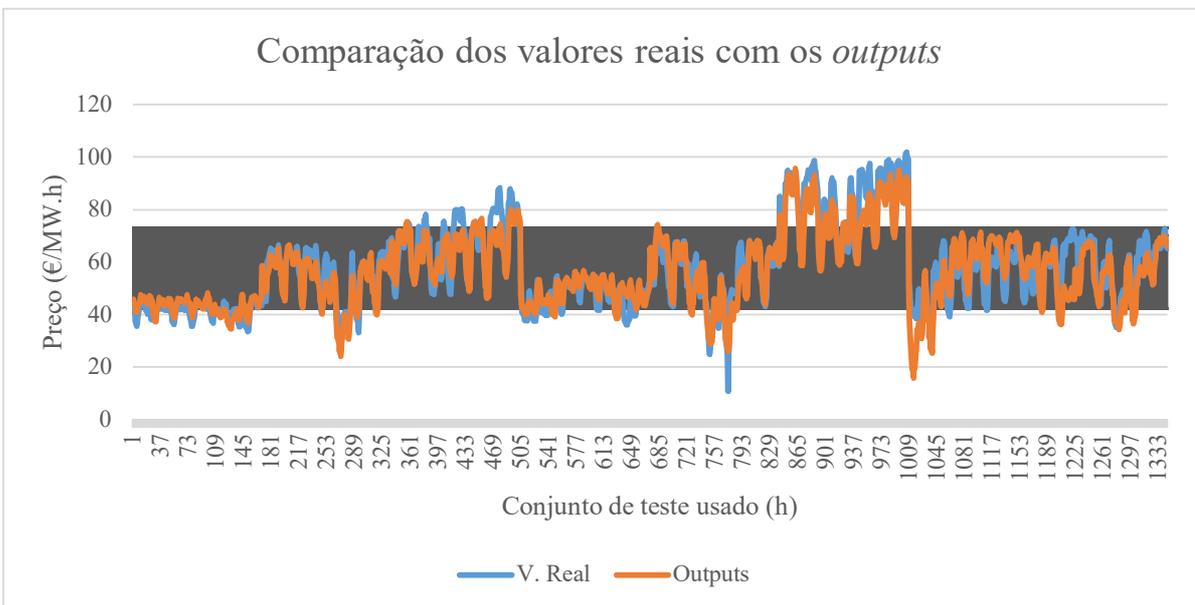


Figura 20 Comparação entre os resultados obtidos e valores reais de preço (Modelo Diário)

Neste, é possível também verificar, a cinzento, a área representativa do desvio padrão dos dados analisados. Pode apurar-se a precisão do modelo selecionado, sendo que o modelo

tem maiores dificuldades em acompanhar o preço real aquando da existência de picos. Por forma a ser mais facilmente visualizada a comparação entre os valores obtidos através da simulação final e do valor real de preço verificado, isolou-se uma semana dentro do conjunto de teste. A semana escolhida é a de 19 de janeiro a 25 de janeiro de 2017, e pode ser verificada na Figura 21.

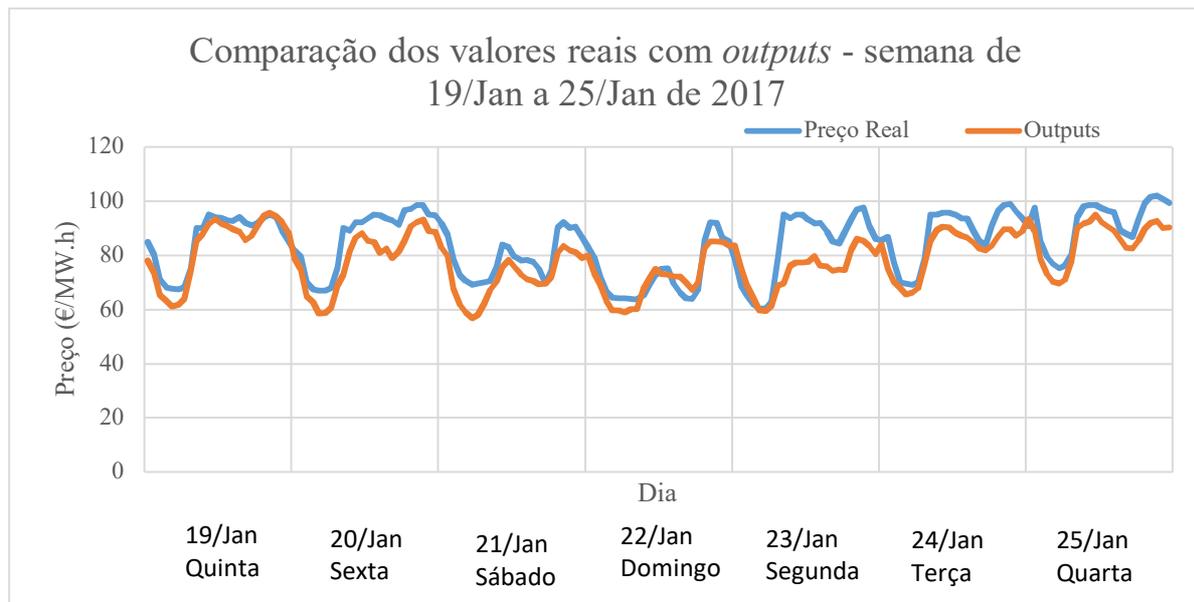


Figura 21 Semana de 19 a 25 de janeiro de 2017, com a comparaç o entre *outputs* e valores reais de preço verificados

Na Figura 22,   poss vel ver esta comparaç o mais em pormenor, tendo-se procedido ao isolamento do dia 19 de janeiro de 2017 (presente na semana seleccionada anteriormente), tendo-se juntado a este gr fico, a informaç o recolhida quanto ao MAPE m dio verificado para cada hora do dia. Para ajudar   an lise do gr fico, inseriu-se tamb m o desvio padr o ocorrido no valor real de pre o.

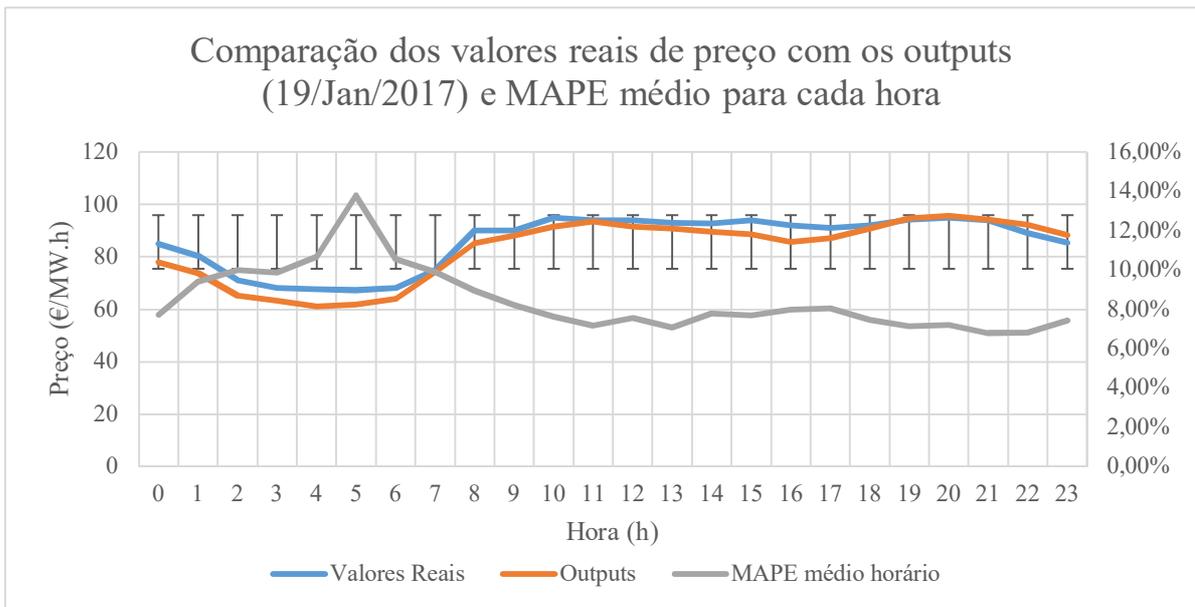


Figura 22 Gráfico que combina a comparação dos valores reais com os *outputs* gerados, e o MAPE médio horário para o total do conjunto de teste

É possível verificar que o maior erro médio verificado é por volta das 4h e 6h da manhã, justamente quando o valor do preço se distancia mais do seu valor médio. Isso deve-se também ao maior erro encontrado na análise aos dados obtidos, que ocorreu justamente às 5h da manhã, falado em seguida e que pode ser verificado na Figura 24. Na Figura 23, abaixo representada, pode ainda verificar-se o histograma dos erros relativos percentuais verificados.

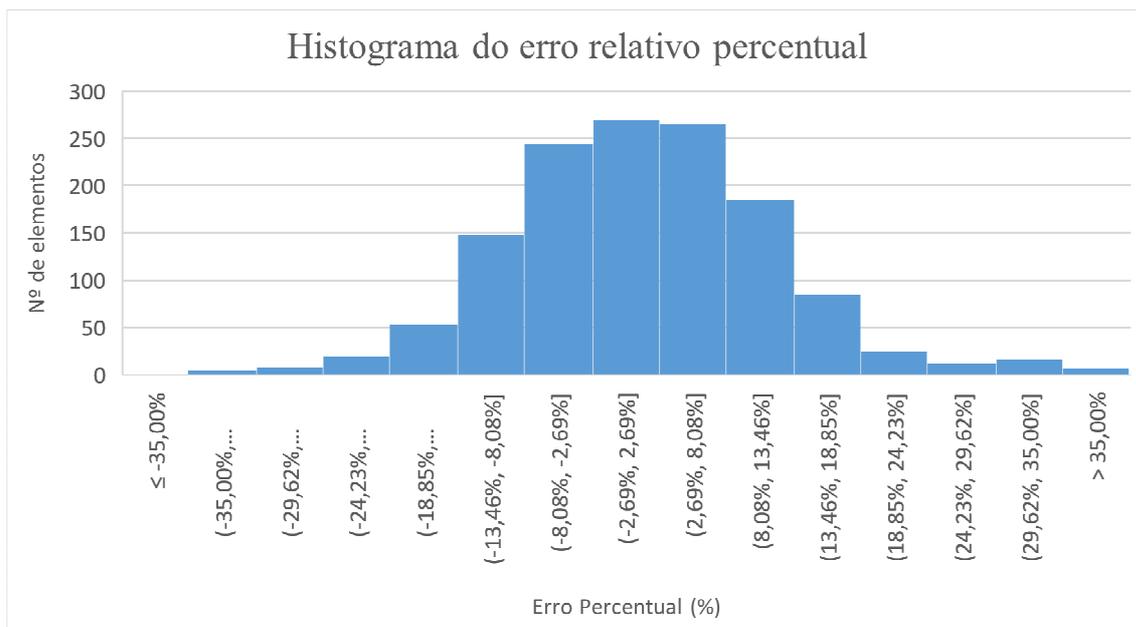


Figura 23 Histograma do erro obtido (Modelo diário)

Como é visível, os erros relativos percentuais obtidos encontram-se centrados no intervalo que contém zero, e situam-se de forma relativamente distribuída em torno deste valor. Em seguida é possível ver o gráfico que demonstra o erro relativo ao longo da amostra do conjunto de teste usado, na Figura 24.

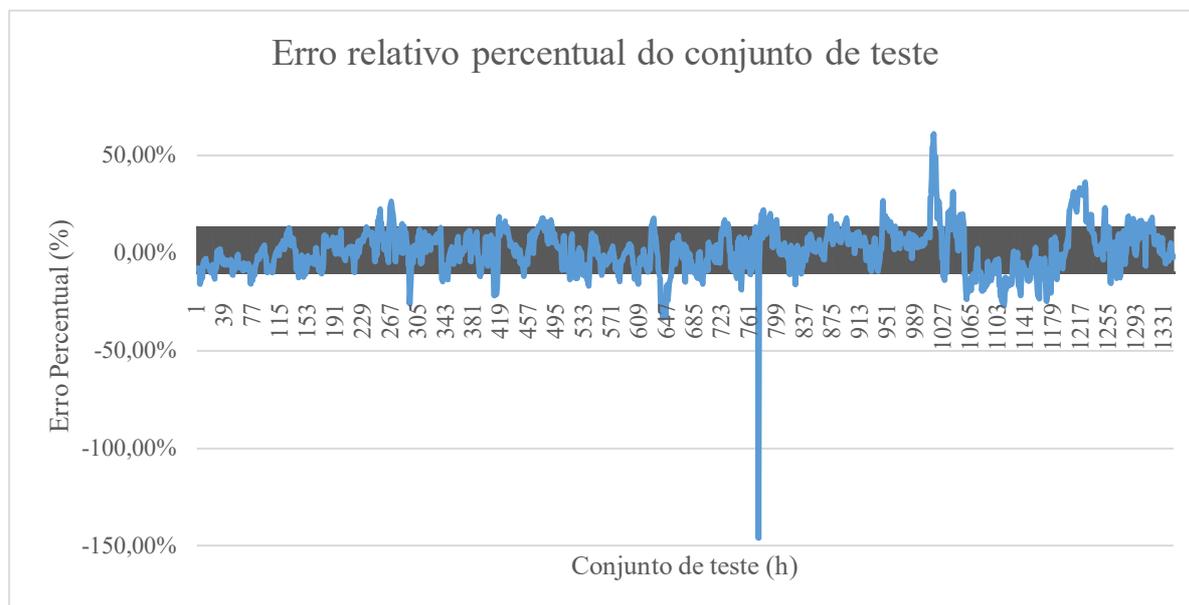


Figura 24 Erro relativo percentual e desvio padrão do mesmo (Modelo diário)

A maioria dos valores encontram-se na zona sombreada, representativa do desvio padrão do erro relativo, sendo que os picos que se verificam devem-se, tal como visto no gráfico da

Figura 20, aos picos verificados no preço real. O maior erro verificado foi de cerca de -146%, e pode dever-se à grande falha apontada ao método usado para a avaliação do desempenho, o MAPE. Essa falha é devida à obtenção de valores de preço real de zero, ou próximos de zero, que fazem com que o erro verificado seja muito elevado, independentemente do erro absoluto que se verifique, [14].

