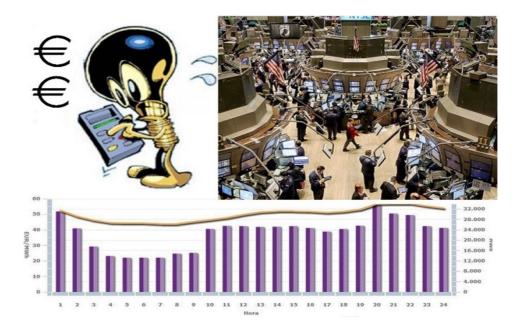


### INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA

## Área Departamental de Engenharia de Sistemas de Potência e Automação



## Abordagem à Previsão do Preço de Energia Elétrica Via Métodos de Suavização Exponencial

## RICARDO ANDRÉ DOS REIS SOARES

(Licenciado em Engenharia Eletrotécnica)

Dissertação para a obtenção do grau de Mestre em Engenharia Eletrotécnica – ramo de Energia

#### Orientadores:

Professora Cristina Inês Camus Equip. Assist. 2º Triénio Eduardo Adelino Mateus Nunes Eusébio

#### Júri:

#### Presidente:

Professor Jorge Alberto Mendes de Sousa

#### Vogais:

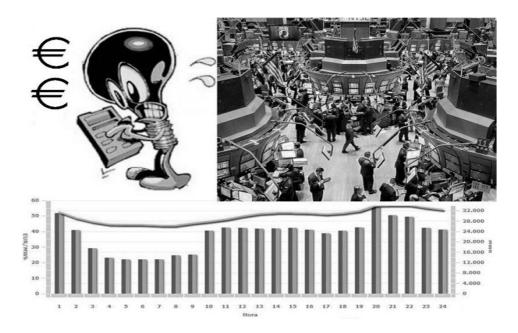
Professora Cristina Inês Camus

Equip. Assist. 2º Triénio Eduardo Adelino Mateus Nunes Eusébio Professor Victor Manuel Fernandes Mendes



## INSTITUTO SUPERIOR DE ENGENHARIA DE LISBOA

## Área Departamental de Engenharia de Sistemas de Potência e Automação



## Abordagem à Previsão do Preço de Energia Elétrica Via Métodos de Suavização Exponencial

## RICARDO ANDRÉ DOS REIS SOARES

(Licenciado em Engenharia Eletrotécnica)

Dissertação para a obtenção do grau de Mestre em Engenharia Eletrotécnica – ramo de Energia

#### Orientadores:

Professora Cristina Inês Camus Equip. Assist. 2º Triénio Eduardo Adelino Mateus Nunes Eusébio

Júri:

Presidente:

Professor Jorge Alberto Mendes de Sousa

Vogais:

Professora Cristina Inês Camus Equip. Assist. 2º Triénio Eduardo Adelino Mateus Nunes Eusébio Professor Victor Manuel Fernandes Mendes

## Dissertação realizada sob orientação de:

## Professora Cristina Inês Camus

Professora Adjunta da Área Departamental de Engenharia de Sistemas de Potência e Automação

## Assistente Eduardo Adelino Eusébio

Equiparado a Assistente 2º Triénio da Área Departamental de Engenharia de Sistemas de Potência e Automação

Resumo

Atualmente a energia elétrica é indiscutivelmente um dos produtos essenciais na

sociedade, tendo dessa forma um peso muito importante na economia global e na sua

competitividade.

Nos últimos anos temos vindo a verificar mudanças significativas na natureza

estrutural e regulamentar no sector da energia elétrica, conduzindo a mercados de

energia mais competitivos. Neste contexto surge em 2007 a integração dos mercados

de eletricidade da Península Ibérica, constituindo-se o Mercado Ibérico de

Eletricidade (MIBEL), no qual se realiza transações de energia elétrica e se

negoceiam instrumentos financeiros que têm como referência essa mesma energia.

A presente dissertação incide sobre a problemática da previsão do preço da energia

elétrica de curto prazo, aplicada, diretamente, a sistemas de energia elétrica. A

metodologia utilizada para a previsão englobará uma análise às séries de preços do

MIBEL e, posteriormente a aplicação dos modelos de previsão nomeadamente os de

alisamento exponencial, vulgarmente, designados por métodos de Holt-Winters.

Os resultados obtidos através dos vários modelos serão sujeitos a uma rigorosa

análise e comparação, para que seja escolhido o melhor modelo que conduza aos

resultados pretendidos. Os melhores resultados serão aqueles que apresentem o

menor erro e que melhor modelizem a série de dados e produzam boas previsões.

Palavras-Chave: Previsão

**Holt-Winters** 

Energia elétrica

**MIBEL** 

i

**Abstract** 

Currently, electricity is undoubtedly one of the most essential products in society,

and it has a very important role in the global economy and its competitiveness.

In recent years we have been observing significant changes in structural and

regulatory sector of electricity, leading to more competitive energy markets. It is in

this context that arises, in 2007, the integration of the electricity markets from Iberian

Peninsula, which constitutes the Iberian Electricity Market (MIBEL), where

electricity transactions occur and where financial instruments related to this energy

are negotiated.

This thesis focuses on the problem of the short-term energy's price prediction,

applied, directly, to electric power systems. The methodology used for forecast

encompasses an analysis of the MIBEL's price series and then the application of

prediction's models namely the exponential smoothing, commonly called Holt-

Winters.

The results obtained through different models will be submitted to a rigorous

analysis and comparison, so we could choose the best model which leads to the

desired results. This results obtained should be the ones that will present the slightest

mistake and which will model the data series and produce good predictions.

**Keywords:** Forecasting

**Holt-Winters** 

Electricity

**MIBEL** 

ii

## **Agradecimentos**

A execução desta dissertação não seria possível sem o apoio e motivação por parte de um conjunto de pessoas, não poderia deixar então de prestar algumas palavras de agradecimento.

Em primeiro lugar aos meus pais, André Soares e Ana Maria Soares, por tudo aquilo que fizerem por mim até hoje, que sempre me apoiaram em todas as situações e decisões ao longo da minha vida, assim como todas as condições que me proporcionaram para a realização de toda a minha formação. Pelos enormes pais que tenho, agradeço-lhes do fundo do meu coração e dedico esta dissertação a eles.

Ao Eng.º Eduardo Adelino Mateus Nunes Eusébio e à Eng.ª Cristina Inês Camus agradeço pela orientação desta dissertação, pelos conselhos prestados, apoio, confiança, paciência, disponibilidade, grande motivação e espírito crítico que sempre me incutiram.

À minha namorada, Joana Almeida agradeço a grande paciência que sempre teve comigo, assim como todo o apoio, carinho e motivação que sempre me deu.

Ao meu irmão, Tiago Soares agradeço por toda a nossa amizade, sua disponibilidade em sempre ajudar e pelas palavras de apoio que sempre manifestou.

A toda a minha família em geral, pelo apoio e força que sempre me transmitiram.

Aos meus colegas do ISEL, por todo o apoio, amizade e companheirismo ao longo deste percurso universitário. Em especial, aos meus colegas Pedro Alves, Diogo Fernandes e Sérgio Conduto pela boa disposição e companheirismo nesta última fase do curso, bastante trabalhadora e morosa, em que tornaram todo o trabalho mais motivador e relaxado.

Por fim, agradeço ainda a todas as pessoas a que não me referi, mas contribuíram de forma direta ou indireta para a elaboração desta dissertação e conclusão do curso.

## Índice de Conteúdos

1 In	trodução	2
1.1	Enquadramento	2
1.2	Motivação	3
1.3	Objeto de Estudo	4
1	1.3.1 Objetivo/Hipóteses	4
1.4	Estrutura do texto	5
1.5	Notação	6
2 M	ercado de Energia	8
2.1	Sistema Elétrico Nacional (SEN)	8
2.2	Mercado Ibérico de Eletricidade (MIBEL)	.12
2.3	Tarifas e Custos da Energia Elétrica	.20
3 M	odelos de Previsão	.26
3.1	Enquadramento e Previsão	.26
3.2	Literatura em Previsão	.28
3.3	Classificação de Métodos de Previsão	.31
3.4	Métodos Qualitativos de Previsão	.32
3.5	Métodos Quantitativos de Previsão	.35
4 Sé	ries de Preços	.41
4.1	Séries de Preços	.41
4.2	Nível e Tendência	.41
4.3	Volatilidade	.42
4.4	Sazonalidade	.43
2	4.4.1 Sazonalidade Semanal	.44
4	4.4.2 Sazonalidade Diária	.45
4.5	Análise Geral	.46
5 M	odelização	48

5.1 I	ntrodução ao Holt-Winters	48
5.2 I	Modelo Padrão - Holt-Winters	48
5	2.1 Aditivo	48
5	2.2 Multiplicativo	49
5.3 I	Modelos Gerais	50
5.4 I	Modelo - Holt-Winters Dupla Sazonalidade	52
5.4	4.1 Dupla Sazonalidade Multiplicativa com Tendência Aditiva	52
5.4	4.2 Dupla Sazonalidade Multiplicativa com Tendência Amortecida	53
5.4	4.3 Dupla Sazonalidade Multiplicativa com Tendência Amortecida e Er	ros
	Estruturados	54
5.4	4.4 Valores Iniciais dos Parâmetros	54
5.5 I	Medidas de Erro dos Métodos de Previsão de Séries Temporais	56
5.6 I	ntervalo de Confiança	57
5.7 I	ndicadores/Medidas de Erro e Ajuste dos Modelos	58
5.	7.1 Estatística de Teste U Theil	58
5.	7.2 Estatística de Teste R <sup>2</sup>	58
6 Case	os de Estudo	61
6.1 I	Enquadramento	61
6.2 I	Dados e Tratamento de Dados	61
6.3 A	Aplicação dos Modelos às Séries de Dados	62
6.3	3.1 Previsão Diária Seleção de Modelos	65
6	3.3.1.1 Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva	va. 65
6	3.3.1.2 Holt-Winters dupla sazonalidade multiplicativa com tendên	cia
a	mortecida	69
6	3.3.1.3 Holt-Winters dupla sazonalidade multiplicativa com tendên	cia
a	mortecida e erros estruturados.	74
6	3.1.4 Comparação do MAPE	79
6.	3.2 Previsão Diária via Modelo de Erros Estruturados	81

	6.3.2.1 Holt-Winters dupla sazonalidade multiplicativa com tendênc	ia
	suavizada e erros estruturados com várias séries de tempo diferenciadas r	10
	tempo	81
	6.3.2.2 Comparação do erro MAPE.	98
	6.3.2.3 Intervalo de confiança	99
	6.3.2.4 Evolução horária do erro quadrático (QE)	.102
	6.3.3 Previsão Semanal Seleção de Modelos	.104
	6.3.3.1 Holt-Winters dupla sazonalidade multiplicativa com tendência aditiv	va
		.104
	6.3.3.2 Holt-Winters dupla sazonalidade multiplicativa com tendênc	ia
	amortecida	.108
	6.3.3.3 Holt-Winters dupla sazonalidade multiplicativa com tendênc	
	amortecida e erros estruturados.	.112
	6.3.3.4 Comparação do erro MAPE	.117
7	Conclusões	.120
	7.1.1 Conclusões.	.120
	7.1.2 Desenvolvimentos Futuros	.124
8	Bibliografia	.127

## Índice de tabelas

Tabela 5.1 - Métodos de Alisamento Exponencial (Holt-Winters)
Tabela 6.1 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva, referentes ao primeiro dia previsto
Tabela 6.2 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados
Tabela 6.3 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados
Tabela 6.4 - Erros de previsão ao longo dos sete de previsão
Tabela 6.5 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.6 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida, referentes ao primeiro dia previsto 70
Tabela 6.7 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados
Tabela 6.8 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados
Tabela 6.9 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.10 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.11 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados, referentes ao primeiro dia previsto
Tabela 6.12 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados
Tabela 6.13 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados
Tabela 6.14 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.15 - Erros de previsão ao longo dos sete dias previstos

Tabela 6.16 - MAPE e média do MAPE dos dias previstos, ao longo dos sete dias,
para os três modelos de previsão com um ano de dados
Tabela 6.17 - Erros e média do erro MAPE dos dias previstos, ao longo dos sete dias, para os três modelos de previsão com dois anos e meio de dados
Tabela 6.18 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados, referentes ao primeiro dia previsto
Tabela 6.19 - Parâmetros otimizados individualmente a cada dia com série de 6 meses de dados (Outubro de 2011 até Março de 2012)
Tabela 6.20 - Parâmetros otimizados individualmente a cada dia com série de 6 meses de dados (Junho de 2012 até Novembro de 2012)
Tabela 6.21 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados
Tabela 6.22 - Parâmetros otimizados individualmente a cada dia com série de 1,5 anos de dados
Tabela 6.23 - Parâmetros otimizados individualmente a cada dia com série de 2 anos de dados
Tabela 6.24 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados
Tabela 6.25 - Parâmetros otimizados individualmente a cada dia com série de 3 anos de dados
Tabela 6.26 - Parâmetros otimizados individualmente a cada dia com série de 3,5 anos de dados
Tabela 6.27 - Parâmetros otimizados individualmente a cada dia com série de 4 anos de dados
Tabela 6.28 - Média dos parâmetros otimizados para o modelo HWTAEE com diversos tamanhos de série
Tabela 6.29 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.30 - Erros de previsão ao longo dos sete dias previstos

Tabela 6.31 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.32 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.33 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.34 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.35 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.36 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.37 - Erros de previsão ao longo dos sete dias previstos
Tabela 6.38 - Erros e média de erros MAPE do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados com várias séries de tempo diferenciadas no tempo
Tabela 6.39 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva, referentes à primeira semana prevista 104
Tabela 6.40 - Parâmetros otimizados individualmente a cada semana com série de 1 ano de dados
Tabela 6.41 - Parâmetros otimizados individualmente a cada semana com série de 2,5 anos de dados
Tabela 6.42 - Erros de previsão ao longo das cinco semanas previstas
Tabela 6.43 - Erros de previsão ao longo das cinco semanas previstas
Tabela 6.44 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida, referentes à primeiro semana prevista 108
Tabela 6.45 - Parâmetros otimizados individualmente a cada semana com série de 1 ano de dados
Tabela 6.46 - Parâmetros otimizados individualmente a cada semana com série de 2,5 anos de dados
Tabela 6.47 - Erros de previsão ao longo das cinco semanas previstas
Tabela 6.48 - Erros de previsão ao longo das cinco semanas previstas

Tabela 6.49 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade
multiplicativa com tendência amortecida e erros estruturados, referentes à primeiro
semana prevista
Tabela 6.50 - Parâmetros otimizados individualmente a cada semana com série de 1
ano de dados
Tabela 6.51 - Parâmetros otimizados individualmente a cada semana com série de
2,5 anos de dados
Tabela 6.52 - Erros de previsão ao longo das cinco semanas previstas
Tabela 6.53 - Erros de previsão ao longo das cinco semanas previstas
Tabela 6.54 - Erros e média do erro MAPE das semanas previstos, ao longo das
cinco semanas, para os três modelos de previsão com um ano de dados117
Tabela 6.55 - Erros e média do erro MAPE das semanas previstos, ao longo das
cinco semanas, para os três modelos de previsão com dois anos e meio de dados 118

## Índice de figuras

Figura 2.1 - Restruturação/Desverticalização do Sistema Elétrico	8
Figura 2.2 - Organização do Sistema Elétrico Nacional em 1995	10
Figura 2.3 - Cadeia de Valor do Setor Elétrico	11
Figura 2.4 - Oferta e procura de energia elétrica no mercado diário	16
Figura 2.5 - Mercado Diário, exemplo de Market Splitting	17
Figura 2.6 - Mercados Intradiários	18
Figura 2.7 - Estrutura dos Preços no Mercado Livre	22
Figura 2.8- Estrutura das Tarifas no Mercado Regulado	23
Figura 3.1 - Métodos de Previsão	31
Figura 3.2 - Métodos Qualitativos	32
Figura 3.3 - Métodos Quantitativos	35
Figura 4.1 - Série de Preços da Energia Elétrica (1 Julho 2007-31 Dezembro 2012	2)41
Figura 4.2 - Série de Preços da Energia Elétrica (1 Agosto 2012-31 Agosto 2012)	. 43
Figura 4.3 - Série de Preços da Energia Elétrica (1 Dezembro 2012-31 Dezem	
Figura 4.4 - Série de Preços da Energia Elétrica (1 Dezembro 2012-15 Dezem	
Figura 4.5 - Série de Preços da Energia Elétrica (1 Agosto 2012-7 Agosto 2012).	44
Figura 4.6 - Série de Preços da Energia Elétrica (23 Abril 2012-7 Maio 2012)	45
Figura 4.7 - Série de Preços da Energia Elétrica (8 de Fevereiro 2012-10 Fever	
Figura 6.1 - Resumo da estrutura adotada para o presenta capítulo	64
Figura 6.2 - Evolução do MAPE ao longo dos sete dias previstos	66
Figura 6.3 - Evolução do MAPE ao longo dos sete dias previstos	67

Figura 6.4 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.5 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia). 68
Figura 6.6 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.7 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia). 68
Figura 6.8 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia),
com o tamanho de série de um ano
Figura 6.9 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de dois anos e meio
Figura 6.10 - Evolução do MAPE ao longo dos sete dias previstos71
Figura 6.11 - Evolução do MAPE ao longo dos sete dias previstos71
Figura 6.12 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.13 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)
Figura 6.14 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.15 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)
Figura 6.16 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de um ano
Figura 6.17 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de dois anos e meio
Figura 6.18 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.19 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.20 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.21 - Valores reais e previstos referentes ao pior dia previsto (quinto dia)77

Figura 6.22 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.23 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)
Figura 6.24 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de um ano
Figura 6.25 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de dois anos e meio
Figura 6.26 - Comparação dos modelos com uma série de dados de um ano (9072 observações)
Figura 6.27 - Comparação dos modelos com uma série de dados de dois anos e meio (20160 observações)
Figura 6.28 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.29 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.30 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.31 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.32 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.33 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.34 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.35 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.36 - Evolução do MAPE ao longo dos sete dias previstos
Figura 6.37 - Valores reais e previstos referentes ao melhor dia previsto (sexto dia)92
Figura 6.38 - Valores reais e previstos referentes ao pior dia previsto (terceiro dia) 92
Figura 6.39 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.40 - Valores reais e previstos referentes ao pior dia previsto (sexto dia) 93
Figura 6.41 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

Figura 6.42 - Valores reais e previstos referentes ao pior dia previsto (quinto dia) 94
Figura 6.43 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.44 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)
Figura 6.45 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.46 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)
Figura 6.47 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)
Figura 6.48 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)
Figura 6.49 - Valores reais e previstos referentes ao melhor dia previsto (quarto dia)
Figura 6.50 - Valores reais e previstos referentes ao pior dia previsto (quinto dia) 96
Figura 6.51 - Valores reais e previstos referentes ao melhor dia previsto (quarto dia)
Figura 6.52 - Valores reais e previstos referentes ao pior dia previsto (quinto dia) 97
Figura 6.53 - Valores reais e previstos referentes ao melhor dia previsto (quarto dia)
Figura 6.54 - Valores reais e previstos referentes ao pior dia previsto (quinto dia) 98
Figura 6.55 - Comparação dos erros MAPE do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados com várias séries de tempo diferenciadas no tempo
Figura 6.56 - Comparação do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados dos melhores resultados
Figura 6.57 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia)

Figura 6.58 - Intervalo de confiança de 95% para o pior dia previsto (primeiro dia)
Figura 6.59 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia)
Figura 6.60 - Intervalo de confiança de 95% para o pior dia previsto (primeiro dia)
Figura 6.61 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia)
Figura 6.62 - Intervalo de confiança de 95% para o pior dia previsto (primeiro dia)
Figura 6.63 - Evolução horária do erro QE dos sete dias previstos individualmente com três séries de tempo diferentes para o modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados
Figura 6.64 - Evolução horária do erro QE do terceiro dia previsto para o modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados para diversos tamanhos de série
Figura 6.65 - Evolução horária do erro QE de três dias previstos individualmente com série de tempo com 2 anos e meios para o modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados
Figura 6.66 - Evolução do MAPE ao longo das cinco semanas previstas
Figura 6.67 - Evolução do MAPE ao longo das cinco semanas previstas 106
Figura 6.68 - Valores reais e previstos referentes à melhor semana prevista (segunda semana)
Figura 6.69 - Valores reais e previstos referentes à pior semana prevista (terceira semana)
Figura 6.70 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)
Figura 6.71 - Valores reais e previstos referentes à pior semana prevista (terceira semana)
Figura 6.72 - Evolução do MAPE ao longo das cinco semanas previstas

Figura 6.73 - Evolução do MAPE ao longo das cinco semanas previstas
Figura 6.74 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)
Figura 6.75 - Valores reais e previstos referentes à pior semana prevista (terceira semana)
Figura 6.76 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)
Figura 6.77 - Valores reais e previstos referentes à pior semana prevista (primeira semana)
Figura 6.78 - Evolução do MAPE ao longo das cinco semanas previstas
Figura 6.79 - Evolução do MAPE ao longo das cinco semanas previstas
Figura 6.80 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)
Figura 6.81 - Valores reais e previstos referentes à pior semana prevista (primeira semana)
Figura 6.82 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)
Figura 6.83 - Valores reais e previstos referentes à pior semana prevista (primeira semana)
Figura 6.84 - Comparação dos modelos com uma série de dados de um ano (8400 observações)
Figura 6.85 - Comparação dos modelos com uma série de dados de dois anos e meio (19488 observações)

#### Lista de Acrónimos/Abreviaturas

ANNs Artificial Neural Networks

AR Auto Regressive

ARIMA Auto Regressive Integrated Moving Average

ARMA Auto Regressive moving average

AT Alta Tensão

BT Baixa Tensão

CAE Contratos de aquisição de energia elétrica

CFDI Confidence Interval

CMEC Custos para a manutenção do equilíbrio contratual

CUR Comercializador de último recurso

EDP Eletricidade de Portugal

EM Erro Médio

EMA Erro Médio Absoluto

EMS Electrical Management System

EPEX Spot Mercado de energia para Alemanha, França, Áustria e Suíça.

ERSE Entidade Reguladora de Serviços Energéticos

EUA Estados Unidos da América

GARCH Auto Regressive Conditional Heteroskedastic

GLS Generalized Least Squares

HWM Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva

HWTA Holt-Winters dupla sazonalidade multiplicativa com tendência

amortecida

HWTAEE Holt-Winters dupla sazonalidade multiplicativa com tendência

amortecida e erros estruturados

MA Moving Averages

MAPE Erro percentual médio absoluto

MAT Muito alta tensão

MCP Market Clearing Price

MIBEL Mercado Ibérico de Eletricidade

MT Média Tensão

NETA New Electricity Traiding Arrangements

OMI Operador de Mercado Ibérico

OMIClear Sociedade de Compensação de Mercados de Energia, S. A.

