

# Previsão do Consumo de Instalações Elétricas e do Preço da Eletricidade no Mercado Ibérico com base em Redes Neurais

**DIOGO BOLDT PEREIRA DE SOUSA**

Outubro de 2016

# Previsão do Consumo de Instalações Elétricas e do Preço da Eletricidade no Mercado Ibérico com base em Redes Neuronais

Diogo Boldt Pereira de Sousa



Departamento de Engenharia Eletrotécnica

Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia

2016



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

Candidato: Diogo Boldt Pereira de Sousa, Nº 1110600, 1110600@isep.ipp.pt

Orientação científica: Dra. Zita Vale, zav@isep.ipp.pt

Empresa: Edigreen

Supervisão: Dr. José Luís Alexandre, jlca@edigreen.pt



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

**2016**



*“Success is the sum of small efforts, repeated day in and day out” – Robert Collier*



## *Agradecimentos*

Agradeço aos meus pais pelo apoio incondicional e pelas oportunidades proporcionadas ao longo destes anos que contribuíram positivamente para a minha realização pessoal, académica e profissional.

À orientadora, professora Dra. Zita Vale, pelas orientações dadas ao longo deste percurso, tendo colaborado com o seu conhecimento para aperfeiçoamento desta dissertação.

À empresa Edigreen e a todos os seus colaboradores, em especial ao professor Dr. José Luís Alexandre pela oportunidade concedida de realizar esta tese em ambiente empresarial, numa área do meu interesse, pela disponibilidade de recursos, pela partilha de conhecimento e por todo o apoio na elaboração desta dissertação de mestrado.



## *Resumo*

Ao longo dos últimos anos, o crescimento do consumo e a constante aposta em produção distribuída provocaram alterações no sistema elétrico ao nível da produção, transporte e distribuição. Desta forma foi necessária a implementação de soluções, para permitir ao operador de sistema realizar eficazmente ações de correção de equilíbrio energético, manutenção do nível de frequência adequado e estabelecimento de reservas estratégicas. O conceito de tarifa dinâmica foi implementado para apresentar vantagens para os consumidores, dado que as suas tarifas variam em tempo real, consoante os preços da energia no mercado diário do Mercado Ibérico de Eletricidade (MIBEL).

Esta dissertação de mestrado aborda a área da Energia e incide em temas-chave como Mercados de Energia e Tarifas Dinâmicas. Segundo os tópicos anteriores foram implementados métodos de previsão de consumos e de preço de energia nos mercados diários, para o MIBEL, numa Rede Neuronal Artificial (RNA), utilizando a ferramenta *Neural Network Toolbox*, do MATLAB. Em ambos os tópicos de previsão foram estudadas e comparadas diferentes RNA, para averiguar qual a influência de determinados parâmetros no processo de aprendizagem e qual destas redes permitiria obter melhores resultados.

Os casos de estudo baseiam-se em duas lojas comerciais com fornecimento de energia em Média Tensão, potência contratada de 186kVA, tarifa tetra-horária e um ciclo Semanal.

Em relação aos métodos de previsão, estes exibem resultados interessantes segundo os objetivos delineados. A previsão de consumos mostra melhor aprendizagem devido à conformidade entre os dias treinados; tal não se averigua no segundo tópico de previsão devido às oscilações do preço, no MIBEL. Pretende-se analisar a influência dos parâmetros Produção Eólica, Hídrica, Térmica e Solar no processo de aprendizagem para previsão do preço de energia. Apresenta-se ainda um estudo sobre a aplicação de tarifas indexadas utilizando ambos os métodos de previsão desenvolvidos, concluindo que esta tarifa é vantajosa em algumas situações, contudo existe sempre risco associado, dado a sua dependência dos preços de energia do MIBEL.

### ***Palavras-Chave***

Mercados de Energia, Previsão, Redes Neurais Artificiais, Tarifas Dinâmicas.



## *Abstract*

Over the past few years, the constant increase of consumption and distributed generation caused changes in the electrical system operation in terms of production, transmission and distribution. Therefore, it occurred the need to implement new solutions to allow the system operator to effectively perform energy balance, maintaining the proper frequency level, regulation, establish strategic reserves, among others (Ancillary Services and Balancing Market). The dynamic pricing concept was implemented to provide benefits to consumers, as their rates vary in real-time, depending on the energy prices in the day-ahead market of the Iberian Electricity Market (MIBEL).

This dissertation addresses the Energy area and intends to focus on issues such as economic analysis, energy contracts, consumption optimization, Energy Markets and Dynamic Tariffs. Therefore, it were implemented forecasting methods for consumption and energy price in the day-ahead markets for MIBEL, through Artificial Neural Networks (ANN), using Neural Network Toolbox tool, from MATLAB. In both forecasting methods were studied and compared different ANN, in order to determine the impact that certain parameters have in the learning process and which of these would benefit to achieve better results.

The case study consists of two shops supplied in medium voltage, 186kVA of contracted power, tetra-hourly rate tariff and weekly cycle.

Regarding forecasting methods, these shows interesting results according to the objectives outlined. Consumption forecast demonstrates better learning results due to compliance detected among the trained data, however, in the second method, the relationship between inputs and targets was harder to achieve due to price variations in MIBEL. It is also studied the influence of wind and solar productions parameters in the ANN learning process. It presents a final study about the implementation of indexed tariffs using the developed forecasted methods and concluded that this rate is advantageous, however has risk associated to it, once it depends on the MIBEL energy prices.

### ***Keywords***

Artificial Neural Networks, Dynamic Pricing, Forecast, Energy Markets.



# Índice

<b>AGRADECIMENTOS</b> .....	<b>I</b>
<b>RESUMO</b> .....	<b>III</b>
<b>ABSTRACT</b> .....	<b>V</b>
<b>ÍNDICE</b> .....	<b>VIII</b>
<b>ÍNDICE DE FIGURAS</b> .....	<b>XI</b>
<b>ÍNDICE DE TABELAS</b> .....	<b>XIII</b>
<b>LISTAGEM DE ACRÓNIMOS</b> .....	<b>XV</b>
<b>NOMENCLATURA</b> .....	<b>XVI</b>
<b>1. INTRODUÇÃO</b> .....	<b>1</b>
1.1.CONTEXTUALIZAÇÃO E MOTIVAÇÃO .....	2
1.2.OBJETIVOS PROPOSTOS .....	4
1.3.ORGANIZAÇÃO DA DISSERTAÇÃO .....	5
<b>2. MERCADO DE ENERGIA</b> .....	<b>7</b>
2.1.INTRODUÇÃO .....	7
2.2.TIPO DE MERCADOS DE ENERGIA.....	11
2.2.1.MERCADO À VISTA .....	11
2.2.1.1.MERCADO DIÁRIO.....	11
2.2.1.2.MERCADO INTRADIÁRIO .....	12
2.2.2.MERCADO A PRAZO .....	13
2.3.CONCLUSÃO.....	14
<b>3. TARIFAS DINÂMICAS</b> .....	<b>15</b>
3.1.INTRODUÇÃO .....	15
3.2.TARIFAS DINÂMICAS .....	17
3.2.1.TARIFAS TEMPO DE USO (TOU).....	17
3.2.2.TARIFAS PREÇO EM TEMPO REAL .....	18
3.2.3.TARIFAS PREÇO EM PERÍODO CRÍTICO.....	18
3.2.4.TARIFAS DESCONTO EM PERÍODOS CRÍTICOS .....	19
3.3.CONCLUSÃO.....	19
<b>4. METODOLOGIA DESENVOLVIDA</b> .....	<b>21</b>
4.1.INTRODUÇÃO .....	21
4.2.REDES NEURONAIIS ARTIFICIAIS .....	23
4.2.1.NEURÓNIOS .....	23

4.2.2.TREINO.....	24
4.3.MÉTODO MONTE CARLO.....	25
4.4.METODOLOGIAS PARA PREVISÃO.....	28
4.4.1.PREVISÃO DOS CONSUMOS.....	28
4.4.2.PREVISÃO DE PREÇOS DE ENERGIA NO MERCADO DIÁRIO.....	31
4.5.CONCLUSÃO.....	35
<b>5. CASOS DE ESTUDO.....</b>	<b>36</b>
5.1.INTRODUÇÃO.....	36
5.2.ANÁLISE DE CENÁRIOS – PREVISÃO DE CONSUMO.....	37
5.2.1.COMPARAÇÃO E VALIDAÇÃO DAS REDES NEURONAIS.....	37
5.2.2.CENÁRIO – 18 DE FEVEREIRO.....	39
5.2.3.CENÁRIO – 1 DE FEVEREIRO DE 2016.....	41
5.2.4.CENÁRIO – 9 E 10 DE MARÇO DE 2016.....	43
5.2.5.CONCLUSÕES.....	44
5.3.ANÁLISE DE CENÁRIOS – PREVISÃO DE PREÇO DE ENERGIA.....	45
5.3.1.COMPARAÇÃO E VALIDAÇÃO DAS REDES NEURONAIS.....	46
5.3.2.CENÁRIO – 1 DE MARÇO.....	47
5.3.3.CENÁRIO – 2 DE MARÇO DE 2016.....	51
5.3.4.CENÁRIO – 3 DE MARÇO DE 2016.....	53
5.3.5.CONCLUSÃO.....	54
5.4.COMPARAÇÃO TARIFA INDEXADA E TARIFA TETRA-HORÁRIA.....	57
<b>6. CONCLUSÕES.....</b>	<b>61</b>
6.1.APRECIÇÕES GERAIS.....	61
6.2.TRABALHOS FUTUROS.....	63
6.3.LISTA DE PUBLICAÇÕES.....	63
<b>REFERÊNCIAS.....</b>	<b>65</b>



## Índice de Figuras

Figura 1 – Estrutura dos Mercados Grossistas e Retalhistas [18].	10
Figura 2 – Cruzamento da Oferta com a Procura [3].	12
Figura 3 – Esquema representativo dos Mercados Intradiários [21].	13
Figura 4 – Classificação dos programas de <i>Demand Response</i> , adaptado de [26].	16
Figura 5 – Metodologia Desenvolvida de acordo com os casos práticos abordados.	22
Figura 6 – Exemplo de um Neurónio.	24
Figura 7 – Modelo não-linear de um neurónio, adaptado de [52].	24
Figura 8 – Esquematização de uma rede RNA do tipo <i>feed-forward</i> , adaptado de [52].	25
Figura 9 – Metodologia Considerada para Aplicação do Método de Monte Carlo.	27
Figura 10 – Esquema da Metodologia Desenvolvida: Previsão de Consumo.	29
Figura 11 – Estrutura da Rede Neural Artificial para Previsão de Consumos – <i>c1</i> .	30
Figura 12 – Estrutura da Rede Neuronal Artificial para Previsão de Consumos – <i>c2</i> .	30
Figura 13 – Estrutura da Rede Neuronal Artificial para Previsão de Consumos – <i>c3</i> .	31
Figura 14 – Estrutura da RNA do método <i>v1</i> – Previsão de Preço de Energia.	32
Figura 15 – Estrutura da RNA do método <i>v2</i> – Previsão de Preço de Energia.	33
Figura 16 – Estrutura da RNA do método <i>v3</i> – Previsão de Preço de Energia.	33
Figura 17 – Estrutura da RNA do método <i>v4</i> – Previsão de Preço de Energia.	33
Figura 18 – Esquema da Metodologia Desenvolvida: Previsão de Preço de Energia.	34
Figura 19 – Resultado da previsão de consumo, cenário de 18 de fevereiro de 2015.	39
Figura 20 – Erro relativo percentual, cenário de 18 de fevereiro de 2015.	40
Figura 21 – Resultado da previsão de consumo, cenário de 18 de fevereiro de 2016.	40
Figura 22 - Erro relativo percentual, cenário de 18 de fevereiro de 2016.	41
Figura 23 - Resultado da previsão de consumo, cenário de 1 de fevereiro de 2016.	42
Figura 24 - Erro relativo percentual, cenário de 1 de fevereiro de 2016.	42

Figura 25 - Resultado da previsão de consumo, cenário de 9 e 10 de março de 2016.	43
Figura 26 – Erro relativo percentual, cenário de 9 e 10 de março de 2016.	44
Figura 27 – Diagrama de Consumo Total Diário, 1 de março de 2015 [65].	48
Figura 28 – Resultado da previsão de preço de energia, cenário de 1 de março de 2015.	48
Figura 29 – Erro relativo percentual do cenário 1 de março de 2015.	49
Figura 30 – Diagrama de Consumo Total Diário, 1 de março de 2016 [65].	49
Figura 31 - Resultado da previsão de preço de energia, cenário de 1 de março de 2016.	50
Figura 32 - Erro relativo percentual do cenário 1 de março de 2016.	50
Figura 33 - Diagrama de Consumo Total Diário, 2 de março de 2016 [65].	51
Figura 34 - Resultado da previsão de preço de energia, cenário de 2 de março de 2016.	52
Figura 35 - Erro relativo percentual do cenário de 2 de março de 2016.	52
Figura 36 - Diagrama de Consumo Total Diário, 3 de março de 2016 [65].	53
Figura 37 - Resultado da previsão de preço de energia, cenário de 3 de março de 2016.	54
Figura 38 - Erro relativo do cenário 3 de março de 2016.	54
Figura 39 – Variação do Preço da Energia em 2014.	55
Figura 40 – Variação do Preço da Energia em 2015.	55
Figura 41 – Comparação do Perfil de Consumo Médio Anual – Cliente A.	57
Figura 42 – Comparação do Perfil de Consumo Médio Anual – Cliente B.	58

## *Índice de Tabelas*

Tabela 1 – Comparação entre Métodos para Previsão de Consumo – 10 de janeiro de 2015.	38
Tabela 2 – Comparação entre Métodos para Previsão de Consumo – 11 de janeiro de 2015.	38
Tabela 3 - Comparação entre Métodos para Previsão de Consumo – 12 de janeiro de 2015.	38
Tabela 4 – Comparação dos erros obtidos – Previsão de consumo, método <i>c2</i> .	45
Tabela 5 – Comparação entre Métodos para Previsão de Preço – 10 de janeiro de 2015.	46
Tabela 6 – Comparação entre Métodos para Previsão de Preço – 11 de janeiro de 2015.	47
Tabela 7 – Comparação entre Métodos para Previsão de Preço – 12 de janeiro de 2015.	47
Tabela 8 - Comparação dos erros obtidos – Previsão de preço de energia, método <i>v1</i> .	56
Tabela 9 – Comparação entre Tarifa Tetra-Horária e Tarifa Indexada.	58

## *Listagem de Acrónimos*

EDP	Energias de Portugal
SEN	Sistema Elétrico Nacional
SG	Smart Grid
PD	Produção Distribuída
ToU	Time-of-Use
CPP	Critical Peak Pricing
RTP	Real-Time Pricing
DR	Demand Response
DSM	Demand Side Management
MIBEL	Mercado Ibérico de Eletricidade
OMIE	Operador do Mercado Ibérico de Energia - Pólo Espanhol
OMIP	Operador do Mercado Ibérico de Energia - Pólo Português
PRO	Produção em Regime Ordinário
PRE	Produção em Regime Especial
RNT	Rede Nacional de Transporte
ORT	Operador de Rede de Transporte
RND	Rede Nacional de Distribuição
ORD	Operador de Rede de Distribuição

## *Nomenclatura*

<i>Actual</i>	Valor Verificado
<i>Forecast</i>	Valor previsto pela rede neuronal
EA	Erro Absoluto
ER	Erro Relativo
<i>MAPE</i>	Erro Absoluto Médio Percentual
<i>n</i>	Número de períodos considerados
$y_j$	<i>Output</i> da rede neuronal
$x_i$	<i>Input</i> da rede neuronal
$w_{ij}$	Peso sináptico $w$ associado ao <i>input</i> $i$ e ao <i>output</i> $j$



# 1. INTRODUÇÃO

A dissertação “Previsão do Consumo de Instalações Elétricas e do Preço da Eletricidade no Mercado Ibérico com base em Redes Neurais” foi desenvolvida pelo aluno Diogo Boldt Pereira de Sousa, nº 1110600, no âmbito da unidade curricular Dissertação, associada ao Mestrado em Engenharia Eletrotécnica – Sistemas Elétricos de Energia, do Instituto Superior de Engenharia do Porto (ISEP). Todo o trabalho desenvolvido foi elaborado em ambiente empresarial, na empresa Edigreen – Soluções Energéticas, Lda., localizada no Parque de Ciência e Tecnologia da Universidade do Porto (UPTEC), Rua Alfredo Allen, no Porto.

A Edigreen é uma empresa *spin-off* da Universidade do Porto que detém *know-how* tecnológico qualificado para atuar no setor da energia. No âmbito da sua atividade, a Edigreen presta um conjunto de serviços que permitem ao cliente final reduzir o seu consumo de energia e a sua pegada ecológica, assim como otimizar os custos de produção, cumprir com as obrigações legais e contribuir para a sustentabilidade económica e social. A Edigreen iniciou a sua atividade em 2012, surgindo no mercado com a preocupação de diminuir os custos da energia. Uma empresa de consultadoria energética que propõe alternativas eficientes, independentes e imparciais, atuando com base em soluções de engenharia, que podem englobar desde medidas básicas até às mais inovadoras e complexas.

## **1.1. CONTEXTUALIZAÇÃO E MOTIVAÇÃO**

A eletricidade hoje em dia é considerado como um bem essencial e imprescindível para o cidadão comum, seja para uso doméstico ou industrial. Segundo a Energias de Portugal (EDP), o Sistema Elétrico Nacional (SEN) de energia tem vindo a ser desenvolvido a nível de Produção, Distribuição, Operação dos Mercados, Comercialização, Logística na Mudança de Comercializador e Transporte, avistando promover a eficiência e racionalidade desde a produção até ao consumidor final, nomeadamente, prezar o serviço a nível de qualidade, fiabilidade e segurança [1]-[2].

O Mercado Elétrico Português atingiu, em 1995, o seu primeiro avanço em prol da liberalização do sector energético, o que veio permitir a introdução de concorrência no fornecimento de energia, tendo em vista uma maior competitividade entre os fornecedores face a preços praticados e à qualidade de serviço apresentada, desta forma os clientes têm à sua disposição uma maior oferta. A introdução desta medida surgiu de forma faseada, sendo disponibilizada, inicialmente, para os consumidores de maior potência e, mais tarde, a 4 de setembro de 2006, alargada a todos os consumidores de Portugal Continental [3]. Outro fator de particular importância é a área da Comercialização, sendo que esta atividade foi destituída da responsabilidade dos distribuidores de energia, permitindo a introdução de novos agentes no mercado e introduzindo uma maior concorrência e competição entre os mesmos – liberalização do setor energético – de forma a apresentar as melhores condições aos consumidores. Com a entrada da liberalização do setor energético, os clientes passam a ter a possibilidade de escolherem livremente a empresa comercializadora pretendida para o fornecimento de energia, passando por três passos fundamentais: Consulta, Comparação e Estabelecimento do contrato com Comercializadores. Contudo, é ainda possível salientar que, no mês de setembro de 2015, a EDP era a entidade responsável pela maior quota do mercado energético (80,5%) para consumidores com potência contratada inferior ou igual a 41,4 kVA, demonstrando ser a principal empresa no setor energético [4].