Os resultados obtidos e os cálculos realizados neste modelo, podem ser consultados no Anexo A.6.

4.5. PREVISÃO MERCADOS FUTUROS

Aqui serão desenvolvidos os modelos que têm por base a previsão do preço da energia elétrica no mercado a prazo: modelo semanal e modelo mensal. A estrutura destes teve por base a construção de modelos com diferentes características, uma vez que o modelo semanal prevê o preço para todas as horas da semana seguinte, e o mensal prevê apenas um valor médio para o mês seguinte. Em ambos foram criadas diferentes hipóteses de modelos para serem testados, da mesma forma que no modelo anterior, sendo posteriormente testados com o intuito de verificar qual o mais eficaz no objetivo a cumprir. Os resultados de ambos os modelos são depois apresentados, assim como o procedimento selecionado para cada um deles.

4.5.1. SEMANAL

Tal como com o modelo diário de previsão do preço da energia elétrica, os conjuntos de treino e teste para este modelo são equivalentes, tendo sido expostos no 4.3. Para este modelo, foram feitas simulações com modelos contíguos equivalentes, porém com valores de parametrização diferentes, de modo a testar o mesmo modelo para duas parametrizações diferentes. As parametrizações selecionadas, tal como previamente, passaram por apenas se fazer variar os dois valores referentes ao nº máximo de verificações de validação sem melhoria de performance (*max_fail* no *nntool*) e de gradiente mínimo de magnitude (*min_grad* no *nntool*). A primeira variante de valores era a parametrização por defeito (*default* na literatura inglesa), e a segunda era com os valores que tinham obtido um valor menor de erro no teste efetuado anteriormente no modelo diário. Estes valores podem ser verificados na Tabela 13.

Tabela 13 Modelos de parametrização desenvolvidos

Parametrização 1	<i>Min_grad</i>	1e-07
	<i>Max_fails</i>	6
Parametrização 2	<i>Min_grad</i>	1e-08
	<i>Max_fails</i>	100

O modelo de previsão semanal criado, contrariamente ao modelo anterior, o modelo diário, foi desenvolvido de maneira destrutiva, ou seja, os modelos iniciais (1 e 2) começam com todas as variáveis ao dispor, tendo estas sido selecionadas entre os valores obtidos de correlação para com a variável em questão, neste caso, o preço. Estas variáveis são Hora (H), Dia (D) Dia da Semana (DDS), Mês (M), Feriado Nacional (FN), Preço(S-1), Preço(S-2), Carga, Radiação Solar (Rad.Solar), Temperatura média (T_{méd}), Sazonalidade (Saz.) e PRO Térmica(S-1) (PRO Térm.(S-1)). Esta decisão foi tomada face à menor quantidade de dados com coeficientes de correlação de valor a considerar.

O par de modelos seguintes (3 e 4), foram pensados sem o valor da carga para o mesmo horizonte temporal do preço a prever. Para os modelos 5 e 6, retiraram-se também as variáveis da Sazonalidade e de PRO Térmica(S-1), para além da Carga. Por fim, nos modelos 7 e 8, acrescentou-se o valor da Carga aos anteriores, mantendo de fora as outras duas variáveis retiradas nestes.

Os modelos terão a denominação MPS – Modelo Preço Semanal – e o aspeto final dos modelos usados para a previsão semanal de preços, no que à distribuição das variáveis diz respeito, pode verificar-se em seguida:

Tabela 14 Constituição dos modelos de previsão semanal

	H	D	DDS	M	FN	Preço (S-1)	Preço (S-2)	Carga	Rad. Solar	Tméd	Saz.	PRO Térm. (S-1)
MPS 01	X	X	X	X	X	X	X	X	X	X	X	X
MPS 02	X	X	X	X	X	X	X	X	X	X	X	X
MPS 03	X	X	X	X	X	X	X		X	X	X	X
MPS 04	X	X	X	X	X	X	X		X	X	X	X
MPS 05	X	X	X	X	X	X	X		X	X		
MPS 06	X	X	X	X	X	X	X		X	X		
MPS 07	X	X	X	X	X	X	X	X	X	X		
MPS 08	X	X	X	X	X	X	X	X	X	X		

Com a construção dos modelos eleita, passou-se então à simulação dos mesmos. Esta fez-se usando a ferramenta do Matlab®, *nntool*, e usando como critério de treino para cada rede, o gráfico da regressão (*regression* na literatura inglesa) e os valores aí apresentados, sendo que os treinos variavam em cada rede, entre 1 e 3 treinos, consoante os valores eram satisfatórios ou não (normalmente próximos de 1). A Figura 25 apresenta o exemplo de um gráfico de regressão.

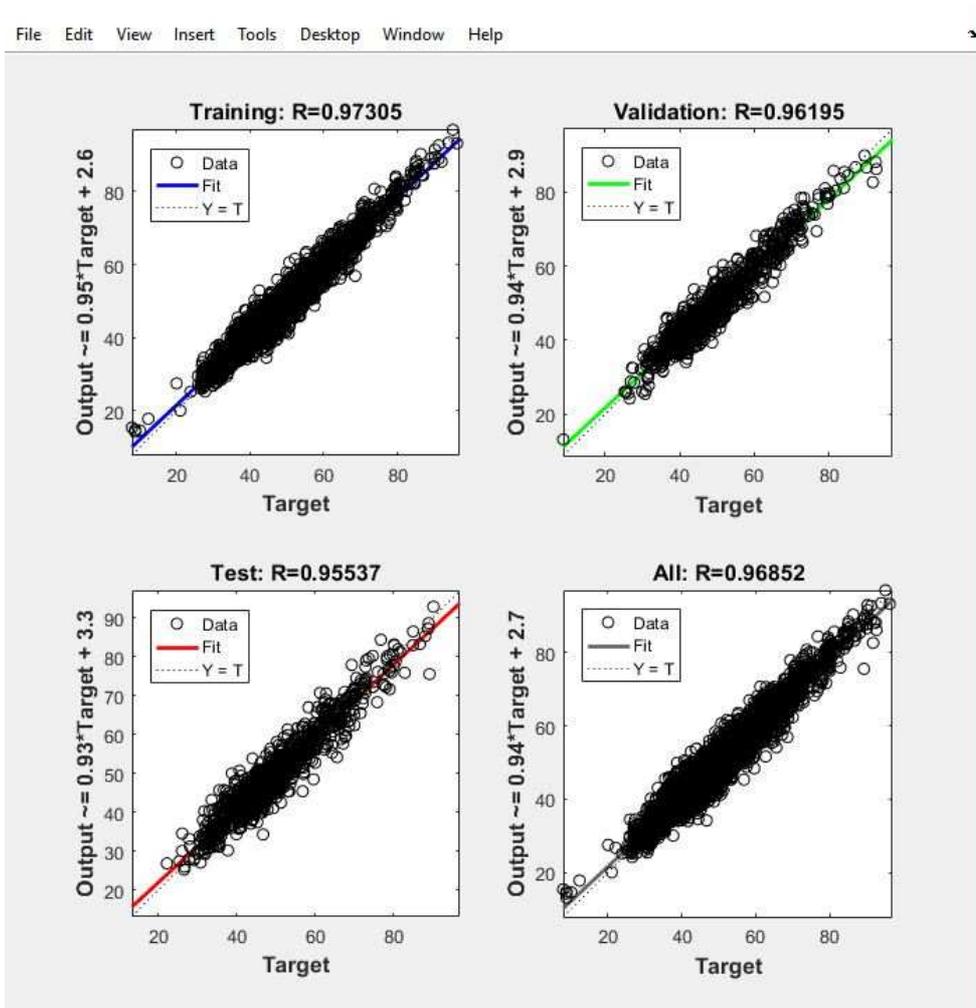


Figura 25 Exemplo de um gráfico de regressão, da ferramenta *nttool*

Em seguida podem ser visualizados os valores obtidos de MAPE nas simulações efetuadas nos modelos de previsão de preço semanais, na Tabela 15.

Tabela 15 Resultados dos modelos de previsão semanais

Modelo	MAPE
MPS 01 (param.1; com Carga)	11,08%
MPS 02 (param.2; com Carga)	12,03%
MPS 03 (param.1; sem Carga)	13,13%
MPS 04 (param.2; sem Carga)	12,52%
MPS 05 (param.1; sem Carga)	12,49%
MPS 06 (param.2; sem Carga)	13,19%
MPS 07 (param.1; com Carga)	10,77%
MPS 08 (param.2; com Carga)	10,71%

Conforme se pode verificar, dentro do grupo dos modelos que continha a carga como uma das suas entradas, o modelo com o menor erro de previsão é o MPS 08, sendo o MPS 05 o que contém um erro menor nos que não incluem a carga como entrada. Uma vez que o modelo com menor erro de todos os testados, é um com a carga nas suas variáveis de entrada, terá de ser desenvolvido um modelo de previsão de carga semanal também neste caso, de forma análoga à anterior. Tal como ocorreu no modelo diário, neste caso, mais uma vez, os modelos selecionados não são os que possuem mais variáveis na sua constituição, sendo que pesa mais a qualidade das variáveis selecionadas, do que a quantidade das mesmas.

A estrutura dos modelos para a previsão da carga foi criada da mesma forma que a de preço, de forma destrutiva, eliminando elementos ao primeiro modelo, que continha todas as entradas consideradas. Da mesma maneira, também foi utilizada a alternância entre os dois modelos de parametrização estimados anteriormente. Desta forma, obtiveram-se os seguintes modelos com a gestão das entradas ponderadas, utilizando todas nos primeiros 2 modelos (1 e 2), e em seguida retirando entradas que não devessem ter tanta preponderância na evolução da carga. Nos modelos seguintes (3 e 4) foi retirada a Sazonalidade apenas, e nos restantes dois modelos (5 e 6) também a informação relativa ao Mês.

A constituição dos modelos criados pode ser visualizada na Tabela 16, que demonstra os modelos de previsão de carga semanais (MCS – Modelo Carga Semanal).

Tabela 16 Constituição dos modelos de previsão de carga semanais

	H	D	DDS	M	FN	Carga (S-1)	Carga (S-2)	D.Rad.Solar	D.Tméd	Saz.
MCS 01	X	X	X	X	X	X	X	X	X	X
MCS 02	X	X	X	X	X	X	X	X	X	X
MCS 03	X	X	X	X	X	X	X	X	X	
MCS 04	X	X	X	X	X	X	X	X	X	
MCS 05	X	X	X		X	X	X	X	X	
MCS 06	X	X	X		X	X	X	X	X	

Uma vez que a carga não tem caracteristicamente a volatilidade do preço, sendo mais facilmente previsível, até por depender de menos variáveis que este, espera-se que os erros MAPE obtidos sejam menores. Estes valores podem ser consultados na Tabela 17.

Tabela 17 Resultados dos modelos de previsão de carga semanais

Modelos	MAPE
MCS 01 (param.1)	6,22%
MCS 02 (param.2)	6,68%
MCS 03 (param.1)	6,19%
MCS 04 (param.2)	5,96%
MCS 05 (param.1)	5,95%
MCS 06 (param.2)	5,66%

O MCS 06 foi o modelo com o erro menor, confirmando a expectativa de que a retirada das duas variáveis de entrada selecionadas (sazonalidade e mês) iria melhorar os valores de previsão. Também conforme o esperado, os erros aqui apresentados têm uma percentagem menor, face aos exibidos na previsão do preço. Uma vez que se obteve o modelo selecionado para a previsão da carga, irá utilizar-se a média dos valores resultantes das simulações deste modelo, para cada hora, de forma a usar-se como entrada no modelo que obteve um erro menor na previsão de preço, e continha a carga nos seus *inputs*, para este horizonte temporal, o MPS 08.

Novamente, a simulação desta nova rede (MPS 08 com previsão de carga) foi realizada tendo em conta os critérios determinados anteriormente, e com 5 *outputs*. A média do erro alcançado nestas simulações resultou num MAPE de cerca de 11,40%. Como se esperava, este valor de erro é superior em relação ao valor obtido para MPS 08 com o valor real de carga, justificando-se devido à própria previsão da carga ter um erro associado. No entanto, uma vez que este valor resultante se mantém abaixo do MAPE do melhor modelo sem utilização da carga ($MAPE_{MPS\ 05} = 12,49\%$), faz com que estes sejam os modelos selecionados para a previsão do preço (e carga) no modelo semanal.

Tal como no modelo anterior, também se recorreu à realização do processo descrito em 4.2.3 com vista a reduzir o erro apresentado pelo modelo final selecionado, com o auxílio do cálculo do desvio padrão. Este processo conseguiu, ao diminuir a dispersão dos valores

previstos para cada hora, uma redução do erro obtido de 11,40%, para 9,44%. Um resumo do método levado a cabo para a previsão do preço no modelo semanal é demonstrado na Figura 26.