OMIE Operador de Mercado Ibérico, polo Espanhol

OMIP Operador de Mercado Ibérico, polo Português

PE Erro Percentual

PRE Produção em Regime Especial

PRO Produção em Regime Ordinário

PURPA Public Utility Regulatory Polocies Act

QE Erro Quadrático

QME Erro Médio Quadrático

RND Rede Nacional de Distribuição

RNT Rede Nacional de Transporte

SARIMA Seasonal Auto Regressive Integrated Moving Average

SEI Sistema Elétrico Independente

SEN Sistema Elétrico Nacional

SENV Sistema Elétrico não Vinculado

SEP Sistema Elétrico de Serviço Público

TVCF Tarifa de Venda a Clientes Finais

VOLA Volatility

#### **Símbolos**

 $D^*_{i,j}$ Fatores dos Ciclos Diários Grosseiros  $D_{i}^{*}$ Fatores dos Ciclos Diários Fatores dos Ciclos Diários Normalizados  $D_{j}$  $D_{t}(0)$ Valor inicial do parâmetro de sazonalidade diária Sazonalidade 1 (Diária)  $D_t$ Sazonalidade  $I_t$ k Período a prever  $\mathbb{R}^2$ Estatística de teste R<sup>2</sup> Índice sazonal S Índice sazonal 1 (Diário)  $s_1$ Índice sazonal 2 (Semanal)  $S_2$ Valor inicial do parâmetro de nível  $S_{t}(0)$  $S_{t}$ Nível Instante de tempo t  $T_{t}(0)$ Valor inicial do parâmetro da tendência Tendência  $T_t$ U Estatística de teste U-Theil  $W_{t}(0)$ Valor inicial do parâmetro de sazonalidade semanal  $W_t$ Sazonalidade 2 (Semanal)  $X_t$ Série histórica de dados  $\hat{X}_t$ Valor previsto para a varável em estudo α Parâmetro de alisamento de atualização do modelo Holt-Winters Parâmetro de alisamento de atualização do modelo Holt-Winters γ Parâmetro de alisamento de atualização do modelo Holt-Winters δ

$\mathcal{E}_{t}$	Erro
λ	Parâmetro de alisamento de atualização do modelo Holt-Winters
σ	Variância
ф	Parâmetro de alisamento de atualização do modelo Holt-Winters
ω	Parâmetro de alisamento de atualização do modelo <i>Holt-Winters</i>

# Capítulo 1

## INTRODUÇÃO

Neste capítulo é elaborada uma introdução ao tema da previsão do preço de mercado da energia elétrica. É exposto o enquadramento do tema, assim como as principais ideias que motivaram a abordagem do mesmo. Por fim, descreve-se a estrutura do texto e ainda a notação utilizada ao longo deste trabalho.

## 1 Introdução

## 1.1 Enquadramento

Desde a pré-história o Homem utiliza a sua inteligência para descobrir novas técnicas e mecanismos que reduzam o seu esforço e aumentem o conforto. Como é o caso da descoberta do fogo que permitiu melhorar a alimentação, iluminação e segurança, inventou a roda e mecanismos que permitiram "multiplicar" a força humana e facilitar a capacidade de transporte. O mesmo sucedeu no caso da eletricidade, que desde a sua descoberta tem vindo a ter cada vez um maior peso na sociedade e em toda a economia, sendo considerada como a principal "chave" da segunda revolução industrial.

No presente a energia elétrica é indiscutivelmente um dos produtos essenciais na sociedade, estando presente em quase todas as vertentes da mesma, desde as indústrias, habitações, escolas, hospitais, iluminação pública, etc. Dessa forma a energia elétrica apresenta um peso de grande importância na economia global e na sua competitividade.

Ao longo dos últimos anos tem existido mudanças significativas na natureza estrutural e regulamentar no sector da energia elétrica. Essas mudanças têm levado ao estabelecimento de um mercado elétrico mais competitivo uma vez que tem vindo a ser implementado um regime liberalizado no mercado em detrimento do regime monopolista e consequentemente uma desintegração vertical que estava implementada. Com a restruturação dos mercados elétricos para mercados liberalizados, o preço da energia elétrica torna-se imprevisível e instável pelo fato de passar a existir concorrência. Além disso o preço apresenta características, onde se destaca o elevado grau de volatilidade e bastante influenciável por diversos fatores, que provêm da própria natureza da energia elétrica, tais como os preços dos combustíveis fósseis, o consumo de energia elétrica, a produção térmica, a produção a partir de energias renováveis, o preço das licenças de emissão de CO<sub>2</sub> e de certificados verdes, entre outros.

Tendo em vista esta abordagem torna-se muito útil efetuar previsões, nomeadamente a previsão do preço da energia elétrica, de forma tentar contrariar a sua elevada incerteza. Essa incerteza no preço acarreta um risco elevado às empresas produtoras de energia, e ao ser possível efetuar uma previsão fiável leva a que as empresas incorram em menor risco, aumentando ainda a competitividade entre as mesmas.

Este trabalho enquadra-se na temática da previsão, mais precisamente na previsão do preço da energia elétrica, num horizonte temporal quantificável e designado por curto

prazo, visto a previsão incidir para um período temporal especifico e bem definido (24h, diário e 168h, semanal), tendo por base dados históricos.

A previsão será realizada através de modelos matemáticos de *Holt-Winters* efetuando-se a discussão entre diferentes configurações do método.

## 1.2 Motivação

A energia elétrica tem vindo a assumir-se ao longo dos anos como um dos pilares mais importantes da nossa sociedade, estando presente no dia-a-dia, na rotina e estilo de vida. Assumindo assim, um papel determinante na competitividade da economia.

O sistema elétrico tem vindo a sofrer muitas alterações ao longo das últimas décadas. Muitas destas alterações visam, de um modo geral, a diminuição e maior eficiência do consumo de energia elétrica, a diminuição do nível de poluição provocado pelos produtores deste sector e, ainda, tornar o mercado de energia elétrica mais equilibrado e competitivo de forma a baixar o preço da energia para os consumidores.

Outra alteração tem-se focado na liberalização dos mercados de energia elétrica e em tornar esses mercados mais competitivos (sempre com a supervisão de uma ou várias entidades, como por exemplo a ERSE). Assim, com os mercados monopolizados os preços da energia eram estáveis e bastante previsíveis para longos períodos de tempo. Assim sendo, os agentes de mercado estavam sujeitos a riscos mínimos. Contrariamente, a liberalização do sector elétrico torna os preços bastante mais instáveis e incertos sendo que os agentes de mercado ficam sujeitos a riscos bastante mais elevados, podendo os mesmos constituir elevadas perdas.

Para se conseguir minimizar este risco torna-se útil, e até essencial, fazer previsões, tal como a previsão do preço da energia elétrica quer a curto quer a médio prazo. Atualmente, mesmo com todo o avanço tecnológico que se tem verificado ao longo das últimas décadas, ainda é impossível prever o futuro. Mas, já é possível fazer boas previsões, nomeadamente, a previsão do preço da energia elétrica. Sendo que quanto melhor for essa previsão, melhor serão as decisões e as medidas de prevenção a tomar. Este tipo de previsão reduz a incerteza no preço da energia elétrica (entre produtores/consumidores, agentes, "empresas") o que tem como consequência uma economia global mais competitiva.

Desta forma, compreende-se a importância de elaborar e tentar melhorar a previsão do preço da energia, dado que esta levará a uma mais-valia para diversos sectores, não só no mercado de energia elétrica como na grande maioria dos sectores da economia.

## 1.3 Objeto de Estudo

O primeiro passo desta dissertação passará pela formulação do problema de forma a fazer emergir os principais objetivos desta dissertação. Posto isto, esta dissertação terá como principal objeto realizar uma tentativa de abordagem de metodologias de alisamento exponencial, designadas por *Holt-Winters* à previsão do preço da energia elétrica no curto prazo.

O objeto de estudo da dissertação terá como principais questões:

- Análise e comparação entre várias metodologias de previsão, através de métodos de *Holt-Winters*, aferida através do valor das medidas de erro, tais como o erro médio quadrático (QME) e o erro percentual médio absoluto (MAPE).
- Discussão sobre a conjugação entre tendência e sazonalidade, nas suas variantes, aditiva, multiplicativa, aditiva suavizada e multiplicativa suavizada, bem como diversos tamanhos de séries de dados.
- Análise e comparação dos resultados obtidos para escolha do modelo que melhor se ajusta e traduz a série de dados.

### 1.3.1 Objetivo/Hipóteses

Nesta dissertação, o principal objetivo passa por resolver os problemas apresentados no objeto de estudo, ou seja, obter-se o modelo mais preciso e que melhor se adequa à série de dados de preços do MIBEL, onde serão concebidas as previsões diárias e semanais do mesmo.

#### 1.4 Estrutura do texto

A dissertação encontra-se dividida em sete grandes capítulos, estando organizados de forma a que ao longo dos capítulos exista um aprofundamento do tema.

No capítulo 1 é elaborado o enquadramento ao tema a que esta tese se insere, assim como a motivação para compor a mesma. É de referir ainda, o objeto de estudo e os objetivos propostos para a tese, assim como a estrutura do texto e a notação utilizada de forma a facilitar a compreensão e leitura da mesma.

O capítulo 2 foca-se numa abordagem geral do mercado de energia elétrica, enquadrando-se na evolução do Sistema Elétrico Nacional e a criação e desenvolvimento do Mercado Ibérico de Energia Elétrica.

No capítulo 3 é abordado o conceito de previsão, tal como os vários tipos de modelos de previsão. Ainda, é apresentada a literatura em previsão, também designada por estado de arte, onde contém alguma da literatura existente acerca da previsão, e dos modelos adequados para a previsão do preço de mercado da energia elétrica.

O capítulo 4 aborda as principais características inerentes às séries históricas de dados do preço da energia elétrica, tal como uma análise a essas mesmas características, para que seja feita a escolha mais adequada do modelo para a série em questão.

No capítulo 5 é abordada a modelização, onde são expostas as formulações e metodologias dos modelos *Holt-Winters* de modo a serem enquadradas no caso em estudo. Ainda, é feita a composição de "ferramentas" de modo a ser possível analisar, comparar e discutir os resultados que serão obtidos.

O capítulo 6 é composto pelos casos de estudo, expondo a formulação dos problemas ao qual se pretende responder aos objetivos apresentados para esta tese. Analogamente, são expostos todos os resultados obtidos, assim como uma breve análise dos mesmos.

No último capítulo, capítulo 7, é elaborada uma síntese do estudo e apresentam-se as conclusões mais importantes desta dissertação, bem como hipóteses de futuros desenvolvimentos.

Por último é apresentada a bibliografia utilizada para o desenvolvimento da dissertação.

## 1.5 Notação

As referências bibliográficas são apresentadas entre parêntesis retos [], e as expressões são apresentadas com parêntesis curvos (). Siglas ou expressões em língua estrangeira são apresentadas em itálico. As figuras, tabelas e expressões são numeradas de forma sequencial no respetivo capítulo, composto por dois algarismos, sendo que o primeiro algarismo se refere ao capítulo em que se encontram inseridas e o segundo algarismo referente à ordem sequencial. As tabelas em Anexo, são numeradas, apresentando uma letra referente ao Anexo em que se encontra e numeradas sequencialmente. Abreviaturas e simbologia utilizada ao longo do texto, são apresentadas previamente no índice de abreviaturas e símbolos.

As referências bibliográficas estão elaboradas de acordo com a normalização IEEE 2006 atualização 2010.

## Capítulo 2

## MERCADOS DE ENERGIA

Neste capítulo é efetuada uma abordagem geral do Mercado de Energia Elétrica. Tendo como principais focos, a evolução do Sistema Elétrico Nacional (SEN), a criação do Mercado Ibérico de Energia Elétrica (MIBEL) assim como os seus principais constituintes e mecanismos de funcionamento.

## 2 Mercado de Energia

## 2.1 Sistema Elétrico Nacional (SEN)

O sistema elétrico tem vindo a sofrer profundas restruturações ao longo das últimas décadas em todo o mundo, a fim de combater a verticalização e monopolização instauradas, essa restruturação pode ser visualizada de forma ilustrativa na Figura 2.1 [1]. São mudanças que apontam no sentido de estabelecer um mercado de energia elétrica mais competitivo.

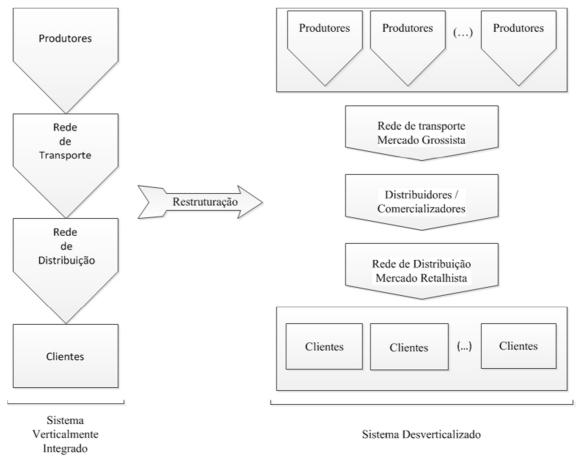


Figura 2.1 - Restruturação/Desverticalização do Sistema Elétrico

O despoletar da restruturação do setor elétrico teve início aquando do primeiro choque petrolífero, nos EUA com a publicação em 1978 da *Public Utility Regulatory Polocies Act* (PURPA).

O *Energy Policy Act* de 1992 desencadeou nos EUA uma profunda restruturação do setor elétrico e das empresas concessionárias (*utilities*). Trazendo ainda uma revisão do PURPA.

A restruturação no sentido da liberalização na Europa iniciou-se na Grã-Bretanha, em 1983 com o *Energy Act*, sendo criado posteriormente um mercado grossista e

obrigatório (*pool*) que entrou em atividade em 1990. Este modelo veio a ser alterado com a criação do *New Electricity Traiding Arrangements* (NETA), em 2001, que eliminou a *pool* obrigatória, permitindo a contratação bilateral entre produtores e consumidores [1].

Foi constituído o *NordPool*, em 1996, agregando a Noruega e a Suécia, posteriormente ampliado à Finlândia e à Dinamarca.

Em Espanha, foi em 1997 aprovada pelas *Cortes a Ley del Sector Eléctrico*, para vigorar a partir de Janeiro de 1998. Esta lei consagrou uma profunda restruturação, tendo por base a criação de um mercado grossista, a liberdade de escolha dos consumidores e o acesso livre de terceiros às redes.

O foco mais importante é em Portugal, pois é neste mercado que este trabalho se insere. Em 1988 foi aberto o setor elétrico com a publicação do Decreto de Lei nº 189/88, que permitiu a produção independente usando fontes renováveis ou cogeração. Em 1995, foi publicado um pacote legislativo (Decreto de Leis nº 182/95 a 188/95) que estabeleceu um novo modelo organizacional do setor elétrico.

Este novo modelo instituído procede à reformulação da constituição institucional, mas mantendo a coexistência de dois subsistemas dentro do Sistema Elétrico Nacional. Estes dois subsistemas são designados por Sistema Elétrico de Serviço Público (SEP), cuja organização tem em vista a prestação de um serviço público, e por Sistema Elétrico Independente (SEI), organizado segundo uma lógica de mercado SENV [2].

A Eletricidade de Portugal (EDP) foi também reorganizada e parcialmente privatizada levando à sua desintegração vertical, dando origem a empresas vocacionadas exclusivamente a cada uma das atividades de produção, transporte ou distribuição de energia [1] [3].

Outro aspeto importante foi a criação da Entidade Reguladora do Setor Elétrico, atualmente denominada de Entidade Reguladora dos Serviços Energéticos (ERSE), com um estatuto de independência em relação ao poder político e à indústria de energia elétrica, à qual foram atribuídas competências que incluem a elaboração de regulamento, a fixação de tarifários e a definição dos níveis de abertura do setor, entre outras.

A seguinte Figura 2.2 ilustra a organização do sistema elétrico nacional em Portugal de acordo com a legislação instaurada em 1995, vigorando até 2006.

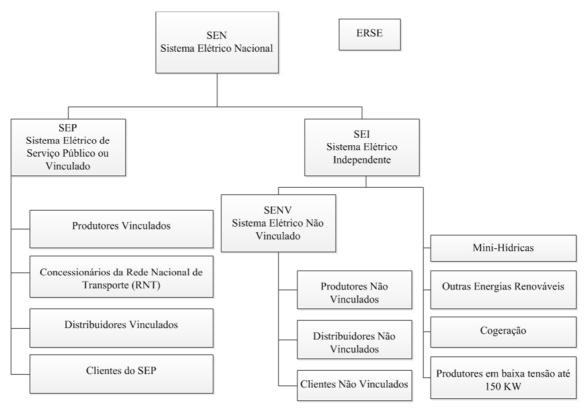


Figura 2.2 - Organização do Sistema Elétrico Nacional em 1995

Em 2005, a resolução do Conselho de Ministros nº 169/2005 aprovou a estratégia nacional para a energia com o principal objetivo de aprofundar a liberalização do SEN iniciada em 1995, que promove uma maior concorrência nos mercados energéticos através da alteração dos respetivos enquadramentos estruturais. O Decreto-Lei n.º 29/2006 concretiza aquela estratégia estabelecendo as novas bases em que assenta a organização do SEN [4] [5].

Nas legislações do Decreto de Lei nº 172/2006 e do Decreto de Lei nº 264/2007, são estabelecidos os princípios de organização e funcionamento do SEN, assim como as regras gerais aplicáveis ao exercício das atividades de produção, transporte, distribuição e comercialização, tendo ainda, a organização dos mercados de eletricidade com a implementação de uma nova etapa na concretização e aprofundamento do Mercado Ibérico de Eletricidade (MIBEL). Desta forma, ficam transpostos para a legislação nacional os princípios da Diretiva nº 2003/54/CE, do Parlamento Europeu e do Conselho, que tinha como objetivo a criação de um mercado livre e concorrencial na área da energia [6] [7] [8].

A nova estrutura do SEN estabelece um sistema integrado, em que as atividades de produção e comercialização são executadas em regime de livre concorrência, mediante a

atribuição de licenças, enquanto as atividades de transporte e distribuição são exercidas mediante a atribuição de concessões de serviço público. [4]

O exercer destas atividades tem em vista a racionalização dos meios a utilizar e a proteção do ambiente, particularmente através da eficiência energética e do incentivo para as energias renováveis, sem prejuízo das obrigações de serviço público. [4]

O sistema elétrico pode ser sintetizado através de uma cadeia de valor, que está representada na seguinte Figura 2.3.

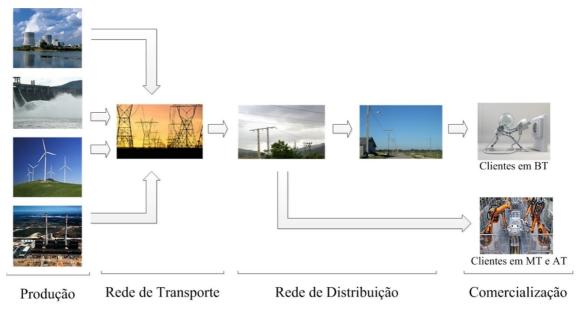


Figura 2.3 - Cadeia de Valor do Setor Elétrico

A produção de eletricidade está classificada de duas formas distintas. A Produção em Regime Ordinário (PRO), que está inerente à produção de eletricidade com base em fontes tradicionais não renováveis e em grandes centros electroprodutores hídricos. Por outro lado, a Produção em Regime Especial (PRE), que é relativa à cogeração e à produção elétrica a partir da utilização de fontes de energia renováveis. [4]

No que diz respeito à atividade do transporte, é praticada mediante a exploração da Rede Nacional de Transporte (RNT), a que corresponde uma única concessão exercida em exclusivo e em regime de serviço público.

Atentando que a rede nacional de transporte assume um papel crucial no sistema elétrico nacional, a sua exploração integra a função de gestão técnica global do sistema, assegurando a coordenação sistémica das instalações de produção e de distribuição, tendo em vista a continuidade e a segurança do abastecimento e o funcionamento integrado e eficiente do sistema (exercício de operador de sistema) [4]. A

concessionária da RNT relaciona-se comercialmente com os utilizadores das respetivas redes, tendo direito a receber, pela utilização destas e pela prestação dos serviços inerentes, uma retribuição por aplicação de tarifas reguladas.

A distribuição de eletricidade processa-se através da exploração da Rede Nacional de Distribuição (RND). Esta rede é explorada mediante uma única concessão do Estado, exercida em exclusivo e em regime de serviço público [4].

As competências fundamentais da entidade concessionária da RND incluem a exploração e manutenção da rede de distribuição em condições de segurança, fiabilidade e qualidade de serviço, assim como gerir os fluxos de eletricidade na rede, assegurando a sua interoperacionalidade com as redes a que esteja ligada e com as instalações dos clientes, no quadro da gestão técnica global do sistema (exercício de operador da rede de distribuição) [4].

Ainda, a atividade de comercialização de eletricidade é livre, ficando, contudo, sujeita a atribuição de licença pela entidade administrativa competente onde se esclarece o elenco dos direitos e dos deveres na perspetiva de um exercício transparente da atividade. No exercício da sua atividade, os comercializadores podem livremente comprar e vender eletricidade, tendo o direito de acesso às redes de transporte e de distribuição, contudo, mediante o pagamento de tarifas reguladas. Desta forma os consumidores podem, nas condições do mercado, escolher livremente o seu comercializador, não sendo a mudança onerada do ponto de vista contratual.

## 2.2 Mercado Ibérico de Eletricidade (MIBEL)

No âmbito da criação do Mercado Interno de Eletricidade têm sido constituídos mercados regionais no espaço da União Europeia. Neste contexto surge a integração dos mercados de eletricidade da Península Ibérica, que consignada pelo Mercado Ibérico de Eletricidade (MIBEL), no qual se realizam transações de energia elétrica e se negoceiam instrumentos financeiros que têm como referência essa mesma energia [9].

A criação do MIBEL foi um processo de construção contínuo que envolveu os dois países em causa, sendo eles Portugal e Espanha. É de assinalar alguns momentos cruciais durante a sua criação [10].

As administrações portuguesas e espanholas iniciaram em 1998 conversações e estudos para, progressivamente, eliminarem obstáculos e favorecerem a criação do MIBEL. Para esse fim, em 29 de Julho de 1998 foi assinado um Memorando de Acordo entre o Ministério da Economia da Republica de Portugal e o Ministério da Indústria e Energia do Reinado de Espanha para a cooperação em matéria de energia elétrica. [11]

A 14 de Novembro de 2001 foi assinado, em Madrid, o Protocolo de Colaboração entre as Administrações Espanhola e Portuguesa com o objetivo de estabelecer as medidas necessárias para a criação do Mercado Ibérico de Eletricidade, sendo estabelecido que no dia 1 de Janeiro de 2003 se daria o início de funcionamento do MIBEL. Ainda definido neste Protocolo de modo a favorecer o desenvolvimento do MIBEL o reforço das interligações elétricas entre Portugal e Espanha, nomeadamente a construção e entrada em serviço das linhas ALQUEVA-BALBOA (2004) e CEDILLO-ORIOL, a instalação de um segundo circuito na linha CARTELLE-LINDOSO (2006) de modo a aumentar a sua fiabilidade e ainda o reforço da capacidade de interligação no Douro Internacional (2006).