Em seguimento destas áreas apresentadas e para tornar o sistema elétrico produtor de energia mais eficiente, o número de produtores tem vindo a aumentar, dado a crescente penetração de centrais de menor potência, como é o exemplo da Produção Distribuída (PD). De salientar que a introdução e a constante penetração de PD na rede veio incentivar a maneira de como é dada a resposta à procura de energia elétrica em determinadas zonas geográficas. Este tipo

de produção é caracterizada por ser implementada localmente, junto dos consumidores, reduzindo os custos inerentes à distribuição e transporte de energia, podendo até criar zonas autossustentáveis a nível energético [5]. Contudo, dado que também inclui fontes renováveis para a produção de energia, trata-se sempre de uma tarefa árdua de estudo, uma vez que é necessário lidar com a imprevisibilidade associada à produção de cada uma destas unidades produtoras e a sua incorreta localização poderá trazer aspetos negativos, nomeadamente, introdução de variações no perfil de tensão da rede [6]. A elevada penetração de PD na rede, bem como a forma como estas são usualmente geridas, essencialmente a nível de distribuição torna-se num dos fatores-chave para a futura implementação de *Smart Grids* (SG).

O sistema tarifário em vigor em Portugal visa promover a eficiência, o equilíbrio económico e financeiro das empresas reguladas, a qualidade do fornecimento de energia elétrica e a estabilidade da evolução tarifária, sendo todos estes parâmetros definidos no Regulamento Tarifário. Com o avanço tecnológico no mundo da energia, nomeadamente, com a introdução do conceito de SG, bem como a constante penetração de PD no sistema de energia, as tarifas convencionais deixaram de ser vistas como as mais adequadas para dar resposta a este progresso. Para tal, foi introduzido o conceito de tarifa dinâmica, uma forma mais moderna e eficaz para proceder à tarifação da energia elétrica, tendo em conta os requisitos que o sistema de energia necessitava. Das tarifas dinâmicas mais usadas a nível mundial podem destacar-se, essencialmente, as seguintes: *Time-of-Use* (ToU), *Critical Peak Pricing* (CPP) e, por fim, *Real-Time Pricing* (RTP) [7]. A implementação das tarifas dinâmicas só veio a ser possível após a introdução de um contador de energia mais recente, denominado por *smart meter*, este permite aos consumidores obter um maior controlo e informação sobre o custo de aquisição de energia, sendo este variável em função da época do ano (verão ou inverno) e do período do dia em que se encontra. Como já referido, uma das principais vantagens deste sistema é dar a conhecer aos clientes os preços da energia, em tempo real, para os determinados períodos do dia, desta forma é pretendido que estes tenham a capacidade de transferir carga das horas de pico para as horas fora de pico, período em que a rede se encontra menos congestionada e, conseqüentemente, os preços demonstram ser mais vantajosos [8].

Este método de tarifação veio contribuir e complementar o avanço do *Demand Side Management* (DSM), ao demonstrar a sua eficiência na gestão de todo o sistema elétrico [9]. O DSM é um mecanismo importante para aumentar a confiabilidade das *Smart Grids*, uma

vez que consiste nos consumidores adquirirem um comportamento dinâmico, contribuindo para a gestão do sistema, sendo remunerados pela sua participação. Estes comportamentos dinâmicos baseiam-se, essencialmente, na redução de consumo ou no deslocamento de carga para outros períodos. Como já mencionado, as tarifas dinâmicas demonstram ser uma das estratégias mais importantes de DSM, já que visam incentivar a um consumo mais eficiente e racional de energia elétrica. Para um estudo mais aprofundado sobre o DSM é aconselhado verificar algumas das seguintes referências [10],[11],[12],[13],[14].

A gestão ativa dos consumos de energia, tem vindo a ser um tema-chave e alvo de inúmeros estudos e, apesar do seu grande avanço já nos Estados Unidos da América, tem vindo a ganhar cada vez mais popularidade na Europa, sendo adequado a possibilidade de implementação nos mercados de energia elétrica. A investigação associada aos mercados de energia elétrica tem ganho cada vez mais peso nos dias de hoje, devido ao aumento da complexidade da rede elétrica e à imprevisibilidade da produção de energia. A gestão ativa dos consumos apresenta um conjunto vasto de vantagens tanto para o consumidor, como para a própria rede elétrica, uma vez que a participação ativa nestes programas permite-lhes ser remunerados financeiramente. Já para a rede elétrica essas vantagens centram-se, essencialmente, numa possível redução dos consumos, nomeadamente, nos períodos do dia em que a procura é mais elevada – horas de pico – evitando, por exemplo, o congestionamento da rede [15],[16]. Estas medidas são implementadas para contribuírem para uma maior estabilidade, fiabilidade e segurança do sistema elétrico, através de uma gestão mais rigorosa dos operadores. Em relação às tarifas dinâmicas, estas consistem em tarifas cujo preço da energia é variável ao longo de um horizonte temporal e podem ser indexadas aos preços de energia do mercado diário do MIBEL.

## **1.2. OBJETIVOS PROPOSTOS**

Esta dissertação de mestrado aborda a área da Energia e tem como principais objetivos o estudo e desenvolvimento de metodologias capazes de proceder à previsão de consumo e do preço da energia no mercado diário do MIBEL. Posteriormente, pretende apresentar um caso de estudo que aborda ambos os métodos de previsão desenvolvidos, sendo que é pretendido comparar a tarifa indexada e a tarifa atual em vigor no contrato de energia do cliente a considerar para o caso de estudo. Desta forma, procura-se a aplicação de ideias inovadoras que contribuem para a redução dos custos associados ao consumo de energia de

consumidores, reforçando as suas competências internas na área da eficiência energética e reforço do seu posicionamento em prol da sustentabilidade energética.

Para uma melhor planeamento desta dissertação de mestrado foram abordados os seguintes tópicos:

- Estudo sobre o estado da arte:
  - Estudo do mercado de energia, principais características e formas de atuação no mesmo;
  - Estudo de diferentes técnicas de Tarifas Dinâmicas para uma melhor gestão do consumo de energia, com vista a promover a eficiência energética.
- Análise e estruturação de dados de perfis de consumidores: Definição de tipologias de clientes com base nos perfis de consumo;
- Estudo do mercado de energia: Foco nas transações de compra e venda de energia e metodologias para otimização dos consumos e realizar poupanças de energia;
- Apresentação da componente prática:
  - Metodologia Desenvolvida – Implementação de dois algoritmos distintos que permitem a previsão de consumos e do preço da energia no mercado diário do Mercado Ibérico de Eletricidade e respetiva validação dos métodos;
  - Apresentação do trabalho prático com base em casos de estudo: Aplicação dos algoritmos desenvolvidos, a cenários, para previsão de consumos e do preço da energia no mercado diário do MIBEL.
- Análise e conclusão dos resultados obtidos, perspetivas futuras;
- Escrita do relatório e apresentação da dissertação de Mestrado.

### **1.3. ORGANIZAÇÃO DA DISSERTAÇÃO**

Este relatório encontra-se dividido em seis capítulos. No primeiro, é feito um breve enquadramento do tema que se pretende desenvolver e são definidos os principais objetivos propostos.

No segundo e terceiro capítulos pretende-se abordar duas componentes teóricas distintas, sendo que a primeira visa o estudo do mercado de energia, nomeadamente o Mercado Ibérico de Eletricidade (MIBEL), expondo a sua constituição, principais tipos de mercados

existentes para transacionar energia, entre outros. O terceiro capítulo pretende focar-se sobre as Tarifas Dinâmicas, abordando vários programas baseados em preço.

No quarto capítulo é esquematizada a metodologia utilizada para a implementação da componente prática, nomeadamente, para previsão dos consumos e do preço de energia no mercado diário do MIBEL.

No quinto capítulo são apresentados os casos de estudo, os resultados obtidos das simulações efetuadas, para ambos os métodos de previsão, sendo que, por fim, no sexto e último capítulo são apresentadas as conclusões e as perspetivas futuras face ao trabalho desenvolvido.

## 2. MERCADO DE ENERGIA

Neste capítulo pretende-se abordar a evolução do mercado de energia, em Portugal, de um prisma monopolista para um mercado liberalizado, sendo, posteriormente, apresentadas as principais alterações e as respetivas vantagens desta transição.

### 2.1. INTRODUÇÃO

Em Portugal, anteriormente à liberalização do mercado, a empresa Energias de Portugal (EDP) era detentora de todas as atividades do setor atuando de uma forma monopolista. Desta forma, as tarifas eram reguladas e os contratos mantidos durante largos intervalos de tempo (médio a longo prazo), não existindo um concurso ou local de negociações para participação de outras entidades. Com a liberalização do setor energético ocorreu uma desverticalização da companhia de energia, por forma a incentivar o aumento da concorrência, na qual surgiram, individualmente, as atividades de Produção, Transporte, Distribuição e, por fim, Comercialização, acabando assim com o monopólio da empresa EDP.

A atividade da Produção, atualmente, divide-se em dois regimes distintos: regime ordinário e regime especial. A produção em regime ordinário (PRO) é relativa à produção de eletricidade com base em fontes tradicionais não renováveis e em grandes centrais hídricas,

já a produção em regime especial (PRE) engloba a produção de eletricidade através de fontes de energia renováveis e cogeração.

A atividade do Transporte de eletricidade, em muito alta tensão (150, 220 e 400 kV) é efetuada através da Rede Nacional de Transporte (RNT), pelo Operador de Rede de Transporte (ORT), mediante uma concessão atribuída pelo Estado, sendo atualmente explorada pela Rede Elétrica Nacional, S.A. (REN). A REN é assim responsável pela atividade de transporte de energia elétrica, bem como planejar, implementar e operar a RNT, entre as quais se pode salientar as interconexões e infraestruturas associadas. A gestão do Sistema Elétrico Nacional passa pela garantia de segurança e continuidade de fornecimento de energia elétrica e a gestão dos serviços de sistema, conseguido através de um mercado próprio operado pela REN.

A atividade da Distribuição é responsável pela Rede Nacional de Distribuição (RND) consistindo na operação das redes de baixa, média e alta tensão, por parte do Operador de Rede de Distribuição (ORD). Esta atividade também se encontra sujeita a concessão, sendo atualmente explorada pela EDP Distribuição. Esta entidade é assim responsável pela exploração e manutenção da rede de distribuição, garantindo a segurança, qualidade e fiabilidade do serviço entregue ao consumidor.

A atividade de Comercialização, anteriormente à liberalização do setor energético, era da responsabilidade da empresa EDP, uma vez que esta geria as atividades desde a produção até à distribuição de energia ao consumidor final, aplicando tarifas reguladas a estes. A introdução do mercado livre de energia, ou liberalização do setor energético, tem estado em curso desde 2000, tendo sido publicadas as diretivas para a sua implementação somente no ano de 2006. O mercado liberalizado veio acabar com o regulado e trouxe consigo um conjunto vasto de benefícios. Neste tipo de mercado os comercializadores de energia podem competir entre si, sendo que os preços de energia e as condições dos contratos são estipulados individualmente pelos fornecedores, de forma a apresentarem as soluções mais atrativas e adequadas para os diversos tipos de consumidores. Desta forma os clientes finais podem optar livremente pelo comercializador que lhes ofereça as condições mais vantajosas, sem qualquer custo adicional. Os comercializadores de energia passam a agir como intermediário entre os consumidores e o mercado de energia, ou seja, os preços da energia são acordados no mercado e é da responsabilidade de cada comercializador apresentar as suas ofertas com preços mais competitivos, ao invés do anterior mercado regulado, na qual os preços de

energia eram fixos e tabelados anualmente pela ERSE. A introdução da liberalização do setor energético veio trazer uma maior variedade de preços de energia, aumentando a competitividade entre os comercializadores de energia, sendo ainda oferecidos incentivos aos fornecedores para aumentar a eficiência na produção de energia elétrica [17].

Todo o processo de compra, venda e comercialização de eletricidade advém das transações que ocorrem nos mercados grossistas e retalhistas. Estes tipos de mercados iniciam-se com a produção, depois de garantida a respetiva aprovação são conectadas à rede e, posteriormente, produzem eletricidade.

Os mercados grossistas são caracterizados pela compra e venda de energia elétrica entre os agentes produtores e uma segunda entidade que pretenda adquirir, seja com a intenção de satisfazer a necessidade de fornecimento de clientes finais ou para consumo próprio. Estes últimos podem incluir empresas de serviços públicos de energia elétrica, fornecedores de energia competitivos e comercializadores de eletricidade.

Os mercados retalhistas pretendem proceder à transação da energia adquirida no mercado grossista através da venda da mesma aos consumidores finais, ficando esta fase ao encargo das empresas comercializadoras de energia. Como exemplo, um consumidor final irá assumir a responsabilidade de pagar a eletricidade adquirida mensalmente ao comercializador de energia, sendo que a compra e venda ocorre no mercado retalhista. Neste tipo de mercado retalhista, os consumidores finais podem estabelecer contratos através do mercado regulado ou do mercado liberalizado. No primeiro, as tarifas são fixas e lançadas anualmente pela ERSE, porém este método está previsto ser extinto até 31 de dezembro de 2017, obrigando a que todos os fornecimentos de energia elétrica ocorram por intermédio do mercado liberalizado. Como já referido, o mercado liberalizado é caracterizado por cada comercializador ser responsável por praticar os seus preços de energia, no entanto são obrigados a respeitar as regras de concorrência e o Regulamento das Relações Comerciais [18]. A figura 1 pretende esquematizar a divisão entre ambos os tipos de mercados – Grossista e Retalhista.

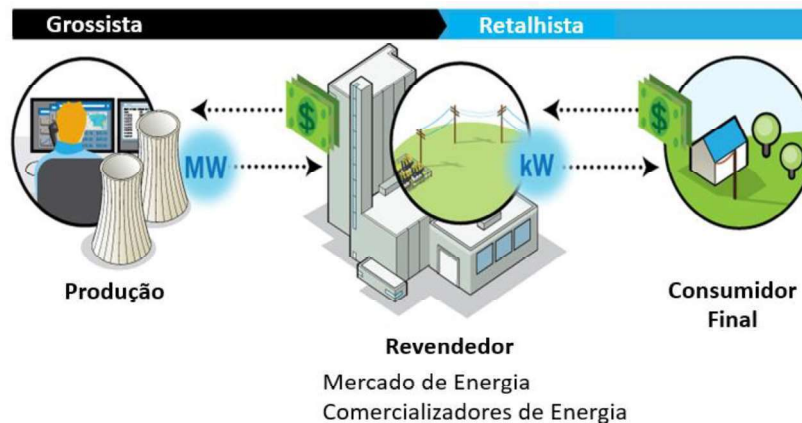


Figura 1 – Estrutura dos Mercados Grossistas e Retalhistas [18].

A constante necessidade de integração de energia no mercado perspectiva futuramente a criação de um Mercado Europeu de Eletricidade. Os Governos de Portugal e Espanha assinaram em novembro de 2001 um protocolo de cooperação que visa promover a integração dos sistemas elétricos e a criação de um Mercado Ibérico de Energia Elétrica – MIBEL. Através do MIBEL é possível proceder à interligação da Península Ibérica com o resto da Europa, segundo as ligações existentes entre Espanha e França, tendo como principal objetivo a contribuição para um Mercado Europeu de Eletricidade.

A 1 de julho de 2007 o MIBEL foi formalmente inaugurado, trazendo benefícios para os consumidores de ambos os países. O MIBEL foi também dividido em duas entidades distintas responsáveis pela organização dos mercados (OMIP e OMIE).

O Operador do Mercado Ibérico de Energia (Pólo Português), SGMR, S.A. – OMIP – entidade que assegura a gestão do mercado a prazo do MIBEL, em Portugal. Já o *Operador del Mercado Ibérico de Energia (Pólo Español) S.A.* – OMIE – é a entidade que gere o mercado *spot* de contratação à vista, responsável pela realização dos mercados diários e dos ajustes intradiários, cuja meta é estabelecer programas de compra e venda de energia para o dia seguinte ao da negociação [19], [20].

Por fim, e na qualidade de Operador de Sistema, a REN, é a entidade responsável pela gestão dos Mercados de Serviço de Sistema, cujos objetivos passam por assegurar o funcionamento de todo o Sistema Elétrico Nacional, desde a sua segurança e harmonia, ao equilíbrio entre a produção e consumo de eletricidade, por forma a garantir a continuidade no fornecimento de energia elétrica.

## **2.2. TIPO DE MERCADOS DE ENERGIA**

### **2.2.1. MERCADO À VISTA**

Neste tipo de contratação, como o próprio nome indica, “à vista”, remete para uma situação de mercado em que as transações ocorrem num curto espaço de tempo. Este tipo de contratação refere-se às transações diárias que se encontram sujeitas a ajustes intradiários.

Como já mencionado, estas transações são da responsabilidade do OMIE, visto que esta é a entidade responsável por gerir os mercados diários e intradiários para o MIBEL. O OMIE é a entidade responsável por gerir o mercado grossista de eletricidade, no qual existe uma participação ativa dos agentes de mercado em sessões para a compra e venda de energia para o dia seguinte. O OMIE agrega as áreas de Portugal e Espanha do MIBEL, na qual prevê que as capacidades de interligação de ambos os países não ultrapassem os fluxos transfronteiriços de energia que a intersecção de ofertas em mercado delimita.

Posteriormente, o Operador do Sistema é responsável por avaliar a viabilidade das transações efetuadas e proceder à contratação dos serviços de sistema e ao respetivo despacho económico. Caso a solução não seja viável, é necessário atuar segundo uma lógica de separação de mercados (*Market Splitting*), sendo acordado, individualmente, preços específicos para cada uma das regiões, por forma a resolver as situações de congestionamento das redes elétricas. Se estes preços forem diferentes para Portugal e Espanha é, usualmente, utilizado o termo *spread* de preço [21].

#### **2.2.1.1. Mercado Diário**

O mercado diário do MIBEL é onde se transaciona a eletricidade que será entregue no dia seguinte à sua negociação. A concorrência nos mercados diários é estabelecida através de leilões, na qual se pretende proceder a um cruzamento de ofertas entre preço e quantidade de energia por parte dos produtores e consumidores (agentes de mercado) [22],[23]. Este tipo de mercado tem sido utilizado no sistema elétrico espanhol desde 1 de Janeiro de 1998 e foi implementado no sistema elétrico português no dia 1 de Julho de 2007, aquando da implementação do MIBEL.

O OMIE é a entidade responsável pela gestão deste mercado, tendo como base de negociação a hora espanhola. O OMIE pretende assim estipular preços para cada uma hora das vinte e quatro horas diárias e para cada um dos 365 ou 366 dias existentes ao longo do ano. Os

preços da eletricidade na Europa são estipulados diariamente (todos os dias do ano) às 12:00 horas, para as vinte e quatro horas do dia seguinte, naquilo que se conhece como Mercado Diário. O preço e o volume de energia numa determinada hora são estabelecidos pelo cruzamento entre a oferta e a procura, como é possível visualizar na figura 2, seguindo o modelo marginalista adotado pela UE, com base no algoritmo aprovado para todos os mercados europeus (EUPHEMIA) [21]. Os agentes de mercado mencionam a sua oferta, de acordo com o preço e quantidade de energia requerida, para uma determinada hora de um dia [3].




Figura 2 – Cruzamento da Oferta com a Procura [3].

#### 2.2.1.2. Mercado Intradiário

O mercado intradiário é visto como um mercado de equilíbrio (*Balancing Market*), ou seja, pretende complementar as transações que ocorrem no mercado diário, através de seis sessões diárias de negociação. Estas seis sessões têm como principal objetivo o ajuste das quantidades de eletricidade que são transacionadas no mercado diário, de forma mais clara e em tempo real, resolvendo possíveis lacunas que possam ocorrer relativamente à oferta e à procura.