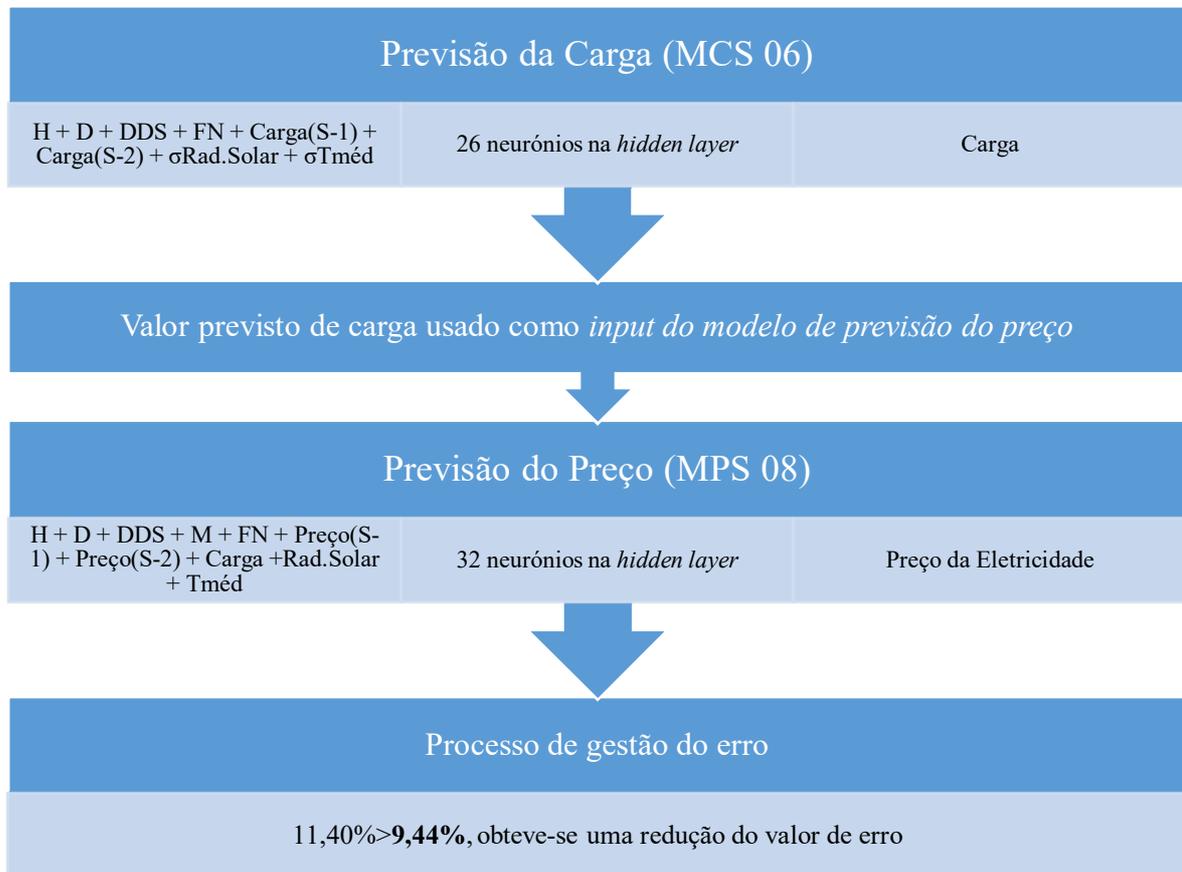


Figura 26 Método usado para a previsão do preço da eletricidade com o Modelo Semanal

Por fim, tal como no modelo diário, calculou-se o coeficiente de *Spearman* dos resultados obtidos no modelo final com os valores reais de preço, e recorreu-se também a uma demonstração gráfica desta relação. O valor obtido através do cálculo do coeficiente de *Spearman* foi de cerca de 88%, e a Figura 27 mostra o gráfico que relaciona estas duas variáveis.

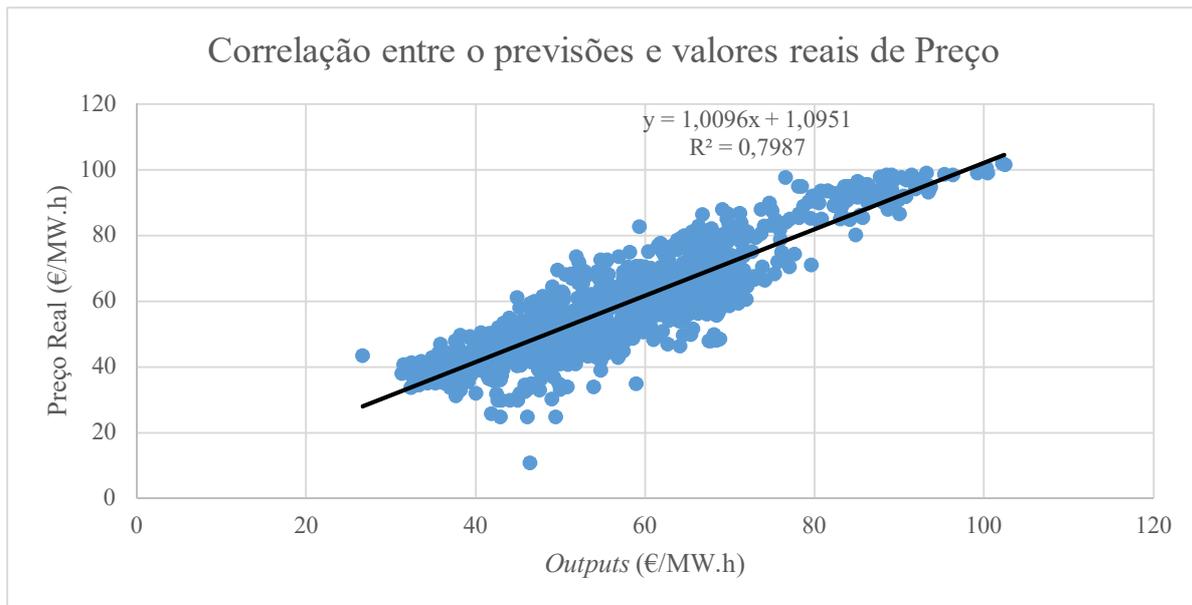


Figura 27 Relação entre as previsões e os valores reais de preço, para o modelo semanal

A correlação dos dados, calculada com recurso ao gráfico, não obteve um resultado tão promissor como quando calculada através do coeficiente de *Spearman*, tal como no caso anterior, sendo que ambos os valores ficaram aquém dos obtidos no modelo diário, conforme seria de esperar. Em seguida, compararam-se os valores de previsão com os valores reais de preço, para o conjunto de teste, através do gráfico da Figura 28.

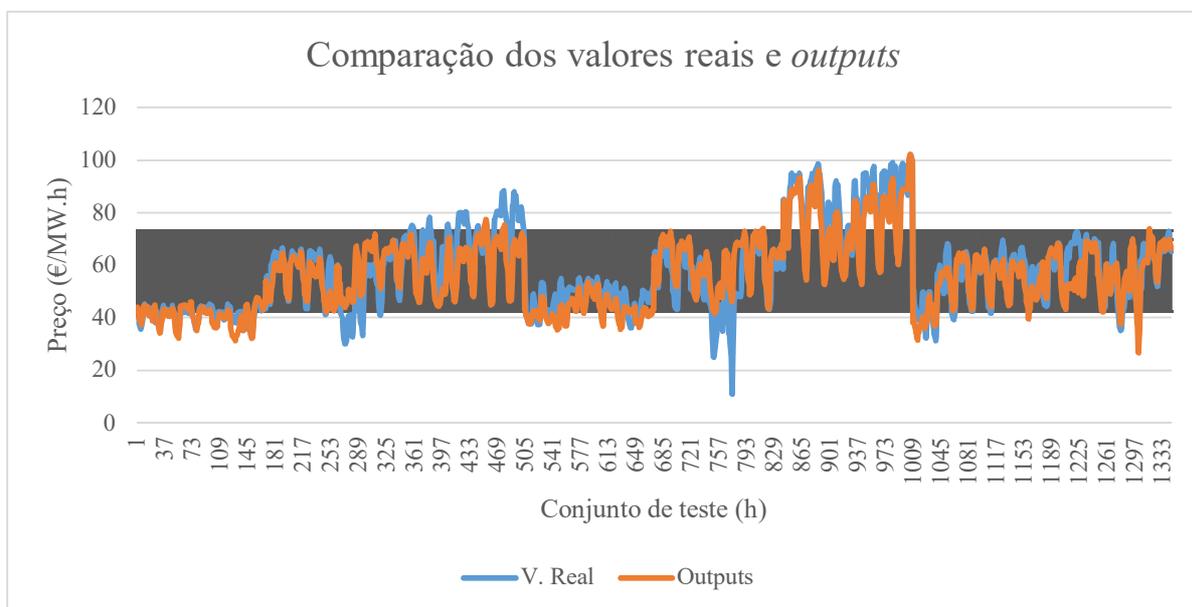


Figura 28 Comparação entre os resultados obtidos e valores reais de preço (modelo semanal)

Neste, é possível apurar, a cinzento, a área representativa do desvio padrão dos dados analisados. É possível averiguar a precisão do modelo selecionado, sendo que o modelo, tal como com o modelo diário, parece ter maiores dificuldades em acompanhar o preço real aquando da existência de picos. Mais uma vez isolou-se a semana de 19 a 25 de janeiro de 2017 com os resultados obtidos nas simulações deste modelo de previsão, com vista à comparação com os valores verificados nessa mesma semana para os preços de eletricidade. A Figura 29 ilustra essa comparação.

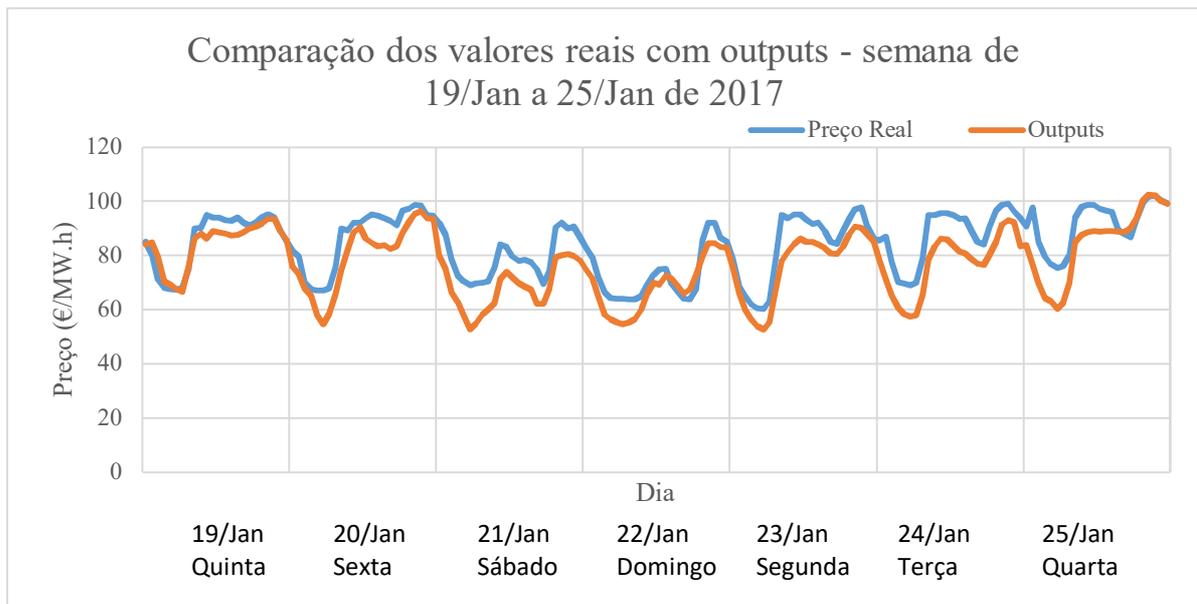


Figura 29 Semana de 19 a 25 de janeiro de 2017, com a comparação dos valores reais de preço e *outputs* obtidos (modelo semanal)

Aqui pode ser visualizada a diferença que existe entre os *outputs* que são gerados pelo modelo semanal desenvolvido, e o valor verificado na realidade para o preço da energia elétrica. Conforme é possível observar, os valores gerados pelo modelo, normalmente apresentam-se ligeiramente abaixo dos valores reais de preço, no que toca aos dados da semana pela qual se optou. No entanto os valores conseguem acompanhar a evolução deste, apesar da volatilidade do mesmo.

Em seguida, pode-se verificar na Figura 30, tal como no modelo diário, a representação gráfica do dia 19 de janeiro de 2017 isolado, e também o MAPE médio horário verificado para este modelo, no conjunto de teste.