Em Outubro de 2002, em Valência na XVIII Cimeira Luso-Espanhola, ficou decidido o modelo de organização do MIBEL, assente na existência do Operador de Mercado Ibérico (OMI) e foram estabelecidas as principais metas de concretização do MIBEL. As conclusões dessa cimeira permitiam prefigurar a construção do MIBEL como uma abordagem intermédia regional do processo de integração dos mercados nacionais num mercado único europeu, segundo um modelo de construção faseada, assente em três eixos principais: [12]

- Estabelecimento de uma plataforma física de suporte do mercado regional ibérico, apoiada no desenvolvimento das infraestruturas de transporte e na articulação da planificação energética e das redes de transporte;
- Harmonização dos enquadramentos legais e regulatórios das condições económicas de participação no MIBEL e dos procedimentos de operação dos sistemas;
- Harmonização das condições económicas de participação no mercado, através da convergência das metodologias de definição das tarifas, dos custos de transição para a concorrência, das condições de acesso às interligações, do grau de abertura dos mercados e da criação de um Operador de Mercado Ibérico (OMI).

- Os Governos de Portugal e Espanha acordaram, ainda, que, durante o período transitório anterior à constituição do OMI, a gestão dos mercados organizados do MIBEL assentaria numa estrutura bipolar interligada, na qual:
  - A gestão do mercado diário e intra-diário seria competência do polo espanhol designado por OMIE;
  - A gestão dos mercados a prazo seria competência do polo português designado por OMIP.

No dia 1 de Outubro de 2004, em Santiago de Compostela, foi celebrado o último acordo entre a República Portuguesa e o Reino de Espanha relativo à Constituição do MIBEL que prevê que o seu funcionamento se iniciará antes de 30 de Junho de 2005 [9] [13].

Neste acordo, a organização dos mercados de contratação de energia elétrica está estabelecida pelo artigo 6°, sendo estes divididos em mercados organizados, mercados não organizados e serviços de ajuste, de acordo com a seguinte descrição [13] [9]:

#### Mercados organizados

- a) Mercados a prazo, que compreendem as transações referentes a blocos de energia com entrega posterior ao dia seguinte da contratação, de liquidação quer por entrega física, quer por diferenças [9] [13];
- b) Mercados diários, que compreendem as transações referentes a blocos de energia com entrega no dia seguinte ao da contratação, de liquidação necessariamente por entrega física [9] [13];
- c) Mercado intra-diário, de liquidação necessariamente por entrega física [9] [13].

#### • Mercados não organizados

Compostos por contratos bilaterais entre as entidades do MIBEL, de liquidação tanto por entrega física como por diferenças [9] [13].

#### • Serviços de ajuste

A contratação dos serviços de ajuste do sistema no próprio dia poderá ser realizada através de mecanismos de mercado, a definir por cada operador de sistema, e a sua liquidação será necessariamente por entrega física [9] [13].

Em Novembro de 2006, foi realizada a XXII.ª Cimeira Luso-Espanhola de Badajoz, os dois Governos reafirmaram o seu empenho no aprofundamento do Mercado Ibérico de Eletricidade (MIBEL), tendo como principal objetivo implementar até ao final do 1°

Trimestre de 2007 o mercado à vista de âmbito ibérico, através de um mecanismo coordenado de gestão das interligações baseado em *market splitting* e leilões explícitos conforme proposto pelo Conselho de Reguladores. [14]

Com a concretização do MIBEL, este arrancou em toda a sua extensão no dia 1 de Julho de 2007, honrando o trabalho de harmonização de condições entre os dois sistemas elétricos nacionais de Portugal e Espanha, numa perspetiva de que do seu funcionamento originariam benefícios para os consumidores de ambos os países. Passou a ser possível, a qualquer consumidor no espaço ibérico, adquirir energia elétrica, num regime de livre concorrência, a qualquer produtor ou comercializador que atue em Portugal ou Espanha. Tudo num panorama de garantia do acesso a todos os interessados em condições de igualdade, transparência e objetividade.

#### O MIBEL tem como principais metas:

- Beneficiar os consumidores de eletricidade dos dois países, através do processo de integração dos respetivos sistemas elétricos;
- Estruturar o funcionamento do mercado com base nos princípios da transparência, livre concorrência, objetividade, liquidez, autofinanciamento e auto-organização;
- Favorecer o desenvolvimento do mercado de eletricidade de ambos os países, com a existência de uma metodologia única e integrada, para toda a península ibérica, de definição dos preços de referência;
- Permitir a todos os participantes o livre acesso ao mercado, em condições de igualdade de direitos e obrigações, transparência e objetividade;
- Favorecer a eficiência económica das empresas do sector elétrico, promovendo a livre concorrência entre as mesmas. [10]

A liberalização do sector elétrico veio acrescentar a existência de mercados organizados, que se constituem como plataformas de negociação tendencialmente independentes dos agentes tradicionais que atuam nas atividades de produção e de comercialização de eletricidade. A contratação de eletricidade é efetuada de várias formas, desde a contratação para o dia seguinte (mercado diário), para prazos mais longos (mercado a prazo) ou de forma bilateral e/ou através de mecanismos legais ou regulamentares específicos.

#### Mercado Diário

No mercado diário do MIBEL, a energia elétrica é transacionada de modo a que seja entregue e satisfeita a procura do dia seguinte ao da negociação. Neste mercado o preço é formado para cada uma das 24h de cada dia, ao longo de todo o ano.

Neste mercado é estabelecido o preço e a quantidade correspondente a cada oferta horária do dia seguinte pelos agentes registados para atuar no mercado. [15]

As ofertas efetuadas no mercado são de dois tipos, as ofertas de venda e as ofertas de compra, que correspondem às chamadas curva de oferta e curva de procura respetivamente. Com estas ofertas é encontrado o preço de mercado, através de um processo em que se ordenam de forma crescente em preço as ofertas de venda e de forma decrescente em preço as ofertas de compra de eletricidade para uma mesma hora, sendo estabelecido pelo encontro do menor preço que garante a satisfação da procura pela oferta como ilustrado na Figura 2.4

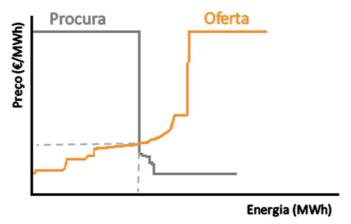


Figura 2.4 - Oferta e procura de energia elétrica no mercado diário [15]

Neste mercado diário todos os compradores pagam o mesmo preço e todos os produtores recebem esse mesmo preço, independentemente do tipo de produção de que disponham, incorrendo assim num modelo de preço marginal único [15].

Assim, pelas regras impostas do funcionamento do mercado, os produtores que façam ofertas de energia elétrica a um preço mais elevado recebem por elas o preço marginal formado mesmo sendo a sua oferta superior, sucedendo analogamente ao caso dos compradores que efetuaram ofertas de compra a um preço mais elevado estes pagam o preço marginal mesmo sendo a sua oferta superior [15].

Outro aspeto importante é o fato de o mercado envolver Portugal e Espanha, e poderem ocorrer certos momentos do dia em que a capacidade de interligação seja insuficiente,

ou seja, excede a sua capacidade, sendo necessário a existência de uma divisão do mercado (designada por *market splitting*) operando cada um dos países individualmente nessas alturas sendo encontrados preços específicos para cada um deles, como ilustrado na Figura 2.5 [15].

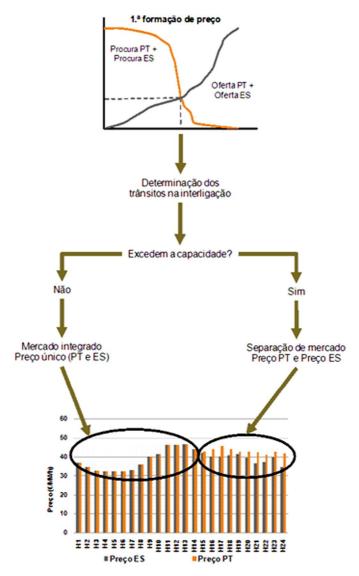


Figura 2.5 - Mercado Diário, exemplo de Market Splitting [15]

O mercado intradiário do MIBEL é uma plataforma complementar ao mercado diário, onde se efetuam transações de eletricidade de forma a realizar ajustes do mercado diário, existindo seis sessões por dia de negociação como ilustrado na Figura 2.6. Cada uma das sessões de mercado intradiário forma preço para as horas objeto de negociação em cada sessão, sendo o seu funcionamento igual ao mercado diário [15].

# ### Recedo intradiário | 1.º mercedo intradiário | 26 hrs | | 2.º mercedo intradiário | 26 hrs | | 3.º mercedo intradiário | 20 hrs | | 4.º mercedo intradiário | 17 hrs | | 5.º mercedo intradiário | 13 hrs | | 6.º mercedo intradiário | 2 hrs | | 6.º mercedo intradiário | 2 hrs | | 7.º mercedo intradiário | 17 hrs | | 8.º mercedo intradiário | 2 hrs | | 9.º mercedo intradiário | 2 hrs | | 9.º mercedo intradiário | 2 hrs | | 1.º mercedo intradiário | 2 hrs |

Figura 2.6 - Mercados Intradiários [15]

#### Mercado a Prazo

O mercado a prazo de eletricidade é um mercado organizado que oferece instrumentos de gestão de risco sob a forma de derivados. O principal objetivo do mercado a prazo é o estabelecimento de contratos de compra e venda de energia elétrica a longo prazo (semana, mês, trimestre, e ano) seguindo as regras específicas do mercado [15].

A entidade responsável pela gestão deste mercado é o OMIP, onde se disponibiliza os seguintes instrumentos para estabelecimento dos contratos:

- Contratos Futuro – são contratos de compra ou venda de energia para um determinado horizonte temporal, em que o comprador se compromete a adquirir eletricidade num dado período de entrega e o vendedor se compromete a colocar essa mesma eletricidade, a um preço determinado no momento da transação [15].

Os ganhos e perdas diários resultantes das oscilações de preços entre o preço de transação e a cotação de mercado durante o período de negociações são liquidados numa base diária com a responsabilidade da câmara de compensação [15].

- Contratos *Forward* estes contratos são semelhantes aos contratos Futuro, divergindo apenas na forma de liquidação dos ganhos e perdas, sendo que nestes contratos não existem liquidações diárias das margens durante o período de negociação, sendo a margem liquidada integralmente nos dias de entrega física ou financeira [15].
- Contratos *SWAP* contratos em que se efetua a troca de posição em preço variável por uma posição de preço fixo, ou vice-versa, dependendo do sentido da troca. Estes contratos têm o sentido de fazer a gestão ou toma de risco financeiro, não havendo

entrega física do produto a que se referem, mas apenas a liquidação das margens correspondentes [15].

#### Estabelecimento de Contratos

No atual quadro de desenvolvimento do MIBEL o funcionamento do mercado grossista de eletricidade assenta na existência de um conjunto de modalidades de contratação que se complementa, sendo estes [15]:

- Mercado de contratação a prazo, que consiste no estabelecimento de compromissos a futuro de produção e de compra de energia elétrica permitindo efetuar liquidação física (entrega da energia) ou liquidação financeira (compensação dos valores monetários subjacentes à negociação) [15];
- Mercado de contratação à vista, que consiste no estabelecimento de programas de venda e de compra de energia elétrica para o dia seguinte ao da negociação, integrando uma componente de contratação diária e uma de ajustes intradiários [15];
- Mercado de serviços de sistema, com funcionamento em tempo real, que efetua o ajustamento de equilíbrio da produção e do consumo de eletricidade [15];
- Mercado de contratação bilateral, em que os agentes de mercado estabelecem contratos de compra e venda de eletricidade para diversos horizontes temporais [15].

Outro aspeto importante a considerar, no atual enquadramento legal e regulamentar, é a energia produzida pela produção em regime especial (PRE) que é totalmente adquirida pelo comercializador de último recurso (CUR), função desempenhada pela EDP Serviço Universal, que faz ajustes relativamente às necessidades de procura no mercado grossista deduzindo a produção expetável em regime especial [15].

#### **Envolvente de Mercado**

Em Portugal o Parque Electroprodutor é constituído por diversas tecnologias de produção, às quais estão associados diferentes custos. Dessa forma o consumo é satisfeito por energia produzida por vários produtores, tendo um grande reflexo no preço pago pelos consumidores nomeadamente devido aos custos de produção. Outros fatores com grande influência no preço da energia elétrica, são os preços e as condições das fontes de energia primária, o regime hidrológico e ainda o mercado de licenças de emissão de CO<sub>2</sub> [15].

A maior parte da eletricidade produzida em Portugal é proveniente de centrais térmicas, nomeadamente de centrais a carvão, gás natural e fuel, que dependem integralmente da importação destes combustíveis fósseis. Portugal apresenta uma grande dependência das centrais hidrolétricas mais do que acontece, por exemplo, em Espanha. Dessa forma, Portugal está sujeito à volatilidade dos preços dos mercados internacionais de energia primária, sendo a formação dos preços de eletricidade no mercado grossista influenciada de forma decisiva, quer aqueles preços aumentem ou diminuam [15].

#### Mercado Retalhista

Inerente ao desenvolvimento do processo de liberalização do setor elétrico ditou a abertura da comercialização ao mercado, sendo dada a liberdade aos consumidores de escolher livremente o seu fornecedor de eletricidade.

A evolução do mercado retalhista é condicionada ao comportamento do mercado grossista, nomeadamente no que diz respeito ao preço da eletricidade, devido a ser neste último onde é determinada uma grande parcela dos custos totais do fornecimento de eletricidade. Os custos de energia são um constituinte fundamental na liberalização do mercado de eletricidade, sendo que é a única parcela negociável entre fornecedor e consumidor, visto os restantes custos (entre eles, custos de utilização e o acesso às infraestruturas nomeadamente as redes) serem regulados e impostos em qualquer regime de mercado sendo iguais para todos os consumidores nas mesmas condições [15].

#### 2.3 Tarifas e Custos da Energia Elétrica

A eletricidade até chegar ao consumidor final tem um enorme percurso que passa pela sua produção, pelo seu transporte, distribuição e por último a comercialização. A cada uma destas atividades estão associados custos que dão origem às tarifas definidas e publicadas anualmente pela ERSE, de acordo com o estabelecido no Regulamento Tarifário [15] [16].

As tarifas são estabelecidas por forma a proporcionar a cada atividade um montante de proveitos calculados de acordo com as fórmulas constantes no Regulamento Tarifário. As várias tarifas que visam remunerar as entidades afetas à produção, transporte, distribuição e comercialização de energia elétrica, são [15] [16]:

Tarifa de Uso Global do Sistema, deve proporcionar os proveitos da atividade de Gestão Global do Sistema, integrando os custos com a operação do sistema, os custos decorrentes de medidas de política energética, ambiental ou de interesse económico geral e os custos para a manutenção do equilíbrio contratual (CMEC) [15] [16].

**Tarifa de Uso da Rede de Transporte**, deve proporcionar os proveitos da atividade de Transporte de Energia Elétrica que inclui o estabelecimento, operação e manutenção das redes de transporte em MAT e das interligações [15] [16].

Tarifa de Uso das Redes de Distribuição em Alta e Média Tensão, deve proporcionar os proveitos das atividades reguladas de distribuição de energia elétrica em AT e MT correspondentes ao planeamento, estabelecimento, operação e manutenção das redes de distribuição, de forma a veicular a energia elétrica até aos clientes finais. De forma análoga, a Tarifa de Uso da Rede de Distribuição em Baixa Tensão permite recuperar os custos da atividade regulada de distribuição de eletricidade em BT [15] [16].

**Tarifa de Energia**, tem o objetivo de recuperar os custos com a atividade de compra e venda de energia elétrica dos comerciantes de último recurso (CUR), incluindo os custos de aquisição de energia elétrica para fornecimento dos clientes e os custos de funcionamento associados [15] [16].

**Tarifa de Comercialização**, deve proporcionar ao CUR os proveitos da atividade regulada de comercialização, englobando as estruturas comerciais de venda de energia elétrica aos seus clientes, nomeadamente a contratação, faturação e serviço de cobrança de eletricidade [15] [16].

- As Tarifas de Acesso às redes englobam as tarifas de Uso Global do Sistema,
   Uso da Rede de Transporte e Uso da Rede de Distribuição, pagas por todos os consumidores de energia elétrica no Mercado Regulado ou Mercado Livre, integrando-se nas tarifas de venda dos vários comercializadores.
- As Tarifas de Venda a Clientes Finais do comercializador de último recurso são o resultado da soma dos preços da Tarifa de Acesso às Redes, Tarifa de Energia e da Tarifa de Comercialização, aplicadas apenas aos consumidores no Mercado Regulado.

Outro aspeto importante de referir é que os comercializadores no Mercado Livre negociam os preços da componente de energia com os seus clientes, enquanto no

Mercado Regulado estes mesmos preços estão integrados nas Tarifas de Venda a Clientes Finais.

#### **Mercado Livre**

Segundo o que foi descrito anteriormente é possível descrever a estrutura que constitui os preços imputados no Mercado Livre, conforme descrito na Figura 2.7.

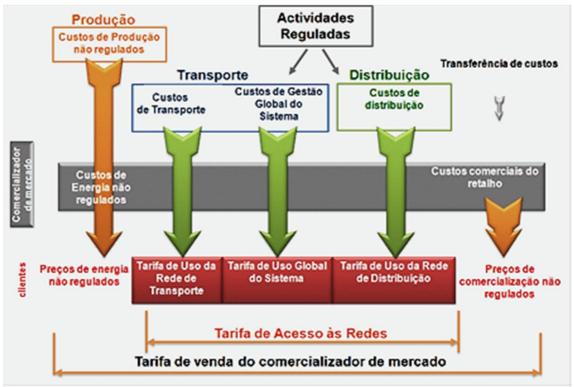


Figura 2.7 - Estrutura dos Preços no Mercado Livre [17]

Neste regime de mercado a energia elétrica é negociada entre o comercializador de mercado livre e o consumidor, resultando neste mercado o produto final que é o Preço de Venda a Clientes. A comercialização é aberta à concorrência e os comercializadores podem comprar e vender eletricidade livremente. Contudo sujeitos ao pagamento das tarifas de acesso às redes, dando o direito de aceder às mesmas, existindo este valor com o intuito de garantir a recuperação de custos assumidos pelas entidades responsáveis pelo Transporte e Distribuição [15] [16].

Nesta estrutura de mercado os consumidores são livres de escolher o seu fornecedor, estando este sujeito a uma série de obrigações de serviço público, ficando com o direito a que seja garantida a qualidade e continuidade do fornecimento, assim como a proteção do consumidor [15] [16].

#### Mercado Regulado

Da mesma forma, é possível descrever a estrutura de preços praticados no Mercado Regulado, conforme apresentado na Figura 2.8.

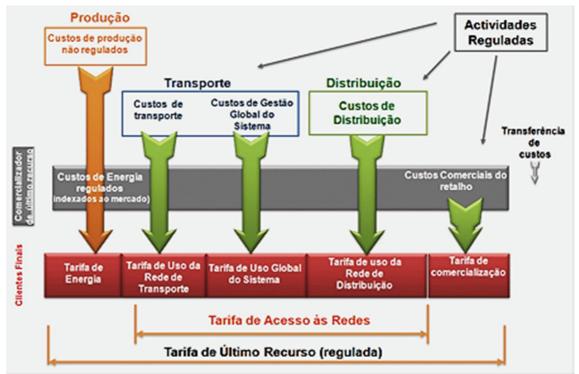


Figura 2.8- Estrutura das Tarifas no Mercado Regulado [17]

No Mercado Regulado são estabelecidos contratos com os produtores de energia elétrica, podendo ser contratos de aquisição de energia elétrica (CAE) ou contratos remunerados pelos atuais custos de manutenção do equilíbrio contratual (CMEC). Estes contratos dão a garantia da cobertura dos custos fixos e variáveis em que incorrem da atividade de produção de energia elétrica, sendo diluídos na Tarifa de Venda a Clientes Finais (TVCF). Assim os preços praticados no Mercado Regulado correspondem às tarifas transitórias de Venda a Clientes Finais aprovadas pela ERSE, calculadas, somando as tarifas de Acesso às Redes com as tarifas transitórias de Energia e de Comercialização [15] [16].

O comercializador de último recurso é, atualmente, obrigado a comprar energia a prazo nos mercados organizados pelo OMIP e pela Sociedade de Compensação de Mercados de Energia, S. A. (OMIClear), correspondente à necessidade de abastecimento dos seus consumidores, tendo ainda obrigação de compra da energia produzida pelos produtores em regime especial (PRE) [15] [16].

Dado que a recuperação dos custos está associada à disponibilidade e oferta de energia pelos produtores, se esta energia é produzida alternativamente pelos PRE sem necessidade de recurso ao regime convencional, fica comprometido o cumprimento das obrigações financeiras assumidas pelo investidor/electroprodutor. Logo é essencial o estabelecimento de condições contratuais que permitam a recuperação dos encargos das centrais produtoras de energia elétrica [15] [16].

## Capítulo 3

### MODELOS DE PREVISÃO

A grande dificuldade do homem em interpretar grandes conjuntos de dados levou grandes mentes em todo o mundo a estudar esta problemática. Ao longo dos tempos, surgiram grandes evoluções especificamente no ramo da matemática sobre o estudo da estatística como forma de resolver problemas deste tipo. Neste capítulo é abordado o conceito de previsão, assim como vários tipos de modelos de previsão. É ainda realizada uma abordagem à literatura existente acerca da previsão, e dos modelos adequados para a previsão do preço de mercado da energia elétrica.

#### 3 Modelos de Previsão

#### 3.1 Enquadramento e Previsão

Prever o futuro é um desejo tão antigo quanto a própria humanidade. A preocupação com o futuro é uma função biológica que leva o homem a preocupar-se em conhecê-lo. Ao longo da história da humanidade, as previsões eram efetuadas pelos profetas, astrólogos, bruxos, adivinhos entre outros. Nos dias que correm, poucos acreditam que a melhor maneira de prever o futuro esteja na "posição das estrelas" ou no "estudo da palma da mão". Dessa forma a superstição deu lugar à racionalidade e o estudo das previsões tornou-se muito mais científico.

A chamada "Previsão moderna" teve início em 1927, quando *Yule* apresentou técnicas autorregressivas para prever o número anual de manchas solares. Este modelo baseavase na soma ponderada de dados históricos [18]. Nos cinquenta anos que se seguiram, este modelo foi muito utilizado até que a pesquisa culminou na metodologia ARIMA desenvolvida por *Box and Jenkins* em 1970. Desde então, vários estudos de previsão foram baseados em séries não estacionárias e séries não lineares [18].

Nos anos 80, o desenvolvimento das tecnologias associadas aos computadores pessoais e todo esse setor, permitiu que séries temporais muito mais complicadas e extensas pudessem ser analisadas. A simplicidade com que, nos dias de hoje, se pode analisar uma série temporal é incomparável com o que era possível realizar à apenas alguns anos atrás. Juntamente com o aparecimento de novas tecnologias computacionais e a sua expansão no mercado mundial, surgiu o conceito de Inteligência Artificial, em que se procura reproduzir o pensamento humano através das máquinas. Através deste conceito surgiu o desenvolvimento de Sistemas de Inteligência Computacional, técnicas computacionais de aprendizagem, que se baseiam na evolução da vida biológica.

A previsão no âmbito deste trabalho foca-se na previsão do preço de mercado da energia elétrica num curto prazo. Sendo que anteriormente ao processo de reestruturação e de liberalização do sector elétrico, as variações nas tarifas de energia elétrica eram, na maior parte das situações, ínfimas e muito controladas pelo estado ou entidades reguladoras. Dessa forma, a evolução dos preços estava fortemente condicionada pelas políticas sociais e industriais dos governos, e a previsão da evolução dos preços estava essencialmente focada nos custos subjacentes, ou seja, nos preços dos combustíveis e na

evolução tecnológica. Eram efetuadas previsões para a evolução dos preços da energia elétrica, mas na sua maioria só numa base de longo prazo.