A primeira sessão deste mercado estabelece o preço para as quatro últimas horas do dia anterior ( $d-1$ ) e para as vinte e quatro horas do dia seguinte ( $d$ ). Por fim a sexta e última sessão determina o preço para as últimas nove horas compreendidas entre as 16 e as 24h do dia  $d$  [3].

Neste mercado de equilíbrio todos os *players* podem tirar proveito, essencialmente, para assegurar condições para ajustar a produção prevista e os desvios relativamente ao consumo, como podem garantir condições para atenuar as flutuações existentes. Tanto os agentes

produtores, como os comercializadores podem ser responsáveis pela compra e venda de energia. A figura 3 pretende esquematizar a organização do mercado intradiário.




Figura 3 – Esquema representativo dos Mercados Intradiários [21].

### 2.2.2. MERCADO A PRAZO

A gestão do mercado a prazo é da responsabilidade do OMIP. Este pretende estabelecer contratos de compra e venda de transação de energia para entrega futura, seja por um período de uma semana, mês, trimestre ou ano, segundo as regras deste mercado [24].

Nos mercados a prazo podem salientar-se as negociações do tipo contínuo ou em leilão. O primeiro, negociações do tipo contínuo, ocorrem dentro do período de negociação definido no Regulamento de Negociação, já o segundo, negociação do tipo leilão, ocorrem sessões de leilão nas quatro primeiras quartas-feiras do mês, havendo a obrigação de compra de energia para os comercializados de último recurso ibéricos.

No mercado a prazo os contratos estabelecidos denominam-se por contratos bilaterais, uma vez que são contratos estabelecidos entre duas partes (comprador e vendedor). Estes são caracterizados através do tipo de contrato pretendido (Contratos Futuro, Contratos *Forward* ou Contratos *SWAP*), segundo as preferências dos participantes na sua negociação. Estes contratos apresentam ligeiras diferenças entre eles, nomeadamente, quanto ao tipo de liquidação, uma vez que esta pode ser física, através da sua oferta no mercado diário ou ser financeira, quando existir liquidação somente financeira das posições em aberto [3].

O Contrato Futuro é o tipo de contrato mais utilizado para as transações que ocorrem neste tipo de mercado. Estes funcionam como um contrato normal, segundo a estipulação da quantidade de energia a ser transacionada e o preço correspondente, de compra e venda de

energia para um determinado horizonte temporal. Ambos os intervenientes, comprador e vendedor, são responsáveis por cumprir o estipulado em contrato, no qual o primeiro se compromete a adquirir o volume de energia requerida, enquanto o segundo se compromete a disponibilizar esta quantidade conforme o preço estabelecido no contrato. Este contrato encontra-se sujeito a liquidações diárias entre o preço de transação e a cotação de mercado (de futuro) entre si, dado que os compradores e vendedores não estabelecem qualquer tipo de relação existindo para tal uma câmara de compensação responsável por proceder a essas liquidações de contratos [3].

Os Contratos *Forward* são semelhantes aos Contratos Futuro, no entanto estes não se encontram sujeitos a liquidações diárias, mas são liquidados integralmente nos dias de entrega física ou financeira [3].

Os Contratos *SWAP* (por diferenças) são contratos em que se procede à troca de uma posição em preço variável por uma outra posição de preço fixo, ou vice-versa. Este tipo de contrato é deliberado para gerir ou tomar risco financeiro, não existindo, por isso, entrega do produto subjacente mas apenas a liquidação das margens correspondentes [3].

### **2.3. CONCLUSÃO**

Com a liberalização do mercado de energia e conseqüente entrada de novos agentes nas atividades de produção e a comercialização de eletricidade, levaram a uma maior competitividade neste setor elétrico e trouxeram consigo um conjunto de vantagens. A implementação de um Mercado Ibérico de Eletricidade (MIBEL) permitiu fortalecer as relações estratégicas entre Portugal e Espanha, sendo a energia comercializada através de dois mercados adjacentes, o mercado à vista, contemplando o mercado diário e intradiário, e o mercado a prazo. Estes mercados são geridos por duas entidades diferentes, sendo que o OMIP – pólo português – é responsável pelos mercados a prazo, sendo o OMIE – pólo espanhol – responsável pela gestão dos mercados à vista.

# 3. TARIFAS DINÂMICAS

Neste capítulo pretende-se retratar o conceito de tarifa dinâmica e analisar um conjunto de estratégias que podem ser implementadas pelos consumidores, por forma a reduzir os consumos energéticos nos períodos críticos.

## 3.1. INTRODUÇÃO

A introdução do conceito de gestão ativa dos consumos em mercados de energia, *Demand Response* (DR), não é novo, porém a sua implementação veio introduzir novas maneiras de equilibrar e regular o sistema de energia, manter o nível de frequência, entre outras. A DR é, usualmente, definida como “... mudanças na utilização da eletricidade pelos consumidores finais, com base nos seus padrões de consumo, em resposta à variação dos preços de eletricidade ou um outro sinal relacionado a problemas técnicos ou de funcionamento do mercado. Contudo, poderá haver pagamentos de incentivos destinados a reduzir o consumo de eletricidade em períodos em que o preço assume valores mais elevados ou até mesmo quando a fiabilidade do sistema está em causa.” [25],[26],[27],[28].

A DR refere-se a um conjunto amplo de estratégias que podem ser executadas, por parte do consumidor, em resposta a condições específicas do sistema de energia, permitindo solucionar problemas de défice de produção, de congestionamento da rede elétrica ou até mesmo de preços de eletricidade elevados [29]. Desta forma o consumidor final terá a

possibilidade de reduzir o seu consumo de eletricidade durante os períodos críticos, ou de ponta, quando os preços de energia assumem valores mais elevados, por exemplo alterar as configurações do termóstato dos sistemas de aquecimento, arrefecimento e ar condicionado (AVAC). Todavia esta medida, apesar de levar a uma redução de consumo, poderá influenciar no conforto do consumidor. Uma segunda medida estratégica comumente empregue é a resposta dos clientes aos preços elevados de eletricidade, surgindo a possibilidade de deslocar cargas dos períodos de pico para outros, fora de pico, em que o preço da eletricidade seja mais baixo. Um exemplo desta aplicação a nível doméstico é usufruir dos aparelhos de maior consumo como máquinas de lavar-roupa ou de lava-loiça nos períodos fora de pico (Cheia, Vazio ou Super Vazio), contribuindo diretamente para uma redução da fatura energética do cliente. Uma terceira opção passaria pela Produção Distribuída (PD), uma forma de produção de energia local que os clientes poderiam possuir. Estes teriam a possibilidade de produzir e consumir instantaneamente (autoconsumo) a sua própria energia, evitando consumo da rede elétrica. Porém esta medida necessita de ser instalada e representa um investimento para o consumidor [30],[31],[32]. Alguns trabalhos com a implementação da DR é apresentado em [33],[34].

A DR é constituída por dois programas distintos: Programa Baseado em Incentivos e Programa Baseado em Preço. A seguinte figura pretende classificar os dois tipos de programas e os respetivos subprogramas associados a cada um deles.

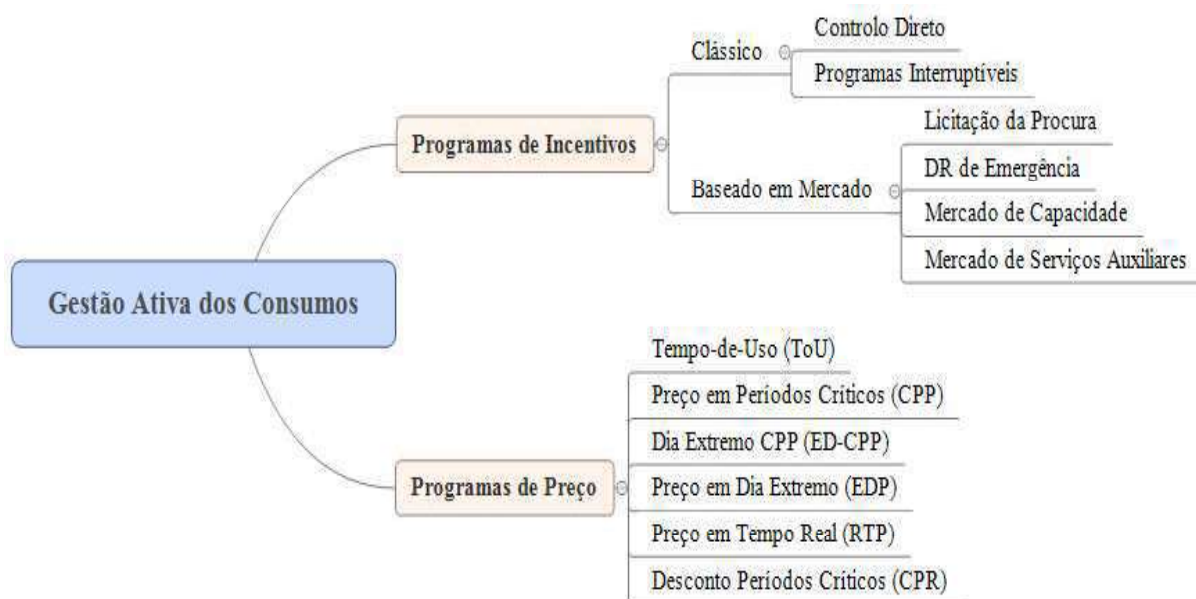


Figura 4 – Classificação dos programas de *Demand Response*, adaptado de [26].

Ao longo desta tese pretende-se abordar, essencialmente, os programas baseados em preço, como irá ser apresentado ao longo deste capítulo. As tarifas dinâmicas surgiram como resposta à evolução do setor energético que foram desenvolvidas de forma a introduzir vantagens e contribuir para atingir os objetivos estipulados para as políticas energéticas, tais como aumentar a fiabilidade do sistema elétrico. Nos últimos anos tem havido um desenvolvimento no sentido de intensificar a implementação deste tipo de tarifas, muito devido à evolução do sistema elétrico, o que veio salientar a necessidade de monitorizar as atividades dos consumidores em tempo real, para tal foi essencial a inclusão de *smart meters* [35]. Anteriormente, as tarifas simples tradicionais eram as predominantes e eram caracterizadas pelo seu preço único, invariável ao longo do dia. As tarifas dinâmicas são definidas como uma variação do preço em função do tempo [36]. A nível de gestão de eletricidade, é esperado um controlo mais acessível por parte dos consumidores, através da instalação de *smart meters*, ficando estes responsáveis por dar uma resposta aos períodos críticos de consumo existentes ao longo do ano, dado que são sinalizados com um preço mais elevado [37].

Em suma, através da implementação das tarifas dinâmicas é esperado que os consumidores sejam informados, em tempo real, do preço da energia, de forma a serem incentivados a reduzir os consumos nas horas de pico ou a transferirem carga para períodos do dia mais vantajosos, ou seja, em que o consumo de energia seja menos intensivo e, conseqüentemente, o preço da energia seja menor – períodos fora de pico [38]. Desta forma, e para que a implementação das tarifas dinâmicas apresente o sucesso pretendido, é necessário que exista flexibilidade por parte dos consumidores para assumir um papel mais ativo na sua gestão dos consumos, ao contribuírem diretamente para a alteração do seu diagrama de cargas, originando assim a diminuição da sua fatura energética [39],[40].

## **3.2. TARIFAS DINÂMICAS**

### **3.2.1. TARIFAS TEMPO DE USO (TOU)**

As tarifas Tempo de Uso, ou *Time-of-Use* (ToU), são caracterizadas por apresentarem um conjunto de tarifas diferentes para distintas horas do dia, ou estações do ano, sendo estipulada no início de um ciclo tarifário e mantida constante, normalmente, durante um ano. Este programa de *Demand Response* (DR), baseado em tempo, pretende incentivar os consumidores a adotarem um comportamento mais responsável, dado que estes têm

conhecimento antecipado do preço da energia para os diversos períodos do dia e competelhes ajustar o seu consumo [41].

As ToU podem ser usualmente compostas por dois ou três períodos diários distintos – vazio, cheia e ponta – podendo variar consoante a estação do ano (inverno ou verão), sendo que em cada um destes períodos encontra-se associada uma tarifa específica. Estas tarifas, juntamente com a aplicação dos *smart meters* vieram dar a possibilidade ao consumidor de monitorizar em tempo real os seus consumos. Como este passou a obter conhecimento da energia consumida e o respetivo preço num determinado momento do dia, o cliente irá possuir uma maior capacidade de atuação no seu diagrama de cargas e, posteriormente, reduzir a sua fatura energética. Uma das medidas que poderá ser implementada, através de uma utilização racional da eletricidade, é a transferência de carga dos períodos de pico para os períodos fora de vazio, de forma a aproveitar as alturas em que o custo da eletricidade é menor [42],[43],[44].

### **3.2.2. TARIFAS PREÇO EM TEMPO REAL**

As tarifas de Preço em Tempo Real, *Real-Time Pricing* (RTP), são caracterizadas por apresentarem diferentes preços de hora em hora, ou então variam a curto-prazo, usualmente estas tarifas encontram-se associadas às modificações existentes nos mercados grossistas [45]. Esta tarifa dinâmica, assim como as apresentadas anteriormente, visa incentivar à redução do consumo nos períodos em que o preço da eletricidade é mais elevado e, naturalmente, à redução da fatura energética dos clientes, contudo aparenta ser a tarifa dinâmica mais complexa e, conseqüentemente, de mais árdua implementação e de custos mais elevados [39]. Assim como no CPP, os participantes são avisados com antecedência dos preços da eletricidade, normalmente na noite anterior, de forma a planearem o seu perfil de consumo energético mais adequadamente para o dia seguinte [46],[47].

As tarifas RTP são importantes para estudar a flexibilidade e a predisposição que os consumidores apresentam para dar resposta aos períodos de pico, sendo fulcral para estudar situações de *Demand Response* [48].

### **3.2.3. TARIFAS PREÇO EM PERÍODO CRÍTICO**

O Preço em Período Crítico, ou *Critical Peak Pricing* (CPP), é visto como uma estratégia adotada para controlar a procura de eletricidade e facilitar a conservação de energia nos

períodos em que o consumo e os preços no mercado grossista são elevados (períodos de pico), tendo como exemplo dias muito quentes ou muito frios que ocorram ao longo do ano.

Nestas tarifas CPP, os clientes ficam responsáveis por pagar preços exorbitantes durante os períodos de pico ou eventos críticos. Esta metodologia é aplicada nos momentos em que a estabilidade do sistema de energia é ameaçada devido ao elevado consumo, tendo como resposta o aumento significativo do preço de eletricidade nos períodos de pico. Os operadores são responsáveis por avisar o consumidor previamente sobre estes eventos, normalmente com um dia de antecedência, sendo esperado que este adote um comportamento que vise reduzir o seu padrão de consumo de energia elétrica, como por exemplo desligar o seu ar condicionado [49],[50].

Os eventos de CPP são caracterizados também por cumprir um conjunto de normas, tais como a limitação do número de eventos, do número máximo de horas e de dias de aplicação de pico por ano, de forma a promover a participação dos consumidores, reduzindo o seu risco [45],[39].

#### **3.2.4. TARIFAS DESCONTO EM PERÍODOS CRÍTICOS**

As tarifas Desconto em Períodos Críticos, ou *Critical Peak Rebates* (CPR), são o oposto à tarifa CPP. Na CPR os participantes vão ser pagos por adotarem medidas que tenham como objetivo a redução de energia nos períodos de pico [39]. Este método tende a ser mais facilmente aceite pelos clientes e pelos reguladores de energia, uma vez que os consumidores apenas vão receber um incentivo caso participem, reduzindo assim os seus consumos nos períodos de maior afluência. Caso não participem, ficam sujeitos às tarifas implementadas [45]. No entanto, esta tarifa comporta-se de semelhante forma à CPP, dado que informa previamente os consumidores acerca do preço da energia, de forma a incentivá-los a reduzir o seu padrão de consumo, nas horas de ponta, visando a poupança na sua fatura energética.

### **3.3. CONCLUSÃO**

O estudo sobre as tarifas dinâmicas, permitiram chegar à conclusão que seria interessante para o consumidor a introdução de uma tarifa de energia que apresentasse uma variação horária consoante os preços do MIBEL, espelhando assim as horas em que o sistema de energia iria apresentar custos mais elevados na produção e compra de energia elétrica. Atualmente, a informação dos preços de energia enviada ao consumidor não apresenta uma

variação temporal refletindo os preços praticados no mercado diário, mas sim dividindo o dia em períodos (ponta, cheia, vazio e super vazio). É assim esperado que através das tarifas dinâmicas os consumidores passem a ter uma maior flexibilidade nas suas respostas aos preços da energia praticada no mercado, originando assim uma reestruturação do sistema elétrico, incentivando a possíveis reduções de custos, tanto para os consumidores, como para os produtores e gestores do sistema.

# 4. METODOLOGIA DESENVOLVIDA

Neste capítulo pretende-se apresentar uma componente teórica apresentando os métodos abordados – Redes Neurais Artificiais e Método de Monte Carlo - a metodologia desenvolvida para a implementação dos casos práticos desenvolvidos.

## 4.1. INTRODUÇÃO

A explicação sobre a metodologia desenvolvida para a realização do trabalho, sendo que este encontra-se dividido em dois casos práticos distintos, no qual o primeiro consiste na previsão dos consumos e o segundo incide na previsão dos preços de energia do mercado diário, no mercado de energia. A figura 5 esquematiza os casos práticos e os principais tópicos abordados.

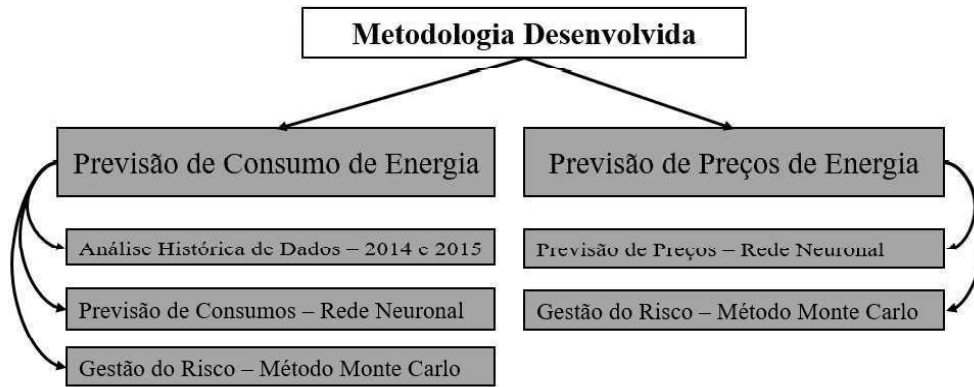


Figura 5 – Metodologia Desenvolvida de acordo com os casos práticos abordados.

Em relação ao primeiro caso é possível enfatizar que segundo os objetivos propostos, pretende focar, a funcionalidade de previsão de consumos de uma loja comercial. Pode salientar-se que para este método os dados de aprendizagem considerados correspondem apenas aos dois anos anteriores, devido à limitação de dados, convém realçar que este limite temporal pode trazer instabilidade nas respostas da rede. Para desenvolvimento da previsão de consumos, utilizou-se a ferramenta do MATLAB, *Neural Networks Toolbox*, para proceder ao treino e validação de uma rede com dados de 2014 e 2015. Por fim, é aplicado o Método de Monte Carlo para proceder à Gestão de Risco, como irá ser demonstrado mais à frente neste documento.