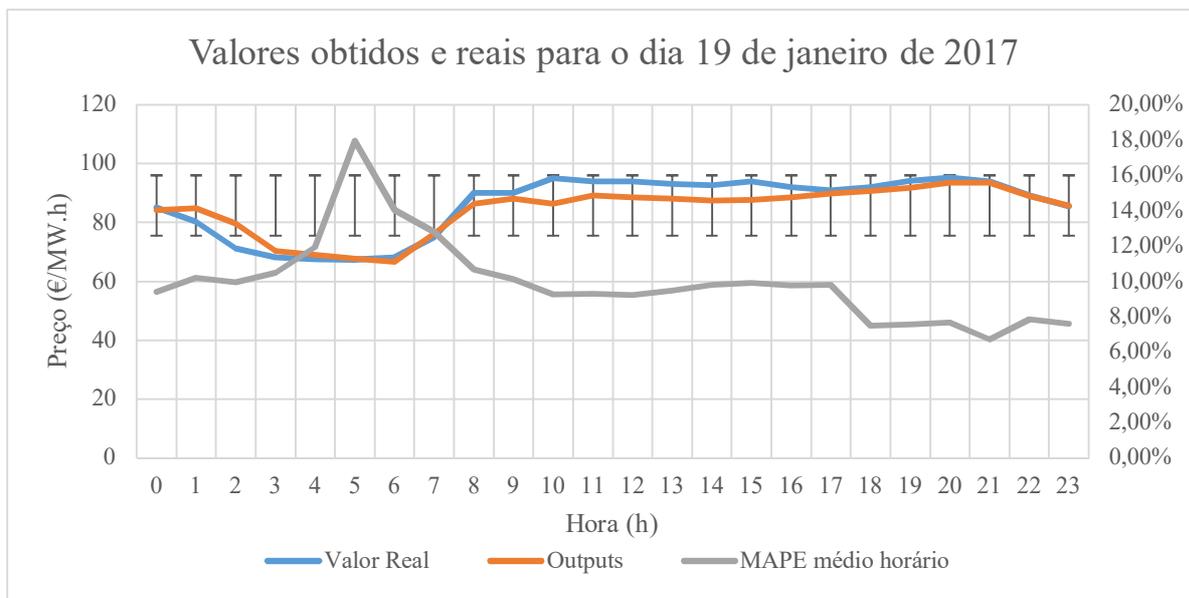


Figura 30 19/01/2017, com valores obtidos e reais, e MAPE médio horário para o conjunto de teste

Também é possível verificar a variação do MAPE médio para cada hora, sendo semelhante à verificada no modelo anterior. Tal como foi mencionado, a razão pela qual o erro às 5h da manhã é tão elevado, deve-se em parte ao erro máximo verificado neste modelo, tendo ocorrido a essa mesma hora. Outro dado a apontar é, mais uma vez, o afastamento dos valores em que o MAPE verificado é superior, face ao desvio padrão e ao valor médio do preço. Na Figura 31, abaixo representada, pode ainda verificar-se o histograma dos erros verificados.

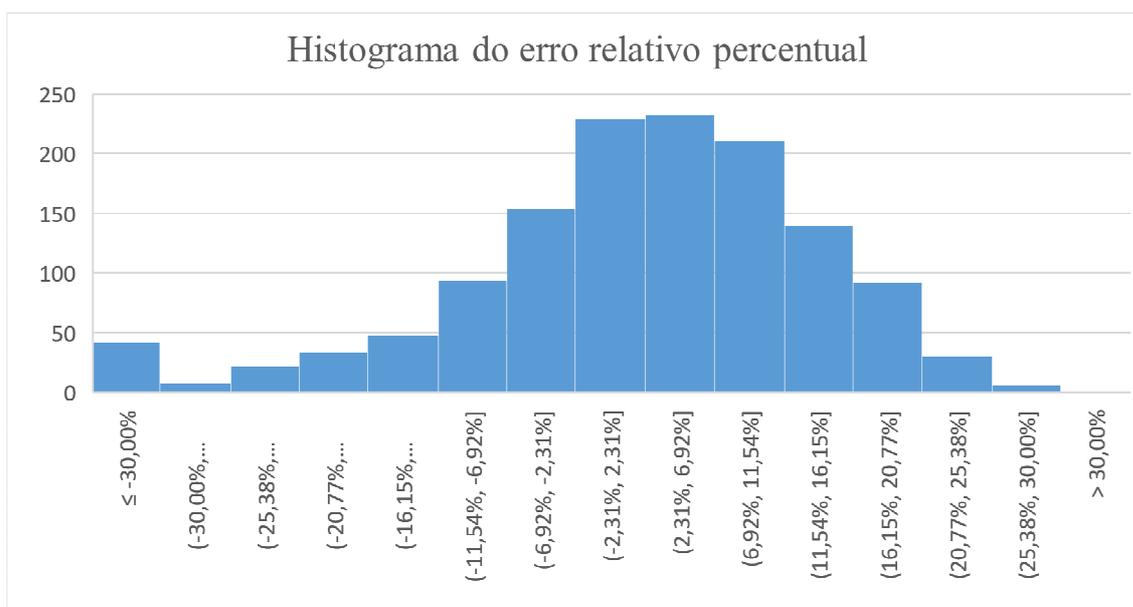


Figura 31 Histograma do erro percentual obtido no modelo semanal

Como é observável, os erros percentuais obtidos encontram-se centrados no intervalo entre 2,31% e 6,92%, estando este bastante próximo do intervalo que contém zero, no que diz respeito a número de amostras. Os valores distribuem-se em torno deste intervalo, porém há mais elementos com um erro de amplitude superior aos -30%, do que seria de esperar. Tratam-se de valores correspondentes a menos de dois dias (42h) com valores de erro grandes, devido à descida muito acentuada dos preços reais de preço da eletricidade, descidas essas que não foram acompanhadas pelas previsões do modelo. Em seguida é possível ver o gráfico que demonstra o erro percentual, para o conjunto teste, na Figura 32.

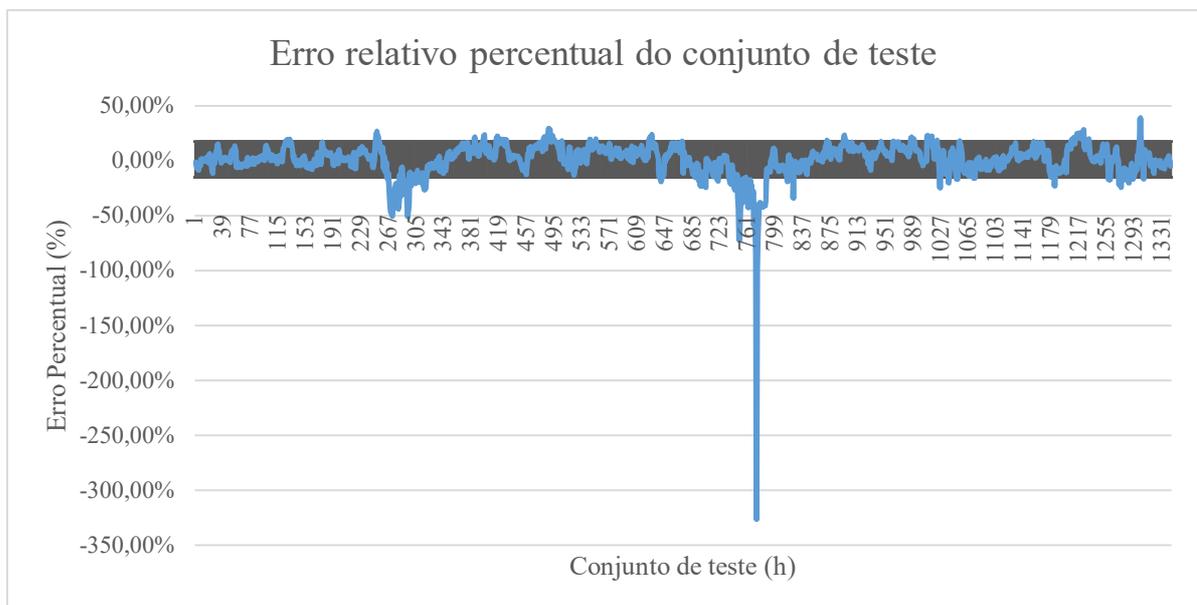


Figura 32 Erro relativo percentual e desvio padrão para o conjunto de teste (modelo semanal)

Aqui, conforme acontece no modelo diário, a maioria dos valores encontram-se na zona representativa do desvio padrão do erro relativo, sendo que os picos que se verificam devem-se, sobretudo, aos picos verificados no preço real. O maior erro verificado, neste caso, foi de cerca de -326%, e tal como no caso anterior, ao que tudo indica, deve ser devido à falha do MAPE quando se obtêm valores de preço real próximos de zero, que fazem com que o erro verificado seja muito elevado. Este valor encontra-se no mesmo ponto que o erro máximo do modelo diário, uma vez que os conjuntos de teste são iguais, porém aqui o erro é superior. Isto deve-se ao maior horizonte temporal das previsões deste modelo, que faz com que os erros obtidos sejam, por norma, superiores.

O processo de obtenção de resultados e os cálculos realizados neste modelo, uma vez que são muito equivalentes aos do modelo diário, podem ser consultados no Anexo A.6.

4.5.2. MENSAL

Para a previsão de preço com o modelo mensal, devido à parca quantidade de dados recolhidos, face aos que seriam necessários para previsões de um mês ou horizonte temporal superior, e também à maior imprevisibilidade e incerteza para previsões de médio/longo prazo, optou-se por prever apenas um valor médio de preço de eletricidade para o mês seguinte. Para tal, usaram-se os valores médios mensais das variáveis à disposição que mostrassem ser mais determinantes na influência demonstrada na evolução do preço. Para se obter esses mesmos valores, foram feitas novas adaptações aos dados recolhidos, sendo que, uma vez que se trata de uma previsão que se pode considerar como sendo de longo prazo, neste caso usaram-se todos os dados disponíveis recolhidos, ou seja, de 01 de julho de 2015 até 30 de julho de 2017. Porém, como uma das entradas escolhidas para os modelos criados foi, por exemplo, o Preço(M-13) (Preço 13 meses antes), recolheram-se dados de dois novos meses (julho e agosto de 2017) de modo a ter dados de entrada suficientes para que se obtivessem dados anteriores de referência para a simulação a levar a cabo. Neste caso selecionou-se então o mês de agosto de 2017 para prever, como conjunto de teste, e os restantes meses com informação completa (de agosto de 2016, a julho de 2017) para treino.

Optou por se utilizar, mais uma vez tal como no modelo semanal, um método destrutivo na estruturação dos modelos, começando por um modelo com a totalidade das entradas ao dispor, e retirando nos modelos seguintes entradas que aparentemente não fossem tão determinantes no comportamento apresentado pelo preço.

A parametrização utilizada para as simulações a levar a cabo no que concerne a este modelo, após se ter testado várias alternativas diferentes, assim como várias funções de treino das redes, acabou por ser o mesmo que foi utilizado nos restantes modelos de previsão (*Levenberg-Marquardt*), e a parametrização anteriormente mencionada, que aparece na ferramenta *nntool* por *default* (*min_grad=1e-07*; e *max_fails=6*). Quanto ao número de treinos, optou-se por, tal como no modelo anterior de previsão do preço, tomar a decisão relativamente aos valores apresentados no gráfico de regressão apresentado aquando do treino das redes, garantindo assim uma boa adaptação das redes aos dados de treino.

Procurou-se também, por outro lado, não exagerar no número de treinos das redes, de maneira a que não ocorresse *overfitting*, uma vez que a pouca quantidade de amostras relativamente aos dados a simular, poderia levar a isso, fazendo com que a rede neuronal, ao invés de “aprender”, memorizasse os valores que lhe eram dados para treinar. Isto iria

incorrer num erro maior, quando lhe fossem fornecidos dados de teste que não tinha experienciado antes, não sabendo como se adaptar. Teve-se o cuidado de, através do gráfico da regressão, tal como no modelo semanal, não permitir que isso ocorresse ao parar os treinos das redes quando o valor R (que indica a correlação da rede com os dados) da validação deixava de aumentar, estabilizando. O *overfitting* também se pode manifestar quando são atribuídos pesos demasiado elevados a algumas variáveis, por parte da função de treino.

A constituição dos modelos criados, como é normal nos métodos de previsão de longo prazo, não continha o mesmo número de variáveis de entrada dos anteriores, nem a mesma facilidade de obtenção de dados. Os dados disponíveis para este modelo são Mês (M), Ano (A), Preço médio mensal dos meses anteriores – Preço(M-x) para 1, 2, 12 e 13 meses – Carga média mensal para o mês a prever (Carga), Radiação Solar (Rad. Solar), Sazonalidade (Saz.) e Temperatura média mensal (Tméd). Conforme mencionado anteriormente, o primeiro modelo criado, continha todas as variáveis consideradas relevantes para esta previsão. Para o segundo modelo, optou por se retirar o valor da carga, e no terceiro modelo também a informação do Ano e da Sazonalidade. No quarto, e último, modelo criado, a decisão pendeu pela retirada dessas duas variáveis apenas, mantendo a carga. A constituição dos modelos (MPM – Modelo Preço Mensal) pode ser verificada na Tabela 18.

Tabela 18 Constituição dos modelos de previsão mensais

	M	A	Preço (M-1)	Preço (M-2)	Preço (M-12)	Preço (M-13)	Carga	Rad. Solar	Saz.	Tméd
MPM 01	X	X	X	X	X	X	X	X	X	X
MPM 02	X	X	X	X	X	X		X	X	X
MPM 03	X		X	X	X	X		X		X
MPM 04	X		X	X	X	X	X	X		X

Prosseguiu-se com as simulações dos modelos em questão, com a criação de 5 redes para cada um, de modo a obter 5 *outputs* diferentes para avaliar o erro. Após calcular-se a média dos *outputs*, foi avaliado então o valor do erro absoluto percentual para classificar o erro do modelo. Os valores obtidos neste processo podem ser verificados na Tabela 19.