Com a reestruturação e a correspondente abertura à livre competição dos mercados de energia elétrica, os ativos, na sua maioria ou na totalidade propriedade do estado, foram privatizados e a energia passou a ser transacionada em bolsas (Pool) ou em mercados organizados [19]. No entanto, devido à necessidade de manter o sistema em constante equilíbrio, fatores como a reduzida elasticidade da procura, a incerteza associada ao preço dos combustíveis, a disponibilidade da produção e as restrições técnicas do sistema condicionam a formação do preço em mercados sujeitos à livre competição e estão na base da elevada volatilidade exibida pelos mesmos [20] [21]. No entanto, a estrutura e a gestão das regras que regem o funcionamento dos mercados de energia elétrica podem também introduzir outras fontes de incerteza [22].

Com a elevada volatilidade dos preços da energia elétrica, os produtores da mesma estão sujeitos a um risco que advém do preço porque vendem a energia a preços variáveis e definidos em *pool*, enquanto o preço dos combustíveis e outros podem não variar. Por outro lado, os distribuidores/retalhistas estão também expostos a um risco de preço, uma vez que compram a energia a preços variáveis e estabelecidos em pool e a fornecem aos seus clientes na sua maioria com tarifas anuais fixas. Os riscos dos produtores de energia elétrica, relativamente aos dos retalhistas, são usualmente menores, pois, se os preços definidos em pool forem demasiado baixos, os produtores podem decidir não produzir. No caso dos distribuidores/retalhistas, na circunstância dos preços em pool serem elevados, só poderão interromper o fornecimento de energia aos clientes com quem possuem contratos de interruptibilidade.

Tendo em conta essa realidade, os produtores e os consumidores podem adaptar as suas estratégias de venda e compra de energia elétrica, respetivamente, recorrendo a previsões para o preço de mercado. Portanto se um produtor possuir boas previsões do preço de curto prazo (por exemplo, para o dia ou semana seguinte, que se insere no âmbito deste trabalho), poderá utilizar essa informação para delinear uma estratégia para a realização de ofertas de venda no mercado com o objetivo de maximizar os seus resultados [23]. Similarmente, se os consumidores tiverem à sua disposição boas previsões para o preço de mercado do dia seguinte, poderão definir um plano que lhes permita minimizar os custos decorrentes do consumo da energia e poderão, se

possuírem produção própria, tirar partido dessa informação para se protegerem dos preços elevados em *pool* [23] [24].

Além da definição de estratégias e planos de atuação no mercado, os agentes de mercados de energia elétrica são diariamente confrontados com a necessidade de tomar várias decisões. Decisões que são sempre difíceis e são influenciadas por diversos fatores, sendo na sua maioria decisões de investimento [25]. Fatores como a sensibilidade e perspicácia do investidor, o comportamento do investimento, as limitações psicológicas e até a envolvente económica e política do país estão na base do condicionamento desse tipo de decisões. No entanto, o risco derivado da elevada volatilidade dos preços em mercado é considerável, acabando mesmo por se transformar num dos fatores que introduz maiores preocupações aos participantes do mercado de energia elétrica. Aqui a previsão do preço torna-se essencial, quer para a definição das estratégias como também para o desenvolvimento das capacidades de negociação.

No caso da previsão a médio e longo prazo (é considerado de seis meses a um ano), se forem efetuadas boas previsões para o preço de mercado, os produtores poderão antecipar as suas estratégias para a constituição de um *portfolio* de contratos a prazo com os clientes e ainda antecipar a energia que deverão tentar negociar no mercado, de forma a maximizar os seus lucros. No caso dos consumidores, estes também podem ponderar as suas decisões para efetuar a compra de energia através de contratos ou através do mercado [23].

#### 3.2 Literatura em Previsão

Através duma análise ao exposto anteriormente, a previsão de preço no mercado de energia elétrica torna-se como uma ferramenta de grande importância. Nesse sentido, e dependendo do objetivo que se pretende obter, vários métodos utilizando diversas técnicas têm sido desenvolvidos no sentido de dar resposta às necessidades dos participantes dos mercados de energia elétrica e afins.

Em 2005, *Guang Li et all* estabelecem a classificação e posterior comparação dos diferentes métodos na literatura da previsão do preço da eletricidade. Segundo os autores, são tipicamente realizadas previsões utilizando horizontes temporais distintos, classificando-se como previsões a curto prazo, a médio prazo e longo prazo [24]. Os modelos de previsão podem ser subdivididos em modelos estatísticos e modelos não

estatísticos. Os modelos estatísticos são executados estabelecendo uma relação de entrada/saída pela utilização de sucessões cronológicas ou através da análise estatística. Já os modelos não estatísticos, referem-se a modelos que possibilitam a simulação, ou ainda modelos de análise de equilíbrio assim como a realização de simulação da operação do sistema elétrico ou a elaboração de despacho económico [24].

Os modelos estatísticos são compostos por três categorias principais, sendo os modelos de sucessões cronológicas, modelos econométricos e sistemas inteligentes. Usualmente as aplicações dos modelos estatísticos na eletricidade centram-se na previsão do preço de fecho de mercado, desiganado por *Market Clearing Price* (MCP), e nas suas propriedades estatísticas como por exemplo os intervalos de confiança, designados por *Confidence Interval* (CFDI), e a volatilidade do MCP, designado por *Volatility* (VOLA) [24].

G. Koroneff et all, propõe um método de previsão de preços na Finlândia como parte integrante de um sistema de gestão de energia, ou Electrical Management System (EMS). Nesse método são determinados dias similares dos dados históricos através da sua separação em três categorias: dias úteis, feriados e fins de semana. Depois para cada categoria é efetuada uma separação dos dados em função das estações do ano a que pertencem. Por fim, face às previsões da temperatura é efetuada uma análise regressiva para conjuntos de períodos horários distintos, isto é, das 06:00 às 22:00 e das 22:00 às 06:00 [26].

Dentro dos modelos regressivos podemos encontrar na literatura modelos baseados nos processos *Auto Regressive Integrated Moving Average* (ARIMA) e *Auto Regressive Conditional Heteroskedastic* (GARCH) para a previsão de preços de curto prazo (dia seguinte) no mercado elétrico de Espanha e da Califórnia [27] [28]. Ainda com modelos ARIMA, *T. Jakaša et all* centram-se na previsão do preço da eletricidade para o dia seguinte no mercado EPEX Spot (mercado de energia para Alemanha, França, Áustria e Suíça) tendo ainda como grande objetivo definir o melhor ajuste do modelo ARIMA para a previsão [25].

Outra literatura no âmbito da previsão do preço apresenta a comparação entre modelos autorregressivos (AR), semiparamétricos e com inovações não paramétricos, para a previsão do preço a curto prazo (dia seguinte) para o mercado de energia na Califórnia, com a introdução de uma nova variável na previsão sendo ela a temperatura do ar [29].

No mercado Espanhol, *F. Weron e A. Misiorek* elaboram a previsão do preço da eletricidade para o dia seguinte e uma média mensal. Através de modelos *Seasonal Auto Regressive Integrated Moving Average* (SARIMA) e Generalized Auto Regressive Conditional Heteroskedastic (GARCH) é feita a previsão para o dia seguinte. Na previsão do preço médio mensal são utilizados modelos de séries temporais e Generalized Least Squares (GLS) com auto-correlação de erros [30].

Em 2009, *C. Herui e Y. Li* implementam um novo método para a previsão, abordando a previsão de curto prazo do preço da energia elétrica, designado por *fractal theory*. Esta teoria tem na sua base dados não regulares e não lineares, elaborando um estudo sobre a regularidade, hierarquia e invariância dos dados inerentes ao fenômeno natural e ao complexo social, cruzando a ciência natural, social e do pensamento. Com base na autosimilaridade entre parte e todo, a *fractal theory* estabelece a propriedade global da parte, ao longo da direção de microscópico a macroscópica. Esta teoria leva a relação entre regional e global como objeto de pesquisa, enfatiza a dependência global da parte. Como o todo é composto pela parte, podemos entender o todo através de parte. Um dos fundamentos filosóficos *fractal theory* é que a unidade e o elemento do sistema contém a propriedade e informações de todo o sistema. Auto-similaridade e invariância de escala são a base da teoria de fractais [31].

Em Itália, *D. Menniti et all* utilizam um modelo *Mean Reverting Process* com dados históricos do preço da energia elétrica no mercado Italiano para efetuar a previsão do preço da energia elétrica do dia seguinte [23]. Outra abordagem em Itália, com o objetivo de melhorar a precisão da previsão de preços de eletricidade no dia seguinte, *D. Menniti et all* elabora um modelo através de *Artificial Neural Networks* (ANNs) [32].

Noutra literatura com o mesmo tema proposto, *T. Jónsson et all* elaboram uma metodologia de duas etapas para a previsão de preço de energia elétrica na Dinamarca pertencente à *Elspot Nord Pool*, introduzindo duas novas variáveis no mesmo modelo para verificar o seu impacto na previsão do preço, sendo as variáveis a carga prevista e a produção de energia eólica. As duas etapas passam por em primeiro lugar, por uma análise da influencia não linear e não estacionária das variáveis com base num modelo de regressão não paramétrico e de tempo variável. Uma segunda etapa passa pela utilização dos modelos *Auto Regressive Moving Average* (ARMA) (que surgem da combinação de duas subfamílias, nomeadamente dos modelos de *Moving Averages* 

(MA) e de modelos *Auto Regressive* (AR)), e *Holt-Winters* nas séries de tempo para o estudo da auto-correlação residual e da dinâmica sazonal das variáveis [33].

#### 3.3 Classificação de Métodos de Previsão

A variedade de métodos de previsão é muito vasta. São muitos os constituintes que formam o processo de previsão, assim como os padrões de dados, horizonte de temporal, *inputs*, entre outros, sendo que cada autor expõe apenas os que considera mais importantes e mais adequado para o seu objetivo pretendido. Logo, a natureza da previsão diverge de área para área, de projeto para projeto. Os modelos desenvolvidos e utilizados para a previsão são os mais diversos possíveis, assim como as classificações propostas tendo em conta que estas variam segundo cada autor. Porém estes modelos em alguns aspetos apenas diferem em termos de terminologia, já em outros casos, existem divergências consideráveis [34] [35].

De uma forma geral, os métodos de previsão dividem-se em duas grandes categorias: métodos qualitativos e quantitativos. Os modelos qualitativos subdividem-se em métodos de avaliação subjetiva e exploratórios, já no que toca aos modelos quantitativos podem ser divididos em séries temporais e explicativas ou causais como ilustrado na Figura 3.1 [34] [35].

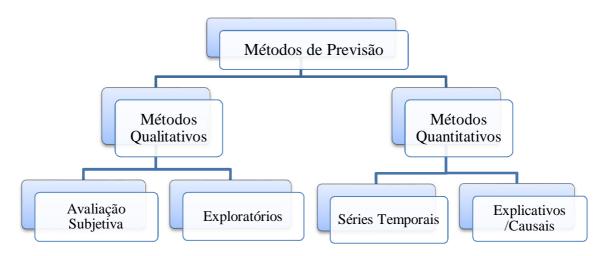


Figura 3.1 - Métodos de Previsão

#### 3.4 Métodos Qualitativos de Previsão

Os métodos qualitativos utilizam ferramentas de recolha de dados através de opiniões, inquéritos e entre outras ferramentas de questionários e opinião de especialistas, sendo normalmente utilizados em estudos de opinião, trabalhos de previsão de dados teóricos onde os valores numéricos não apresentam grande influência. Os principais métodos qualitativos são, os Métodos de Avaliação Subjetiva e os Métodos Exploratórios como ilustrado na Figura 3.2 [34] [35].

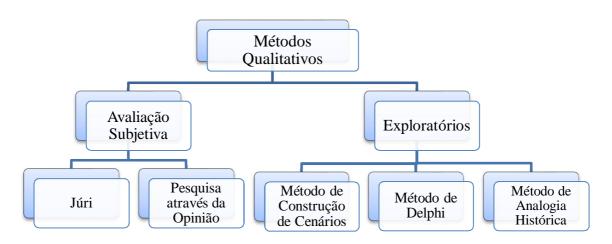


Figura 3.2 - Métodos Qualitativos

#### Métodos de Avaliação Subjetiva

#### 1. Júri

Através da recolha de opiniões de ou apreciação, as opiniões individuais de cada elemento são avaliadas e discutidas em grupo até se chegar a um consenso comum. Este método é simples e usado com frequência, mas pode induzir a erros, consequentes da subjetividade da análise. Contudo apresenta vantagens, uma vez que aglomera conhecimentos e experiências de pessoas especializadas, dado que conhecem em pormenor o que se pretende prever, por outro lado minimiza o risco de algum fator qualitativo importante que deixou de ser considerado. De uma análise geral, é um método prático, rápido e simples e torna co-responsáveis os indivíduos diretamente envolvidos na previsão.

Ao invés, este método também a apresenta desvantagens, pois pode tornar subjetiva a avaliação, pode falhar na sistematização dos dados e na sua correta ponderação. Este método deve ser usado com um complemento a outros [35].

#### 2. <u>Pesquisa através da Opinião</u>

A forma mais simples de explicitar este método é através de um exemplo. Assim, um vendedor com base nas suas expetativas de vendas é convidado a estimar as vendas para o próximo ano. O somatório das previsões de vendas dos vários vendedores fornece a estimativa global de vendas. Os vendedores são os elementos da empresa que têm maior contacto com o mercado [35].

Este método apresenta vantagens como o aproveitamento do conhecimento dos vendedores, fazendo com que os vendedores tenham mais confiança nos critérios de estabelecimento das quotas a eles atribuídas e comprometendo e responsabilizando os vendedores no cumprimento das previsões [35].

Por outro lado este método apresenta também algumas desvantagens, tal como, pode ser proposto tendências abaixo das possibilidades de vendas, para reduzir o valor da quota de vendas fixada a partir da previsão de vendas e ainda a dificuldade em se obter a objetividade adequada dos vendedores. Além disso, o vendedor tende a ter sempre uma visão de curto prazo e não de médio ou longo prazo tendo dificuldade em captar as condições atuais de mercado e da empresa, assim como suas implicações futuras [35].

#### **Métodos Exploratórios**

Os métodos exploratórios utilizam conhecimento e avaliações sobre o passado para prever o futuro. O método, como o próprio nome diz, explora variáveis e fatos através de modelos classificados em, Construção de Cenários, Matrizes *Cross-Impact*, Ajustes de Curva, Analogia, Pesquisa Morfológica e ainda Teoria de Catástrofe [35].

#### 1. Método de Construção de Cenários

Muitos autores mencionam que o método de construção de cenários não é um modelo de previsão, mas a construção de cenários pode ser perfeitamente utilizada em previsão e com uma grande vantagem, sendo ela a introdução das incertezas futuras no método. Por meio da construção de cenários é possível prever como seria o futuro se as suposições adotadas ocorressem. Através de uma sequência hipotética de acontecimentos, construídos como objetivo de conduzir a atenção para os fatos bastante prováveis, torna-se possível construir caminhos para a decisão. Este método é bastante utilizado para análises de investimentos através da manipulação de algumas variáveis principais. Usualmente, a elaboração de cenários deverá envolver [35]:

- Levantamento de dados;
- Análise e seleção dos objetivos;
- Identificação das variáveis internas intervenientes;
- Identificação das variáveis do meio ambiente;
- Construção e seleção de cenários;
- Calcular as probabilidades de cada cenário selecionado;
- Análise dos cenários selecionados;
- Cálculo da previsão de vendas, com base na seleção de cenários.

#### 2. Método de Delphi

Um conjunto de especialistas é interrogado através de uma sequência de questionários, sendo que, a partir do segundo, eles são construídos a partir das respostas do anterior e assim consecutivamente até ao último questionário. As informações disponíveis são transmitidas a todos os entrevistados, habilitando-os a prever com as mesmas informações. Procura-se então confrontar as respostas com razões e argumentos dados anteriormente, permitindo a oportunidade de revisão das estimativas. O programa é aplicado em fases, que irá sendo aprofundando nos detalhes sobre as previsões estudadas [34] [35].

Este método procura obter o consenso de um grupo através de um modelo mais sistemático no uso das avaliações individuais. Eliminando as influências psicológicas que existem nos comitês assim como, a divergência de opiniões, persuasão de alguns elementos, a opinião da maioria, atingindo-se bons resultados porque questionários sequenciais são aplicados separadamente aos participantes [34] [35].

O método Delphi também apresenta desvantagens, como por exemplo a elevada incidência de ambiguidade nos questionários. Contudo, a sua larga aplicação tem comprovado a sua força no processo de previsão [34] [35].

#### 3. Método de Analogia Histórica

Este método é constituído através de uma análise comparativa de estágios, desde o crescimento, maturidade e por fim declínio, cujos dados são considerados semelhantes no processo de previsão. No primeiro estágio, por exemplo a venda de um produto, este inicia-se com um crescimento de vendas, sendo que esse crescimento irá estabilizar a partir de um determinado instante designado por estágio de maturidade. Atingido esse

estágio, o estágio posterior será o declínio, onde se observará um declínio nas vendas. Efetuando a comparação entre estágios, é possível efetuar previsões de vendas para outros produtos que sejam similares [34] [35].

#### 3.5 Métodos Quantitativos de Previsão

Os métodos quantitativos utilizam a informação quantificada historicamente, isto é, os métodos pressupõem que os padrões de comportamento e inter-relações do passado se irão manter no futuro. Normalmente os dados são quantificados sob a forma de séries ou sucessões cronológicas.

Os métodos quantitativos de previsão podem ser classificados em duas principais categorias: séries temporais e métodos explicativos ou causais como ilustrado na Figura 3.3 [34] [35].

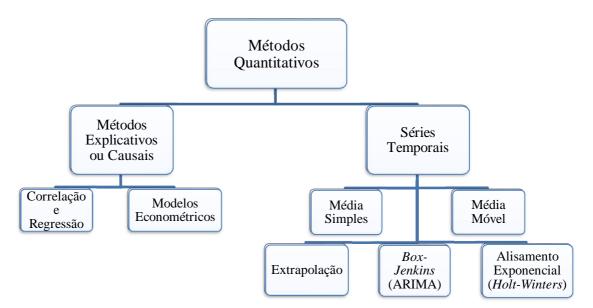


Figura 3.3 - Métodos Quantitativos

#### Métodos Explicativos ou Causais

Os métodos explicativos de previsão pressupõem uma relação de causa e efeito entre os *inputs* e os *outputs* de um sistema em estudo. Qualquer mudança nos *inputs* irá afetar os *outputs*. Consideram relações estáveis entre variáveis explicativas (dependentes) e a variável a prever (independente). O objetivo dos métodos de previsão neste contexto é encontrar a relação entre os dois, através da análise dos resultados dos outputs. Os

métodos causais ou explicativos podem-se dividir em: correlação e regressão simples, regressão múltipla e modelos econométricos [34] [35].

#### 1. Correlação e Regressão

A análise de regressão é muito usada em previsão. A análise de regressão pode envolver desde fator simples (Regressão simples), para a determinação de um dado concreto, até múltiplos fatores (Regressão múltipla). A relação de correlação entre os diversos fatores pode ser linear ou não linear (logarítmica, exponencial, etc.). No caso específico de uma análise de regressão linear simples assume-se que uma variável dependente relacionasse linearmente com uma variável independente.

A análise de regressão linear procura encontrar a equação da reta que melhor se ajuste a um conjunto de observações. Esta equação da reta deve minimizar os desvios ocorridos entre as observações e os valores obtidos através da equação [34] [35].

A qualidade do ajuste de uma regressão linear é medida através do coeficiente de determinação, caracterizado pela relação entre a soma dos quadrados dos desvios dos resultados obtidos pela regressão, a média das observações e a soma dos quadrados dos desvios das observações em si e a média dessas observações. A qualidade de uma regressão também pode ser medida através do coeficiente de correlação (trata-se da raiz quadrada do coeficiente de determinação), que demonstra o tipo de relação que as variáveis apresentam entre si. Para que o modelo de regressão seja aceite, é preciso que o coeficiente de correlação seja menor do que "– 0,70" ou maior do que "+0,70". É de salientar que o coeficiente de correlação pode variar de "–1" a "+1", onde "0" (zero) representa ausência de correlação [34] [35].

A regressão múltipla segue o mesmo raciocínio do que a regressão simples, porém, associa mais do que uma variável independente à mesma variável dependente.

#### 2. Modelos Econométricos

Tanto no modelo de regressão simples como no modelo de regressão múltipla, observase a existência de apenas uma equação. Isto significa que todos os elementos da mesma equação são tratados de forma idêntica. Tomando por exemplo a regressão múltipla, existem várias variáveis independentes que interferem com uma determinada variável dependente. Quando se trata de determinadas variáveis de uma forma endógena, apenas se consideram os resultados desta variável e deixa-se de lado tudo o que interfere nesta variável. Nos modelos econométricos são consideradas as variáveis endógenas e as variáveis exógenas e, teoricamente, as equações econométricas refletem os resultados com maior precisão. No entanto, são modelos complexos e que necessitam do auxílio de computador, *software* específico e especialistas em estatística [35].

#### <u>Séries Temporais</u>

Por oposição aos métodos causais ou explicativos, a previsão através de séries temporais aborda o sistema como uma "caixa preta", não procurando identificar os fatores que afetam o seu comportamento, devido sobretudo à dificuldade de compreensão e organização dos dados. Este método analisa e projeta para o futuro padrões de comportamento de séries cronológicas. Os principais padrões ou componentes das séries temporais/cronológicas são: o nível, a tendência, a componente cíclica, sazonalidade e ainda flutuações irregulares. Estes são métodos aceitáveis para prazos não muito longos em que as condições de estabilidade se mantenham [34] [35].

Os métodos de séries temporais podem ser: extrapolação, médias e amortecimento/alisamento exponencial (*Holt-Winters*).

#### 1. Extrapolação

Através de dados históricos, da análise da sazonalidade, tendência e componente aleatória é feita a análise e implementação do método de extrapolação. O método de extrapolação é muito eficiente especialmente para previsões de curto prazo. Este método apresenta algumas desvantagens, dado que é um método que tem pouca capacidade para detetar "pontos de viragens", onde a taxa de crescimento ou declínio da série de tempo muda significativamente, e ainda apresenta dificuldades em detetar tendências úteis ou padrões. Dessa forma, este método requer que os dados históricos sejam muito estáveis para efetuar uma boa previsão [35].

#### 2. Média Simples

O método da média simples é bastante simplificado e consiste em fazer a previsão a partir da média aritmética dos dados passados. Dessa forma é preciso conhecer os dados correspondentes às séries históricas.

A média simples apresenta o inconveniente de ser influenciada por dados discrepantes. Ou seja, a média será sempre influenciada, para cima ou para baixo, de acordo com dados aleatórios provenientes de alguma irregularidade. Outro inconveniente da média simples é que ela considera o mesmo peso para todos os dados históricos [35].