O segundo caso prático visa abordar os mercados de energia, tendo como principal intuito a previsão dos preços de energia praticados para o mercado diário. De forma semelhante ao primeiro caso, pretende-se proceder à previsão do preço de energia, no mercado diário do MIBEL, utilizando a *Neural Network Toolbox*, do MATLAB, para treinar e validar a rede consoante os parâmetros de entrada considerados. Por fim, assim como no método anterior, através dos *outputs* da rede neuronal são gerados novos cenários através de um método estatístico, por forma a gerir o risco associado.

A previsão do risco dos cenários é calculada através dos erros absolutos, relativos e, por fim, erro MAPE, como demonstram, respetivamente, as equações apresentadas na seguinte tabela:

$$EA = | Actual - Forecast | \quad (1)$$

$$ER = \left( \frac{EA}{| Actual |} \right) \times 100 \quad (2)$$

$$MAPE = \left( \frac{1}{n} \sum_{i=1}^n \frac{| Actual_i - Forecast_i |}{| Actual_i |} \right) \times 100 \quad (3)$$

O erro absoluto, apresentado na Equação 1, foi considerado para determinar a precisão da previsão obtida através da rede neuronal, em relação ao seu valor real.

O erro relativo, apresentado na Equação 2, encontra-se dependente do cálculo do erro absoluto, uma vez que o pretende comparar com o valor real (*Actual*), no contexto desta dissertação que visa a previsão de consumo e de preço de energia.

O erro MAPE, apresentado, anteriormente, na Equação 3, é um erro muito usual em métodos estatísticos. Este erro é calculado através do somatório dos erros relativos percentuais e dividido pelo número de períodos considerados (*n*).

## 4.2. REDES NEURONAIAS ARTIFICIAIS

As Redes Neurais Artificiais (RNA) foram desenvolvidas com o intuito de modelar o cérebro humano para desempenhar determinadas funções. As RNA são compostas por várias unidades de processamento, conectadas por canais de comunicação que se associam a um determinado peso sináptico, tornando-se essencial para a rede se adaptar à informação disponível e obter o conhecimento esperado [51]. Para atingir melhores resultados é necessário existir uma boa interligação entre neurónios, de forma a serem adaptados ao processo de aprendizagem, uma vez que as RNA aprendem com a experiência [52],[53].

### 4.2.1. NEURÓNIOS

Os neurónios recebem e transmitem sinais de e para outros neurónios através das conexões estabelecidas, chamadas sinapses. O neurónio é constituído pelo corpo celular (núcleo celular), pelas dendrites (*inputs*) – recetores de mensagens – e pelo axónio (*output*) – transmite o impulso nervoso. A figura 6 esquematiza um neurónio e pretende demonstrar o percurso de transmissão de um sinal desde as dendrites até à passagem para um segundo neurónio.

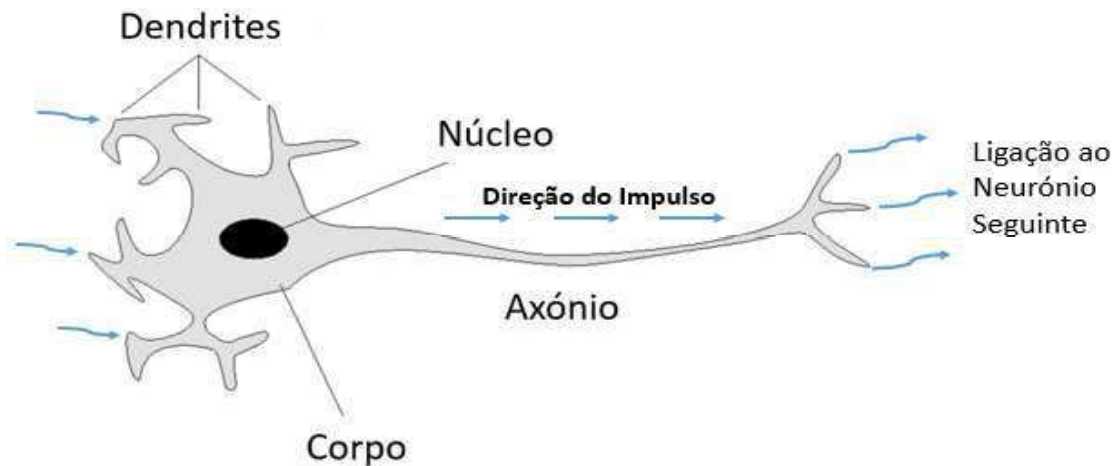


Figura 6 – Exemplo de um Neurónio.

Segundo Haykin, o modelo de um neurónio pode ser identificado em três elementos básicos: Sinapses, Somador e Função de Ativação. As Sinapses, ou elos de ligação, de um neurónio são caracterizadas pela sua amplitude ou força de ligação – pesos sinápticos – entre dois neurónios. O Somador é responsável por somar os sinais de entrada, de acordo com os pesos das respetivas sinapses. Por fim, a Função de Ativação tem como principal função definir a saída (*outputs*) definindo os parâmetros de entrada (*inputs*) e a limitação da amplitude de saída, com base nos respetivos pesos sinápticos [52]. A imagem 7 apresentada dá conta de um modelo não-linear de um neurónio.

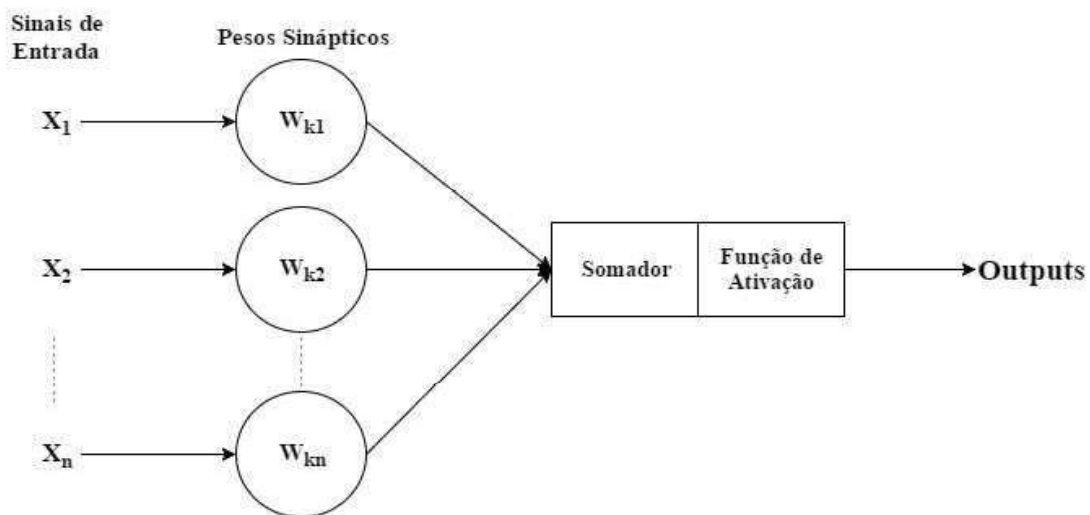


Figura 7 – Modelo não-linear de um neurónio, adaptado de [52].

#### 4.2.2. TREINO

A aprendizagem do treino provém da experiência, ou seja para atingir melhores resultados, é necessário fornecer parâmetros de entrada coerentes e as respetivas respostas (*targets*), de forma à rede aprender qual deveriam ter sido os *outputs* produzidos. Durante o treino da rede

existe um constante ajuste dos pesos sinápticos ligados aos neurónios, para que a resposta produzida pela rede, perante um determinado *input* seja a mais adequada, ou seja é esperado que a rede estabeleça uma relação entre os *inputs* e os *targets* [54],[55]. A equação 4 apresenta os *outputs* ( $y$ ) de um neurónio  $j$ , de acordo com a relação estabelecida entre os *inputs* ( $x$ ) do neurónio  $i$  e o peso sináptico ( $w$ ) entre os respetivos neurónios  $i$  e  $j$ .

$$y_j = \sum_i w_{ij} \cdot x_i \quad (4)$$

As redes podem ser submetidas a dois tipos de treino diferentes, do tipo *forward* ou *backward*. Os treinos elaborados ao longo desta dissertação foram desenvolvidos segundo o tipo *feed-forward*, ou seja, os sinais propagam-se numa única direção, desde a camada dos *inputs* até à camada dos *outputs*, gerando os *outputs* na camada dos *outputs*. O algoritmo utilizado para aprendizagem é designado por *Back Propagation Algorithm* (BPA). Mais informação sobre o BPA é apresentada nas seguintes referências [52], [56], [57]. A imagem 8 esquematiza uma rede RNA do tipo *feed-forward*, dividida em três camadas distintas: *inputs* (a), *hidden layer* ou camada oculta (b), e, por fim, *outputs* (c).




Figura 8 – Esquematização de uma rede RNA do tipo *feed-forward*, adaptado de [52].

### 4.3. MÉTODO MONTE CARLO

O Método Monte Carlo (MMC) é utilizado quando surge a necessidade de proceder a estimativas, previsões ou decisões, em síntese, sempre que existir um elevado grau de incerteza associado. Este método foi considerado com o propósito de gerir o risco dos

*outputs* gerados pela RNA, relativamente à previsão de consumo e de preço da energia. Assim aplica-se um método estocástico, capaz de reduzir, ou até mesmo mitigar, o risco associado na tomada de decisão [58].

Desta forma, o MMC pretende fornecer soluções aproximadas para uma variedade de problemas matemáticos através da realização de experiências, sendo que neste contexto foi utilizado para gerir o risco associado dos problemas abordados. Este pode ser definido como um método estatístico que permite gerar cenários, onde cada cenário é composto por uma sequência de números aleatórios. Pretende-se assim com este processo desenvolver um conjunto vasto de cenários, através de números aleatórios, e identificar o cenário com maior probabilidade de ocorrência e que mais se aproxime da resposta pretendida, segundo o problema em questão – previsão de consumo e preço de energia. Contudo, como se trata de uma aproximação, a análise do erro é um fator importante a ter em conta na validação destes métodos. Mais informação pode ser encontrada nos seguintes trabalhos [59],[60],[61].

A figura 9 descreve a metodologia considerada para a aplicação do MMC. Como é possível visualizar, os *outputs* previstos pela RNA foram considerados para a Gestão de Risco. É também importante evidenciar que para cada parâmetro de entrada encontra-se associado um parâmetro de saída. Como já referido, os parâmetros de entrada são criados através de amostragens aleatórias de cada distribuição, já os valores dos parâmetros de saída são obtidos através dos diversos cenários simulados. De salientar que tanto os parâmetros de entrada, como os de saída apresentam o mesmo conjunto de valores [62].

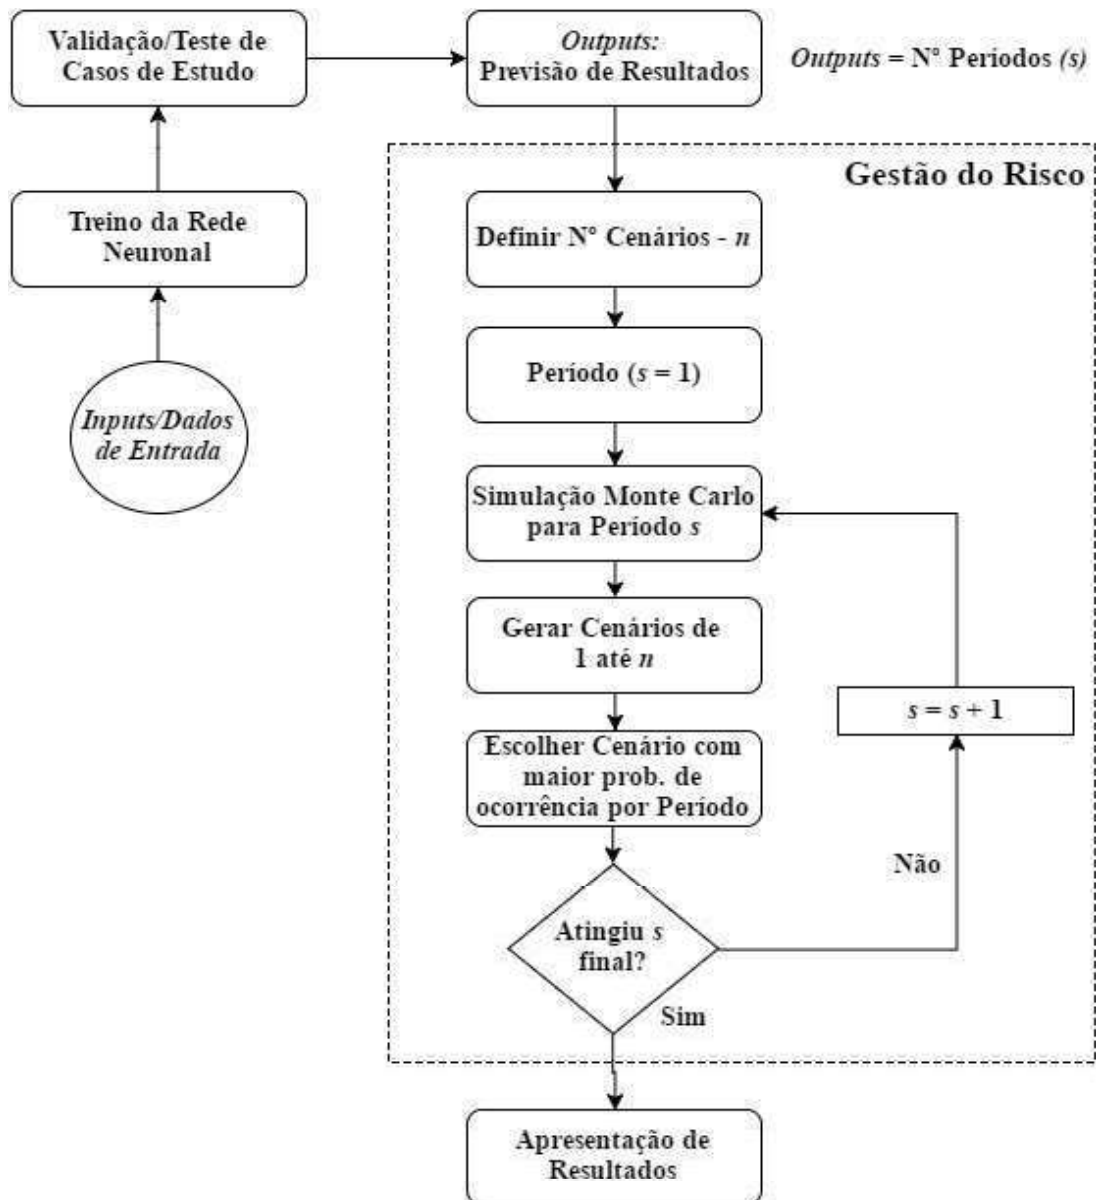


Figura 9 – Metodologia Considerada para Aplicação do Método de Monte Carlo.

As seguintes equações abaixo apresentadas – média e desvio padrão – foram as principais equações consideradas para a simulação do Método de Monte Carlo, relativamente à Gestão de Risco. De salientar que o desvio padrão representa a “dispersão” de resultados em relação à média, ou seja, quanto menor for o desvio padrão maior é a proximidade dos dados ao valor médio, se o desvio padrão for elevado maior será a variação dos dados à média. A equação 5 e 6 dizem respeito, respetivamente, ao valor médio e ao desvio padrão sendo estas equações utilizadas para gerar cenários para cada período.

$$\bar{x} = \frac{1}{n} \sum_i x_i \quad (5)$$

$$\sigma = \sqrt{\frac{1}{N-1} \sum_i (x_i - \bar{x})^2} \quad (6)$$

## 4.4. METODOLOGIAS PARA PREVISÃO

### 4.4.1. PREVISÃO DOS CONSUMOS

Com o intuito de proceder à previsão de consumos foi desenvolvido um algoritmo que empregou a *Neural Network Toolbox*, uma ferramenta computacional facultada pelo MATLAB, concebida para implementar Redes Neurais Artificiais [63].

Esta metodologia foca-se na sua principal funcionalidade, previsão de consumos, permitindo ao utilizador introduzir o período para o qual deseja obter uma previsão dos seus consumos para o ano de 2016 (*output*). Assume-se assim os consumos do ano de 2014 e 2015 como parâmetros de entrada para o treino e respetiva validação, da rede neuronal artificial. Por outro lado, dada a limitação de dados no processo de treino, os resultados produzidos pela rede demonstram ser mais consistentes para um horizonte temporal de curto a médio prazo, como será revelado no Capítulo 5.

De modo a complementar os resultados gerados pela RNA, salienta-se a utilização de um método estatístico, Método Monte Carlo (MMC), para proceder à gestão do risco. Assim sendo, e como parâmetro de entrada, foi introduzido o *output* gerado pela rede neuronal, para ser alvo da criação de  $n$  cenários. O principal objetivo consiste em gerar  $n$  cenários para cada período do dia, sendo assumido que os cenários que se repetem mais vezes podem ser considerados como as situações com maior probabilidade de ocorrência.

Como curiosidade sobre o processo de treino da Rede Neuronal Artificial salientam-se os seguintes parâmetros de entrada, sendo  $d$  o dia que se pretende prever: Consumo ( $d-1$ ), Consumo Semana Anterior ( $d-7$ ), Consumo Médio Diário ( $d-1$ ), Temperatura ( $d-1$  – Graus Celsius), os Feriados Nacionais (0 ou 1), a Sazonalidade (1-inverno/2-verão) e o respetivo Dia da Semana ( $d-1$  a 7: segunda a domingo). Os parâmetros de entrada referente à Carga, Carga Semana Anterior e Temperatura consideraram 96 valores diários, já o Consumo Médio Diário, Feriados Nacionais, Sazonalidade e Dia da Semana é atribuído um valor diário por parâmetro, como irá ser verificado mais à frente nesta secção. A base de dados utilizada foi cedida pela empresa Edigreen, sendo esta informação preservada ao longo do documento por questões de confidencialidade e proteção de informação privada do cliente.

Relativamente aos valores de Consumo, estes foram obtidos através de telecontagem, já os valores de Temperatura foram obtidos através de análise da estação meteorológica localizada mais próxima do cliente, uma vez que este parâmetro assume ligeiras variações consoante a zona Norte, Centro ou Sul do país.

A figura 10 representa um esquema do conteúdo apresentado anteriormente, relativamente à componente prática de previsão dos consumos.