Tabela 19 Resultados obtidos na avaliação dos modelos de previsão mensais

Modelos	APE
MPM 01 (com Carga)	7,79%

MPM 02 (sem Carga)	5,58%
MPM 03 (sem Carga)	0,50%
MPM 04 (com Carga)	5,37%

O modelo que obteve uma percentagem de erro menor foi então o modelo MPM 03 com um valor de APE de 0,50%, sendo também o modelo que possui menos variáveis dos quatro criados. Tratando-se este de um modelo sem valor da carga incluído nas suas entradas, não necessita então que se desenvolva um modelo de previsão de carga para obter esse valor, ao contrário dos modelos anteriores, dos restantes horizontes temporais, o diário e o semanal.

Com a aplicação do método introduzido no ponto 4.2.3, ao contrário dos restantes casos, neste não se obteve uma redução do valor de erro do indicador escolhido, o APE. Apesar de a aplicação do processo mencionado ter reduzido a amplitude e a variância dos valores obtidos nas simulações, o resultado do erro manteve-se aproximadamente no mesmo valor, piorando ligeiramente, de 0,50% para 0,57%. Estes valores podem ser um pouco enganadores, dada a parca quantidade de valores obtidos para treinar a rede em questão. Porém, uma vez que se trata da previsão de apenas um valor, ao contrário dos restantes modelos, é compreensível que se obtenha um valor de erro menor do que nos restantes casos. O método final para o modelo mensal e os resultados obtidos podem ser consultados na Figura 33.

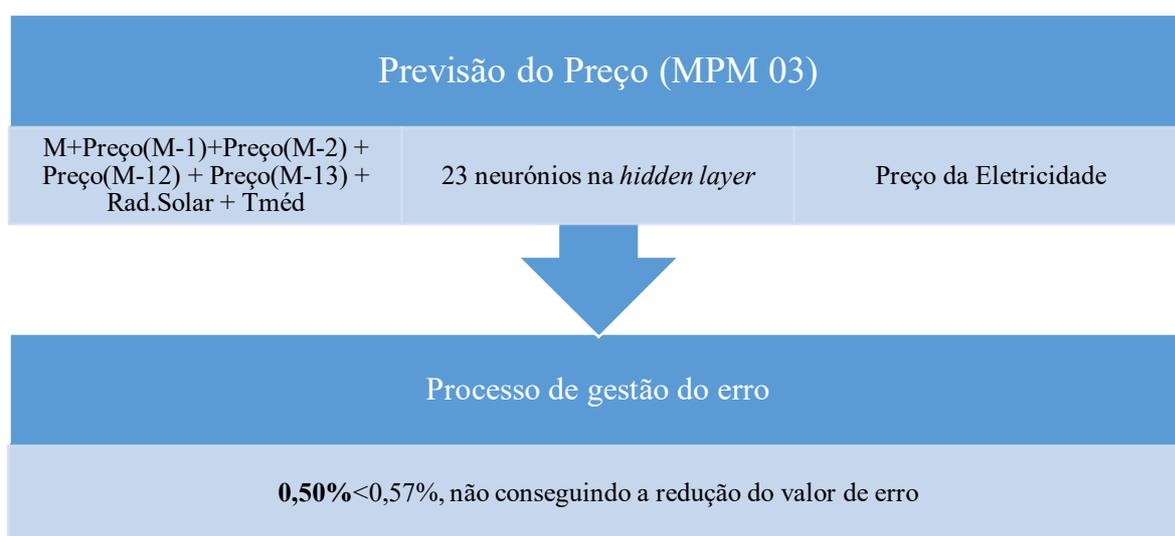


Figura 33 Método usado para a previsão do preço da eletricidade com o Modelo Mensal

Em seguida, encontra-se a Figura 34 que demonstra o valor real de preço médio para o mês de agosto de 2017, assim como os cinco valores previstos.

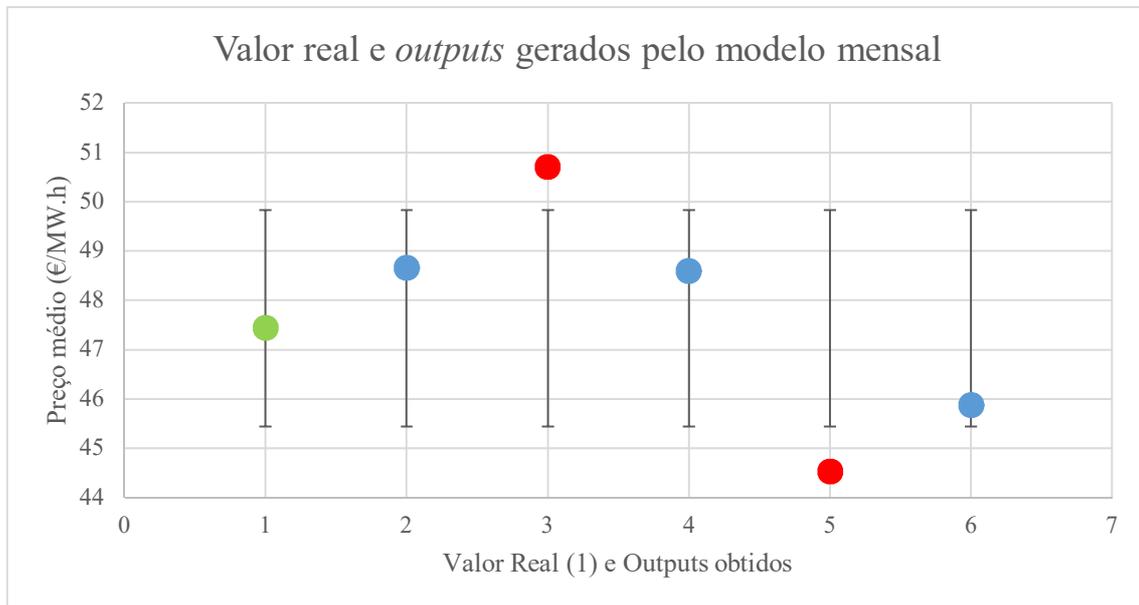


Figura 34 Valor real e valores previstos do preço médio para o mês de agosto/2017

O valor real encontra-se a verde (1º valor) e os seguintes são as simulações feitas, sendo que, aquelas cujo valor se encontra fora do intervalo que traduz o desvio padrão do conjunto, estão a vermelho, e as restantes a azul. Foram os valores desses três pontos, a azul, que foram tidos em conta para a média final que definiu o valor de simulação, que foi usada para a avaliação do erro após o processo de gestão do mesmo. Os cálculos e os resultados obtidos neste modelo podem ser consultados no Anexo A.7.

4.6. CONCLUSÕES

Primeiramente, como maneira de estudar o melhor método para proceder à previsão de preços, foram testados dois que permitem a construção de RNA's: *nntool* e *nftool*. Ambos fazem parte do conjunto de ferramentas disponibilizadas pelo *software* Matlab®. Com isto, foi selecionado o método que apenas utilizava a ferramenta *nntool*, sendo depois testadas, para cada horizonte temporal, diferentes combinações de parametrizações e de nº de treinos, com o objetivo da melhoria dos resultados conseguidos.

Tendo como base os resultados obtidos no capítulo 3, foram selecionadas as variáveis que deveriam ser incluídas nos modelos a ser criados, para cada horizonte temporal. Como forma

a garantir o melhor resultado possível, foram desenvolvidos vários modelos para cada cenário, utilizando-se as variáveis ao dispor. Em seguida, estudou-se também a possibilidade de se recorrer também à previsão da carga, de forma a auxiliar na precisão dos modelos do preço. Nos modelos diário e semanal, este processo demonstrou conseguir melhores resultados, sendo que no modelo mensal, apenas se recorre ao resultado obtido diretamente no modelo que prevê o preço da energia elétrica.

Seguidamente, os resultados que foram obtidos nos modelos selecionados para cada um dos horizontes temporais, foram alvo de um processo de gestão do erro, com o objetivo de o minorar. Este processo baseava-se no cálculo do desvio padrão dos *outputs* finais dos modelos selecionados em cada caso, construindo-se então um intervalo em torno da média, usando este valor. Os valores de *output* que não estivessem englobados neste intervalo, seriam então excluídos, contando-se apenas com os restantes para o novo cálculo da média dos *outputs* de cada simulação, correspondente a cada período (hora para os modelos diário e semanal, e mês para o mensal). O valor resultante seria então aquele que seria considerado. Com isto, conseguiu-se uma redução do indicador MAPE para os dois primeiros modelos. No caso do modelo mensal, o valor alcançado de APE, apesar de ser aproximado do que tinha sido obtido anteriormente à gestão do erro, é ligeiramente superior. Este facto pode-se dever a que neste caso se prevê apenas um valor singular, sendo que foi aplicado o mesmo processo aos restantes modelos mensais (MPM 01, 02 e 04), e em todos os casos o valor de erro piorou.

5. CONCLUSÕES

5.1. CONCLUSÕES FINAIS E PRINCIPAIS CONTRIBUTOS

A presente dissertação teve como principal objetivo desenvolver modelos de previsão do preço da energia elétrica no MIBEL, adequados a cada um dos mercados, spot e futuros, recorrendo às ferramentas consideradas necessárias. A ferramenta pela qual se optou, após prévio estudo, foi a *nntool*, que utiliza o método das Redes Neurais Artificiais (RNA), no *software* Matlab[®].

Inicialmente foi necessária a recolha dos dados que se considerasse que pudessem ter influência na evolução do preço da energia elétrica. Procurou-se recolher o maior número de informação possível, com atenção quanto à qualidade desta. Os dados foram depois tratados e estudados, de maneira a que se analisasse quais destes teriam maior importância para o treino das RNA a desenvolver, e pudessem ser usados como *inputs* das mesmas, tendo o cuidado de se adaptar os dados ao horizonte temporal de cada modelo desenvolvido.

Independentemente do horizonte temporal, o método pelo qual se optou para concretizar o objetivo proposto, foi através da construção de modelos com as variáveis à disposição, procurando encontrar a melhor combinação, para que o erro obtido, avaliado através do

indicador MAPE, fosse mínimo. Com isto, também se fez variar os valores dos parâmetros com vista a encontrar a parametrização ótima para cada caso, o número de treinos e o método ideal por forma a não deixar nada ao acaso. Quando era definido qual o melhor modelo e parametrização, se este possuísse a carga como uma das suas entradas, era desenvolvido um modelo de previsão desta para o horizonte temporal análogo do modelo de preço. Posto isto, após a averiguação do MAPE do modelo de previsão da carga, os valores previstos, após tratamento, eram usados como entrada para o modelo “vencedor” da previsão do preço. A nova previsão feita, teria à partida um erro superior ao que ocorria anteriormente, devido ao erro existente na previsão da carga, no entanto, sendo inferior ao erro do melhor modelo inicial de preço sem carga nas suas entradas, estes seriam os escolhidos como modelos finais para o horizonte em questão. Isto ocorreu para os horizontes temporais diário e semanal, sendo que apenas no mensal, um modelo sem carga como *input* foi o que obteve um erro menor, não havendo a necessidade de desenvolvimento de um modelo de previsão da mesma.

A constituição dos modelos que obtiveram melhores resultados para cada horizonte temporal, assim como os resultados de MAPE obtidos, foram os seguintes:

- **Modelo Diário**
 - **MCD 03**
 - $H + D + DDS + M + FN + \text{Carga}(S-1) + \text{Carga}(S-2) + \text{Carga}(D-2)$
 - **MPD 10**
 - $H + D + DDS + FN + \text{Vento} + \text{Carga} + \text{Preço}(D-1) + \text{Preço}(S-1) + \text{Rad.Solar} + T_{\text{méd}} + \text{rácio MIX3/Carga}(S-1)$
 - MAPE = 9,32%
- **Modelo Semanal**
 - **MCS 06**
 - $H + D + DDS + FN + \text{Carga}(S-1) + \text{Carga}(S-2) + D.\text{Rad.Solar} + D.T_{\text{méd}}$
 - **MPS 08**
 - $H + D + DDS + M + FN + \text{Preço}(S-1) + \text{Preço}(S-2) + \text{Carga} + \text{Rad.Solar} + T_{\text{méd}}$
 - MAPE = 11,40%
- **Modelo Mensal**
 - **MPM 03**
 - $H+D+DDS +M+FN +\text{Preço}(S-1) +\text{Preço}(S-2) +\text{Carga} +\text{Rad.Solar} +T_{\text{méd}}$
 - APE = 0,50%

Seguidamente, através do cálculo do desvio padrão dos *outputs* originados para cada período, procedeu-se à execução de um intervalo ao somar e subtrair este valor à média inicial destes. Os valores de cada simulação que não integrassem este intervalo, eram

excluídos, e era calculada a média novamente apenas com os valores restantes. Isto originou uma redução dos valores de MAPE para os dois primeiros modelos, não se alcançando uma melhoria no mensal. Os valores finais são apresentados em seguida:

- $MAPE_{\text{Modelo Diário}} = 8,24\%$
- $MAPE_{\text{Modelo Semanal}} = 9,44\%$
- $APE_{\text{Modelo Mensal}} = 0,57\% \rightarrow 0,50\%$

Por fim foram analisados os resultados obtidos, para cada um dos modelos desenvolvidos de previsão do preço, com vista a tentar compreender as características do erro obtido em cada caso e o porquê de isso acontecer. Isto foi feito com recurso ao estudo do coeficiente de *Spearman* dos *outputs* em comparação com os valores reais de preço, e também recorrendo à demonstração gráfica da relação das duas variáveis. Em seguida, demonstrou-se graficamente também a comparação entre uns valores e outros ao longo do tempo, e dos erros relativos percentuais obtidos, ao longo do conjunto de teste e através de um histograma, demonstrando onde se situava o ponto médio do erro das previsões em cada modelo.