#### 3. Média Móvel

O método das médias móveis é muito útil na suavização de curvas que representam tendências e atenuação de distorções. O método consiste na média dos N dados mais recentes. Se os dados são fornecidos anualmente, ou mensalmente, as médias móveis de ordem N são denominadas, respetivamente, média móvel de N anos ou de N meses. A média móvel produz resultados de previsões que dependem de N. Logo, se o "N" utilizado é baixo, a média poderá estar a incorporar variações aleatórias. Ao invés, se o valor de N for alto, a média não estará a ser muito sensível às variações na medida em que se aumenta o número de observações. Ou seja, no caso de se utilizar um grande número de observações, estar-se-iam a filtrar as variações aleatórias, porém, as variações reais também não seriam consideradas. Existem outros aperfeiçoamentos no que diz respeito à aplicação da metodologia da média móvel, no entanto, ela continua a dar o mesmo peso para todos os dados no cálculo da previsão, além de necessitar de uma grande quantidade de dados para obter resultados satisfatórios [35].

#### 4. Box-Jenkins (ARIMA)

As séries temporais são ajustadas com modelos matemáticos que são ótimos no sentido de que eles apresentam erros menores do que qualquer outro modelo. Uma série histórica deverá estar ordenada cronológica e isto cria uma espécie de dependência entre os números de um período para outro, dependência chamada de autocorrelação. No modelo de *Box-Jenkins* são feitas análises da autocorrelação e autocorrelações parciais de uma série histórica e, em seguida, é calculada uma estimação dos parâmetros, minimizando o erro quadrático [34] [35].

A grande vantagem deste modelo é que através da análise da autocorrelação, é efetuado um diagnóstico dos resíduos de tal forma que os parâmetros estimados apresentem o erro quadrático mínimo. Este é aparentemente uma das mais apuradas ferramentas estatísticas disponíveis, mas também uma das dispendiosas em consumo de tempo e de compreensão complexa [34] [35].

#### 5. Amortecimento ou Alisamento Exponencial (Holt-Winters)

Estes modelos caracterizam-se por decompor as séries temporais em componentes, e posteriormente organizar essas mesmas componentes para efetuar a previsão. As componentes mais importantes destes modelos são: o nível, a tendência e a sazonalidade. Sendo, o nível/média, o valor médio das observações num determinado

período. A tendência, é a diferença sequencial entre dois níveis consecutivos. A sazonalidade é um determinado evento que se repete com uma periodicidade constante.

Mais concretamente, a suavização exponencial simples é geralmente aplicada a previsões de curto prazo, onde considera a previsão correspondente ao período anterior e faz um ajuste para obter a previsão para o período seguinte. O modelo assume que os dados oscilam em torno de uma média estável, ou seja, com um padrão de crescimento consistente. A suavização do modelo é realizada através da multiplicação do erro de previsão da observação anterior e de uma constante de amortecimento que atribuí pesos às observações, que variam com a "antiguidade" das observações, ou seja, observações recentes têm mais peso na previsão do que as observações mais antigas.

A suavização exponencial dupla, é em tudo semelhante à anterior excetuando que neste modelo a previsão é efetuada através de duas variáveis simultaneamente.

No que toca aos modelos de *Holt-Winters*, estes são modelos adequados para as séries de dados que apresentem tendência e ainda componentes de sazonalidade, sendo modelos muito robustos e com elevada precisão.

Algumas desvantagens do modelo são as dificuldades em determinar os valores mais apropriados das constantes de suavização e/ou impossibilidade de estudar as propriedades estatísticas, tais como média e variância da previsão.

Os modelos de *Holt-Winters* possuem dois tipos de procedimentos, multiplicativo e aditivo cuja utilização depende das características das séries consideradas. O procedimento multiplicativo é indicada para séries temporais em que a amplitude da sazonalidade varia com o nível/média. O procedimento aditivo é apropriado para séries temporais cuja amplitude da sazonalidade é independente do nível.

Além dos modelos padrão de *Holt-Winters*, recentemente foi implementado um novo modelo, modelo de alisamento exponencial com dupla sazonalidade, aplicado a séries temporais que apresentem dois padrões sazonais/ciclo [36].

No âmbito deste trabalho, a previsão do preço de mercado da energia elétrica terá por bases os modelos de previsão *Holt-Winters*, mais concretamente o modelo de alisamento exponencial com dupla sazonalidade.

# Capítulo 4

## SÉRIES DE PREÇO

Neste capítulo são abordadas as séries de tempo, especificamente do preço de mercado da energia elétrica. É elaborada uma análise às características mais específicas desta série de tempo, assim como a análise para o ajuste dessas características à escolha dos modelos de previsão mais adequados para a série.

#### 4 Séries de Preços

#### 4.1 Séries de Preços

As séries de tempo ou sucessões cronológicas designam-se por um conjunto de observações quantitativas sobre determinada variável respeitantes a diferentes momentos no tempo, que deverão ser equidistantes (horas, dias, semanas, meses, trimestres, anos, etc.). No âmbito deste trabalho a série em estudo apresenta observações do preço da energia elétrica de hora em hora do mercado diário de energia elétrica do MIBEL apresentado anteriormente neste trabalho [37] [38].

#### 4.2 Nível e Tendência

Na Figura 4.1 é possível analisar a evolução dos preços de energia elétrica, desde o início de funcionamento em pleno do MIBEL, ou seja, desde dia 1 de Julho de 2007 até ao dia 31 de Dezembro de 2012. Verifica-se através da figura que os preços apresentam uma grande volatilidade ao longo dos anos, porém nota-se um decréscimo constante no preço médio ao longo dos anos, ou seja, o preço apresenta uma tendência ligeiramente decrescente, Figura 4.1.

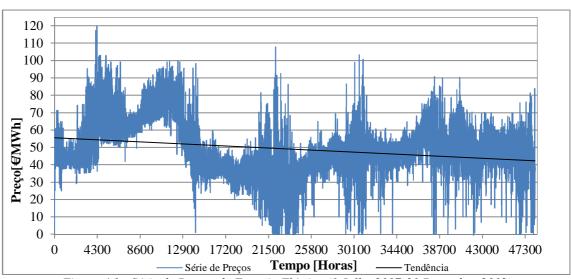


Figura 4.1 - Série de Preços da Energia Elétrica (1 Julho 2007-31 Dezembro 2012)

#### 4.3 Volatilidade

Os preços de energia elétrica têm uma grande dependência da procura da mesma e são muito influenciados pelas atividades económicas e pelas condições climatéricas, dado que nos meses mais frios e mais quentes existe elevado consumo de eletricidade, para aquecimento nos meses mais frios e o uso de equipamentos de refrigeração para os meses mais quentes [39]. Por outro lado, nos meses de maior pluviosidade ou mesmo anos, haverá uma grande utilização das centrais hídricas o que poderá levar o preço da energia a baixar. Ainda da mesma forma, nos meses ou anos mais secos poderá levar ao aumento dos preços uma vez que haverá pouca utilização das centrais hídricas e consequentemente a utilização das centrais térmicas que devido à sua natureza possuem custos marginais mais elevados, contribuindo para o aumento do preço.

Estas séries de preços da energia elétrica apresentam uma elevada volatilidade, como é possível analisar nas Figura 4.2 e Figura 4.3. Esta elevada volatilidade, entre outros fatores, é o mais relevante atualmente, bem como a impossibilidade de armazenar grandes quantidades de energia elétrica aliado ao fato de serem ainda escassos os bens seus substitutos (é notória uma cada vez maior dependência mundial da energia elétrica). Não sendo a eletricidade armazenável de modo economicamente eficiente torna-se imprescindível um continuado encontro entre a produção e o consumo, o que justifica que os choques da procura e da oferta não sejam facilmente "suavizados", com inevitável e direto efeito sobre os preços de equilíbrio [39].

Outra análise possível de se efetuar das Figura 4.2 e Figura 4.3 acerca da volatilidade dos preços da energia elétrica é que apesar de ambas apresentarem elevada volatilidade é notório que no verão (Figura 4.2) verifica-se uma menor volatilidade que no inverno (Figura 4.3). Esta menor volatilidade no verão pode ser explicada pelo fato de no verão serem por "norma" meses secos, existindo pouca utilização das centrais hídricas sendo a procura abastecida na sua maioria por centrais térmicas e dessa forma o preço será menos volátil. Da mesma forma pode ser explicada a maior volatilidade no inverno, uma vez que sendo tipicamente meses com elevada pluviosidade existirá uma maior utilização das centrais hídricas, podendo levar o preço a valor baixos em certas alturas do dia mas também a valores consideravelmente altos noutras alturas do dia com a elevada procura e a necessidade de utilização das centrais térmicas pois as centrais hídricas poderão não ter a capacidade para abastecer a procura total.

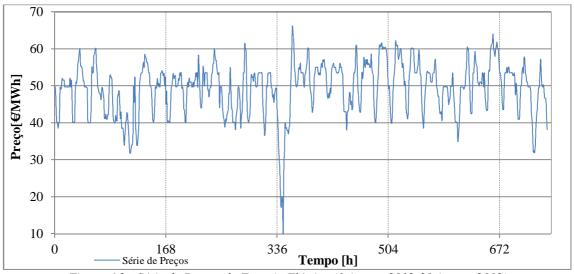


Figura 4.2 - Série de Preços da Energia Elétrica (1 Agosto 2012-31 Agosto 2012)

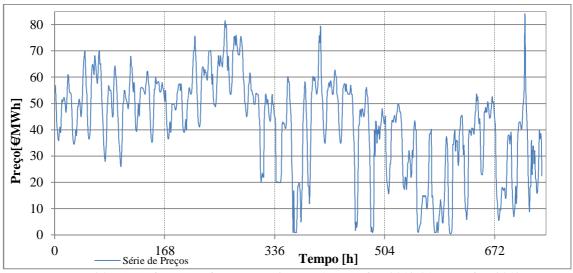


Figura 4.3 - Série de Preços da Energia Elétrica (1 Dezembro 2012-31 Dezembro 2012)

#### 4.4 Sazonalidade

Nas séries de tempo a sazonalidade é uma característica importante, uma vez que representa uma flutuação com periodicidade fixa onde se caracterizam os padrões regulares de uma sucessão cronológica. Uma mesma sucessão cronológica pode possuir mais do que uma sazonalidade. Os períodos de variação da sazonalidade são designados por estações, podendo esses períodos ser anuais, mensais, semanais ou até mesmo diários.

Nas séries de preços da energia elétrica a sazonalidade está presente, apresentando uma sazonalidade anual, mensal, semanal e ainda diária. Para o presente trabalho as sazonalidades mais importantes serão as semanais e as diárias, uma vez que são as mais evidentes e com maior peso para uma previsão de curto prazo.

#### 4.4.1 Sazonalidade Semanal

Na Figura 4.4 é possível verificar que a série apresenta padrões semelhantes que se repetem dia-a-dia ao longo da semana, tanto nos dias de semana como nos fins de semana, apresentando assim a referida sazonalidade semanal. Esta sazonalidade semanal pode ser explicada pelo fato de existir também sazonalidade diária (apresentada mais à frente neste trabalho), e ainda o fato de o preço da energia elétrica estar bastante dependente da procura de eletricidade. Outro aspeto importante é o fato de que nos fins de semana ser possível verificar um decréscimo no preço com se verifica na Figura 4.5, devendo-se ao fato de existir menos consumo durante esses dias.

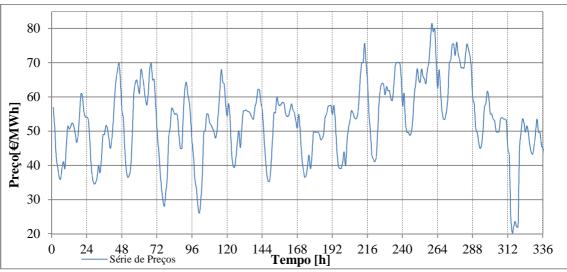


Figura 4.4 - Série de Preços da Energia Elétrica (1 Dezembro 2012-15 Dezembro 2012)

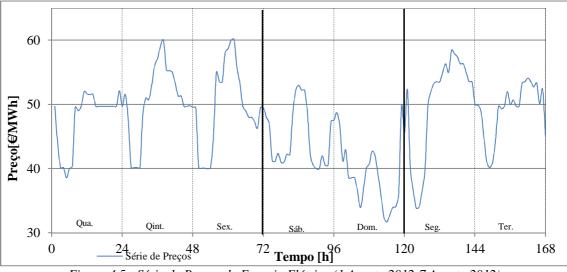


Figura 4.5 - Série de Preços da Energia Elétrica (1 Agosto 2012-7 Agosto 2012)

No entanto existe um fenómeno que afeta ligeiramente a sazonalidade semanal sendo ele a ocorrência de feriados. Os feriados são considerados eventos atípicos nas séries de

preços de energia elétrica, apesar da sua taxa de ocorrência ser relativamente baixa em relação aos dias regulares. Os dias de feriado apresentam uma grande semelhança com os dias de fim de semana, o que se pode verificar na Figura 4.6 expondo o mesmo padrão de sazonalidade diário dos dias de fim de semana.

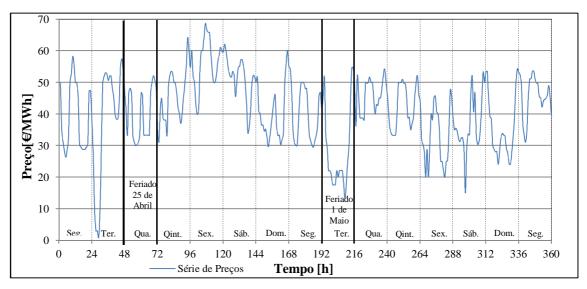


Figura 4.6 - Série de Preços da Energia Elétrica (23 Abril 2012-7 Maio 2012)

#### 4.4.2 Sazonalidade Diária

Pode ser feita a mesma análise efetuada anteriormente para a Figura 4.7, onde está representada a série de preços que evidencia a repetição do mesmo padrão de dia para dia, verificando-se picos e cavas em horas aproximadas do dia. Dessa forma é possível afirmar que a série apresenta sazonalidade diária. A sazonalidade diária pode ser explicada pela diminuição do consumo (doméstico e industrial) de eletricidade durante as horas noturnas e ao seu incremento durante o período diurno [39].

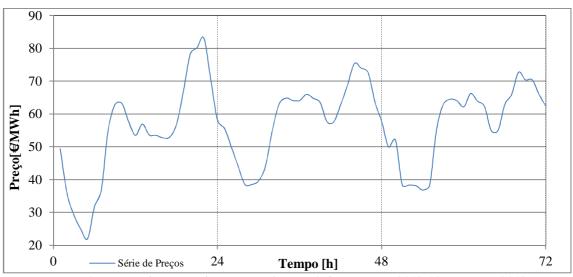


Figura 4.7 - Série de Preços da Energia Elétrica (8 de Fevereiro 2012-10 Fevereiro 2012)

#### 4.5 Análise Geral

Com a análise feita anteriormente é possível afirmar que a serie de preços da energia elétrica apresenta duas sazonalidades bem evidentes, sendo elas a sazonalidade semanal e diária. Dessa forma, para se efetuar uma análise eficaz destas séries e posteriormente previsão com base na série de tempo, terá que se ter em conta a dupla sazonalidade pois existem métodos de previsão que mais se adequam a estas características. Entres os vários métodos de previsão, tendo em conta que neste trabalho se propõe uma abordagem através de modelos de suavização exponencial, o que mais se adequa às características da série e será implementado para efetuar a previsão do preço da energia elétrica neste trabalho será o método de suavização/alisamento exponencial mais concretamente os métodos de *Holt-Winters* nas suas diversas variantes com dupla sazonalidade.

# Capítulo 5

## MODELIZAÇÃO

Neste capítulo é abordada a modelização, com o objetivo de expor diversas questões sobre a caracterização e construção de metodologias adequadas para os casos de estudo. É efetuada uma breve análise sobre os métodos de Holt-Winters, assim como exposta a constituição dos mesmos nas suas diversas variantes.

Ainda, é efetuada a composição de "ferramentas" de modo a ser possível analisar, comparar e discutir os resultados que serão obtidos.

#### 5 Modelização

#### 5.1 Introdução ao Holt-Winters

A previsão do preço da energia elétrica será efetuada através dos métodos de *Holt-Winters*, sendo que este é um modelo que se adequa às características da série de preços apresentado no capítulo 4.

O método de amortecimento de *Holt-Winters* é um método univariado, isto é, usa somente a própria série para realizar a previsão. Este método faz parte da classe dos Métodos de Amortecimento Exponencial, os quais são frequentemente utilizados para realizar previsão de séries que possuem tendência e sazonalidade.

Contudo, pelo seu preciosismo, robustez e adaptabilidade, é muito utilizado em várias áreas, como por exemplo, em consumo de energia elétrica, previsões de vendas, etc. Contudo, antes das previsões serem realizadas, é necessário estimar os valores iniciais do nível, tendência e cada sazonalidade e há também os hiperparâmetros (que são quatro, um para cada parâmetro anterior), designadas por constantes de amortecimento do modelo [40] [41].

Dessa forma o modelo de *Holt-Winters* incorpora tanto o nível e a tendência quanto o comportamento sazonal da série, podendo esse comportamento sazonal ser formulado de forma aditiva ou multiplicativa. No caso da sazonalidade aditiva, é recomendado a utilização em séries que apresentam a variância constante ao longo do tempo, enquanto que no caso da sazonalidade multiplicativa é recomendado a utilização em séries que apresentam uma alteração da variância ao longo do tempo [42].

#### 5.2 Modelo Padrão - Holt-Winters

#### 5.2.1 Aditivo

Este modelo é adequado para as séries que apresentam um efeito de tendência aditiva e um efeito sazonal aditivo sobreposto.

Assim, assumindo uma série, X<sub>t</sub>, e considerando que ela possui unicamente um ciclo e ainda sazonalidade aditiva, essa série pode ser modelada da seguinte forma:

$$X_t = S_t + KT_t + I_t + \varepsilon_t (5.1)$$

onde,  $S_t$  refere-se ao nível,  $T_t$  à tendência,  $I_t$  ao fator sazonal e por fim  $\varepsilon_t$  ao resíduo aleatório [42].

Estes parâmetros (nível, tendência e sazonalidade) devem ser atualizados a cada instante de tempo. Para tal, utilizam-se as seguintes equações:

Nível 
$$S_t = \alpha (X_t - I_{t-s}) + (1 - \alpha)(S_{t-1} + T_{t-1})$$
 (5.2)

Tendência 
$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1}$$
 (5.3)

Sazonalidade 
$$I_t = \delta (X_t - S_t) + (1 - \delta)I_{t-s}$$
 (5.4)

Nas três equações acima, é considerado  $X_t$  como sendo a observação no período t e onde  $\alpha$ ,  $\gamma$  e  $\delta$  são constantes de amortecimento compreendidas entre valores de 0 e 1 [41].

A subtração da componente de sazonalidade (estimada s instantes atrás) à observação  $X_t$ , na equação (5.2), é realizada para retirar desta observação a sazonalidade, com o objetivo de permitir que o processo de atualização da componente de nível seja somente baseada na estimativa prévia dela mesma e da tendência.

Na equação (5.4) procede-se à atualização do índice sazonal para a estação correspondente ao instante t (avaliado pela última vez s instantes atrás) introduzindo a avaliação mais recente (para o instante t) do efeito sazonal (estimado através da diferença entre a observação e o nível para esse instante t).

Com base nestas equações é possível efetuar a previsão para instantes futuros, onde k corresponde ao período a prever, sendo incorporadas numa só representada pela equação (5.5) [41].

Previsão 
$$\hat{X}_t(k) = S_t + kT_t + I_{t-s+k}$$
 (5.5)

#### 5.2.2 Multiplicativo

Este modelo adequa-se a séries em que a amplitude das flutuações sazonais é proporcional ao nível de série.

Assim, assumindo uma série, X<sub>t</sub>, é considerando que essa possui unicamente um ciclo e ainda sazonalidade aditiva, esta série pode ser modelada da seguinte forma:

$$X_t = (S_t + KT_t) \times I_t + \varepsilon_t \tag{5.6}$$

Onde os coeficientes e siglas da equação (5.6) são iguais às definições do modelo anterior.

As equações de atualização dos parâmetros continuam a ser calculadas com o mesmo intuito do modelo anterior, assim, obtêm-se as seguintes equações:

Nível 
$$S_t = \alpha \left( \frac{X_t}{I_{t-s}} \right) + (1 - \alpha)(S_{t-1} + T_{t-1})$$
 (5.7)

Tendência 
$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1}$$
 (5.8)

Sazonalidade 
$$I_t = \delta\left(\frac{X_t}{S_t}\right) + (1 - \delta)I_{t-s}$$
 (5.9)

O modelo assume que a tendência aditiva é estimada pelo somatório do passo local amortecido, e pelas sucessivas diferenças amortecidas,  $S_t + S_{t-1}$ , do nível local  $S_t$ . O índice sazonal local,  $I_t$ , é estimado pela razão amortecida do valor observado,  $X_t$ , e o nível,  $S_t$  [41].

Com base nestas equações é possível efetuar a previsão para instantes futuros, onde k corresponde ao período a prever, sendo incorporadas numa só representada pela equação (5.10).

Previsão 
$$\hat{X}_t(k) = (S_t + kT_t) \times I_{t-s+k}$$
 (5.10)

#### 5.3 Modelos Gerais

Os modelos de amortecimento exponencial mais precisamente de *Holt-Winters* apresentados nos pontos anteriormente são designados por modelos padrão. Através desses modelos padrão existe a possibilidade de elaborar diversos modelos, combinando vários tipos de sazonalidade e tendência de acordo com as características da série.

Na Tabela 5.1 [40] é possível observar as equações gerais dos vários modelos possíveis de se combinar, com tendência aditiva, aditiva amortecida, multiplicativa e multiplicativa amortecida ainda com sazonalidade aditiva ou multiplicativa.