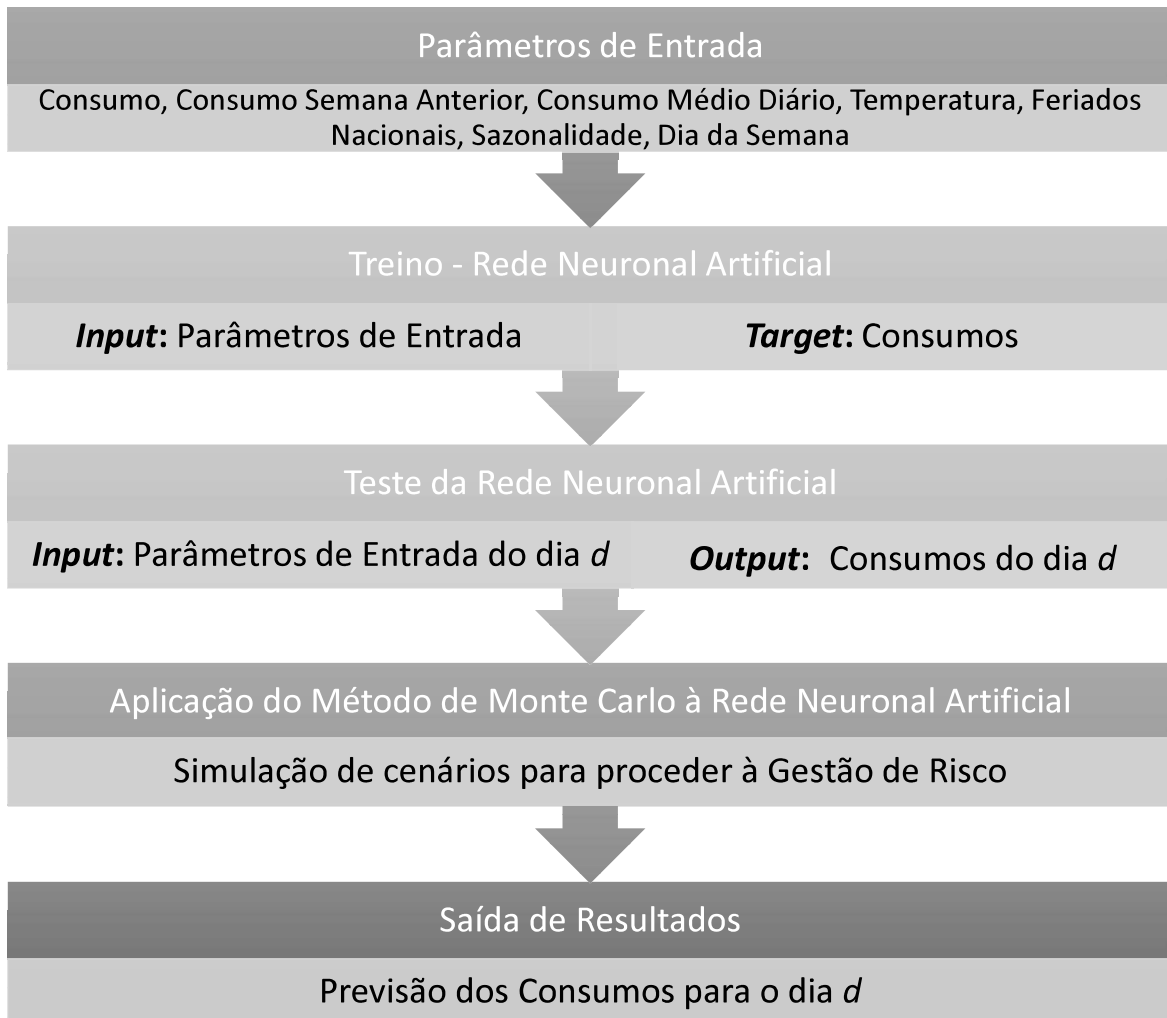


Figura 10 – Esquema da Metodologia Desenvolvida: Previsão de Consumo.

A nível computacional deve salientar-se ainda que foram desenvolvidas e comparadas três redes neuronais distintas  $c1$ ,  $c2$  e  $c3$  para proceder à previsão do consumo. As três redes neuronais foram treinadas por uma camada intermédia de cem (100) neurónios para atingir o desempenho inicialmente definido. A RNA  $c1$  é constituída por 292 parâmetros de entrada. Como mencionado anteriormente, os parâmetros referentes à Sazonalidade, Dia da Semana, Feriados Nacionais e Consumo Médio Diário consideram um valor diário, os restantes

parâmetros consideram 96 valores de entrada para cada dia. Pretende-se com a rede *c1* obter como *output* os consumos para os 96 períodos diários, como é demonstrado na figura seguinte.




Figura 11 – Estrutura da Rede Neural Artificial para Previsão de Consumos – *c1*.

A rede *c2* para o processo de aprendizagem engloba os mesmos parâmetros da rede *c1*, no entanto apenas considerou 208 valores de entrada. Os parâmetros relativamente à Carga, Carga da Semana Anterior e à Temperatura, ao invés dos 96 períodos, foram atribuídos 68 valores, correspondendo ao período em que a loja comercial iria estar em funcionamento, entre as 7h às 23:45h (68 períodos). Desprezando o período em que a loja se encontra encerrada – da 00h às 6:45h – uma vez que durante este intervalo de tempo, este consumidor, apresenta um consumo médio noturno de 12 kW, salvo ligeiras discrepâncias que possam aparecer devido a manutenção ou limpeza da instalação. Na sua totalidade foram treinados 208 parâmetros de entrada e é esperado a previsão para os 68 períodos – 7h às 23:45h.




Figura 12 – Estrutura da Rede Neuronal Artificial para Previsão de Consumos – *c2*.

A rede *c3*, tal como a *c1*, apresenta 96 períodos do dia como *output*, no entanto apresenta 291 dados de entrada. Esta rede apenas considerou para treino os meses referentes à estação de inverno do ano de 2014 e 2015 (janeiro a março e outubro a dezembro), excluindo assim o parâmetro da Sazonalidade, visto ser treinada apenas para uma estação do ano. Esta rede

foi desenvolvida para proceder à previsão de consumos de cenários que se situem temporalmente nesta estação do ano, como irá ser abordado ao longo nesta dissertação.




Figura 13 – Estrutura da Rede Neural Artificial para Previsão de Consumos – c3.

#### 4.4.2. PREVISÃO DE PREÇOS DE ENERGIA NO MERCADO DIÁRIO

Em seguida irá ser apresentado e explicado todo o processo que englobe a metodologia desenvolvida referente à previsão do preço de energia do Mercado Diário, do Mercado Ibérico de Eletricidade.

Para a execução deste algoritmo foram tidos em conta os mesmos métodos computacionais considerados na previsão de consumos exibidos anteriormente, ou seja a utilização da *Neural Network Toolbox*, do MATLAB, para proceder à previsão de resultados e, posteriormente, o Método de Monte Carlo para gerir o risco associado.

Nesta componente prática, a RNA foi treinada para um horizonte temporal de 26 meses, de janeiro de 2014 a fevereiro de 2016, sendo pretendido obter uma previsão a curto prazo do preço da energia, para o mês seguinte, março de 2016.

Sabendo que se pretende prever para o dia  $d$ , os parâmetros de entrada considerados para treino foram os seguintes: Preço da Energia ( $d-2$ ), Preço da Energia Semana Anterior ( $d-7$ ), Temperatura ( $d-2$ ), Velocidade do Vento ( $d-2$ ), Produção Eólica ( $d-2$ ), Produção Térmica ( $d-2$ ), Produção Hídrica ( $d-2$ ), Produção Solar ( $d-2$ ), Consumo ( $d-2$ ), Sazonalidade ( $d-2$ ), Dia da Semana ( $d-2$ ) e, por fim, os Feriados Nacionais.

O preço da energia foi conseguido segundo o levantamento de dados intensivo do Operador de Mercado Ibérico – Pólo Espanhol S.A. (OMIE) que dirige o Mercado Ibérico de energia elétrica (MIBEL) para Portugal e Espanha. Relativamente à Temperatura e Velocidade do Vento estes foram obtidos através da *Weather Underground*, um *website* cujo conteúdo remete para a apresentação dos valores registados pelas estações meteorológicas [64]. Os

valores dos parâmetros de Produção Térmica, Solar, Eólica e Hídrica foram conseguidos segundo o Centro de Informação da REN, um *website* que disponibiliza informação referente aos diagramas de consumo registados, em Portugal, relativamente à quantidade de energia produzida por tipo de tecnologia, bem como dados de consumo, importação/exportação, entre outros, em períodos de quinze minutos [65].

Assim como na previsão de consumos, procedeu-se ao desenvolvimento de quatro RNA distintas –  $v1$ ,  $v2$ ,  $v3$  e  $v4$ . O intuito seria comparar os quatro métodos por forma a verificar qual o impacto que a ausência de determinados parâmetros no processo de aprendizagem poderia causar, posteriormente, na previsão de resultados.

A estrutura das quatro RNA relativamente ao processo de treino consistiu numa camada intermédia constituída por cem neurónios, por forma a atingir o desempenho previamente definido, no entanto as redes variam entre elas na quantidade de parâmetros de entrada considerados. Todavia são esperados 24 *outputs* da rede correspondendo cada um desses valores a um preço de energia de cada hora do dia que se pretende prever.

O método  $v1$  pretende utilizar todos os parâmetros de entrada ponderados, contabilizando duzentas e dezanove (219) entradas. Estas são compostas pelos parâmetros de Sazonalidade (1-inverno / 2-verão), Dia da Semana (de 1 até 7 - segunda até domingo) e Feriados (0- dia normal/1- feriado ou fim-de-semana) que assumem, individualmente, um valor de entrada em cada dia, já os restantes parâmetros assumem 24 valores diários.




Figura 14 – Estrutura da RNA do método  $v1$  – Previsão de Preço de Energia.

O método  $v2$ , dos parâmetros de entrada apresentados anteriormente, não considerou a Produção Térmica e Produção Hídrica, contabilizando na sua totalidade cento e setenta e uma (171) entradas.




Figura 15 – Estrutura da RNA do método v2 – Previsão de Preço de Energia.

O método v3, em relação aos anteriores, não considerou os parâmetros de Produção Solar, Velocidade de Vento e Produção Eólica para o processo de treino, obtendo um total de cento e quarenta e sete (147) entradas.




Figura 16 – Estrutura da RNA do método v3 – Previsão de Preço de Energia.

Por fim, o método v4, é semelhante ao v1, apenas difere no parâmetro de Produção Solar que não foi ponderado, adquirindo assim as cento e noventa e cinco (195) entradas como parâmetros de treino para a rede neuronal.




Figura 17 – Estrutura da RNA do método v4 – Previsão de Preço de Energia.

Posteriormente, as RNA anteriormente apresentadas foram validadas para os dias 10, 11 e 12 de janeiro de 2015, por forma a validar o processo de treino e comparar as respectivas respostas. Desta forma, podemos concluir que o treino da rede neuronal com todos os parâmetros incluídos (Velocidade de Vento, Produção Eólica, Solar, Térmica e Hídrica)

revelou ser mais eficaz, contribuindo para a obtenção de melhores resultados, relativamente à previsão dos preços da energia.

O algoritmo foi testado de duas formas distintas: Erro Relativo Percentual proveniente do *output* gerado pela RNA (S/ Gestão Risco) e Erro Relativo Percentual calculado através do Método de Monte Carlo (C/Gestão Risco). Por fim, esta última figura pretende esquematizar a componente prática desenvolvida, referente à previsão do preço da energia para o mercado diário no MIBEL.

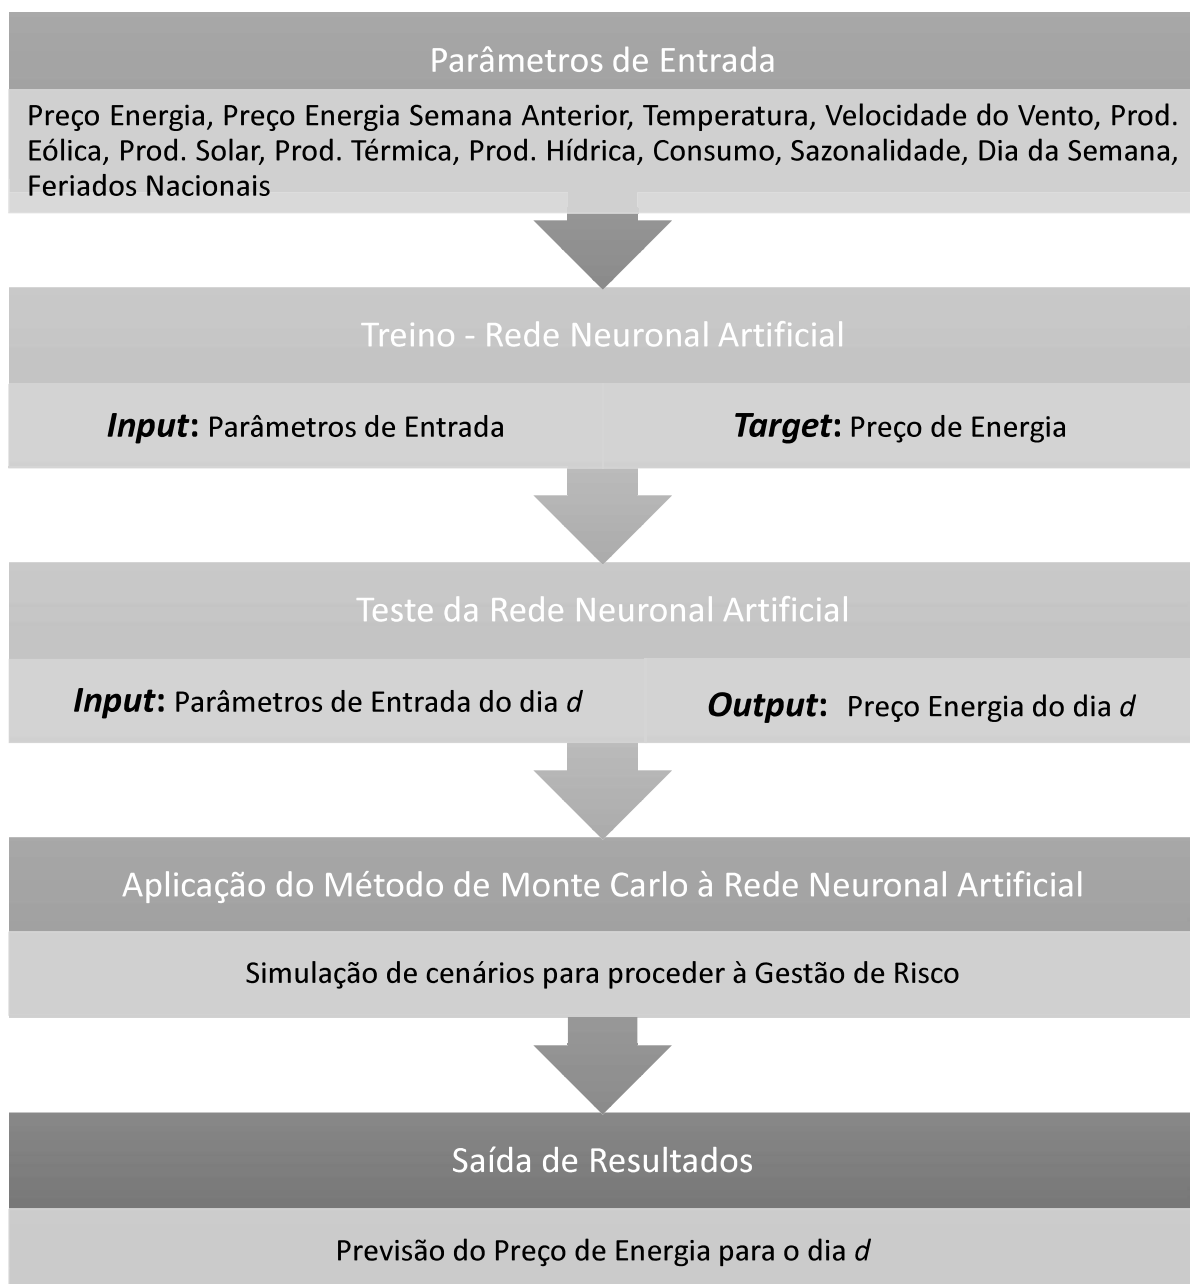


Figura 18 – Esquema da Metodologia Desenvolvida: Previsão de Preço de Energia.

## 4.5. CONCLUSÃO

Neste capítulo foram apresentadas as metodologias desenvolvidas para estudo da previsão de consumos e do preço de energia, utilizando a ferramenta do MATLAB, *Neural Network Toolbox*.

Inicialmente, procedeu-se à apresentação de uma breve componente teórica sobre os principais métodos abordados, as Redes Neurais Artificiais, para previsão do consumo, e o Método de Monte Carlo, para proceder à gestão do risco.

Posteriormente, é apresentada cada metodologia de forma mais detalhada. Relativamente à previsão de consumos é esperado obter uma previsão de consumos para o ano de 2016, para tal são comparadas três redes neuronais distintas ( $c1$ ,  $c2$  e  $c3$ ), variando entre si no número de períodos e nos parâmetros considerados para o processo de aprendizagem. Quanto à previsão do preço de energia é esperada que seja a curto prazo, nomeadamente, para o mês de março de 2016. Assim como no método anterior foram consideradas quatro redes neuronais ( $v1$ ,  $v2$ ,  $v3$  e  $v4$ ), sendo diferenciadas entre si nos parâmetros de entrada considerados no processo de aprendizagem da rede neuronal. Os respetivos resultados serão apresentados no próximo capítulo.

# 5. CASOS DE ESTUDO

Ao longo deste capítulo são apresentados os casos de estudo, cujo principal objetivo passa pela utilização das ferramentas descritas no capítulo anterior. As previsões referem-se aos consumos e ao preço da energia do mercado diário, no MIBEL.

## 5.1. INTRODUÇÃO

Como já mencionado, as previsões de consumo são desenvolvidas segundo os dados fornecidos pela empresa Edigreen, já para a previsão do preço de energia são utilizados dados da REN e da *Weather Underground*. O primeiro método, apesar da limitação de dados, apresenta valores semelhantes ao longo dos dias e foi considerado, essencialmente, para prever consumos a curto e médio prazo, como é demonstrado ao longo deste capítulo. Relativamente ao preço de energia, pretende-se uma previsão a curto prazo, sendo desejado gerar resultados para o mês seguinte ao do treino, março de 2016. Devido à elevada volatilidade do preço de energia e à imprevisibilidade na produção de energia proveniente de fontes renováveis, assumiu-se uma previsão a curto prazo, por forma a obter resultados mais consistentes e fiáveis.

Após a apresentação dos casos de estudo, prossegue-se com a análise de resultados e, posteriormente, são apresentadas as conclusões sobre ambos os métodos.

## **5.2. ANÁLISE DE CENÁRIOS – PREVISÃO DE CONSUMO**

De seguida apresentar-se os cenários que irão ser abordados para previsão de consumos através da simulação da ferramenta desenvolvida para esse efeito “*TesteTarifas*”. Para testar a eficácia do método de previsão, a ferramenta foi aplicada a um cliente da empresa Edigreen, cujo imóvel corresponde a uma loja comercial situado no distrito do Porto, sendo a alimentação ao mesmo feita em Média Tensão (MT), com uma potência contratada de 186 kVA, apresenta ainda uma tarifa simples tetra-horária (Ponta, Cheia, Vazio e Super Vazio) com ciclo semanal. O diagrama de cargas deste consumidor pode ser consultado na subsecção 5.4. e é referido como cliente A.

De seguida vão ser apresentados os resultados obtidos para a previsão de consumos, utilizando como caso de estudo o Cliente A, anteriormente mencionado. Inicialmente pretende-se comparar as RNA desenvolvidas ao validar as mesmas para os dias 10, 11 e 12 de janeiro de 2015. Posteriormente, pode salientar-se que os cenários foram atribuídos de forma aleatória e correspondem ao dia 1 e 18 de fevereiro e ao dia 9 e 10 de março de 2016.