Em suma, pode-se concluir que finalizados os trabalhos propostos nesta dissertação, os objetivos foram cumpridos, podendo ainda ser melhorada o tipo de informação disponível para os modelos de maior horizonte temporal, o semanal e o mensal. Os resultados obtidos foram satisfatórios e resultam num bom indicador dos preços a esperar para o mercado spot e para os mercados futuros, dando um auxílio na estratégia a desenvolver quanto à compra e venda de energia no MIBEL.

5.2. TRABALHOS FUTUROS

Como trabalhos futuros a ser realizados, destaca-se como prioritária a melhoria da informação a ser disposta no modelo mensal ou de horizonte temporal superior a uma semana. Para tal, foi pensada a adaptação do modelo mensal de forma a possuir um intervalo de variação disponível, além do valor médio do preço para o mês seguinte. Este seria possível verificar, prevendo o valor médio para o preço do mês seguinte, e através do valor do desvio padrão do preço no mês análogo do ano anterior, fazer um intervalo de variação para o valor a prever. Assim, obter-se-ia uma ideia da variação típica do mês em questão, adaptando essa variação ao valor médio previsto.

Por outro lado, também foi pensado um outro método, que não invalida o desenvolvimento do primeiro, de forma a prever valores horários de até um mês (4 semanas) de dados de preço de energia elétrica. Este método funcionaria de maneira iterativa, a partir do modelo de previsão semanal. Usando os valores previstos para a próxima semana (semana 1), seria possível utilizar esses dados como inputs para a semana 2, os dessa semana para a 3, e por fim, os da terceira semana para a quarta. Isto teria de ser executado também para o modelo de previsão de carga para acompanhar os dados de entrada necessários às previsões de preço. O erro deste modelo muito provavelmente seria superior aos falados até aqui, uma vez que teria de se contabilizar os erros cumulativos da utilização de *outputs* com um erro associado, como *inputs* dos modelos seguintes, múltiplas vezes. No entanto seriam dados interessantes de se prever por forma a ter uma ideia mais pormenorizada dos preços, de hora a hora, para o horizonte temporal de até um mês no futuro.

São dois modelos que merecem ser trabalhados e iriam melhorar a qualidade da informação resultante das previsões, apesar de aumentarem os erros dos mesmos modelos relativamente aos valores atuais. Junto com isto, há ainda maneiras de aperfeiçoar os modelos já desenvolvidos no decurso desta dissertação, de forma a aprimorar os resultados obtidos por estes, seja experimentando mais combinações de entradas e de parametrizações, seja aplicando a gestão do erro utilizada com recurso ao desvio padrão, também aos modelos iniciais usados nos cálculos intermédios. Uma outra possibilidade seria a recolha de dados históricos mais abrangentes, provenientes de outras fontes, permitindo uma maior segurança no que concerne principalmente às previsões de longo prazo.

Referências

- [1] EDP - Energias de Portugal, “A Liberalização.” [Online]. Available: <https://www.edpdistribuicao.pt/pt/mudancaComercializador/mercadoElectrico/Pages/aLiberalizacao.aspx>. [Accessed: 12-Jun-2017].
- [2] P. P. da Silva, *O sector da energia eléctrica na União Europeia: evolução e perspectivas*. 2007.
- [3] F. Azevedo, “Gestão do Risco em Mercados Competitivos de Electricidade: Previsão de Preços e Optimização do Portfolio de Contratos,” 2007.
- [4] P. S. Engineering and M. Asme, “P U RP-A NEW HORIZONS FOR ELECTRIC UTILITIES AND INDUSTRY HOUSTON , TEXAS,” no. 6, pp. 2784–2789, 1981.
- [5] A. Haurie, R. Loulou, and G. Savard, “A two-player game model of power cogeneration in new england,” *IEEE Trans. Automat. Contr.*, vol. 37, no. 9, pp. 1451–1456, 1992.
- [6] T. de C. Baptista, “A « liberalização do mercado energético em portugal» - verdadeira concorrência?,” pp. 1–69, 2014.
- [7] C. Pinto, D. Teixeira, J. Ramos, and D. Leocádio, “Qualidade de Serviço,” Porto, 2016.
- [8] “Mercado interno da energia | Fichas técnicas da UE | Parlamento Europeu.” [Online]. Available: http://www.europarl.europa.eu/atyourservice/pt/displayFtu.html?ftuId=FTU_5.7.2.html. [Accessed: 13-Sep-2017].
- [9] F. M. Santos, *Integração Europeia nos Domínios da Energia: da origem à auspiciosa “União Energética.”* 2017.
- [10] “Modelo de Organização do Mercado Ibérico de Electricidade.”
- [11] M. Ib and C. Ib, “Plano de Compatibilização entre Portugal e Espanha no sector energético,” 2007.
- [12] “Mibel - Conselho de Reguladores & Constituição,” Feb. 2007.
- [13] L. Mira Amaral, *Energia e Mercado Ibérico*. 2006.
- [14] L. Miguel Moreira Ribeiro, “Previsão probabilística de preços de eletricidade para o mercado diário MIBEL,” 2016.
- [15] D. Ricardo, J. Gomes, and S. Bento, “Previsão Probabilística dos Preços de Energia Elétrica do Mercado Ibérico de Electricidade,” 2015.
- [16] “Portal ERSE - Mercado Diário.” [Online]. Available: <http://www.erse.pt/pt/supervisaodemercados/mercadodeelectricidade/mercadodiario/Paginas/default.aspx>. [Accessed: 15-Sep-2017].
- [17] “Spread.” [Online]. Available: <http://www.investopedia.com/terms/s/spread.asp>. [Accessed: 18-Sep-2017].
- [18] J. M. Figueiras Loureiro, “Desenvolvimento de Modelos de Previsão a Longo Prazo de Preços de Mercado de Electricidade,” 2008.
- [19] “5.2.2 - Modelos GARCH - Séries Temporais | Portal Action.” [Online]. Available: <http://www.portalaction.com.br/series-temporais/522-modelos-garch>. [Accessed: 26-Sep-2017].
- [20] P. Socha, V. Miskovsky, H. Kubatova, and M. Novotny, “Optimization of Pearson

- correlation coefficient calculation for DPA and comparison of different approaches,” in *2017 IEEE 20th International Symposium on Design and Diagnostics of Electronic Circuits & Systems (DDECS)*, 2017, pp. 184–189.
- [21] E. Reggiani, E. D'Arnese, A. Purgato, and M. D. Santambrogio, “Pearson Correlation Coefficient Acceleration for Modeling and Mapping of Neural Interconnections,” in *2017 IEEE International Parallel and Distributed Processing Symposium Workshops (IPDPSW)*, 2017, pp. 223–228.
- [22] R. Weron, “Electricity price forecasting: A review of the state-of-the-art with a look into the future,” *Int. J. Forecast.*, vol. 30, no. 4, pp. 1030–1081, 2014.
- [23] S. K. Aggarwal, L. M. Saini, and A. Kumar, “Electricity price forecasting in deregulated markets: A review and evaluation,” *Int. J. Electr. Power Energy Syst.*, vol. 31, no. 1, pp. 13–22, Jan. 2009.
- [24] A. Misiołek, S. Trueck, and R. Weron, “Studies in Nonlinear Dynamics & Econometrics NONLINEAR ANALYSIS OF ELECTRICITY PRICES Point and Interval Forecasting of Spot Electricity Prices: Linear vs. Non-Linear Time Series Models Point and Interval Forecasting of Spot Electricity Prices: Linear vs. Non-Linear Time Series Models *.”
- [25] F. J. Nogales, J. Contreras, A. J. Conejo, and R. Espinola, “Forecasting Next-Day Electricity Prices by Time Series Models,” *IEEE Power Eng. Rev.*, vol. 22, no. 3, pp. 58–58, Mar. 2002.
- [26] P. Cortez and J. Neves, *Redes Neurais Artificiais*. Minho, 2004.
- [27] “What is a smart grid | ABB.” [Online]. Available: <http://new.abb.com/smartgrids/what-is-a-smart-grid>. [Accessed: 13-Sep-2017].
- [28] “Smart Meters - Smart Grid: Where Power is Going.” [Online]. Available: <http://www.whatissmartgrid.org/smart-grid-101/smart-meters>. [Accessed: 13-Sep-2017].
- [29] C. Silva, “Planeamento de uma rede de distribuição em contexto de Smart Grid,” 2017.
- [30] Entidade Reguladora dos Serviços Energéticos, *Decreto-Lei n.º 97/2002*. 2002, p. 35.
- [31] “Decreto-Lei n.º 169/2008 - Diário da República n.º 164/2008, Série I de 2008-08-26 - DRE.” [Online]. Available: <https://dre.pt/pesquisa/-/search/453563/details/maximized>. [Accessed: 13-Sep-2017].
- [32] D. DA ENERGIA Docente, S. Tavares da Silva Realizado por, and A. Catarina Almeida, “Ordenamento Jurídico Espanhol,” 2015.
- [33] “CNMV - Comisión Nacional del Mercado de Valores.” [Online]. Available: <http://www.cnmv.es/portal/home.aspx>. [Accessed: 13-Sep-2017].

Anexos

Ao longo desta secção apenas é exposta parte da informação tratada, como dados de entrada, *outputs* das simulações e resultados finais dos modelos. Isto deve-se ao facto da impossibilidade da inclusão neste relatório de todo o conjunto de informação recolhido e tratado. Para o acesso aos dados tratados neste estudo, poderá efetuar pedido através dos contactos fornecido no *website* criado para o efeito: www.1101507.wixsite.com/tesemestrado. No mesmo, terá ainda possibilidade de consultar a apresentação e *Curriculum Vitae* do autor desta dissertação, bem como o resumo, *abstract* e os anexos aqui apresentados.

A.1 Dados Horários

Tabela 20 Dados Horários – parte 1

Data	Hora	Semana	Dia	DDS	Mês	Ano	Feriado	Sazonalidade
19/01/2017	0	3	19	5	1	2017	0	0
19/01/2017	1	3	19	5	1	2017	0	0
19/01/2017	2	3	19	5	1	2017	0	0
19/01/2017	3	3	19	5	1	2017	0	0
19/01/2017	4	3	19	5	1	2017	0	0
19/01/2017	5	3	19	5	1	2017	0	0
19/01/2017	6	3	19	5	1	2017	0	0
19/01/2017	7	3	19	5	1	2017	0	0
19/01/2017	8	3	19	5	1	2017	0	0
19/01/2017	9	3	19	5	1	2017	0	0
19/01/2017	10	3	19	5	1	2017	0	0
19/01/2017	11	3	19	5	1	2017	0	0
19/01/2017	12	3	19	5	1	2017	0	0
19/01/2017	13	3	19	5	1	2017	0	0
19/01/2017	14	3	19	5	1	2017	0	0
19/01/2017	15	3	19	5	1	2017	0	0
19/01/2017	16	3	19	5	1	2017	0	0
19/01/2017	17	3	19	5	1	2017	0	0
19/01/2017	18	3	19	5	1	2017	0	0
19/01/2017	19	3	19	5	1	2017	0	0
19/01/2017	20	3	19	5	1	2017	0	0
19/01/2017	21	3	19	5	1	2017	0	0
19/01/2017	22	3	19	5	1	2017	0	0
19/01/2017	23	3	19	5	1	2017	0	0

Tabela 21 Dados Horários – parte 2

Data	Hora	Preço (D) (€/MW.h)	Preço (D-6) (€/MW.h)	Preço (H-1) (€/MW.h)	Preço (D-1) (€/MW.h)	Preço (S-1) (€/MW.h)	Preço (S-2) (€/MW.h)
19/01/2017	0	85,0	77,51	89,22	74,08	77,51	61,95
19/01/2017	1	80,27	75,0	85	67,88	75	63,1
19/01/2017	2	71,1	65,25	80,27	62,58	65,25	63,1
19/01/2017	3	68,1	60,71	71,1	59,94	60,71	54,08

Data	Hora	Preço (D) (€/MW.h)	Preço (D-6) (€/MW.h)	Preço (H-1) (€/MW.h)	Preço (D-1) (€/MW.h)	Preço (S-1) (€/MW.h)	Preço (S-2) (€/MW.h)
19/01/2017	4	67,6	59,51	68,1	58,96	59,51	53,98
19/01/2017	5	67,35	59,11	67,6	57,29	59,11	53,78
19/01/2017	6	68,1	60,01	67,35	59,83	60,01	53,78
19/01/2017	7	75,03	73,69	68,1	63,1	73,69	54,09
19/01/2017	8	90,0	82,87	75,03	78,87	82,87	66,21
19/01/2017	9	90,1	82,16	90	82,69	82,16	69,7
19/01/2017	10	95,0	88,01	90,1	85,1	88,01	72,6
19/01/2017	11	94,0	86,71	95	86,63	86,71	73,03
19/01/2017	12	93,88	86,4	94	85	86,4	72,6
19/01/2017	13	93,0	82,94	93,88	84	82,94	72,54
19/01/2017	14	92,73	81,19	93	84,1	81,19	71,51
19/01/2017	15	94,01	79,69	92,73	81,17	79,69	71,1
19/01/2017	16	92,0	76,98	94,01	81	76,98	70,51
19/01/2017	17	91,03	77,15	92	81,51	77,15	69,7
19/01/2017	18	92,0	79,97	91,03	85,01	79,97	73,87
19/01/2017	19	94,22	82,1	92	90	82,1	75,15
19/01/2017	20	95,11	81,28	94,22	92,01	81,28	76,1
19/01/2017	21	94,0	78,33	95,11	92,6	78,33	73,69
19/01/2017	22	89,19	74,03	94	91,69	74,03	71,68
19/01/2017	23	85,46	69,21	89,19	89,22	69,21	66,76