Tabela 5.1 - Métodos de Alisamento Exponencial (Holt-Winters) [38]

	Tabeta 5.1 - Metodos de	Sazonalidade	winiers) [30]	
Tendência	(Sem sazonalidade)	Aditiva	Multiplicativa	
	$S_t = \alpha X_t + (1 - \alpha) S_{t-1}$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)S_{t-1}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)S_{t-1}$	
	$\hat{X}_t(m) = S_t$	$I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$	$I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$	
(Com tândoncia)		$\hat{X}_t(m) = S_t + I_{t-p+m}$	$\hat{X}_t(m) = S_t I_{t-p+m}$	
(Sem têndencia)	$S_t = S_{t-1} + \alpha e_t$	$S_t = S_{t-1} + \alpha e_t$	$S_t = S_{t-1} + \alpha e_t / I_{t-p}$	
	$\hat{X}_t(m) = S_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t / S_t$	
		$\hat{X}_t(m) = S_t + I_{t-p+m}$	$\hat{X}_t(m) = S_t I_{t-p+m}$	
	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + T_{t-1})$	$S_{t} = \alpha(X_{t} - I_{t-p}) + (1 - \alpha)(S_{t-1} + T_{t-1})$	$S_{t} = \alpha(X_{t}/I_{t-p}) + (1-\alpha)(S_{t-1} + T_{t-1})$	
	$T_{t} = \gamma (S_{t} - S_{t-1}) + (1 - \gamma)T_{t-1}$	$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)T_{t-1}$	$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1}$	
	$\hat{X}_t(m) = S_t + mT_t$	$I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$	$I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$	
Aditiva		$\hat{X}_t(m) = S_t + mT_t + I_{t-p+m}$	$\hat{X}_t(m) = (S_t + mT_t)I_{t-p+m}$	
Hannya	$S_t = S_{t-1} + T_{t-1} + \alpha e_t$	$S_t = S_{t-1} + T_{t-1} + \alpha e_t$	$S_t = S_{t-1} + T_{t-1} + \alpha e_t / I_{t-p}$	
	$T_t = T_{t-1} + \alpha \gamma e_t$	$T_t = T_{t-1} + \alpha \gamma e_t$	$T_t = T_{t-1} + \alpha \gamma e_t / I_{t-p}$	
	$\hat{X}_t(m) = S_t + mT_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t / S_t$	
		$\hat{X}_t(m) = S_t + mT_t + I_{t-p+m}$	$\hat{X}_t(m) = (S_t + mT_t)I_{t-p+m}$	
	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} + \phi T_{t-1})$	$S_{t} = \alpha(X_{t} - I_{t-p}) + (1 - \alpha)(S_{t-1} + \phi T_{t-1})$	$S_{t} = \alpha(X_{t}/I_{t-p}) + (1-\alpha)(S_{t-1} + \phi T_{t-1})$	
	$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1}$	$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1}$	$T_t = \gamma(S_t - S_{t-1}) + (1 - \gamma)\phi T_{t-1}$	
	$\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t$	$I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$	$I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$	
Aditiva		$\hat{X}_{t}(m) = S_{t} + \sum_{i=1}^{m} \phi^{i} T_{t} + I_{t-p+m}$	$\hat{X}_t(m) = (S_t + \sum_{i=1}^m \phi^i T_t) I_{t-p+m}$	
Amortecida	$S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t$	$S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t$	$S_t = S_{t-1} + \phi T_{t-1} + \alpha e_t / I_{t-p}$	
	$T_t = \phi T_{t-1} + \alpha \gamma e_t$	$T_{t} = \phi T_{t-1} + \alpha \gamma e_{t}$	$T_t = \phi T_{t-1} + \alpha \gamma e_t / I_{t-p}$	
	$\hat{X}_t(m) = S_t + \sum_{i=1}^m \phi^i T_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t / S_t$	
		$\hat{X}_{t}(m) = S_{t} + \sum_{i=1}^{m} \phi^{i} T_{t} + I_{t-p+m}$	$\hat{X}_{t}(m) = (S_{t} + \sum_{i=1}^{m} \phi^{i} T_{t}) I_{t-p+m}$	
	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1}R_{t-1})$	$S_{t} = \alpha(X_{t} - I_{t-p}) + (1 - \alpha)S_{t-1}R_{t-1}$	$S_t = \alpha(X_t / I_{t-p}) + (1 - \alpha)S_{t-1}R_{t-1}$	
	$R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}$	$R_t = \gamma (S_t / S_{t-1}) + (1 - \gamma) R_{t-1}$	$R_{t} = \gamma(S_{t} / S_{t-1}) + (1 - \gamma)R_{t-1}$	
	$\hat{X}_t(m) = S_t R_t^m$	$I_{t} = \delta(X_{t} - S_{t}) + (1 - \delta)I_{t-p}$	$I_t = \delta(X_t / S_t) + (1 - \delta)I_{t-p}$	
Multiplicativa		$\hat{X}_t(m) = S_t R_t^m + I_{t-p+m}$	$\hat{X}_t(m) = (S_t R_t^m) I_{t-p+m}$	
,	$S_t = S_{t-1}R_{t-1} + \alpha e_t$	$S_t = S_{t-1}R_{t-1} + \alpha e_t$	$S_t = S_{t-1}R_{t-1} + \alpha e_t / I_{t-p}$	
	$R_t = R_{t-1} + \alpha \gamma e_t / S_{t-1}$	$R_t = R_{t+1} + \alpha \gamma e_t / S_{t-1}$	$R_t = R_{t-1} + (\alpha \gamma e_t / S_{t-1}) / I_{t-p}$	
	$\hat{X}_t(m) = S_t R_t^m$	$I_{t} = I_{t-p} + \delta(1-\alpha)e_{t}$	$I_t = I_{t-p} + \delta(1-\alpha)e_t / S_t$	
		$\hat{X}_t(m) = S_t R_t^m + I_{t-p+m}$	$\hat{X}_t(m) = (S_t R_t^m) I_{t-p+m}$	
	$S_t = \alpha X_t + (1 - \alpha)(S_{t-1} R_{t-1}^{\phi})$	$S_t = \alpha(X_t - I_{t-p}) + (1 - \alpha)S_{t-1}R_{t-1}^{\phi}$	$S_{t} = \alpha(X_{t}/I_{t-p}) + (1-\alpha)(S_{t-1}R_{t-1}^{\phi})$	
	$R_{t} = \gamma (S_{t} / S_{t-1}) + (1 - \gamma) R_{t-1}^{\phi}$	$R_t = \gamma(S_t / S_{t-1}) + (1 - \gamma)R_{t-1}^{\phi}$	$R_{t} = \gamma(S_{t}/S_{t-1}) + (1 - \gamma)R_{t-1}^{\phi}$	
	$\hat{X}_{t}(m) = S_{t} R_{t}^{\sum_{i=1}^{m} \phi^{i}}$	$I_t = \delta(X_t - S_t) + (1 - \delta)I_{t-p}$	$I_t = \delta(X_t/S_t) + (1-\delta)I_{t-1}$	
Multiplicativa		$\hat{X}_{t}(m) = S_{t} R_{t}^{\sum_{i=1}^{m} \phi^{i}} + I_{t-p+m}$	$\hat{X}_t(m) = (S_t R_t^{\sum_{l=1}^m \phi^l}) I_{t-p+m}$	
Amortecida	$S_t = S_{t-1}R_{t-1}^{\phi} + \alpha e_t$	$S_t = S_{t-1} R_{t-1}^{\phi} + \alpha e_t$	$S_t = S_{t-1}R_{t-1}^{\phi} + \alpha e_t / I_{t-p}$	
	$R_t = R_{t-1}^{\phi} + \alpha \gamma e_t / S_{t-1}$	$R_{t} = R_{t-1}^{\phi} + \alpha \gamma e_{t} / S_{t-1}$	$R_t = R_{t-1}^{\phi} + (\alpha \gamma e_t / S_{t-1}) / I_{t-p}$	
	$\hat{X}_{t}(m) = S_{t} R_{t}^{\sum_{i=1}^{m} \phi^{i}}$	$I_t = I_{t-p} + \delta(1-\alpha)e_t$	$I_t = I_{t-p} + \delta(1-\alpha)e_t / S_t$	
		$\hat{X}_{t}(m) = S_{t} R_{t}^{\sum_{i=1}^{m} \phi^{i}} + I_{t-p+m}$	$\hat{X}_t(m) = (S_t R_t^{\sum_{i=1}^m \phi^i}) I_{t-p+m}$	

As combinações de modelos apresentados na Tabela 5.1 não serão adequados para elaborar a previsão do preço da energia elétrica uma vez que a série em estudo apresenta

dupla sazonalidade, como foi descrito anteriormente no capítulo 4 mais especificamente no ponto 4.5. Dessa forma os modelos padrão anteriores não serão utilizados para elaborar a previsão neste trabalho na sua totalidade, pois serão utilizados modelos que tenham a possibilidade de integrar a dupla sazonalidade, contudo esses modelos com dupla sazonalidade terão com base os modelos da Tabela 5.1.

#### 5.4 Modelo - *Holt-Winters* Dupla Sazonalidade

Os modelos padrão de *Holt-Winters* são apenas capazes de comtemplar uma sazonalidade. No entanto, em 2003 James Taylor sugere que as séries de consumo elétrico possuem duas sazonalidades, que apresentam um mesmo perfil entre os dias, e outro semanal, configurando um perfil semelhante entre semanas. Dessa forma, tendo estes dois padrões sazonais e sabendo que o método de *Holt-Winters* é conhecido pela sua robustez e precisão, Taylor adaptou o método de *Holt-Winters* padrão de tal forma que ele passasse a introduzir mais do que um padrão sazonal, isto é, múltiplos ciclos. Portanto, este método é adequado para séries com duas ou mais sazonalidades [40] [41].

As séries de preço da energia elétrica apresentam muitas semelhanças com as séries de consumo elétrico, ou seja, elas também apresentam duas sazonalidades e idênticas às séries de consumo elétrico como pode ser verificado no capítulo 4.

Assim, as equações do modelo com dupla sazonalidade são compostas por índices de sazonalidades distintos,  $D_t$  (diário) e  $W_t$  (semanal) com períodos  $S_1$  e  $S_2$  respetivamente [40] [41].

#### 5.4.1 Dupla Sazonalidade Multiplicativa com Tendência Aditiva

Assumindo uma série,  $X_t$ , e considerando que possui dois ciclos sazonais e ainda sazonalidade multiplicativa, esta série pode ser modelada da seguinte forma:

$$X_t = (S_t + kT_t)D_tW_t + \varepsilon_t (5.11)$$

Onde os coeficientes e siglas da equação (5.11) são iguais às definições do modelo anterior, com a exceção que a sazonalidade  $I_t$  passa a ser designada por  $D_t$  e é introduzida uma nova equação de sazonalidade, sazonalidade semanal  $(W_t)$ ,

As equações de atualização dos parâmetros continuam a ser calculadas com o mesmo intuito dos modelos anteriores com a exceção da introdução de um novo parâmetro ( $\omega$ ) correspondente à equação da sazonalidade semanal ( $W_t$ ). Este modelo é constituído com 4 parâmetros de atualização. Assim, obtêm-se as seguintes equações [41] [43]:

Nível 
$$S_t = \alpha \left( \frac{X_t}{D_{t-s_1} W_{t-s_2}} \right) + (1 - \alpha) (S_{t-1} + T_{t-1})$$
 (5.12)

Tendência 
$$T_t = \gamma (S_t - S_{t-1}) + (1 - \gamma) T_{t-1}$$
 (5.13)

Sazonalidade 1 
$$D_t = \delta \left( \frac{X_t}{S_t W_{t-s_2}} \right) + (1 - \delta) D_{t-s_1}$$
 (5.14)

Sazonalidade 2 
$$W_t = \omega \left( \frac{X_t}{S_t D_{t-s_1}} \right) + (1 - \omega) W_{t-s_2}$$
 (5.15)

Com base nestas equações é possível efetuar a previsão para instantes futuros, onde k corresponde ao período a prever, sendo incorporadas numa só representada pela equação (5.16) [41].

Previsão 
$$\hat{X}_t(k) = (S_t + kT_t)D_{t-s_1+k}W_{t-s_2+k}$$
 (5.16)

#### 5.4.2 Dupla Sazonalidade Multiplicativa com Tendência Amortecida

Outro método possível com dupla sazonalidade, insere a possibilidade de suavizar ou amortecer a tendência, adicionando ao modelo mais um parâmetro de alisamento,  $\varphi$ , tal que  $\gamma \leq \varphi \leq 1$ . Dessa forma este modelo é constituído por 5 parâmetros de atualização e as equações de atualização são formuladas por [44] [36]:

Nível 
$$S_t = \alpha \left( \frac{X_t}{D_{t-s_1} W_{t-s_2}} \right) + (1 - \alpha) (S_{t-1} + \phi T_{t-1})$$
 (5.17)

Tendência 
$$T_t = \gamma (S_t - S_{t-1}) + (\phi - \gamma) T_{t-1}$$
 (5.18)

Sazonalidade 1 
$$D_t = \delta \left( \frac{X_t}{S_t W_{t-s_2}} \right) + (1 - \delta) D_{t-s_1}$$
 (5.19)

Sazonalidade 2 
$$W_t = \omega \left( \frac{X_t}{S_t D_{t-s_1}} \right) + (1 - \omega) W_{t-s_2}$$
 (5.20)

Com base nestas equações é possível efetuar a previsão para instantes futuros, onde k corresponde ao período a prever, sendo incorporadas numa só representada pela equação (5.21):

$$\widehat{X}_{t}(k) = (S_{t} + (\sum_{i=1,...,k} \phi^{i}) \times T_{t}) D_{t-s_{1}+k} W_{t-s_{2}+k}$$
 (5.21)

## 5.4.3 Dupla Sazonalidade Multiplicativa com Tendência Amortecida e Erros Estruturados

Este método toma por base o modelo anterior (5.4.2), aumentando a complexidade do modelo, onde se introduz um novo parâmetro,  $\lambda$ , que permite que a sua modulação seja efetuada com maior precisão. Dessa forma este modelo é constituído por 6 parâmetros de atualização, onde o processo de atualização dos mesmos, realiza-se através das equações (5.17) a (5.20) apresentadas no ponto anterior. Com base nestas equações é possível efetuar a previsão para instantes futuros, onde k corresponde ao período a prever, sendo incorporadas numa só representada pela equação (5.22) [43] [44] [36]:

$$\widehat{X}_t(k) = \left(S_t + \left(\sum_{i=1,..,k} \Phi^i\right) \times T_t\right) D_{t-s_1+k} W_{t-s_2+k} + \lambda^k (X_t - (S_t + \Phi \times T_t) D_{t-s_1} W_{t-s_2}) \quad (5.22)$$

#### 5.4.4 Valores Iniciais dos Parâmetros

Todos os modelos descritos anteriormente têm que ser inicializados, ou seja, possuem valores inicias dos parâmetros  $S_t(0)$ ,  $T_t(0)$ ,  $D_t(0)$  e  $W_t(0)$  que são determinados através do procedimento descrito de seguida [44] [45]. Este procedimento é apresentado para o caso dos modelos com dois ciclos sazonais, um ciclo diário e um ciclo semanal, aplicados a dados horários.

A série temporal  $X_t(0)$  pode ser escrita na forma matricial, onde as linhas representam o ciclo menor (dia,  $s_1 = 24$ ) e as colunas o ciclo maior como se segue:

Existem I dias completos de dados hórarios históricos, ou seja, o número de ciclos diários provenientes dos dados históricos. Deste modo calcula-se [44] [45]:

• Passo 1: Médias "Diárias"

$$\bar{X}_i = \frac{\sum_{j=1}^{s_1} X_{i,j}}{s_1}$$
, para  $i = 1, ..., I$  (5.24)

Sendo i os dias e j as horas do ciclo.

Passo 2: Fatores dos Ciclos Diários Grosseiros

Onde,

$$D_{i,j}^* = \frac{X_{i,j}}{\bar{X}_i}$$
, para  $j = 1, ..., s_1 \text{ e } i = 1, ..., I$  (5.26)

Passo 3: Fatores dos Ciclos Diários

$$D_j^* = \frac{\sum_{i=1}^l D_{i,j}^*}{l}, \text{ para } j = 1, \dots, s_1$$
 (5.27)

Passo 4: Fatores dos Ciclos Diários Normalizados

$$D_{j} = \left(\frac{D_{j}^{*}}{\sum_{j=1}^{s_{1}} D_{j}^{*}}\right) \times S_{1}, j = 1, ..., S_{1}$$
(5.28)

• Passo 5: Estimativas Iniciais para os Parâmetros do Modelo

$$S_t(0) \cong \bar{X}_1 \tag{5.29}$$

$$T_t(0) \cong \frac{\bar{X}_2 - \bar{X}_1}{s_2}$$
 (5.30)

$$D_j(0) \cong D_j$$
, para  $j = 1, \dots, s_1$  (5.31)

$$W_j(0) \cong W_j \text{ , para } j = 1, ..., s_2$$
 (5.32)

É de salientar o fato, de que para os valores iniciais dos parâmetros do modelo para o ciclo semanal,  $W_t(0)$  para  $j = 1, ..., S_2$ , o procedimento é idêntico (segue-se os passos 1 a 4). Neste caso, os dados passam a ser organizados numa matriz cujas linhas são as horas das semanas (dimensão  $S_2$ ).

Os valores estimados do nível e da tendência iniciais (Passo 5), são determinados de acordo com os valores médios do ciclo semanal.

### 5.5 Medidas de Erro dos Métodos de Previsão de Séries Temporais

A precisão de um método de previsão pode ser mensurada através de diversas medidas de erro.

Erro: Considera-se como erro a diferença entre o valor observado e a previsão no mesmo instante t, descrito pela equação [46]:

$$\varepsilon_{t} = X_{t} - \widehat{X}_{t} \tag{5.33}$$

Erro Médio: O valor do erro médio pode assumir, valores negativos assim como valores positivos, porém o critério de avaliação é o de que quanto mais próximo do valor zero, melhor será o método escolhido, o erro médio obtém-se pela equação [46]:

$$\mathsf{EM} = \frac{1}{n} \sum_{i=1}^{n} \varepsilon_{\mathsf{t}} \tag{5.34}$$

Erro Médio Absoluto: Quanto mais próximo do valor zero, melhor será a aptidão do método escolhido para efetuar previsões, a sua determinação obedece à expressão [46]:

$$\mathsf{EMA} = \frac{1}{n} \sum_{i=1}^{n} |\varepsilon_{t}| \tag{5.35}$$

Erro Quadrático: É definido como o quadrado dos desvios, conforme a seguinte expressão:

$$QE = \varepsilon_t^2 \tag{5.36}$$

Erro Médio Quadrático: É definido como a soma dos quadrados dos desvios, dividida pelo número de observações, este tipo de erro enfatiza os erros de maior valor, conforme a seguinte expressão [46]:

$$QME = \frac{1}{n} \sum_{i=1}^{n} \varepsilon_t^2$$
 (5.37)

Erro Percentual: A equação abaixo apresentada, pretende verificar a relação percentual entre o valor observado e a previsão num dado instante *t*, tem-se [46]:

$$PE_{t} = \frac{(X_{t} - \widehat{X}_{t})}{X_{t}} \times 100 \tag{5.38}$$

Erro Percentual Médio Absoluto: É outro indicador de grande importância, onde verifica a relação entre o valor observado e o valor de previsão, de forma que esse resultado será sempre visto como positivo. Avalia-se que quanto mais próximo de zero mais adequados será o método em estudo, refira-se ainda que este é um dos indicadores mais utilizados para aferir a qualidade de um modelo proposto, bem como para estabelecer comparações entre diferentes modelos. É traduzido pela expressão [46]:

$$MAPE = \frac{1}{n} \sum_{i=1}^{n} |PE_t|$$
 (5.39)

#### 5.6 Intervalo de Confiança

A importância do intervalo de confiança deve-se à sua contribuição para o estudo do método que está sendo proposto, tendo o conhecimento das amplitudes de previsão. É importante o conhecimento do intervalo de confiança uma vez que o verdadeiro valor pode estar dentro deste intervalo de previsão, assumindo-se assim um certo nível de confiança para o intervalo [47].

O estabelecimento de intervalos de confiança realizados sobre as previsões efetuadas, considerando k passos à frente do instante t, e n correspondente ao tamanho do intervalo previsto, é traduzido pela expressão:

$$\left(\widehat{X}_{t+k} - Z_{\frac{\alpha}{2}} \times \frac{\sigma}{\sqrt{n}}; \ \widehat{X}_{t+k} + Z_{\frac{\alpha}{2}} \times \frac{\sigma}{\sqrt{n}}\right)$$
 (5.40)

É de salientar que, o intervalo de confiança será determinado recorrendo à distribuição normal  $Z_{\alpha/2}$  tendo em conta os dados disponíveis, e é efetuado através da variância dos valores previstos.

A variância é dada pela seguinte expressão [47]:

$$\sigma = \sqrt{\sigma^2} \tag{5.41}$$

$$\sigma^2 = \sum_{k=1}^{n} \frac{\left(\widehat{x}_k - \overline{\widehat{x}_k}\right)^2}{n} \tag{5.42}$$

$$\overline{\hat{X}_k} = \frac{\sum_{k=1}^n \hat{X}_k}{n} \tag{5.43}$$

#### 5.7 Indicadores/Medidas de Erro e Ajuste dos Modelos

#### 5.7.1 Estatística de Teste U Theil

A estatística de teste U Theil permite uma comparação relativa a métodos formais de previsão com método cândido e pelo fato de envolver no seu cálculo os quadrados dos erros, traduz também a importância dos grandes erros, aos quais é dado um maior peso do que aos pequenos.

Estatística de teste U Theil: Uma medida relativa ao erro de previsão, é dada por [48]:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left(\frac{\hat{X}_{t+1} - X_{t+1}}{X_t}\right)^2}{\sum_{t=1}^{n-1} \left(\frac{X_{t+1} - X_t}{X_t}\right)^2}}$$
 (5.44)

Quando a previsão  $\hat{X}_{t+1}$  é perfeita, ou seja, exatamente igual ao valor observado $X_{t+1}$ , o valor U é igual a zero. Na medida que  $X_{t+1}$  e  $\hat{X}_{t+1}$  são diferentes, a previsão não está representada com perfeição, o valor de estatística U aumenta e pode apresentar valores maiores que um.

Dessa forma, a verificação da adequação de um determinado modelo supostamente representativo da série histórica de dados está dependente na medida de erro adotada para efetuar a validação. Assim, de acordo com o exposto em cima, tem-se que [48]:

- U = 1 : o método cândido é tão bom quanto a técnica de previsão que está sendo avaliada.
- U < 1 : o método de previsão em estudo é melhor do que o método cândido.</li>
   Quanto menos a estatística U, mais adequado será o método em relação ao método cândido.
- U > 1 : não existe nenhuma razão em se utilizar métodos formais de previsão, já que o uso de um método cândido produzirá melhores resultados.

#### 5.7.2 Estatística de Teste R<sup>2</sup>

A estatística de teste  $R^2$ , com  $R^2$  designado por coeficiente de determinação, é um parâmetro de grande importância na análise do ajuste do modelo à série histórica de dados, ou seja, é uma medida percentual de avaliação do ajuste do modelo [46].

Dessa forma, o R<sup>2</sup> traduz a fração da variabilidade da série indicando quanto o modelo consegue explicar os valores observados, e é traduzido através da seguinte expressão [46]:

$$R^{2} = 1 - \frac{\sum_{t=2}^{n} (X_{t} - \hat{X}_{t})^{2}}{\sum_{t=2}^{n} (X_{t} - \bar{X})^{2}}$$
 (5.45)

O valor de R<sup>2</sup> varia entre 0 e 1, sendo que:

- R<sup>2</sup> próximo da unidade, assinala um ajuste bom do modelo à série histórica.
- R<sup>2</sup> próximo do valor zero, assinala um ajuste pobre do modelo à série histórica.
- $R^2 = 1$ , assinala um ajuste perfeito do modelo à série histórica.

# Capítulo 6

### **CASOS DE ESTUDO**

Neste capítulo são expostos os casos de estudo, apresentada a formulação dos problemas aos quais se pretende responder bem como, resposta aos objetivos propostos para esta tese. Da mesma forma, são expostos todos os resultados obtidos assim como uma breve análise dos mesmos.

#### 6 Casos de Estudo

#### 6.1 Enquadramento

Como referido anteriormente no subcapítulo 1.1, com os mercados de energia elétrica liberalizados o preço da energia elétrica torna-se imprevisível e instável pois existe bastante concorrência. Além disso o preço apresenta características com um elevado grau de volatilidade e bastante influenciável por diversos fatores, que provém da própria natureza da energia elétrica. Dessa forma, torna-se muito útil a previsão do preço da energia elétrica, de forma tentar contrariar a sua elevada incerteza.

O principal objetivo deste trabalho é efetuar a previsão do preço da energia elétrica, num horizonte temporal de 24h e de 168h através da criação de modelos de previsão com base em expressões matemáticas e apenas com o auxílio da ferramenta computacional *Microsoft Excel* 2010. Os modelos de previsão utilizados são os modelos matemáticos de *Holt-Winters* nas suas diversas variantes como designadas no capítulo 5, tendo como objetivo a escolha da variante do modelo que melhor se adequa à previsão do preço da energia elétrica. Para essa escolha, irão ser feitas comparações entre os modelos, entre o número de observações para a base do modelo, comparações entre alterações de parâmetros, entre outras que serão explicadas no desenvolvimento deste capítulo.