### **5.2.1. COMPARAÇÃO E VALIDAÇÃO DAS REDES NEURONAIS**

Recordando o capítulo anterior, relativamente à previsão dos consumos, procedeu-se à comparação de três métodos distintos – *c1*, *c2* e *c3* – sendo que as principais diferenças entre estes consistem no número de entradas consideradas e no número de saídas geradas em cada rede.

As seguintes tabelas apresentam a comparação e os resultados obtidos as redes *c1*, *c2* e *c3*, para os respetivos cenários validados – dia 10, 11 e 12 de janeiro de 2015. Comprovou-se que com a rede *c2* é possível obter resultados mais interessantes e consistentes do que com as restantes redes, uma vez que desprezou os períodos em que a loja comercial não se encontrava em funcionamento. Assim foca-se a aprendizagem da rede neuronal somente para os períodos em que o imóvel se encontra aberto, por forma a prever o diagrama de cargas durante o horário de expediente. Ao treinar a rede apenas para estes períodos, evita-se a introdução de informação excessiva para a RNA o que poderia vir a introduzir erro na previsão de resultados. Segundo a comparação efetuada entre as redes, para os cenários considerados, chegou-se à conclusão que o método *c2* foi o elegido para proceder à previsão de consumos que irá ser divulgada ao longo deste capítulo.

Tabela 1 – Comparação entre Métodos para Previsão de Consumo – 10 de janeiro de 2015.

Dia 10 de janeiro 2015		<i>c1</i>	<i>c2</i>	<i>c3</i>
S/ Gestão Risco	Erro MAPE	21,92%	16,88%	18,13%
	ER Máximo	65,52%	61,25%	60,44%
	ER Mínimo	0,79%	0,96%	0,06%
C/ Gestão Risco	Erro MAPE	18,02%	16,07%	16,89%
	ER Máximo	66,67%	39,66%	75,00%
	ER Mínimo	0,00%	0,96%	0,00%

Tabela 2 – Comparação entre Métodos para Previsão de Consumo – 11 de janeiro de 2015.

Dia 11 de janeiro 2015		<i>c1</i>	<i>c2</i>	<i>c3</i>
S/ Gestão Risco	Erro MAPE	25,09%	15,48%	21,42%
	ER Máximo	93,42%	78,24%	96,90%
	ER Mínimo	0,41%	0,14%	0,17%
C/ Gestão Risco	Erro MAPE	21,23%	12,36%	16,05%
	ER Máximo	88,89%	55,56%	88,89%
	ER Mínimo	0,00%	0,00%	0,00%

Tabela 3 - Comparação entre Métodos para Previsão de Consumo – 12 de janeiro de 2015.

Dia 12 de janeiro 2015		<i>c1</i>	<i>c2</i>	<i>c3</i>
S/ Gestão Risco	Erro MAPE	27,23%	15,67%	23,81%
	ER Máximo	89,83%	65,64%	90,05%
	ER Mínimo	1,23%	0,33%	0,01%
C/ Gestão Risco	Erro MAPE	21,60%	11,07%	20,26%
	ER Máximo	90,00%	70,37%	88,89%
	ER Mínimo	0,00%	0,00%	0,00%

## 5.2.2. CENÁRIO – 18 DE FEVEREIRO

Este cenário foi alvo de dois casos de estudo distintos, o primeiro corresponde a 18 de fevereiro de 2015, uma quarta-feira, um dos dias para o qual a rede neuronal foi validada, segundo o processo de aprendizagem a que foi submetida, por forma a averiguar a viabilidade do treino. O segundo caso de estudo remete para o dia 18 de fevereiro de 2016, uma quinta-feira, este representa um dos dias para o qual a rede neuronal foi testada, segundo o processo de aprendizagem a que foi submetido, por forma a prever o consumo diário.

Como é possível visualizar na figura 19, o caso de estudo relativo à validação do processo de aprendizagem demonstrou resultados interessantes, uma vez que o valor previsto pela rede (Previsão 2015), relativamente ao consumo diário do consumidor, aproximou-se do valor real medido (*Target 2015*).




Figura 19 – Resultado da previsão de consumo, cenário de 18 de fevereiro de 2015.

Em relação a este caso de estudo é possível afirmar que, tendo por base os erros relativos apresentados, o erro MAPE obtido é de 8,51%. Ao analisar de forma detalhada os resultados alcançados, conclui-se que durante o período noturno (00 até 6:45h) o erro oscila entre os 0% e os 9%. Estes valores são explicados, como já mencionado, devido à atribuição de um consumo médio de 12kW, quando os valores reais oscilam, usualmente, entre os 10 e os 12kW, contudo existem situações esporádicas de manutenção de equipamento ou limpeza do estabelecimento que manifestam consumos mais elevados para o mesmo período. Porém,

é entre as 23h e as 23:45h, períodos correspondentes ao encerramento da loja comercial, que se registou os erros mais elevados do dia.




Figura 20 – Erro relativo percentual, cenário de 18 de fevereiro de 2015.

O segundo caso de estudo deste cenário pretende testar a resposta da rede e proceder à previsão dos consumos para o dia 18 de fevereiro de 2016, sendo os respetivos resultados apresentados nas figuras seguintes. Segundo o exemplo anterior, para o período em que a loja comercial se encontra encerrada, período noturno – entre a 00h e às 6:45h – foi também considerado um consumo médio de 12kW.

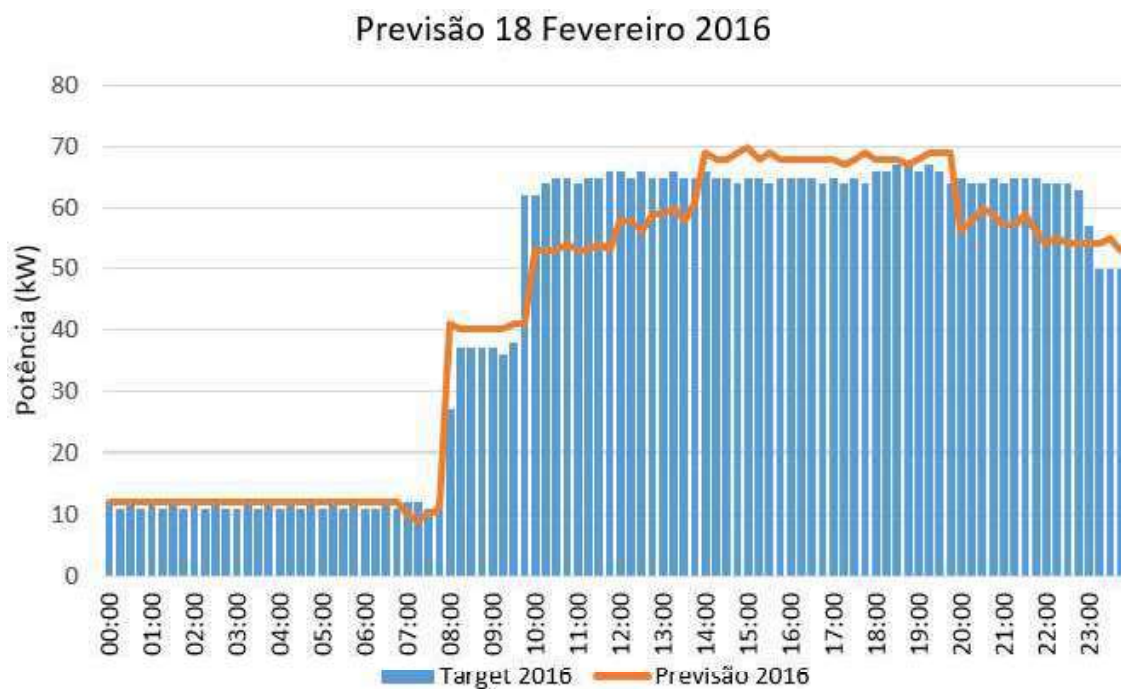


Figura 21 – Resultado da previsão de consumo, cenário de 18 de fevereiro de 2016.

Semelhante aos resultados obtidos no caso de estudo anterior, referente à validação da rede (dia 18 de fevereiro de 2015), é possível verificar que ao longo do período noturno, período esse em que a loja se encontra encerrada, a diferença entre os valores previstos e os reais foram mínimos, oscilando entre os 0 e os 9%, levando a que o erro obtido atingisse valores baixos. Contrariamente ao que foi registado no caso de estudo anterior, foi durante o período da manhã que foram registadas as maiores discrepâncias, possivelmente devido a oscilações no consumo de energia na entrada de funcionamento da loja comercial. Ao comparar ambos os casos de estudo durante as 7h e as 9h do dia, na primeira situação, o consumo situa-se próximo dos 50 kW, já no segundo caso, para o mesmo período, esse valor situa-se, aproximadamente, nos 35 kW.

Todavia, como demonstra a figura 22, ao longo do dia os erros relativos percentuais registados situam-se maioritariamente abaixo dos 10%, no entanto devido aos picos verificados, durante o período da manhã, o erro MAPE obtido foi de 10,38%.




Figura 22 - Erro relativo percentual, cenário de 18 de fevereiro de 2016.

### 5.2.3. CENÁRIO – 1 DE FEVEREIRO DE 2016

O presente cenário diz respeito à previsão do perfil de consumo diário do consumidor MT relativamente ao dia 1 de fevereiro de 2016, correspondendo a um dia da semana (segunda-feira). A figura 23 aponta os respetivos resultados da previsão de consumos para o período da amostra em questão.




Figura 23 - Resultado da previsão de consumo, cenário de 1 de fevereiro de 2016.

Ao analisar a figura 24, correspondente aos erros relativos obtidos, é possível concluir que para este cenário o *output* da rede neuronal apresentou dois picos, na qual os erros relativos assumiram valores mais elevados em dois períodos distintos, ao longo do dia em questão. Estes ocorreram, essencialmente, durante a abertura e o fecho da loja, no entanto é nos últimos quatro períodos do dia que se confirma os erros relativos mais elevados por hora.

Contudo, e após cálculo dos erros relativos percentuais, é possível afirmar que para o período em que se pretendeu prever resultados, os resultados revelaram ser interessantes. Os *outputs* gerados mantiveram-se, ao longo do dia, na sua maioria inferior a 10%, mas devido às discrepâncias registadas, durante o período correspondente à abertura e fecho da loja, o erro MAPE alcançado foi de 11,27%.




Figura 24 - Erro relativo percentual, cenário de 1 de fevereiro de 2016.

#### 5.2.4. CENÁRIO – 9 E 10 DE MARÇO DE 2016

O cenário seguinte representa o último caso de estudo em análise e, ao contrário dos cenários anteriores, este visa a previsão do perfil de consumo diário do cliente MT para um horizonte temporal mais alargado, pretendendo-se a obtenção de resultados por parte da rede neuronal para dois dias consecutivos da semana, nomeadamente para o dia 9 e 10 de março de 2016 que correspondem, respetivamente, a uma quarta e quinta-feira.




Figura 25 - Resultado da previsão de consumo, cenário de 9 e 10 de março de 2016.

Ao analisar a figura 26, referente aos erros relativos verifica-se que a rede neuronal apresenta uma coerência relativamente aos cenários anteriores, ao ser visível uma maior disparidade de valores durante o período de abertura (7h) e de encerramento (23h). Os resultados obtidos para o perfil diário de consumo do cliente demonstraram ser interessantes, dado que de um total de 136 períodos analisados, aproximadamente 108 (54 períodos referentes ao dia 9 de março e 54 períodos referentes ao dia 10 de março) apresentam um erro relativo inferior a 15%. Como já referido, a maior distorção de valores ocorre nos períodos de abertura e de fecho da loja comercial e é verificada em ambos os dias em estudo. Este cenário permitiu obter um erro MAPE de 10,61%.




Figura 26 – Erro relativo percentual, cenário de 9 e 10 de março de 2016.

### 5.2.5. CONCLUSÕES

A previsão do consumo de energia tem vindo a ser cada vez mais alvo de estudo, uma vez que uma gestão eficiente das cargas permite obter poupanças significativas na fatura energética. Hoje em dia, as previsões de séries temporais são consideradas para horizontes distintos, nomeadamente a curto, médio e longo prazo. A curto prazo estima-se a previsão do consumo para as horas ou dias seguintes. A médio prazo pretende-se ter em conta um horizonte temporal que poderá englobar algumas semanas ou até meses. Por fim, com as previsões a longo prazo, pretende-se fornecer estimativas da evolução da procura num espaço de um ano, permitindo estudar estratégias, de forma antecipada, para remediar situações indesejáveis. Ao longo deste trabalho foi desenvolvido um algoritmo – “*TesteTarifas*” – que permitisse a previsão de consumos a curto e a médio prazo, ou seja, para os dias, semanas ou até meses seguintes.

Desta forma, o treino da rede neuronal englobou dados de entrada desde janeiro de 2014 a dezembro de 2015 e, conforme os cenários apresentados, foi possível obter resultados consistentes e interessantes para os meses de fevereiro e março de 2016. Contudo deve-se salientar que quanto maior for o horizonte temporal escolhido pelo utilizador para previsão de resultados, maior será a distorção dos mesmos.

Relativamente aos dias em que se pretendeu prever os consumos, é possível salientar que os mesmos exibiram resultados aliciantes e, embora em alguns períodos do dia houvesse uma maior inconsistência entre o valor real e o previsto, nomeadamente nos períodos de abertura

e fecho de loja, o erro MAPE assume valores promissores. A tabela 4 pretende resumir os erros relativos (ER) máximos e mínimos e o erro MAPE obtido em cada um dos cenários analisados:

Tabela 4 – Comparação dos erros obtidos – Previsão de consumo, método *c2*.

	<b>18 de fev. 2015</b>	<b>1 de fev. 2016</b>	<b>18 de fev. 2016</b>	<b>9 e 10 de março 2016</b>
<b>Erro MAPE</b>	8,51%	11,27%	10,38%	10,61%
<b>ER Máximo</b>	75,00%	52,00%	51,85%	64,00%
<b>ER Mínimo</b>	0,00%	0,00%	0,00%	0,00%

Como verificado na apresentação de resultados, optou-se por assumir como padrão de consumo de energia para este cliente durante o período de madrugada (00h até às 7h) um consumo médio a rondar os 12kW. Dado que, em alguns dias da semana, são registados valores que podem oscilar entre os 20 e os 30 kW, assim como dos 50 aos 60 kW. Esta medida foi implementada com o intuito de uniformizar e simplificar o processo de aprendizagem da RNA, dado que os períodos são reduzidos com o objetivo de evitar a introdução de erro adicional na rede, como comprovado na tabela 1, 2 e 3.

Em suma, o trabalho produzido relativamente à previsão dos consumos de energia gerou resultados coerentes. Contudo, se houvesse uma maior disponibilidade de dados que permitisse um alargamento do horizonte temporal, seria possível introduzir na rede mais cenários para aprendizagem que iria contribuir com maior precisão na previsão de resultados.

Esta componente prática permitiu estudar aprofundadamente a influência de determinados parâmetros no processo de aprendizagem e o respetivo comportamento da rede neuronal na apresentação de resultados.

### **5.3. ANÁLISE DE CENÁRIOS – PREVISÃO DE PREÇO DE ENERGIA**

O principal objetivo deste método consiste na previsão do preço de energia, no mercado *spot* diário, a curto prazo, ou seja para o dia ou dias seguintes, à sua negociação, no Mercado Ibérico de Eletricidade. Ao longo deste capítulo são apresentados e analisados os diversos cenários estudados, simulados através da ferramenta desenvolvida para previsão do preço da energia, por fim, são apresentadas as conclusões gerais.

### 5.3.1. COMPARAÇÃO E VALIDAÇÃO DAS REDES NEURONAIS

Como já referido, procedeu-se à comparação de quatro métodos de previsão de preço de energia distintos – *v1*, *v2*, *v3* e *v4* – sendo que as principais diferenças entre eles residem nos parâmetros de entrada considerados no processo de aprendizagem.

As tabelas abaixo apresentadas pretendem mostrar a comparação efetuada entre as redes *v1*, *v2*, *v3* e *v4*, na qual são demonstrados os resultados obtidos, relativamente a nível de erros máximos, mínimos e MAPE, de acordo com os cenários validados – dia 10, 11 e 12 de janeiro de 2015. Confirma-se, pelo que é evidenciando nas tabelas, que o método *v1* demonstrou ser o mais eficiente e consistente, segundo os cenários testados, devido a apresentar o menor erro MAPE. Desta forma, este método foi considerado para proceder à previsão de cenários apresentada ao longo deste capítulo.

Os parâmetros Velocidade de Vento, Produção Eólica e Produção Solar são vistos como essenciais para o processo de treino da RNA, uma vez que o preço de energia encontra-se relacionado com a variação destes parâmetros ao longo do dia.

As tabelas 5, 6 e 7 apresentam os resultados da comparação das quatro RNA estudadas, relativamente à previsão do preço da energia:

Tabela 5 – Comparação entre Métodos para Previsão de Preço – 10 de janeiro de 2015.

Dia 10 de janeiro 2015		<i>v1</i>	<i>v2</i>	<i>v3</i>	<i>v4</i>
S/ Gestão Risco	Erro MAPE	4,71%	4,95%	8,47%	7,83%
	ER Máximo	12,29%	14,09%	23,86%	31,64%
	ER Mínimo	0,02%	0,48%	0,09%	0,18%
C/ Gestão Risco	Erro MAPE	4,51%	4,56%	7,10%	7,05%
	ER Máximo	11,31%	13,45%	25,43%	19,32%
	ER Mínimo	0,91%	0,28%	0,00%	0,28%

Tabela 6 – Comparação entre Métodos para Previsão de Preço – 11 de janeiro de 2015.

<b>Dia 11 de janeiro 2015</b>		<b>v1</b>	<b>v2</b>	<b>v3</b>	<b>v4</b>
<b>S/ Gestão Risco</b>	<b>Erro MAPE</b>	<b>6,57%</b>	<b>6,97%</b>	<b>11,72%</b>	<b>13,17%</b>
	<b>ER Máximo</b>	<b>15,17%</b>	<b>18,89%</b>	<b>28,85%</b>	<b>34,34%</b>
	<b>ER Mínimo</b>	<b>0,21%</b>	<b>1,02%</b>	<b>2,48%</b>	<b>0,25%</b>
<b>C/ Gestão Risco</b>	<b>Erro MAPE</b>	<b>6,41%</b>	<b>6,44%</b>	<b>8,97%</b>	<b>9,79%</b>
	<b>ER Máximo</b>	<b>13,95%</b>	<b>16,22%</b>	<b>23,95%</b>	<b>25,58%</b>
	<b>ER Mínimo</b>	<b>0,00%</b>	<b>0,51%</b>	<b>0,51%</b>	<b>1,09%</b>

Tabela 7 – Comparação entre Métodos para Previsão de Preço – 12 de janeiro de 2015.

<b>Dia 12 de janeiro 2015</b>		<b>v1</b>	<b>v2</b>	<b>v3</b>	<b>v4</b>
<b>S/ Gestão Risco</b>	<b>Erro MAPE</b>	<b>6,15%</b>	<b>6,26%</b>	<b>19,36%</b>	<b>8,36%</b>
	<b>ER Máximo</b>	<b>18,21%</b>	<b>12,49%</b>	<b>37,89%</b>	<b>23,08%</b>
	<b>ER Mínimo</b>	<b>0,02%</b>	<b>0,88%</b>	<b>1,48%</b>	<b>0,31%</b>
<b>C/ Gestão Risco</b>	<b>Erro MAPE</b>	<b>5,75%</b>	<b>5,92%</b>	<b>17,72%</b>	<b>6,49%</b>
	<b>ER Máximo</b>	<b>16,14%</b>	<b>16,14%</b>	<b>35,43%</b>	<b>19,10%</b>
	<b>ER Mínimo</b>	<b>0,12%</b>	<b>0,00%</b>	<b>1,46%</b>	<b>0,16%</b>

### 5.3.2. CENÁRIO – 1 DE MARÇO

Este cenário pretende apresentar dois casos de estudo distintos, sendo que o primeiro caso corresponde a 1 de março de 2015, um dos dias para o qual a rede neuronal foi validada, e o segundo a 1 de março de 2016, um segundo dia para o qual a rede foi testada, por forma a obter resultados relativamente a previsão do preço de energia.