Tabela 22 Dados Horários – parte 3

Data	Hora	Carga (D-1) (MW.h)	Carga (D-2) (MW.h)	Carga (S-1) (MW.h)	Carga (S-2) (MW.h)	PRO Térm. (S-1) (MW.h)	Ratio MIX3/Carga
19/01/2017	0	33636,12	34820,60	32210,75	31851,37	12281,63	0,50
19/01/2017	1	32871,84	30488,52	31455,93	30783,18	11239,20	0,55
19/01/2017	2	29439,27	31101,11	28163,82	27454,62	11198,20	0,54
19/01/2017	3	30588,45	28750,27	29102,83	28232,54	11020,87	0,56
19/01/2017	4	28678,67	30510,34	27376,73	26356,92	11087,57	0,56
19/01/2017	5	30885,19	28660,77	29564,71	28325,53	11647,57	0,58
19/01/2017	6	31927,98	32952,32	30436,12	28627,32	13359,07	0,53
19/01/2017	7	39459,06	36519,25	37708,67	34262,17	14965,30	0,49
19/01/2017	8	42063,23	42888,97	39773,07	35528,92	17529,70	0,45
19/01/2017	9	46452,74	41993,53	43318,08	40480,18	17245,10	0,46
19/01/2017	10	44840,82	45320,92	41257,40	39361,33	17988,73	0,46
19/01/2017	11	47553,38	42624,30	43342,74	41901,12	16402,23	0,51
19/01/2017	12	44612,90	44532,99	40173,15	38569,95	15971,87	0,55
19/01/2017	13	46846,20	41890,52	42189,68	40407,28	15210,90	0,59
19/01/2017	14	43282,70	43180,06	38701,20	36870,43	15263,57	0,61
19/01/2017	15	45106,62	40278,92	40396,69	37728,78	14479,80	0,65
19/01/2017	16	42489,23	42604,57	37907,18	34986,70	15706,13	0,62
19/01/2017	17	45536,93	40535,83	40884,27	37489,38	15942,50	0,58
19/01/2017	18	45137,75	45430,50	40809,37	36711,75	16991,20	0,53
19/01/2017	19	49466,25	44990,85	44780,01	39616,99	15825,67	0,54
19/01/2017	20	46716,15	47850,14	42249,65	36867,72	16020,67	0,54
19/01/2017	21	47983,64	44290,40	43846,33	39077,03	14676,50	0,56
19/01/2017	22	41868,68	43673,38	38500,30	35083,37	13894,07	0,60
19/01/2017	23	40037,37	37069,85	36729,23	34816,60	12149,87	0,68

A.2 Dados Diários e Mensais

Tabela 23 Dados Diários e Mensais – parte 1

Data	Carga média diária (MW.h)	Carga média mensal (MW.h)	Preço médio diário (€/MW.h)	Preço médio mensal (€/MW.h)	Temp. máxima (°C)	Temp. média (°C)	Temp. mínima (°C)
01/01/2017	27879,800		51,853		10,464	5,250	-0,250
02/01/2017	34416,727		58,878		11,964	7,107	2,286
03/01/2017	37039,149		65,246		13,429	8,607	3,643
04/01/2017	36560,164		66,700		14,179	9,179	4,214
05/01/2017	35153,893		66,859		13,464	8,643	3,714
06/01/2017	30952,528		64,525		12,857	6,929	1,036
07/01/2017	32682,674		65,584		12,964	6,393	-0,214
08/01/2017	32037,344		60,012		13,821	6,500	-0,536
09/01/2017	38048,779		69,860		13,393	6,929	0,357
10/01/2017	39225,128		65,910		13,143	7,964	2,964
11/01/2017	38285,363		72,145		15,714	10,321	5,286
12/01/2017	37634,603	36526,277	75,825	71,504	15,607	9,857	4,143
13/01/2017	37598,266		67,479		12,250	8,321	4,464
14/01/2017	34524,412		65,401		10,893	6,321	1,750
15/01/2017	32481,890		61,565		12,000	6,893	1,536
16/01/2017	38232,512		68,791		13,750	7,857	2,250
17/01/2017	39289,954		72,654		12,107	6,464	1,179
18/01/2017	41029,194		78,094		6,929	2,464	-2,000
19/01/2017	41273,256		85,762		8,143	3,536	-1,143
20/01/2017	40736,695		86,745		9,643	5,071	0,571
21/01/2017	35657,503		79,385		11,786	6,571	1,321
22/01/2017	33170,857		72,921		12,107	6,714	1,214
23/01/2017	39021,584		83,574		12,464	7,036	1,536
24/01/2017	39172,683		87,683		12,929	6,464	0,000
25/01/2017	39506,638		91,679		12,643	5,536	-1,500
26/01/2017	39911,855		87,717		11,536	6,357	1,214
27/01/2017	39198,908		75,839		12,214	9,071	5,857
28/01/2017	34604,388		61,867		12,929	8,643	4,179
29/01/2017	32306,327		62,258		14,179	9,464	4,821
30/01/2017	37327,544		70,686		15,714	11,321	7,107
31/01/2017	37353,959		73,140		15,500	10,500	5,821

Tabela 24 Dados Diários e Mensais – parte 2

Data	Temp. máxima mensal (°C)	Temp. média mensal (°C)	Temp. mínima mensal (°C)	Vento (km/h)	Vento médio mensal (km/h)	Precip. (mm)	Precip. média mensal (mm)
01/01/2017				7,250		0,226	
02/01/2017				10,286		0,752	
03/01/2017				7,500		1,749	
04/01/2017				6,393		0,327	
05/01/2017				7,286		0,013	
06/01/2017				7,429		0,004	
07/01/2017				6,500		0,009	
08/01/2017				6,429		0,000	
09/01/2017				6,786		0,009	
10/01/2017				10,929		1,101	
11/01/2017				12,714		0,781	
12/01/2017	12,604	7,364	2,156	9,036	10,149	0,361	1,126
13/01/2017				15,321		0,546	
14/01/2017				11,250		0,602	
15/01/2017				12,714		1,110	
16/01/2017				12,821		1,006	
17/01/2017				14,464		0,329	
18/01/2017				14,429		1,653	
19/01/2017				12,179		4,487	
20/01/2017				12,357		2,079	
21/01/2017				11,214		2,597	
22/01/2017				11,500		0,386	
23/01/2017				9,607		0,320	
24/01/2017				7,464		0,037	
25/01/2017				7,714		0,085	
26/01/2017				9,179		5,370	
27/01/2017				14,179		4,664	
28/01/2017				13,071		1,063	
29/01/2017				8,714		1,519	
30/01/2017				9,750		0,195	
31/01/2017				8,143		1,527	

Tabela 25 Dados Diários e Mensais – parte 3

Data	Rad.Solar (Wh/m2/day)	D. Rad.Solar (Wh/m2/day)	D. Temp. média diária (°C)	Preço méd.(M-1) (€/MW.h)	Preço méd.(M-12) (€/MW.h)	Carga méd.(M- 1) (MW.h)	Carga méd.(M-12) (MW.h)
01/01/2017			11,076				
02/01/2017			9,219				
03/01/2017			7,719				
04/01/2017			7,148				
05/01/2017			7,684				
06/01/2017			9,398				
07/01/2017			9,934				
08/01/2017			9,826				
09/01/2017			9,398				
10/01/2017			8,362				
11/01/2017			6,005				
12/01/2017	3277,143	1610,149	6,469	60,267	36,406	33801,971	34109,383
13/01/2017			8,005				
14/01/2017			10,005				
15/01/2017			9,434				
16/01/2017			8,469				
17/01/2017			9,862				
18/01/2017			13,862				
19/01/2017			12,791				
20/01/2017			11,255				
21/01/2017			9,755				
22/01/2017			9,612				
23/01/2017			9,291				
24/01/2017			9,862				
25/01/2017			10,791				
26/01/2017			9,969				
27/01/2017			7,255				
28/01/2017			7,684				
29/01/2017			6,862				
30/01/2017			5,005				
31/01/2017			5,826				

Tabela 26 Dados Diários e Mensais – parte 4

Data	Temp. méd.(M-1) (°C)	Temp. méd.(M-12) (°C)	D. Temp. méd. mensal	D. Temp. méd.mensal (M-1)	D. Temp. méd.mensal (M-12)	ΣPluv. (M-1) (mm)	ΣPluv. (M-12) (mm)	Sazon.
01/01/2017								
02/01/2017								
03/01/2017								
04/01/2017								
05/01/2017								
06/01/2017								
07/01/2017								
08/01/2017								
09/01/2017								
10/01/2017								
11/01/2017								
12/01/2017	9,709	10,244	8,728	6,384	5,848	36,725	53,626	0
13/01/2017								
14/01/2017								
15/01/2017								
16/01/2017								
17/01/2017								
18/01/2017								
19/01/2017								
20/01/2017								
21/01/2017								
22/01/2017								
23/01/2017								
24/01/2017								
25/01/2017								
26/01/2017								
27/01/2017								
28/01/2017								
29/01/2017								
30/01/2017								
31/01/2017								

A.3 Dados Meteorológicos

Tabela 27 Dados Meteorológicos

Data	Temperatura (°C)			Vento (km/h)	Precip. (mm)	Mês
	Máxima	Média	Mínima	Média	Soma	
01/01/2017	10,464	5,250	-0,250	7,250	0,220	Janeiro
02/01/2017	11,964	7,107	2,286	10,286	0,730	
03/01/2017	13,429	8,607	3,643	7,500	1,690	
04/01/2017	14,179	9,179	4,214	6,393	0,320	
05/01/2017	13,464	8,643	3,714	7,286	0,010	
06/01/2017	12,857	6,929	1,036	7,429	0,000	
07/01/2017	12,964	6,393	-0,214	6,500	0,010	
08/01/2017	13,821	6,500	-0,536	6,429	0,000	
09/01/2017	13,393	6,929	0,357	6,786	0,010	
10/01/2017	13,143	7,964	2,964	10,929	1,060	
11/01/2017	15,714	10,321	5,286	12,714	0,750	
12/01/2017	15,607	9,857	4,143	9,036	0,350	
13/01/2017	12,250	8,321	4,464	15,321	0,530	
14/01/2017	10,893	6,321	1,750	11,250	0,580	
15/01/2017	12,000	6,893	1,536	12,714	1,070	
16/01/2017	13,750	7,857	2,250	12,821	0,970	
17/01/2017	12,107	6,464	1,179	14,464	0,320	
18/01/2017	6,9286	2,4643	-2,000	14,429	0,050	
19/01/2017	8,1429	3,5357	-1,143	12,179	4,330	
20/01/2017	9,6429	5,0714	0,571	12,357	2,000	
21/01/2017	11,786	6,5714	1,321	11,214	2,500	
22/01/2017	12,107	6,7143	1,214	11,500	0,370	
23/01/2017	12,464	7,0357	1,536	9,607	0,310	
24/01/2017	12,929	6,4643	0,000	7,464	0,040	
25/01/2017	12,643	5,5357	-1,500	7,714	0,080	
26/01/2017	11,536	6,3571	1,214	9,179	5,180	
27/01/2017	12,214	9,0714	5,857	14,179	4,570	
28/01/2017	12,929	8,6429	4,179	13,071	1,020	
29/01/2017	14,179	9,4643	4,821	8,714	1,500	
30/01/2017	15,714	11,321	7,107	9,750	0,190	
31/01/2017	15,500	10,500	5,821	8,143	1,470	

A.4 Dados de Radiação Solar

Tabela 28 Dados de Radiação Solar

Month	H_h	H_{opt}	$H(90)$	I_{opt}	T_{24h}	N_{DD}
Jan	2030	3230	3200	61	6.8	254
Feb	2650	3650	3160	52	6.7	203
Mar	4410	5520	4060	43	9.7	124
Apr	4860	5170	2960	25	12.5	105
May	6230	6070	2760	13	15.7	24
Jun	6940	6450	2520	6	19.2	4
Jul	7110	6750	2720	10	22.3	2
Aug	6610	6890	3430	22	22.3	3
Sep	4940	5880	3940	37	19.7	22
Oct	3430	4650	3860	50	15.3	80
Nov	2120	3140	2950	58	10.0	222
Dec	1720	2740	2760	62	7.3	255

A.5 Análise de Correlações

Tabela 29 Análise da correlação entre a Carga e o Desvio do valor médio de Radiação Solar