Existe uma vasta bibliografia sobre a previsão do preço da energia elétrica, mas quase na sua totalidade, a previsão é efetuada através de programas/software informáticos prédefinidos para solucionar problemas deste foro. É de salientar que não foi encontrada nenhuma bibliografia sobre a previsão do preço da energia elétrica através de modelos de previsão de *Holt-Winters*. Dessa forma este trabalho recai sobre uma tentativa de uma nova abordagem e será criado de raiz, apenas com a base nas fórmulas matemáticas dos moledos de *Holt-Winters* e da opção *Solver* do *Microsoft Excel* 2010 de forma a otimizar os parâmetros referentes aos modelos.

#### 6.2 Dados e Tratamento de Dados

O principal objetivo desde trabalho é efetuar a previsão do preço da energia elétrica, como tal os modelos construídos para efetuar a previsão assentam numa base que é os próprios dados do preço da energia elétrica (modelos univariados). Os dados referem-se

ao preço da energia elétrica de hora em hora do mercado diário de energia elétrica do MIBEL, desde o dia 1 de Julho de 2007 até 31 de Dezembro de 2012, sendo retirados através da internet no *website* da REN e da OMIE [37] [38].

Para o tratamento dos dados, foi efetuada a separação dos dados pretendidos para cada intervalo de tempo utilizado nos modelos através da ferramenta computacional *Matlab* 7.11.0 (R2010b). Este passo foi necessário uma vez que os ficheiros que contêm os dados possuem informação não só referente ao mercado diário do MIBEL mas também a informação do mercado intradiário do MIBEL, assim como a informação desses mesmos preços da energia elétrica referente a Portugal e a Espanha. Como referido no subcapítulo 2.2, isto deve-se à existência do mercado diário do MIBEL, onde a energia elétrica é transacionada de modo a que seja entregue e satisfeita a procura no dia seguinte ao da negociação sendo o preço formado para cada uma das 24h de cada dia. Por outro lado, existe o mercado intradiário do MIBEL com o objetivo de complementar o mercado diário, onde se efetuam transações de eletricidade de forma a fazer ajustes do mercado diário, existindo seis sessões por dia de negociação. Posto isto, no âmbito desde trabalho os dados que são pretendidos são os do mercado diário e assim foi efetuada a separação desses mesmos dados.

Ainda no tratamento de dados, foram construídas as matrizes necessárias para o cálculo dos valores inicias referidos no subcapítulo 5.4.4 para cada modelo utilizado nas suas diversas variantes, através do auxílio da ferramenta computacional *Matlab* 7.11.0 (R2010b).

#### 6.3 Aplicação dos Modelos às Séries de Dados

De acordo com o referido no capítulo 4, as séries de dados em estudo confirmam a existência de comportamentos cíclicos diários e semanais, ou seja, dupla sazonalidade. Assim, para se efetuar a previsão irão ser utilizados os seguintes modelos:

- Holt-Winters dupla sazonalidade multiplicativa e tendência aditiva.
- Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida.
- Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados.

Irão ser determinado somente dois ciclos, sendo eles o diário e o semanal, sendo que os mesmos são designados por S<sub>1</sub> e S<sub>2</sub>, respetivamente. Sintetizando, o S<sub>1</sub> terá 24 fatores de ciclo diário iniciais, cada um correspondendo a cada hora das 24 horas do dia, e S<sub>2</sub> terá 168 fatores de ciclo semanal iniciais, cada um correspondendo a cada um hora das 168 horas da semana.

Posteriormente à obtenção dos valores iniciais dos parâmetros, é feita a construção dos modelos para vários intervalos temporais e ainda efetuadas diversas simulações de otimização dos parâmetros de alisamento. A otimização dos parâmetros de alisamento  $\alpha$ ,  $\gamma$ ,  $\delta$ ,  $\omega$ ,  $\phi$  e  $\lambda$  foi estimada de acordo com um procedimento de otimização, que tem como objetivo, encontrar a combinação das referidas constantes que minimizem o somatório do erro percentual médio absoluto, designado por (MAPE). A otimização dos parâmetros foi realizada através do *software solver* do *Microsoft Excel* 2010.

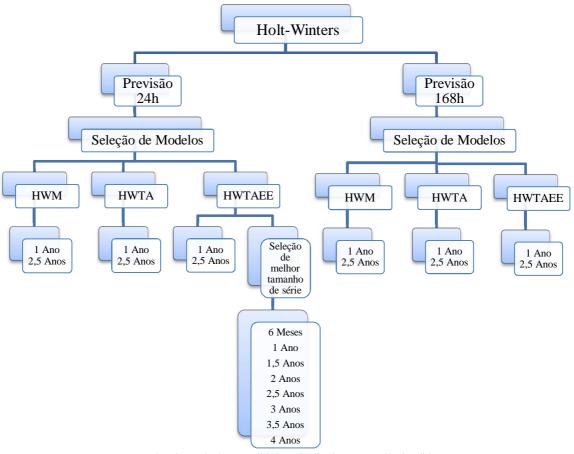
De acordo com os passos anteriores, é efetuada a previsão do preço da energia elétrica para um horizonte temporal de 24h numa primeira fase do caso de estudo (diária) e 168h para uma segunda fase do caso de estudo (semanal), isto para todos os modelos e suas variantes expostas ao longo deste capítulo.

Os modelos serão criados nas suas diversas variantes, estando entre elas diversos intervalos de séries de dados, sendo eles:

- Série de dados com 6 meses e um número de observações de 4032, referentes a Junho de 2012 até Novembro de 2012.
- Série de dados com um ano e um número de observações de 9072, referentes a Novembro de 2011 até Novembro de 2012.
- Série de dados com um ano e meio e um número de observações de 12768, referentes a Junho de 2011 até Novembro de 2012.
- Série de dados com dois anos e um número de observações de 17136, referentes a Novembro de 2010 até Novembro de 2012.
- Série de dados com dois anos e meio e um número de observações de 20160, referentes a Agosto de 2010 até Novembro de 2012.
- Série de dados com três anos e um número de observações de 25872, referentes a Novembro de 2009 até Novembro de 2012
- Série de dados com três anos e meio e um número de observações de 30408, referentes a Junho de 2009 até Novembro de 2012

• Série de dados com quatro anos e um número de observações de 35448, referentes a Novembro de 2008 até Novembro de 2012

A Figura 6.1 apresenta um resumo da estrutura seguida ao longo deste capítulo, de forma a facilitar a compreensão, interpretação e leitura da mesma.



HWM – Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva HWTA - Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida HWTAEE - Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados Figura 6.1 - Resumo da estrutura adotada para o presenta capítulo.

Por forma a poder ser feita uma adequada avaliação da precisão dos modelos e ainda a comparação entre os modelos e suas variantes foram calculados os erros e intervalos de confiança. Os erros foram determinados considerando a série histórica de dados a cada modelo e variante do mesmo, e representam a adequação dos modelos aos dados conforme descritos no subcapítulo 5.5 e ainda determinados os intervalos de confiança das previsões como descritos no subcapítulo 5.6 de forma a complementar a análise dos erros. Deste modo, como já descrito anteriormente o critério de escolha e comparação entre os modelos e suas variantes recaí essencialmente sobre aqueles que apresentam menores medidas de erro, ou seja, quanto mais próximo de zero forem os erros melhor será o modelo.

#### 6.3.1 Previsão Diária Seleção de Modelos.

#### 6.3.1.1 Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva.

Os fatores de ciclo iniciais serão determinados seguindo o procedimento descrito no ponto 5.4.4, e considerando o modelo proposto no subcapítulo 5.4.1.

Neste caso de estudo o modelo foi desenvolvido com uma série de dados referentes a um ano de dados horários desde Novembro de 2011 até Dezembro de 2012 com um número de observações de 9072, e ainda o mesmo modelo mas com uma série de dados referentes a dois anos e meio de dados horários desde Agosto de 2010 até Dezembro de 2012 com um número de observações de 20160. O número de observações apresentado corresponde só ao primeiro modelo criado para o primeiro dia a prever, sendo que o número de observações irá aumentar para cada modelo ao longo de cada dia a prever. É de referir, ainda, que foi necessário otimizar o modelo de cada dia que se pretendia prever, obtendo assim valores diferentes para os parâmetros de amortecimento para cada um dos modelos.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme Tabela 6.1 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis.

Tabela 6.1 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva, referentes ao primeiro dia previsto

	U	R <sup>2</sup>	MAPE	EMA	QME
HW M (1 Anos)	0,000784	0,999999	0,041387%	0,007738	0,000075
HW M (2,5 Anos)	0,000087	1,000000	0,009563%	0,002811	0,000003

Após a execução e otimização destes modelos, é feita a previsão dos sete dias seguintes individualmente a cada dia (24h). Os dias previstos correspondem a domingo dia 2 de Dezembro de 2012 até sábado dia 8 de Dezembro de 2012.

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos na Tabela 6.2 e Tabela 6.3 no que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 9072 e 20160 observações.

Tabela 6.2 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados

Parâmetro	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99954	0,99953	0,99953	0,99953	0,99953	0,99953	0,99953	0,99953
γ	0,00013	0,00013	0,00013	0,00013	0,00013	0,00013	0,00013	0,00013
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,22458	0,22457	0,22457	0,22457	0,22457	0,22457	0,22457	0,22457

Tabela 6.3 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados

Parâmetro	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010

A Figura 6.2 e Figura 6.3 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de dias previstos, respetivamente, para as séries de tamanho 9072 e 20160 observações. Um resumo dos valores de erro obtidos no conjunto dos dias previstos é apresentado na Tabela 6.4 e Tabela 6.5.

#### • Série de dados com um ano e um número de observações de 9072.

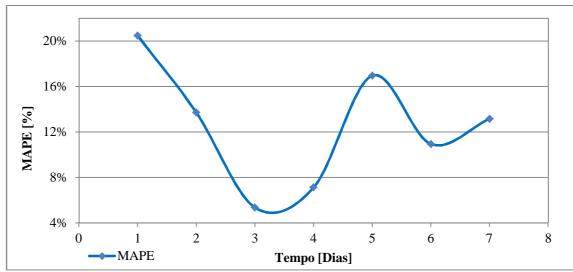


Figura 6.2 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.4 - Erros de previsão ao longo dos sete de previsão

Dia Previsto	MAPE	EMA	QME	U
1	20,47%	9,51	103,43	2,56
2	13,71%	6,98	63,70	1,66
3	5,36%	2,48	11,52	0,63
4	7,13%	3,57	20,19	0,76
5	16,96%	8,32	97,72	2,93
6	10,94%	5,51	43,54	1,69
7	13,17%	6,08	48,20	2,16

#### • Série de dados com dois anos e meio e um número de observações de 20160.

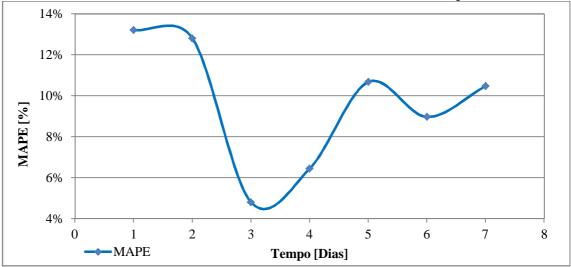


Figura 6.3 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.5 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	13,21%	6,27	48,76	1,71
2	12,81%	6,83	54,69	1,44
3	4,81%	2,36	8,31	0,50
4	6,45%	3,38	18,81	0,72
5	10,68%	5,34	43,14	1,79
6	8,98%	4,58	38,29	1,55
7	10,48%	4,86	29,89	1,69

A Figura 6.4 e Figura 6.5, Figura 6.6 e Figura 6.7, apresentam-nos, respetivamente, para as séries de tamanho 9072 e 20160, os melhores e piores resultados da previsão diária efetuada. Tendo como critério de seleção na escolha da melhor previsão, o valor do MAPE.

#### • Série de dados com um ano e um número de observações de 9072.

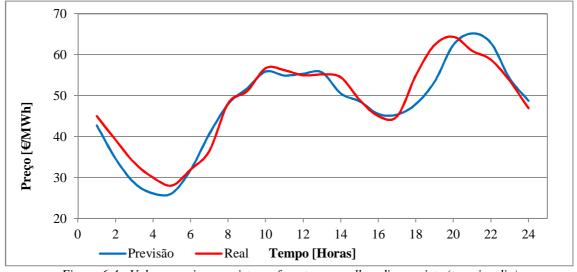


Figura 6.4 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

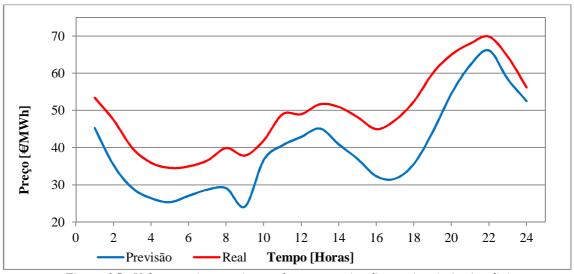


Figura 6.5 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

#### • Série de dados com dois anos e meio e um número de observações de 20160.

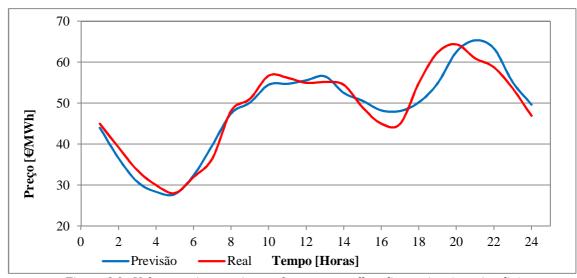


Figura 6.6 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

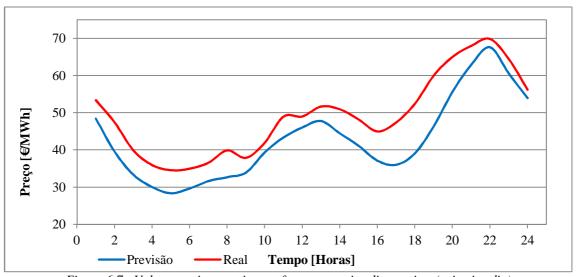


Figura 6.7 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

A Figura 6.8 e Figura 6.9, apresentam os intervalos de confiança das previsões efetuadas, para um valor de 95% respetivamente, para as séries de tamanho 9072 e 20160, referindo-se em ambos os casos à melhor previsão efetuada.

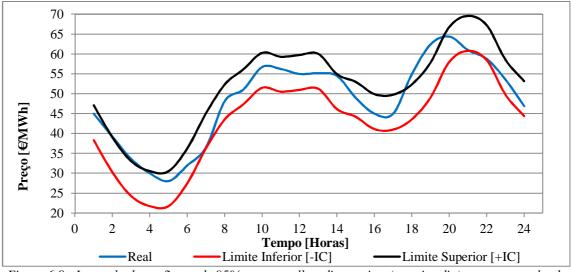


Figura 6.8 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de um ano.

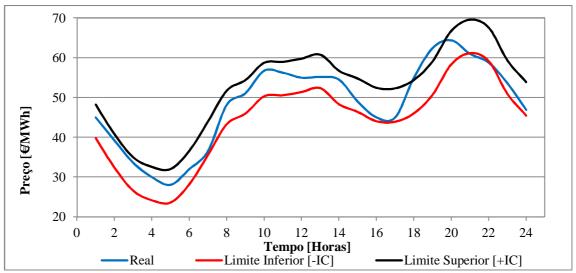


Figura 6.9 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de dois anos e meio.

## 6.3.1.2 Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida.

Neste caso de estudo o modelo foi desenvolvido de forma idêntica ao já referido ponto 6.3.1.1, apenas considerando o modelo proposto no subcapítulo 5.4.2.

Resumidamente, o modelo foi desenvolvido com uma série de dados referentes a um ano de dados horários referentes a um número de observações de 9072, e ainda o

mesmo modelo mas com uma série referente a dois anos e meio de dados horários relativos a um número de observações de 20160. É necessário otimizar o modelo de cada dia que se pretendia prever, obtendo assim valores diferentes para os parâmetros de amortecimento para cada um dos modelos.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme Tabela 6.6 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis.

Tabela 6.6 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida, referentes ao primeiro dia previsto.

	U	$\mathbb{R}^2$	MAPE	EMA	QME
HW TA (1 Anos)	0,000109	1,000000	0,001484%	0,000377	0,0000002
HW TA (2,5 Anos)	0,000103	1,000000	0,001527%	0,000349	0,0000002

Após a execução e otimização destes modelos, é feita a previsão dos sete dias seguintes individualmente a cada dia (24h). Os dias previstos correspondem a domingo dia 2 de Dezembro de 2012 até sábado dia 8 de Dezembro de 2012.

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos na Tabela 6.7 e Tabela 6.8 no que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 9072 e 20160 observações.

Tabela 6.7 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010

Tabela 6.8 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010

A Figura 6.10 e Figura 6.11 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de dias previstos, respetivamente, para as séries de tamanho 9072 e 20160 observações. Um resumo dos erros obtidos no conjunto dos dias previstos é apresentado na Tabela 6.9 e Tabela 6.10.

#### • Série de dados com um ano e um número de observações de 9072.

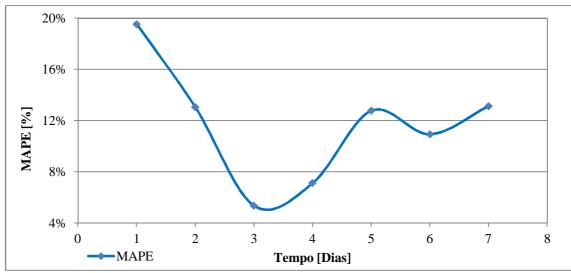


Figura 6.10 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.9 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	19,56%	9,16	96,52	2,44
2	13,06%	6,74	56,57	1,49
3	5,36%	2,48	11,50	0,63
4	7,13%	3,57	20,13	0,76
5	12,78%	6,43	60,60	2,10
6	10,94%	5,51	43,61	1,69
7	13,15%	6,07	48,13	2,15

#### • Série de dados com dois anos e meio e um número de observações de 20160.

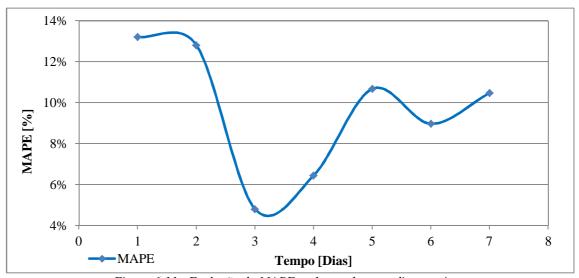


Figura 6.11 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.10 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	13,21%	6,27	48,77	1,71
2	12,81%	6,83	54,69	1,44
3	4,81%	2,36	8,31	0,50
4	6,45%	3,38	18,82	0,72
5	10,68%	5,34	43,14	1,79
6	8,98%	4,58	38,28	1,55
7	10,48%	4,86	29,89	1,69

A Figura 6.12 e Figura 6.13, Figura 6.14 e Figura 6.15, apresentam-nos, respetivamente, para as séries de tamanho 9072 e 20160, os melhores e piores resultados de previsão diária efetuada. Tendo como critério de seleção na escolha da melhor previsão, o valor do MAPE.

#### Série de dados com um ano e um número de observações de 9072.

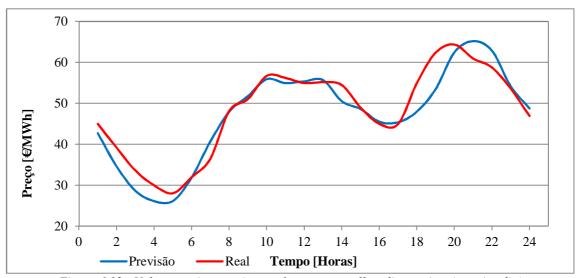


Figura 6.12 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

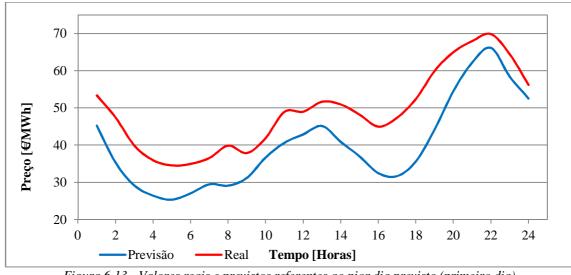


Figura 6.13 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

#### • Série de dados com dois anos e meio e um número de observações de 20160.

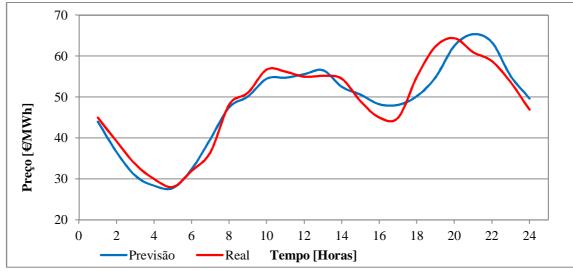


Figura 6.14 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

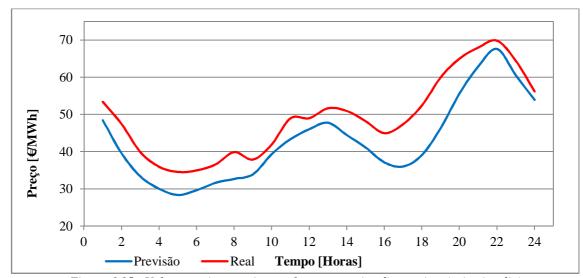


Figura 6.15 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

A Figura 6.16 e Figura 6.17, apresentam os intervalos de confiança das previsões efetuadas, para um valor de 95% respetivamente, para as séries de tamanho 9072 e 20160, referindo-se em ambos os casos à melhor previsão efetuada.

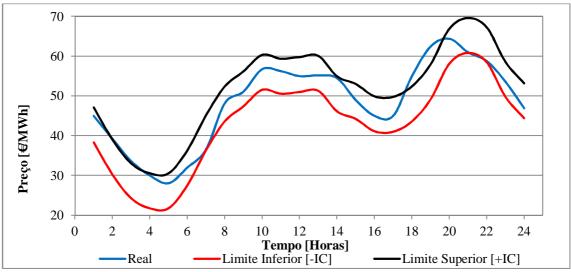


Figura 6.16 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de um ano.

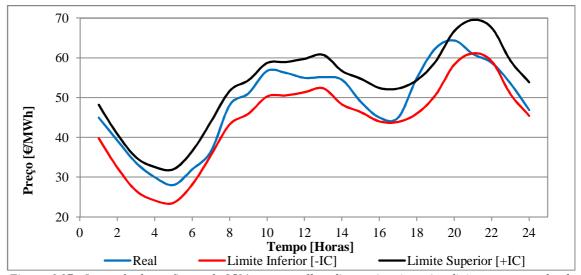


Figura 6.17 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de dois anos e meio.

### 6.3.1.3 Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados.

Neste caso de estudo o modelo foi desenvolvido de forma idêntica ao referido no ponto 6.3.1.1, apenas considerando o modelo proposto no subcapítulo 5.4.3.