Sabendo que a previsão de consumos é feita com dois dias de antecedência, foram consideradas as 24 horas do dia 27 de fevereiro de 2015 para prever o preço da energia para o dia 1 de março de 2016. O diagrama de consumo abaixo apresentado representa as respetivas produções e consumos registados do presente caso de estudo.

Como é possível visualizar, ao longo do dia, a maior percentagem de produção diária foi registada pelas fontes PRE, seguida das Centrais de Fio de Água, posteriormente, surgem as

Centrais a Carvão com a terceira maior representação, no que toca a produção de energia elétrica. Contudo deve salientar-se a existência de um elevado saldo importador de energia, durante o período da madrugada extendendo-se até ao final da tarde, por forma a suprimir os valores de consumo e, inclusive, executar o processo de bombagem para armazenamento de água nas Centrais Hídricas de albufeira.




Figura 27 – Diagrama de Consumo Total Diário, 1 de março de 2015 [65].

As figuras 28 e 29 visam representar a validação da rede para o presente caso em estudo, comparando o valor previsto pela rede neuronal (Previsão 2015) com os valores reais disponibilizados pelo OMIE (*Target* 2015) e o erro relativo associado a este cenário.




Figura 28 – Resultado da previsão de preço de energia, cenário de 1 de março de 2015.

Segundo os resultados obtidos para as 24 horas diárias deste caso de estudo, é possível afirmar que o erro MAPE obtido foi de 8,81%. Comprovando que os valores previstos não se distanciaram muito dos reais, contudo, as discrepâncias ao longo deste dia podem ser justificadas pelo elevado saldo importador de energia registado, cujo valor não foi contabilizado como parâmetro de entrada no processo de aprendizagem da RNA.

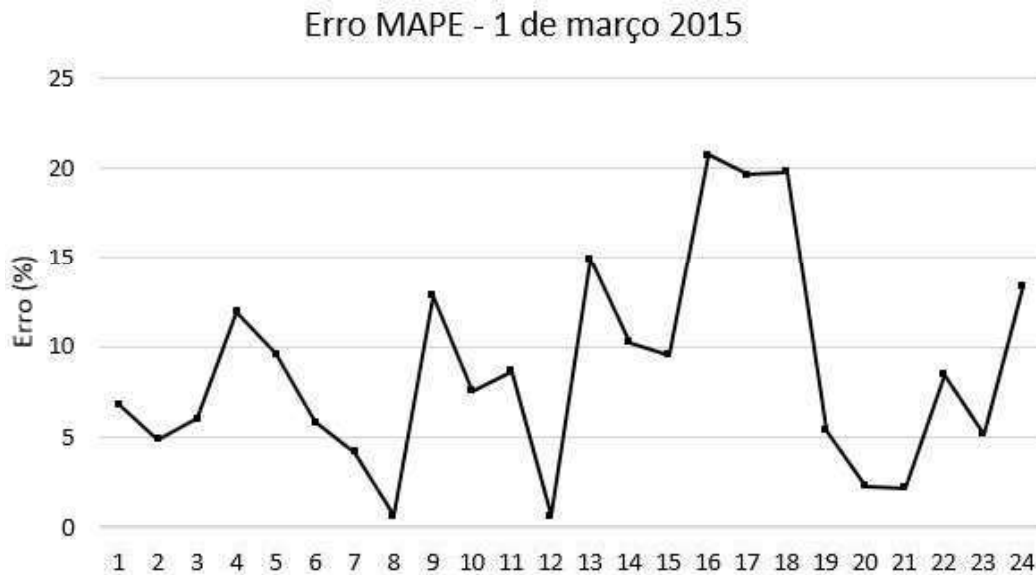


Figura 29 – Erro relativo percentual do cenário 1 de março de 2015.

Em relação ao segundo caso de estudo, o diagrama de consumo apresentado remete para a previsão do preço da energia para o presente caso de estudo, dia 1 de março de 2016, tendo por base os parâmetros de entrada registados dois dias antes, dia 28 de fevereiro de 2016.




Figura 30 – Diagrama de Consumo Total Diário, 1 de março de 2016 [65].

Segundo uma breve análise ao diagrama de consumo apresentado anteriormente, é possível salientar que ao longo do dia foi verificada uma produção de energia constante pelas Centrais de Fio de Água. De realçar ainda o papel preponderante que as fontes PRE e as Centrais a Carvão assumiram para a produção de energia nacional. Porém, nos períodos de pico foi registada uma elevada parcela proveniente das Centrais Hídricas de Albufeira, para auxiliar a suprimir o consumo requerido para os mesmos instantes.



Figura 31 - Resultado da previsão de preço de energia, cenário de 1 de março de 2016.

Ao proceder à comparação entre os valores reais (*Target 2016*) e os previstos pela RNA (*Previsão 2016*) podemos concluir que estes são bastante aproximados ao longo das 24 horas diárias, salientando que a previsão permitiu obter um erro MAPE de 11,79%, comprovando a consistência de resultados.




Figura 32 - Erro relativo percentual do cenário 1 de março de 2016.

### 5.3.3. CENÁRIO – 2 DE MARÇO DE 2016

Este cenário visa proceder à simulação da RNA para previsão do preço de energia para o dia 2 de março de 2016. Este dia é caracterizado por apresentar uma elevada penetração de energia proveniente de fontes PRE e Fio de Água ao longo do dia, sendo as PRE responsáveis por atingir as maiores metas de produção. Porém, os valores correspondentes às Centrais Hídricas de Albufeira e ao saldo importador de energia, também apresentam impacto para os valores de energia produzida no âmbito nacional, nomeadamente para auxiliar nos períodos de pico e no processo de bombagem, como demonstrado na figura 33.




Figura 33 - Diagrama de Consumo Total Diário, 2 de março de 2016 [65].

Segundo o diagrama de consumo diário a nível nacional e comparando o mesmo com a figura dos resultados obtidos relativamente à previsão do preço da energia, é possível comprovar que os picos do preço de energia verificados ao longo do dia, correspondem aos picos de produção das Centrais Hídricas de Albufeira.

Relativamente ao valor real do preço da energia (*Target 2016*) e o valor gerado pela RNA (Previsão 2016) é possível salientar que existe alguma discrepância de valores entre alguns períodos, segundo o presente caso de estudo, como é demonstrado na figura 34.




Figura 34 - Resultado da previsão de preço de energia, cenário de 2 de março de 2016.

Ao analisar o gráfico 35, podemos comprovar que os erros relativos mais elevados correspondem aos períodos de pico do dia em que foi necessário utilizar as Centrais Hídricas em Albufeira para gerar uma maior quantidade de energia, apontado ao objetivo diário de suprimir o consumo. Conclui-se que o menosprezo destes dados levou à introdução de um erro na RNA, todavia, este cenário permitiu obter um erro MAPE de 10,22%.

A possibilidade de introdução de parâmetros adicionais à rede neuronal possibilita uma nova proposta para aperfeiçoar o processo de treino, diminuindo o erro associado ao cenário previsto pela RNA e é algo que poderá ser ponderado e desenvolvido numa perspetiva futura deste trabalho.




Figura 35 - Erro relativo percentual do cenário de 2 de março de 2016.

### 5.3.4. CENÁRIO – 3 DE MARÇO DE 2016

Este último cenário apresentado pretende dar continuidade à previsão a curto prazo, do preço de energia praticado no mercado diário do MIBEL, para o dia 3 de março de 2016. As fontes PRE, neste cenário, demonstram uma elevada penetração de energia renovável, sendo por isso responsável pelos maiores valores de produção de energia registados. Ainda assim, e tal como nos cenários analisados anteriormente, é possível verificar que existe uma quantidade significativa de energia produzida proveniente das Centrais Hídricas de Albufeira, servindo para dar resposta à procura de energia em Portugal, mas também para aumentar significativamente o saldo exportador de energia, de Portugal para Espanha.




Figura 36 - Diagrama de Consumo Total Diário, 3 de março de 2016 [65].

Ao analisar o gráfico 37, é possível verificar algumas flutuações entre os valores previstos (Previsão 2016) e os reais (*Target* 2016). Desta forma, a nível diário os preços de energia são mais elevados quando se confirmam os picos de produção de energia com uso das Centrais Hídrica de Albufeira. Estes valores podem estar na origem da introdução de erro para a RNA, uma vez que não foram considerados no processo de aprendizagem da rede e contribuíram expressivamente para a produção de energia diária.

Ainda assim os valores estimados pela RNA (Previsão 2016) e os reais (*Target* 2016) foram semelhantes, dado que as fontes de produção de energia consideradas como parâmetros no processo de aprendizagem – Produção Eólica, Solar, Térmica e Hídrica (fio de água) – da rede neuronal foram as principais fontes responsáveis pela geração de energia neste cenário.




Figura 37 - Resultado da previsão de preço de energia, cenário de 3 de março de 2016.

Todavia, e segundo o gráfico que apresenta os erros relativos apresentado a seguir, é possível enfatizar o erro MAPE diário deste cenário situa-se, aproximadamente, nos 12%. Com estes resultados demonstrou-se que os valores simulados pela rede neuronal são plausíveis, dado que se aproximam dos valores reais deste cenário.



Figura 38 - Erro relativo do cenário 3 de março de 2016.

### 5.3.5. CONCLUSÃO

A previsão de preço de eletricidade no mercado diário do MIBEL tem vindo a ser uma área de pesquisa cada vez mais interessante, devido à liberalização do setor energético o que veio introduzir uma maior concorrência entre comercializadores e, conseqüentemente, uma maior

oferta quanto aos preços entre eles praticados. Contudo, estes preços demonstram ser muito inconstantes, dado a sua elevada volatilidade e variações severas nos preços praticados de hora para hora, nomeadamente, no mercado diário, muito devido à imprevisibilidade na produção de energia elétrica por parte das fontes de origem renovável. Estas oscilações no preço de energia são, usualmente, definidas como *spikes* ou *jumps* [66],[67].

Segundo a literatura, os *spikes* podem ser definidos como preços que ultrapassam um determinado valor específico [68]. As figuras 39 e 40 apresentados demonstram a variação dos preços de energia ao longo dos anos de 2014 e 2015, respetivamente, nos quais é possível visualizar e comprovar a inconsistência do preço da energia ao longo dos anos.




Figura 39 – Variação do Preço da Energia em 2014.




Figura 40 – Variação do Preço da Energia em 2015.

Segundo os resultados gerados relativamente aos cenários estudados e aos parâmetros para o qual a rede neuronal foi treinada, é possível concluir que o resultado final do trabalho referente à previsão de preço demonstrou ser bastante interessante, exibindo erros MAPE diários que variam entre os 10 e os 12%, como demonstra a tabela abaixo apresentada.

Em suma, é possível comprovar que o preço da energia no mercado *spot* do MIBEL encontra-se, não só dependente dos valores de consumo do SEN, mas também dos valores de produção proveniente de fontes renováveis. Assim salienta-se os parâmetros de entrada mais significativos para o treino da RNA, nomeadamente, a Produção Solar e a Produção Eólica, sendo este último dependente de um dado meteorológico – Velocidade do Vento – ao longo das 24 horas do dia. Tanto a Produção Solar, como a Produção Eólica são vistas como fontes prioritárias, relativamente ao despacho económico de energia, desta forma a sua produção tende a ser maximizada sempre que possível.

Em relação aos resultados dos cenários apresentados, é possível enfatizar que os mesmos demonstraram ser interessantes. Contudo, como já referido e visível na tabela abaixo apresentada, os Erros Relativos Máximos apresentam, em alguns cenários, valores mais elevados, o que podem ser justificados pela ocorrência de *spikes* num determinado período, pela inconsistência na produção de energia por parte de fontes renováveis, ou pela utilização de recursos que não foram considerados no processo de aprendizagem da RNA.

A tabela 8 pretende apresentar os erros relativos (ER) máximos e mínimos registados, bem como o respetivo erro MAPE obtido em cada um dos cenários:

Tabela 8 - Comparação dos erros obtidos – Previsão de preço de energia, método *v1*.

	1 de mar. 2015	1 de mar. 2016	2 de mar. 2016	3 de mar. 2016
<b>Erro MAPE</b>	8,81%	11,79%	10,22%	11,63%
<b>ER Máximo</b>	20,74%	34,78%	28,97%	24,43%
<b>ER Mínimo</b>	0,64%	0,00%	0,00%	0,54%

Em relação a perspetivas futuras, esta ferramenta pode ser melhorada por forma a tornar-se mais eficiente, apresentando melhores desempenhos e uma maior fiabilidade, contribuindo para uma melhor previsão de resultados e respetiva diminuição dos erros associados. Como já identificado, o acréscimo de conhecimento à RNA, através da introdução de novos

parâmetros para treino como é o exemplo da energia exportada/importada, ou da energia gerada proveniente de Centrais Hídricas de Albufeira, é algo que poderá ser ponderado e desenvolvido em trabalho futuro. Um constante alargamento do horizonte temporal permite introduzir novos cenários para a RNA que poderá beneficiar da sua aprendizagem e contribuir, posteriormente, para a redução do erro.

#### 5.4. COMPARAÇÃO TARIFA INDEXADA E TARIFA TETRA-HORÁRIA

Como mencionado no capítulo da introdução, pretende-se dar ênfase a um último caso de estudo que tem como principal particularidade a utilização de ambas as ferramentas desenvolvidas – previsão de consumos e de preço de energia – para investigar possíveis formas de reduzir a fatura energética dos clientes, abordando os temas de mercado de energia e de tarifa dinâmica. Pretende-se assim proceder ao estudo das tarifas indexadas, um exemplo de tarifa dinâmica, dado que depende para cada hora do dia do preço da energia praticado no mercado diário, do MIBEL.

O caso de estudo consiste em comparar os gastos com energia elétrica entre dois clientes MT – Cliente A e Cliente B – segundo a aplicação da tarifa tetra-horária em vigor e a tarifa indexada. Para isso foi considerado um cenário que abrange as duas primeiras semanas do mês de março e as duas últimas de março, dia 1 a 30 de março (30 dias). Ambos os clientes MT são lojas comerciais, com potência contratada de 186kVA, tarifa tetra-horária e ciclo Semanal, sendo as diferenças entre o cliente A e o cliente B registadas a nível do perfil diário de consumo. As figuras 41 e 42 apresentam um perfil de consumo diário médio anual dos clientes abordados.




Figura 41 – Comparação do Perfil de Consumo Médio Anual – Cliente A.




Figura 42 – Comparação do Perfil de Consumo Médio Anual – Cliente B.

Como já referido, este estudo consistiu na aplicação de ambos os métodos de previsão estudados anteriormente. Desta forma, a cada um dos casos de estudo, foi aplicada a tarifa tetra-horária em vigor do cliente e o preço de energia previsto pelo método *v1*, aos consumos previstos pela rede *c2*, para o cenário que se pretende analisar – 1 a 30 de março de 2016.

A tabela 9 exhibe os valores previstos que cada cliente iria pagar, para o período em questão, consoante a aplicação da tarifa tetra-horária ou da tarifa indexada, bem como as respetivas poupanças provadas, em ambos os casos de estudo.

Tabela 9 – Comparação entre Tarifa Tetra-Horária e Tarifa Indexada.

	Cliente A		Cliente B	
	1-15 de mar./2016	16-30 de mar./2016	1-15 de mar./2016	16-30 de mar./2016
<b>Tarifa Tetra-Horária</b>	<b>1 528,22 €</b>	<b>1 279,65 €</b>	<b>670,57 €</b>	<b>616,56 €</b>
<b>Tarifa Indexada</b>	<b>1 095,87 €</b>	<b>1 053,32 €</b>	<b>550,20 €</b>	<b>256,92 €</b>
<b>Poupança [€]</b>	432,35 €	226,33 €	120,37 €	359,64 €
<b>Total [€]</b>	<b>658,68 €</b>		<b>480,01 €</b>	

Para os períodos analisados, é possível confirmar que a tarifa indexada demonstrou ser vantajosa face às tarifas tetra-horárias apresentadas pelo comercializador, sendo verificada uma maior poupança no cliente A.

Contudo, deve salientar-se que as tarifas indexadas, contrariamente às tetra-horárias, apresentam um risco associado na sua utilização, dado que se encontram dependentes dos preços de energia em vigor no MIBEL, podendo ao longo do ano exibir situações vantajosas, como o caso do estudo anterior, como outras mais desvantajosas para o cliente. Em contrapartida, em caso de situação desfavorável, o cliente poderá adotar um papel preponderante e ativo na sua gestão de energia e adotar medidas que lhe permitam alterar o seu padrão de consumo, face à tendência do mercado de energia.

# 6. CONCLUSÕES

## 6.1. APRECIACÕES GERAIS

Os principais objetivos deste trabalho passaram pelo estudo do Mercado de Energia e das Tarifas Dinâmicas para, posteriormente, proceder à implementação de métodos de previsão de consumos e do preço da energia no mercado diário do MIBEL, utilizando Redes Neurais Artificiais. Pode salientar-se que esta tese contribui com estratégias inovadoras, para a redução da fatura energética de consumidores, incentivando os mesmos a adotar medidas que reforcem as suas competências internas na área da energia e fortalecimento dos seus objetivos em prol da eficiência energética.

Relativamente aos métodos de previsão de consumos desenvolvidos, o método *c2* apresenta resultados mais eficientes, de acordo com os objetivos delineados. A eficácia deste método deve-se ao treino somente para os períodos referentes ao funcionamento da loja comercial, das 7h às 23:45h (68 períodos), ao invés dos 96 períodos dos restantes métodos, desconsiderando assim a fase em que a loja se encontra encerrada, evitando a introdução de erro adicional aos resultados. Este método demonstrou ser eficiente, dado que para os cenários testados o erro MAPE rondou os 9 e os 11%, contudo estes valores poderiam ser aperfeiçoados ao alargar o horizonte temporal nos dados de entrada num novo processo de treino da rede.

Em relação aos métodos para previsão de preço de energia no mercado diário do MIBEL, pode salientar-se que os que consideraram os parâmetros da Velocidade do Vento, Produção Eólica e Produção Solar permitiram obter melhores resultados, como é o exemplo dos métodos  $v1$  e  $v2$ . Contudo, optou-se pelo primeiro para previsão de resultados, método  $v1$ , pois considerou mais parâmetros de entrada no processo de aprendizagem, refletindo-se nos casos de estudo testados, apresentando ligeiras melhorias no erro MAPE face ao método  $v2$ . A Velocidade do Vento, embora seja um parâmetro meteorológico, permite relacionar-se com a Produção Eólica, este último apresenta um peso significativo na produção de energia a nível nacional. Em situações em que se regista maior produção de energia eólica, os preços de energia são mais baixos e em situações em que esta produção é precária, como resposta, o preço da energia aumenta. O parâmetro da Produção Solar permite obter uma relação entre a produção fotovoltaica nos meses de inverno e de verão, sendo que nesta última estação o período de incidência solar é maior e, como tal, regista-se uma maior produção. Deve salientar-se que a produção solar e a produção eólica são fontes de energia renováveis e, portanto, são consideradas como prioritárias no despacho económico.