Carga X_i	Rad.Solar	V. médio Tméd	Desvio Y_i	posto $x(i)$	posto $y(i)$	d_i	d_i^2
36449,82	6355,36	4887,29	1468,06	23	17	6	36
32521,25	6223,21		1335,92	9	13	-4	16
31725,13	5606,43		719,14	5	7	-2	4
31195,70	4592,50		294,79	3	1	2	4
32514,75	3296,07		1591,22	8	19	-11	121
32965,78	2797,86		2089,44	11	23	-12	144
34109,38	3277,14		1610,15	18	21	-3	9
35231,68	3838,57		1048,72	22	11	11	121
33978,33	5212,50		325,21	17	3	14	196
32474,88	5296,43		409,14	7	5	2	4
30944,04	5913,57		1026,28	2	9	-7	49
32594,37	6237,86		1350,56	10	15	-5	25
34803,17	6355,36		1468,06	20	17	3	9
33466,24	6223,21		1335,92	13	13	0	0
33647,91	5606,43		719,14	15	7	8	64
31271,88	4592,50		294,79	4	1	3	9
33594,58	3296,07		1591,22	14	19	-5	25
33801,97	2797,86		2089,44	16	23	-7	49
36526,28	3277,14		1610,15	24	21	3	9
34790,99	3838,57		1048,72	19	11	8	64
33322,52	5212,50		325,21	12	3	9	81
30801,45	5296,43		409,14	1	5	-4	16
31777,46	5913,57		1026,28	6	9	-3	9
35007,85	6237,86		1350,56	21	15	6	36
$\sum d_i^2 = 1100$		$\rho = 0,5217$		<p>Relação entre a Carga (valores de médias diárias) e os valores máximos e mínimos de Rad. Solar revela um aumento de Consumo aquando de valores mais extremos de radiação.</p>			

A.6 Modelo Diário – Entradas e resultados

Tabela 30 Dados de entrada e resultados – Simulações 1 e 2 (Modelo Diário)

Dia	Hora	Rede Teste 10 c/previsão de Carga			Simul. 1	Rede Teste 10 c/previsão de Carga			Simul. 2
		Previsão	V. Real	EA		Previsão	V. Real	EA	
19/01/2017	0	79,300	85	5,700	MAPE 0,0386 ↓ 3,86%	89,845	85	4,845	MAPE 0,0317 ↓ 3,17%
	1	75,950	80,27	4,320		86,704	80,27	6,434	
	2	65,977	71,1	5,123		74,250	71,1	3,150	
	3	61,962	68,1	6,138		68,639	68,1	0,539	
	4	59,501	67,6	8,099		64,289	67,6	3,311	
	5	60,188	67,35	7,162		64,210	67,35	3,140	
	6	60,768	68,1	7,332		64,283	68,1	3,817	
	7	73,696	75,03	1,334		80,289	75,03	5,259	
	8	85,828	90	4,172		91,521	90	1,521	
	9	87,085	90,1	3,015		93,345	90,1	3,245	
	10	92,654	95	2,346		95,949	95	0,949	
	11	92,757	94	1,243		95,572	94	1,572	
	12	91,630	93,88	2,250		93,752	93,88	0,128	
	13	91,951	93	1,049		92,083	93	0,917	
	14	91,855	92,73	0,875		89,748	92,73	2,982	
	15	90,541	94,01	3,469		88,752	94,01	5,258	
	16	88,606	92	3,394		85,383	92	6,617	
	17	89,087	91,03	1,943		86,850	91,03	4,180	
	18	92,154	92	0,154		90,038	92	1,962	
	19	95,579	94,22	1,359		96,889	94,22	2,669	
	20	95,748	95,11	0,638		96,140	95,11	1,030	
	21	95,212	94	1,212		94,477	94	0,477	
	22	93,418	89,19	4,228		89,988	89,19	0,798	
	23	88,279	85,46	2,819	85,897	85,46	0,437		

Tabela 31 Dados de entrada e resultados – Simulações 3 e 4 (Modelo Diário)

		Rede Teste 10 c/previsão de Carga			Simul. 3	Rede Teste 10 c/previsão de Carga			Simul. 4
Dia	Hora	Previsão	V. Real	EA		Previsão	V. Real	EA	
19/01/2017	0	78,234	85	6,766	MAPE	73,841	85	11,159	MAPE
	1	72,970	80,27	7,300	0,0628	71,606	80,27	8,664	0,0623
	2	64,255	71,1	6,845	↓	65,723	71,1	5,377	↓
	3	62,191	68,1	5,909	6,28%	63,207	68,1	4,893	6,23%
	4	59,736	67,6	7,864		60,867	67,6	6,733	
	5	59,848	67,35	7,502		61,065	67,35	6,285	
	6	60,460	68,1	7,640		63,682	68,1	4,418	
	7	75,909	75,03	0,879		73,727	75,03	1,303	
	8	85,153	90	4,847		83,320	90	6,680	
	9	88,162	90,1	1,938		85,126	90,1	4,974	
	10	90,300	95	4,700		88,444	95	6,556	
	11	90,819	94	3,181		90,595	94	3,405	
	12	89,644	93,88	4,236		89,827	93,88	4,053	
	13	88,576	93	4,424		87,125	93	5,875	
	14	87,118	92,73	5,612		86,472	92,73	6,258	
	15	86,733	94,01	7,277		85,641	94,01	8,369	
	16	84,356	92	7,644		84,223	92	7,777	
	17	85,669	91,03	5,361		83,816	91,03	7,214	
	18	88,080	92	3,920		87,727	92	4,273	
	19	90,295	94,22	3,925		91,906	94,22	2,314	
	20	90,003	95,11	5,107		94,397	95,11	0,713	
	21	88,571	94	5,429		93,228	94	0,772	
	22	84,253	89,19	4,937		92,870	89,19	3,680	
	23	79,473	85,46	5,987		91,844	85,46	6,384	

Tabela 32 Dados de entrada e resultados finais – Simulação 5 (Modelo Diário)

		Rede Teste 10 c/previsão de Carga			Simul. 5	Simulação	MAPE	
Dia	Hora	Previsão	V. Real	EA				
19/01/2017	0	76,475	85	8,525	MAPE	Simulação 1	3,86%	
	1	74,308	80,27	5,962		0,0316	Simulação 2	3,17%
	2	65,429	71,1	5,671		↓	Simulação 3	6,28%
	3	65,971	68,1	2,129		3,16%	Simulação 4	6,23%
	4	62,815	67,6	4,785			Simulação 5	3,16%
	5	65,799	67,35	1,551		MAPE (médio) antes da gestão do erro	4,54%	
	6	65,295	68,1	2,805				
	7	73,612	75,03	1,418				
	8	84,909	90	5,091				
	9	88,891	90,1	1,209				
	10	91,505	95	3,495				
	11	94,066	94	0,066				
	12	93,882	93,88	0,002				
	13	94,029	93	1,029				
	14	92,575	92,73	0,155				
	15	93,379	94,01	0,631				
	16	90,539	92	1,461				
	17	91,564	91,03	0,534				
	18	91,595	92	0,405				
	19	98,125	94,22	3,905				
	20	96,638	95,11	1,528				
	21	97,840	94	3,840				
	22	92,500	89,19	3,310				
	23	91,069	85,46	5,609				

Tabela 33 Gestão do Erro – parte 1 (Modelo Diário)

Média dos Outputs de previsão do Preço		Média + D.Padrão	Desvio Padrão	Média - D.Padrão
79,539		85,013	5,474	74,065
76,308		81,702	5,394	70,914
67,127		70,737	3,610	63,517
64,394		66,951	2,557	61,838
61,441		63,285	1,844	59,598
62,222		64,582	2,360	59,862
62,897		64,834	1,937	60,960
75,447		78,018	2,571	72,876
86,146		88,957	2,811	83,336
88,522		91,246	2,725	85,797
91,770		94,282	2,512	89,259
92,762		94,663	1,901	90,861
91,747		93,575	1,828	89,919
90,753		93,276	2,524	88,229
89,553		91,999	2,445	87,108
89,009		91,767	2,758	86,251
86,621		89,140	2,518	84,103
87,397		90,093	2,696	84,702
89,919		91,708	1,789	88,130
94,559		97,539	2,980	91,579
94,585		96,994	2,409	92,176
93,865		96,913	3,047	90,818
90,606		93,993	3,387	87,219
87,312		91,763	4,450	82,862

Tabela 34 Gestão do Erro – parte 2 (Modelo Diário)

<i>Outputs</i>					LIMITES				
Simul.1	Simul.2	Simul.3	Simul.4	Simul.5	Simul.1	Simul.2	Simul.3	Simul.4	Simul.5
79,300	89,845	78,234	73,841	76,475	OK	NOT	OK	NOT	OK
75,950	86,704	72,970	71,606	74,308	OK	NOT	OK	OK	OK
65,977	74,250	64,255	65,723	65,429	OK	NOT	OK	OK	OK
61,962	68,639	62,191	63,207	65,971	OK	NOT	OK	OK	OK
59,501	64,289	59,736	60,867	62,815	NOT	NOT	OK	OK	OK
60,188	64,210	59,848	61,065	65,799	OK	OK	NOT	OK	NOT
60,768	64,283	60,460	63,682	65,295	NOT	OK	NOT	OK	NOT
73,696	80,289	75,909	73,727	73,612	OK	NOT	OK	OK	OK
85,828	91,521	85,153	83,320	84,909	OK	NOT	OK	NOT	OK
87,085	93,345	88,162	85,126	88,891	OK	NOT	OK	NOT	OK
92,654	95,949	90,300	88,444	91,505	OK	NOT	OK	NOT	OK
92,757	95,572	90,819	90,595	94,066	OK	NOT	NOT	NOT	OK
91,630	93,752	89,644	89,827	93,882	OK	NOT	NOT	NOT	NOT
91,951	92,083	88,576	87,125	94,029	OK	OK	OK	NOT	NOT
91,855	89,748	87,118	86,472	92,575	OK	OK	OK	NOT	NOT
90,541	88,752	86,733	85,641	93,379	OK	OK	OK	NOT	NOT
88,606	85,383	84,356	84,223	90,539	OK	OK	OK	OK	NOT
89,087	86,850	85,669	83,816	91,564	OK	OK	OK	NOT	NOT
92,154	90,038	88,080	87,727	91,595	NOT	OK	NOT	NOT	OK
95,579	96,889	90,295	91,906	98,125	OK	OK	NOT	OK	NOT
95,748	96,140	90,003	94,397	96,638	OK	OK	NOT	OK	OK
95,212	94,477	88,571	93,228	97,840	OK	OK	NOT	OK	NOT
93,418	89,988	84,253	92,870	92,500	OK	OK	NOT	OK	OK
88,279	85,897	79,473	91,844	91,069	OK	OK	NOT	NOT	OK

Tabela 35 Gestão do Erro e resultados – parte 3 (Modelo Diário)

VALORES A CONSIDERAR					MÉDIA FINAL	V. REAIS	ERRO ABSOLUTO
79,300	-	78,234	-	76,475	78,003	85	6,997
75,950	-	72,970	71,606	74,308	73,709	80,27	6,561
65,977	-	64,255	65,723	65,429	65,346	71,1	5,754
61,962	-	62,191	63,207	65,971	63,333	68,1	4,767
-	-	59,736	60,867	62,815	61,139	67,6	6,461
60,188	64,210	-	61,065	-	61,821	67,35	5,529
-	64,283	-	63,682	-	63,982	68,1	4,118
73,696	-	75,909	73,727	73,612	74,236	75,03	0,794
85,828	-	85,153	-	84,909	85,297	90	4,703
87,085	-	88,162	-	88,891	88,046	90,1	2,054
92,654	-	90,300	-	91,505	91,486	95	3,514
92,757	-	-	-	94,066	93,411	94	0,589
91,630	-	-	-	-	91,630	93,88	2,250
91,951	92,083	88,576	-	-	90,870	93	2,130
91,855	89,748	87,118	-	-	89,574	92,73	3,156
90,541	88,752	86,733	-	-	88,676	94,01	5,334
88,606	85,383	84,356	84,223	-	85,642	92	6,358
89,087	86,850	85,669	-	-	87,202	91,03	3,828
-	90,038	-	-	91,595	90,817	92	1,183
95,579	96,889	-	91,906	-	94,791	94,22	0,571
95,748	96,140	-	94,397	96,638	95,731	95,11	0,621
95,212	94,477	-	93,228	-	94,305	94	0,305
93,418	89,988	-	92,870	92,500	92,194	89,19	3,004
88,279	85,897	-	-	91,069	88,415	85,46	2,955
MAPE_{FINAL} =					4,06%	<	4,54%

A.7 Modelo Mensal – Entradas e Resultados

Tabela 36 Dados de entrada e resultados do Modelo Mensal

Preço	Ano	Mês	Preço méd. (M-1)	Preço méd. (M-2)	Preço méd. (M-12)	Preço méd. (M-13)	Rad. Solar	T méd mensal
41,141	2016	8	40,364	38,267	55,582	59,611	6223,214	24,263
43,604	2016	9	41,141	40,364	51,928	55,582	5606,429	21,627
52,780	2016	10	43,604	41,141	49,898	51,928	4592,500	17,432
56,236	2016	11	52,780	43,604	51,452	49,898	3296,071	11,519
60,267	2016	12	56,236	52,780	52,933	51,452	2797,857	9,709
71,504	2017	1	60,267	56,236	36,406	52,933	3277,143	7,364
51,431	2017	2	71,504	60,267	27,371	36,406	3838,571	10,566
43,963	2017	3	51,431	71,504	27,696	27,371	5212,500	12,185
44,183	2017	4	43,963	51,431	23,495	27,696	5296,429	14,658
47,097	2017	5	44,183	43,963	24,918	23,495	5913,571	18,623
50,235	2017	6	47,097	44,183	38,267	24,918	6237,857	23,115
48,600	2017	7	50,235	47,097	40,364	38,267	6355,357	26,000
47,438	2017	8	48,600	50,235	41,141	40,364	6223,214	24,000

	Simulações				
	Rede 1	Rede 2	Rede 3	Rede 4	Rede 5
<i>Output</i>	48,659	50,7038	48,589	44,5353	45,8792
APE	2,57%	6,88%	2,43%	6,12%	3,29%
Valor Real	Output médio	APE			
47,438	47,673	0,496			