Ao comparar os restantes métodos  $v2$ ,  $v3$  e  $v4$ , é possível salientar que os piores resultados foram obtidos com o método  $v3$ , como seria esperado, dado que este não considerou os parâmetros de Produção considerados como prioritários e que mais peso apresentam para a definição do preço da energia, como é o caso da Velocidade do Vento, da Produção Eólica e Produção Solar. Em relação aos métodos  $v2$  e  $v4$  conclui-se que o primeiro apresenta ligeiras melhorias face ao segundo. Como já mencionado, o método  $v4$  não considerou a Produção Solar, ao invés do método  $v2$  que desconsiderou a Produção Térmica e Hídrica, podendo enfatizar que a Produção Solar, relativamente à Produção Térmica e Hídrica, contribui de forma mais positiva para o processo de aprendizagem da rede neuronal, permitindo atingir melhores resultados.

Comparativamente ao estudo efetuado entre a tarifa tetra-horária e a tarifa indexada, é importante referir que a segunda tarifa demonstrou ser mais vantajosa face à primeira, para o período analisado. No entanto não se pode confirmar que esta tendência se mantenha ao longo do ano, devido à sua dependência dos preços de energia praticados no MIBEL. Todavia, face à volatilidade dos preços da energia e para uma maior eficiência da tarifa indexada é esperado que os consumidores assumam um papel mais ativo na gestão dos

diagramas de cargas das suas instalações, sendo capazes de adaptar os seus consumos como resposta às variações do preço da energia no mercado.

O tema abordado demonstrou ser benéfico para a minha formação académica, dado que contribuiu para a aquisição de conhecimento sobre técnicas de previsão, nomeadamente, sobre a implementação de redes neuronais, aplicadas ao consumo e ao preço de energia. Estas duas vertentes são cada vez mais alvo de estudo, tanto a nível académico, como a nível profissional, incentivando o aumento da eficiência das instalações, a uma melhor gestão da distribuição das cargas ao longo do dia, consoante os preços de energia praticados no MIBEL e, posteriormente, à redução da fatura energética.

A área da Energia é uma área promissora que me desperta curiosidade, devido à sua complexidade e a toda a envolvimento que este tema aborda: desde a produção até à distribuição de energia ao consumidor final; à formação do preço no mercado e às sucessivas propostas de otimização e evolução do sistema elétrico, devido ao interesse que este tema tem despoletado na investigação.

## **6.2. TRABALHOS FUTUROS**

Em relação a perspetivas futuras deste trabalho, pode salientar-se um algoritmo de otimização de cenários que inclua o parâmetro de *Demand Response*, por forma a incentivar à redução do consumo ou ao deslocamento de cargas entre períodos.

A inclusão de novos parâmetros de entrada e o alargamento do horizonte temporal para o processo de aprendizagem podendo levar à obtenção de resultados mais consistentes, nomeadamente para previsões de períodos mais longos.

A extensão do estudo da aplicação das tarifas indexadas a consumidores domésticos será algo interessante de ser ponderado, bem como o estudo da aplicação do conceito de autoconsumo e a sua contribuição para a redução da fatura energética em instalações de consumo.

## **6.3. LISTA DE PUBLICAÇÕES**

- D. Boldt, P. Faria and Z. Vale, "Study and analysis of wind curtailment situations and developing an appropriated methodology for its management," *PowerTech, 2015 IEEE Eindhoven*, Eindhoven, 2015, pp. 1-6.

- D. Boldt, P. Faria and Z. Vale, "Demand Response Shifting Management Applied to Distributed Generation and Pumping," *Computational Intelligence, 2015 IEEE Symposium Series on*, Cape Town, 2015, pp. 1537-1544.
- D. Boldt, P. Faria and Z. Vale, "Integration of Pumping in Virtual Power Players management considering demand response," *2016 13th International Conference on the European Energy Market (EEM)*, Porto, 2016, pp. 1-5.
- D. Boldt, F. Sousa, P. Faria and Z. Vale, "An Approach for Distributed Generation and Demand Response Management Focusing on Wind Power," *2016, 4<sup>th</sup> Elecon Workshop*.

## Referências

- [1] Energias de Portugal, “Sistema Eléctrico Português.” [Online]. Available: <http://www.edp.pt/pt/aedp/sectordeenergia/sistemaelectricoportugues/Pages/SistElec Nacional.aspx>. [Accessed: 05-Jan-2016].
- [2] T. Baptista, “A «Liberalização do Mercado Energético em Portugal» - Verdadeira Concorrência?,” 2014. [Online]. Available: <https://repositorio-aberto.up.pt/bitstream/10216/77260/2/105032.pdf>. [Accessed: 05-Jan-2016].
- [3] Entidade Reguladora dos Serviços Energéticos, “Portal ERSE - Liberalização do Setor.” [Online]. Available: <http://www.erse.pt/pt/electricidade/liberalizacaodosector/Paginas/default.aspx>. [Accessed: 07-Dec-2015].
- [4] Entidade Reguladora dos Serviços Energéticos, “Resumo Informativo do Mercado Liberalizado,” 2015. [Online]. Available: [http://www.erse.pt/pt/electricidade/liberalizacaodosector/informacaosobremercado liberalizado/2015/Comunicados/201509\\_ML\\_elec\\_ResInf.pdf](http://www.erse.pt/pt/electricidade/liberalizacaodosector/informacaosobremercado liberalizado/2015/Comunicados/201509_ML_elec_ResInf.pdf). [Accessed: 30-Sep-2015].
- [5] D. Boldt, P. Faria, and Z. Vale, “Study and analysis of wind curtailment situations and developing an appropriated methodology for its management,” in *2015 IEEE Eindhoven PowerTech*, 2015, pp. 1–6.
- [6] R. S. Al Abri, E. F. El-Saadany, and Y. M. Atwa, “Optimal Placement and Sizing Method to Improve the Voltage Stability Margin in a Distribution System Using Distributed Generation,” *IEEE Trans. Power Syst.*, vol. 28, no. 1, pp. 326–334, Feb. 2013.
- [7] A. R. Khan, A. Mahmood, A. Safdar, Z. A. Khan, and N. A. Khan, “Load forecasting, dynamic pricing and DSM in smart grid: A review,” *Renew. Sustain. Energy Rev.*, vol. 54, pp. 1311–1322, Feb. 2016.
- [8] S. Buryk, D. Mead, S. Mourato, and J. Torriti, “Investigating preferences for dynamic electricity tariffs: The effect of environmental and system benefit disclosure,” *Energy Policy*, vol. 80, pp. 190–195, May 2015.
- [9] S. Chakraborty, T. Ito, and T. Senjyu, “Smart pricing scheme: A multi-layered scoring rule application,” *Expert Syst. Appl.*, vol. 41, no. 8, pp. 3726–3735, Jun. 2014.

- [10] W.-Y. Chiu, H. Sun, and H. V. Poor, “Energy Imbalance Management Using a Robust Pricing Scheme,” *IEEE Trans. Smart Grid*, vol. 4, no. 2, pp. 896–904, Jun. 2013.
- [11] P. Warren, “A review of demand-side management policy in the UK,” *Renew. Sustain. Energy Rev.*, vol. 29, pp. 941–951, Jan. 2014.
- [12] G. Strbac, “Demand side management: Benefits and challenges,” *Energy Policy*, vol. 36, no. 12, pp. 4419–4426, Dec. 2008.
- [13] Charles River Associates, “Primer on Demand-Side Management,” 2005. [Online]. Available: <http://siteresources.worldbank.org/INTENERGY/Resources/PrimeronDemand-SideManagement.pdf>. [Accessed: 04-Feb-2016].
- [14] P. Palensky and D. Dietrich, “Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads,” *IEEE Trans. Ind. Informatics*, vol. 7, no. 3, pp. 381–388, Aug. 2011.
- [15] U.S. Department of Energy, “Benefits of Demand Response in Electricity Markets and Recommendations for Achieving them a Report to the United States Congress Pursuant to Section 1252 of the Energy Policy Act of 2005,” 2006.
- [16] Z. Vale, H. Morais, S. Ramos, J. Soares, and P. Faria, “Using data mining techniques to support DR programs definition in smart grids,” in *2011 IEEE Power and Energy Society General Meeting*, 2011, pp. 1–8.
- [17] P. Joskow, “Lessons Learned From Electricity Market Liberalization,” *The Energy Journal, Special Issue. The Future of Electricity: Papers in Honor of David Newbery.*, 2008. [Online]. Available: <http://economics.mit.edu/files/2093>. [Accessed: 22-Mar-2016].
- [18] PJM Learning Center, “Market for Electricity,” *Electricity Basics*. [Online]. Available: <https://learn.pjm.com/electricity-basics/market-for-electricity.aspx>. [Accessed: 19-Apr-2016].
- [19] M. F. Dias and D. Magueta, “Cross-ownership and concentration in MIBEL: Liberalization and integration experience,” in *2015 12th International Conference on the European Energy Market (EEM)*, 2015, pp. 1–5.
- [20] J. Borges, “MIBEL and the Market Splitting - 5<sup>th</sup> International Conference on the European electricity market,” in *2008 5th International Conference on the European Electricity Market*, 2008, pp. 1–5.

- [21] “OMIE - Operador del Mercado Ibérico de Energia (Pólo Español) S.A.” [Online]. Available: <http://www.omie.es/inicio>. [Accessed: 01-Apr-2016].
- [22] J. Contreras, O. Candiles, J. I. de la Fuente, and T. Gomez, “Auction design in day-ahead electricity markets,” *IEEE Trans. Power Syst.*, vol. 16, no. 3, pp. 409–417, 2001.
- [23] R. Huisman, C. Huurman, and R. Mahieu, “Hourly electricity prices in day-ahead markets,” *Energy Econ.*, vol. 29, no. 2, pp. 240–248, Mar. 2007.
- [24] “OMIP - Operador de Mercado Ibérico de Energia (Pólo Português).” [Online]. Available: <http://www.omip.pt/>. [Accessed: 01-Apr-2016].
- [25] P. Palensky and D. Dietrich, “Demand Side Management: Demand Response, Intelligent Energy Systems, and Smart Loads,” *IEEE Trans. Ind. Informatics*, vol. 7, no. 3, pp. 381–388, Aug. 2011.
- [26] M. H. Albadi and E. F. El-Saadany, “Demand Response in Electricity Markets: An Overview,” in *2007 IEEE Power Engineering Society General Meeting*, 2007, pp. 1–5.
- [27] “Benefits of Demand Response In Electricity Markets and Recommendations for Achieving them a Report to the United States Congress Pursuant to Section 1252 of The Energy Policy Act of 2005,” 2006.
- [28] Z. Vale, H. Morais, S. Ramos, J. Soares, and P. Faria, “Using data mining techniques to support DR programs definition in smart grids,” in *2011 IEEE Power and Energy Society General Meeting*, 2011, pp. 1–8.
- [29] P. Faria, Z. A. Vale, J. Soares, and H. Khodr, “ANN Based Day-Ahead Spinning Reserve Forecast for Electricity Market Simulation,” in *2009 15th International Conference on Intelligent System Applications to Power Systems*, 2009, pp. 1–6.
- [30] G. Pepermans, J. Driesen, D. Haeseldonckx, R. Belmans, and W. D’haeseleer, “Distributed generation: definition, benefits and issues,” *Energy Policy*, vol. 33, no. 6, pp. 787–798, 2005.
- [31] T. Ackermann, G. Andersson, and L. Söder, “Distributed generation: a definition,” *Electr. Power Syst. Res.*, vol. 57, no. 3, pp. 195–204, 2001.
- [32] J. A. P. Lopes, N. Hatziargyriou, J. Mutale, P. Djapic, and N. Jenkins, “Integrating distributed generation into electric power systems: A review of drivers, challenges and opportunities,” *Electr. Power Syst. Res.*, vol. 77, no. 9, pp. 1189–1203, 2007.

- [33] D. Boldt, P. Faria, and Z. Vale, “Integration of Pumping in Virtual Power Players management considering demand response,” in *2016 13th International Conference on the European Energy Market (EEM)*, 2016, pp. 1–5.
- [34] D. Boldt, P. Faria, and Z. Vale, “Demand Response Shifting Management Applied to Distributed Generation and Pumping,” in *2015 IEEE Symposium Series on Computational Intelligence*, 2015, pp. 1537–1544.
- [35] A. Faruqui and J. Palmer, “The Discovery of Price Responsiveness – A Survey of Experiments involving Dynamic Pricing of Electricity,” *Submitted to the EDI Quarterly*, 2012.
- [36] S. Chopra and P. Meindl, *Supply Chain Management*. New Jersey: Prentice Hall, 2007.
- [37] B. Santosa, “Dynamic Pricing in Electricity: Research Potential in Indonesia,” *Procedia Manuf.*, vol. 4, pp. 300–306, 2015.
- [38] M. Yalcintas, W. T. Hagen, and A. Kaya, “An analysis of load reduction and load shifting techniques in commercial and industrial buildings under dynamic electricity pricing schedules,” *Energy Build.*, vol. 88, pp. 15–24, Feb. 2015.
- [39] Entidade Reguladora dos Serviços Energéticos, “Introdução de Tarifas Dinâmicas no Acesso às Redes,” 2014.
- [40] E. Shirazi and S. Jadid, “Optimal residential appliance scheduling under dynamic pricing scheme via HEMDAS,” *Energy Build.*, vol. 93, pp. 40–49, Apr. 2015.
- [41] P. Khajavi, H. Abniki, and A. B. Arani, “The role of incentive based Demand Response programs in smart grid,” in *2011 10th International Conference on Environment and Electrical Engineering*, 2011, pp. 1–4.
- [42] A. Faruqui and J. R. Malko, “The residential demand for electricity by time-of-use: A survey of twelve experiments with peak load pricing,” *Energy*, vol. 8, no. 10, pp. 781–795, Oct. 1983.
- [43] Ipsos MORI, “Consumer Experiences Of Time of Use Tariffs,” 2012. [Online]. Available: <https://www.ipsos-mori.com/researchpublications/publications/1506/Consumer-Experiences-Of-Time-of-Use-Tariffs.aspx>. [Accessed: 22-Feb-2016].
- [44] J. Torriti, “Price-based demand side management: Assessing the impacts of time-of-use tariffs on residential electricity demand and peak shifting in Northern Italy,”

- Energy*, vol. 44, no. 1, pp. 576–583, Aug. 2012.
- [45] S. Borestein, M. Jaske, and A. Rosenfeld, “Dynamic Pricing, Advanced Metering, and Demand Response in Electricity Markets,” *eScholarship Repository, University of California*, 2002. [Online]. Available: [http://sites.energetics.com/MADRI/toolbox/pdfs/vision/dynamic\\_pricing.pdf](http://sites.energetics.com/MADRI/toolbox/pdfs/vision/dynamic_pricing.pdf). [Accessed: 22-Feb-2016].
- [46] R. Sundaram B. and S. K. Vasudevan, “Smart Meter Based on Real Time Pricing,” *Procedia Technol.*, vol. 21, pp. 120–124, 2015.
- [47] H. Allcott, “Rethinking real-time electricity pricing,” *Resour. Energy Econ.*, vol. 33, no. 4, pp. 820–842, Nov. 2011.
- [48] M. G. Lijesen, “The real-time price elasticity of electricity,” *Energy Econ.*, vol. 29, no. 2, pp. 249–258, Mar. 2007.
- [49] J. Stromback, C. Dromacque, and M. H. Yassin, “The potential of smart meter enabled programs to increase energy and systems efficiency: a mass pilot comparison,” *VaasaETT - Global Energy Think Tank*, 2011. [Online]. Available: [http://esmig.eu/sites/default/files/2011.10.12\\_empower\\_demand\\_report\\_final.pdf](http://esmig.eu/sites/default/files/2011.10.12_empower_demand_report_final.pdf). [Accessed: 22-Feb-2016].
- [50] G. R. Newsham and B. G. Bowker, “The effect of utility time-varying pricing and load control strategies on residential summer peak electricity use: A review,” *Energy Policy*, vol. 38, no. 7, pp. 3289–3296, Jul. 2010.
- [51] G. Zhang, B. Eddy Patuwo, and M. Y. Hu, “Forecasting with artificial neural networks:: The state of the art,” *Int. J. Forecast.*, vol. 14, no. 1, pp. 35–62, 1998.
- [52] S. Haykin, “Neural Networks - A Comprehensive Foundation,” Ontario, Canada, 1998.
- [53] S. Ramos, J. Soares, Z. Vale, and S. Ramos, “Short-term load forecasting based on load profiling,” in *2013 IEEE Power & Energy Society General Meeting*, 2013, pp. 1–5.
- [54] D. Shanthi, G. Sahoo, and N. Saravanan, “Comparison of Neural Network Training Algorithms for the prediction of the patient’s post-operative recovery area.,” vol. 4, pp. 24–32, Jan. 2009.
- [55] J. Schmidhuber, “Deep learning in neural networks: An overview,” *Neural Networks*, vol. 61, pp. 85–117, 2015.

- [56] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 2nd Edition. Prentice Hall, 2002.
- [57] C. Kaensar, “Analysis on the Parameter of Back Propagation Algorithm with Three Weight Adjustment Structure for Hand Written Digit Recognition,” in *2013 10th International Conference on Service Systems and Service Management*, 2013, pp. 18–22.
- [58] L. A. Deleris and F. Erhun, “Risk Management in Supply Networks Using Monte-Carlo Simulation,” in *Proceedings of the Winter Simulation Conference, 2005.*, pp. 1643–1649.
- [59] L. A. Deleris and F. Erhun, “Risk Management in Supply Networks Using Monte-Carlo Simulation,” in *Proceedings of the Winter Simulation Conference, 2005.*, 2005, pp. 1643–1649.
- [60] H. Keko and V. Miranda, “Impact of clustering-based scenario reduction on the perception of risk in unit commitment problem,” in *18th International Conference on Intelligent System Application to Power Systems (ISAP)*, 2015, pp. 1–6.
- [61] P. Pinson, H. Madsen, H. Aa Nielsen, G. Papaefthymiou, B. Kjøckl, and P. Pinson, “From Probabilistic Forecasts to Statistical Scenarios of Short-term Wind Power Production,” *Publ. Wind Energy*, 2008.
- [62] S. Raychaudhuri, “Introduction to Monte Carlo simulation,” in *2008 Winter Simulation Conference*, 2008, pp. 91–100.
- [63] M. Beale, M. Hagan, and H. Demuth, “Neural Network Toolbox™ User’s Guide,” 2016.
- [64] “Weather Undergroud - Wunderground.” [Online]. Available: <https://www.wunderground.com/>.
- [65] “Estatística Diária - Centro de Informação - REN.” [Online]. Available: <http://www.centrodeinformacao.ren.pt/PT/Paginas/CIHomePage.aspx>.
- [66] I. Simonsen, “Volatility of power markets,” *Physica A*, vol. 355, pp. 10–20, 2005.
- [67] D. W. Bunn, *Modelling prices in competitive electricity markets*. J. Wiley, 2004.
- [68] M. Bierbrauer, S. Trück, and R. L. Weron, “LNCS 3039 - Modeling Electricity Prices with Regime Switching Models,” 2004.