Sinteticamente, o modelo foi desenvolvido com uma série de dados referentes a um ano de dados horários referentes a um número de observações de 9072, e ainda o mesmo modelo mas com uma série referente a dois anos e meio de dados horários relativos a um número de observações de 20160. É necessário otimizar o modelo de cada dia que se pretendia prever, obtendo assim valores diferentes para os parâmetros de amortecimento para cada um dos modelos.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme Tabela 6.11 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis.

Tabela 6.11 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados, referentes ao primeiro dia previsto

	U	$\mathbb{R}^2$	MAPE	EMA	QME
HW TAEE (1 Anos)	1,000210	0,881993	12,300401%	2,668460	15,5044429
HW TAEE (2,5 Anos)	0,999959	0,875085	13,273422%	2,422475	14,9089104

Após a execução e otimização destes modelos, é feita a previsão dos sete dias seguintes individualmente a cada dia (24h). Os dias previstos correspondem a domingo dia 2 de Dezembro de 2012 até sábado dia 8 de Dezembro de 2012.

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos na Tabela 6.12 e Tabela 6.13 no que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 9072 e 20160 observações.

Tabela 6.12 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,97234	0,97231	0,97236	0,97229	0,97224	0,92602	0,97098	0,96551
γ	0,72276	0,72277	0,72271	0,72269	0,72294	0,86157	0,72259	0,74258
δ	0,00076	0,00083	0,00080	0,00078	0,00082	0,00859	0,00088	0,00192
ω	0,00668	0,00725	0,00720	0,00735	0,00789	0,01670	0,01071	0,00911
Φ	0,68247	0,68347	0,68325	0,68274	0,68340	0,63468	0,67606	0,67515
λ	0,47337	0,47242	0,47230	0,46987	0,46785	0,47892	0,48241	0,47388

Tabela 6.13 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,51682	0,51682	0,51682	0,51682	0,51682	0,48035	0,51682	0,51161
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00024	0,00024	0,00024	0,00024	0,00024	0,00026	0,00024	0,00024
λ	0,62338	0,62338	0,62338	0,62338	0,62338	0,62366	0,62156	0,62316

A Figura 6.18 e Figura 6.19 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de dias previstos, respetivamente, para as séries de tamanho 9072 e 20160 observações. Um resumo dos erros obtidos no conjunto dos dias previstos é apresentado na Tabela 6.14 e Tabela 6.15.

#### Série de dados com um ano e um número de observações de 9072.

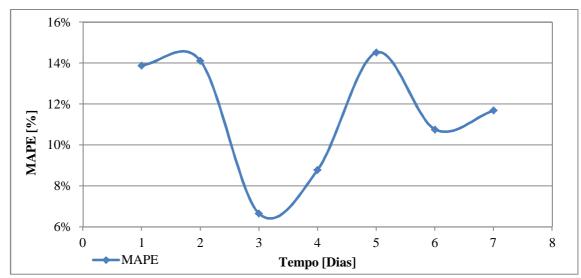


Figura 6.18 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.14 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	13,90%	6,39	55,12	1,89
2	14,12%	7,46	69,39	1,66
3	6,66%	3,23	17,27	0,74
4	8,79%	4,59	32,98	0,95
5	14,52%	7,58	78,20	2,38
6	10,77%	5,63	59,20	1,88
7	11,69%	5,40	37,18	1,92

#### • Série de dados com dois anos e meio e um número de observações de 20160.

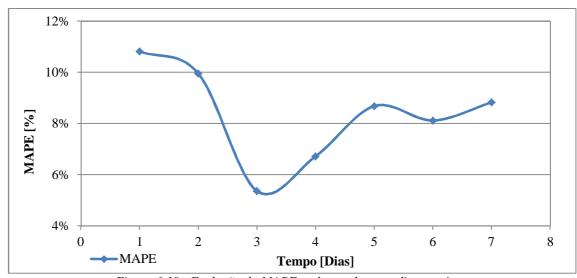


Figura 6.19 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.15 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	10,82%	5,29	40,18	1,54
2	9,95%	5,63	41,49	1,20
3	5,37%	2,55	8,93	1,00
4	6,72%	3,47	18,90	0,72
5	8,69%	4,41	26,91	1,44
6	8,12%	4,29	36,60	1,46
7	8,83%	4,14	20,01	1,40

A Figura 6.20 e Figura 6.21, Figura 6.22 e Figura 6.23, apresentam-nos, respetivamente, para as séries de tamanho 9072 e 20160, os melhores e piores resultados de previsão diária efetuada. Tendo como critério de seleção na escolha da melhor previsão, o valor do MAPE.

#### Série de dados com um ano e um número de observações de 9072.

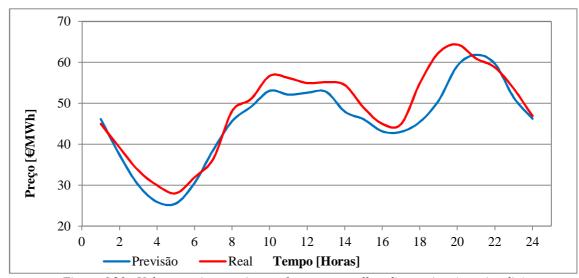


Figura 6.20 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

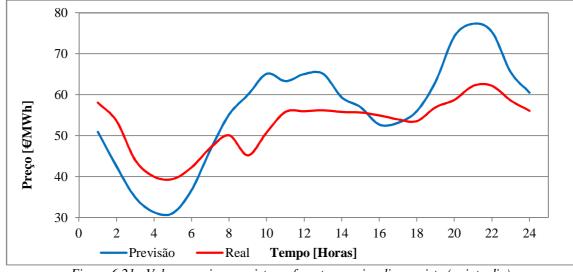


Figura 6.21 - Valores reais e previstos referentes ao pior dia previsto (quinto dia)

#### • Série de dados com dois anos e meio e um número de observações de 20160.

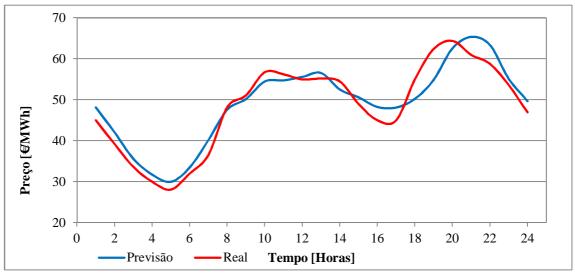


Figura 6.22 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

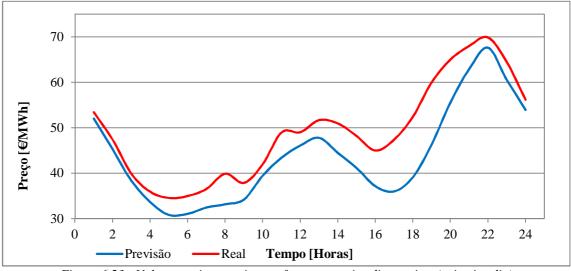


Figura 6.23 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

A Figura 6.24 e Figura 6.25, apresentam os intervalos de confiança das previsões efetuadas, para um valor de 95% respetivamente, para as séries de tamanho 9072 e 20160, referindo-se em ambos os casos à melhor previsão efetuada.

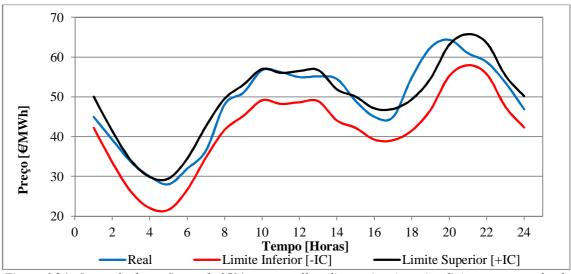


Figura 6.24 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de um ano.

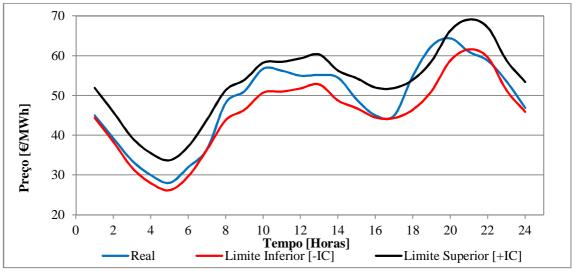


Figura 6.25 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia), com o tamanho de série de dois anos e meio.

#### 6.3.1.4 Comparação do MAPE.

De modo a que seja feita uma melhor análise dos resultados a Figura 6.26 e Figura 6.27, e a Tabela 6.16 e Tabela 6.17 apresentam-nos, respetivamente, para as séries de tamanho 9072 e 20160 observações, os valores dos erros MAPE para os vários modelos. Seguindo o prossuposto em 5.5 e como referido avalia-se que quanto mais próximo de zero esteja o valor do MAPE mais adequados será o método em estudo, refira-se ainda que este é um dos indicadores mais utilizados para aferir a qualidade de um modelo proposto, bem como para estabelecer comparações entre diferentes modelos.

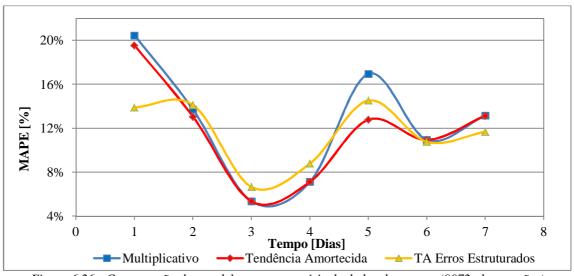


Figura 6.26 - Comparação dos modelos com uma série de dados de um ano (9072 observações)

Tabela 6.16 - Erros e média do erro MAPE dos dias previstos, ao longo dos sete dias, para os três modelos de previsão com um ano de dados

Dia Previsto	HWM	HWTA	HWTAEE
1	20,47%	19,56%	13,90%
2	13,71%	13,06%	14,12%
3	5,36%	5,36%	6,66%
4	7,13%	7,13%	8,79%
5	16,96%	12,78%	14,52%
6	10,94%	10,94%	10,77%
7	13,17%	13,15%	11,69%
Média	12,54%	11,71%	11,49%

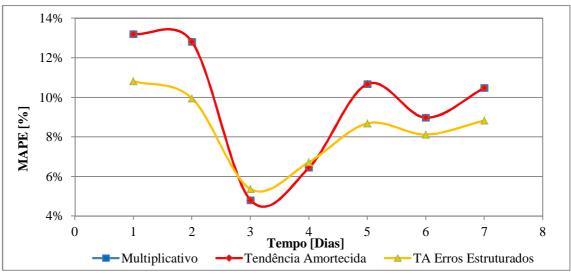


Figura 6.27 - Comparação dos modelos com uma série de dados de dois anos e meio (20160 observações)

Tabela 6.17 - Erros e média do erro MAPE dos dias previstos, ao longo dos sete dias, para os três modelos de previsão com dois anos e meio de dados

Dia Previsto	HWM	HWTA	HWTAEE
1	13,21%	13,21%	10,82%
2	12,81%	12,81%	9,95%
3	4,81%	4,81%	5,37%
4	6,45%	6,45%	6,72%
5	10,68%	10,68%	8,69%
6	8,98%	8,98%	8,12%
7	10,48%	10,48%	8,83%
Média	9,63%	9,63%	8,36%

#### 6.3.2 Previsão Diária via Modelo de Erros Estruturados

Através de uma análise aos pontos anteriores, é possível verificar que o modelo que apresenta melhores resultados é o modelo *Holt-Winters* dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados. Ainda é possível verificar que o intervalo de observações utlizada nos modelos tem influência, dado que o mesmo modelo com um número de observações diferentes (9072 e 20160 observações referentes a um ano e dois anos de dados respetivamente), apresentando melhores resultados os modelos com a série de dados de dois anos e meio.

# 6.3.2.1 Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados com várias séries de tempo diferenciadas no tempo.

Este subcapítulo irá basear-se no modelo *Holt-Winters* dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados dado ser o modelo que apresentou melhores resultados nas previsões efetuadas. Serão criadas várias variantes deste mesmo modelo com a série de dados e diversos intervalos de tempo de modo a efetuar uma análise para verificar qual o intervalo de observações que melhor se adequa ao modelo e produz melhores resultados.

Os fatores de ciclo iniciais serão determinados seguindo o procedimento descrito no ponto 5.4.4, e considerando o modelo proposto no subcapítulo 5.4.3.

O número de observações apresentado corresponde só ao primeiro modelo criado para o primeiro dia a prever, sendo que o número de observações irá aumentar para cada modelo ao longo de cada dia a prever.

Os intervalos de tempo das séries aplicados ao modelo são:

- Série de dados com seis meses e um número de observações de 4032, referentes a Outubro de 2011 até Março de 2012, com o objetivo de ter só dados referentes ao "Inverno" (estação húmida).
- Série de dados com seis meses e um número de observações de 4032, referentes a Junho de 2012 até Novembro de 2012, com o objetivo da previsão ser efetuada coincidente com os outros modelos (estação seca).
- Série de dados com um ano e um número de observações de 9072, referentes a Novembro de 2011 até Novembro de 2012.
- Série de dados com um ano e meio e um número de observações de 12768, referentes a Junho de 2011 até Novembro de 2012.
- Série de dados com dois anos e um número de observações de 17136, referentes a Novembro de 2010 até Novembro de 2012.
- Série de dados com dois anos e meio e um número de observações de 20160, referentes a Agosto de 2010 até Novembro de 2012.
- Série de dados com três anos e um número de observações de 25872, referentes a Novembro de 2009 até Novembro de 2012
- Série de dados com três anos e meio e um número de observações de 30408, referentes a Junho de 2009 até Novembro de 2012
- Série de dados com quatro anos e um número de observações de 35448, referentes a Novembro de 2008 até Novembro de 2012

É de referir ainda que o modelo foi otimizado para cada dia a prever, obtendo-se assim diferentes valores para os parâmetros de amortecimento de cada um dos modelos parametrizados.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme a Tabela 6.18 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis, com especial relevo para os valores de R<sup>2</sup>.

Tabela 6.18 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados, referentes ao primeiro dia previsto

	U	$\mathbb{R}^2$	MAPE	EMA	QME
HW TAEE (6 Meses*)	0,999959	0,870184	28,049698%	2,721076	19,1407816
HW TAEE (6 Meses)	1,281540	0,893174	10,301859%	2,605766	13,5431246
HW TAEE (1 Anos)	1,000210	0,881993	12,300401%	2,668460	15,5044429
HW TAEE (1,5 Anos)	0,999958	0,881439	14,762180%	2,502967	14,3869812
HW TAEE (2 Anos)	0,999962	0,875794	13,501414%	2,433254	15,0820093
HW TAEE (2,5 Anos)	0,999959	0,875085	13,273422%	2,422475	14,9089104
HW TAEE (3 Anos)	1,010326	0,810813	25,041458%	3,808435	40,8010188
HW TAEE (3,5 Anos)	1,016317	0,873822	21,867590%	3,043166	24,0024136
HW TAEE (4 Anos)	1,016966	0,887721	19,528816%	2,942946	22,2981777

Após a execução e otimização destes modelos, é feita a previsão dos sete dias seguintes individualmente a cada dia (24h). Os dias previstos correspondem a domingo dia 2 de Dezembro de 2012 até sábado dia 8 de Dezembro de 2012. Ainda, unicamente para o caso do modelo com a série de dados com 6 meses e um número de observações de 4032, referentes a Outubro de 2011 até Março de 2012, com o objetivo de ter só dados referentes a meses típicos de Inverno para ser feita uma análise específica se existe uma melhoria no modelo, os dias previstos correspondem a sábado dia 31 de Março de 2012 até sexta-feira dia 6 de Abril de 2012.

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos da Tabela 6.19 à Tabela 6.27 o que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 4032 (dois modelos, ambos com seis meses de dados mas diferenciados no tempo), 9072, 12768, 17136, 20160, 25872, 30408 e 35448 observações.

Tabela 6.19 - Parâmetros otimizados individualmente a cada dia com série de 6 meses de dados (Outubro de 2011 até Março de 2012)

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99984	0,99984	0,99984	0,99984	0,99984	0,99984	0,99985
γ	0,28693	0,68894	0,68892	0,68892	0,68892	0,68892	0,68892	0,63150
δ	0,01994	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00293
w	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Ф	0,00017	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00011
λ	0,67917	0,63277	0,63461	0,63474	0,63576	0,63637	0,63677	0,64146

Tabela 6.20 - Parâmetros otimizados individualmente a cada dia com série de 6 meses de dados (Junho de 2012 até Novembro de 2012)

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,90925	0,91056	0,90940	0,91013	0,90983	0,91069	0,91253	0,91034
γ	0,89683	0,89447	0,89876	0,89538	0,89701	0,90329	0,90648	0,89889
δ	0,02168	0,02181	0,02239	0,02192	0,02129	0,02150	0,02242	0,02186
ω	0,03473	0,03049	0,01893	0,02255	0,02885	0,01991	0,02216	0,02538
Φ	0,79096	0,79225	0,79103	0,79182	0,79122	0,79186	0,79313	0,79175
λ	0,37481	0,37665	0,37557	0,37479	0,37571	0,38289	0,39025	0,37867

Tabela 6.21 - Parâmetros otimizados individualmente a cada dia com série de 1 ano de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,97234	0,97231	0,97236	0,97229	0,97224	0,92602	0,97098	0,96551
γ	0,72276	0,72277	0,72271	0,72269	0,72294	0,86157	0,72259	0,74258
δ	0,00076	0,00083	0,00080	0,00078	0,00082	0,00859	0,00088	0,00192
ω	0,00668	0,00725	0,00720	0,00735	0,00789	0,01670	0,01071	0,00911
Φ	0,68247	0,68347	0,68325	0,68274	0,68340	0,63468	0,67606	0,67515
λ	0,47337	0,47242	0,47230	0,46987	0,46785	0,47892	0,48241	0,47388

Tabela 6.22 - Parâmetros otimizados individualmente a cada dia com série de 1,5 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,51674	0,51674	0,51674	0,51674	0,51674	0,51674	0,51674	0,51674
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030	0,00030
λ	0,59970	0,59970	0,59970	0,59970	0,59970	0,59970	0,59970	0,59970

Tabela 6.23 - Parâmetros otimizados individualmente a cada dia com série de 2 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,51682	0,51682	0,51682	0,51682	0,51682	0,51682	0,51682	0,51682
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00035	0,00035	0,00035	0,00035	0,00035	0,00035	0,00035	0,00035
λ	0,62652	0,62652	0,62652	0,62652	0,62652	0,62652	0,62652	0,62652

Tabela 6.24 - Parâmetros otimizados individualmente a cada dia com série de 2,5 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,51682	0,51682	0,51682	0,51682	0,51682	0,48035	0,51682	0,51161
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00024	0,00024	0,00024	0,00024	0,00024	0,00026	0,00024	0,00024
λ	0,62338	0,62338	0,62338	0,62338	0,62338	0,62366	0,62156	0,62316

Tabela 6.25 - Parâmetros otimizados individualmente a cada dia com série de 3 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,92044	0,99388	0,99388	0,99388	0,99388	0,99388	0,99388	0,98339
γ	0,83463	0,76099	0,76099	0,76099	0,76099	0,76099	0,76099	0,77151
δ	0,00417	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00068
ω	0,01607	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00238
Φ	0,80030	0,77958	0,77958	0,77958	0,77958	0,77958	0,77958	0,78254
λ	0,31528	0,22061	0,22061	0,22061	0,22061	0,22061	0,22061	0,23413

Tabela 6.26 - Parâmetros otimizados individualmente a cada dia com série de 3,5 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média	
α	0,97292	0,97292	0,97291	0,97291	0,97291	0,97291	0,97291	0,97291	
γ	0,87342	0,87342	0,87343	0,87342	0,87345	0,87342	0,87344	0,87343	
δ	0,00026	0,00026	0,00026	0,00026	0,00026	0,00026	0,00026	0,00026	
w	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	
Φ	0,80481	0,80479	0,80479	0,80478	0,80481	0,80481	0,80478	0,80480	
λ	0,29801	0,29799	0,29800	0,29797	0,29802	0,29800	0,29799	0,29800	

Tabela 6.27 - Parâmetros otimizados individualmente a cada dia com série de 4 anos de dados

Parâmetros	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5	Dia 6	Dia 7	Média
α	0,97343	0,97359	0,97359	0,97359	0,97359	0,97361	0,97361	0,97357
γ	0,88086	0,88313	0,88313	0,88313	0,88313	0,88341	0,88341	0,88288
δ	0,00033	0,00033	0,00033	0,00033	0,00033	0,00033	0,00033	0,00033
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,81282	0,81536	0,81536	0,81536	0,81536	0,81575	0,81575	0,81511
λ	0,31881	0,32253	0,32253	0,32253	0,32253	0,32305	0,32305	0,32215

De modo a que seja feita uma melhor análise dos resultados a Tabela 6.28 apresenta, em uma única tabela, a média dos parâmetros otimizados para o modelo *Holt-Winters* dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados com os diversos tamanhos de séries referidos anteriormente.

Tabela 6.28 - Média dos parâmetros otimizados para o modelo HWTAEE com diversos tamanhos de série

Par.	6 Meses*	6 Meses	1 Ano	1,5 Anos	2 Anos	2,5 Anos	3 Anos	3,5 Anos	4 Anos
α	0,99985	0,91034	0,96551	0,99990	0,99990	0,99990	0,98339	0,97291	0,97357
γ	0,63150	0,89889	0,74258	0,51674	0,51682	0,51161	0,77151	0,87343	0,88288
δ	0,00293	0,02186	0,00192	0,00010	0,00010	0,00010	0,00068	0,00026	0,00033
ω	0,00010	0,02538	0,00911	0,00010	0,00010	0,00010	0,00238	0,00010	0,00010
Φ	0,00011	0,79175	0,67515	0,00030	0,00035	0,00024	0,78254	0,80480	0,81511
λ	0,64146	0,37867	0,47388	0,59970	0,62652	0,62316	0,23413	0,29800	0,32215

Da Figura 6.28 à Figura 6.36 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de dias previstos, respetivamente, para as séries de tamanho 4032 (dois modelos, ambos com seis meses de dados mas diferenciados no tempo), 9072, 12768, 17136, 20160, 25872, 30408 e 35448 observações. Um resumo dos erros obtidos no conjunto dos dias previstos é apresentado da Tabela 6.29 à Tabela 6.37.

• Série de dados com seis meses e um número de observações de 4032, referentes a Outubro de 2011 até Março de 2012

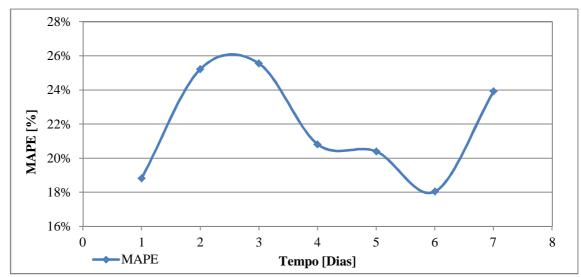


Figura 6.28 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.29 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	18,83%	8,95	106,35	2,65
2	25,23%	11,69	175,56	1,27
3	25,55%	14,16	275,09	2,80
4	20,82%	10,71	151,89	1,15
5	20,40%	10,64	161,92	1,17
6	18,05%	8,37 103,26		1,04
7	23,92%	11,28		

• Série de dados com seis meses e um número de observações de 4032, referentes a Junho de 2012 até Novembro de 2012

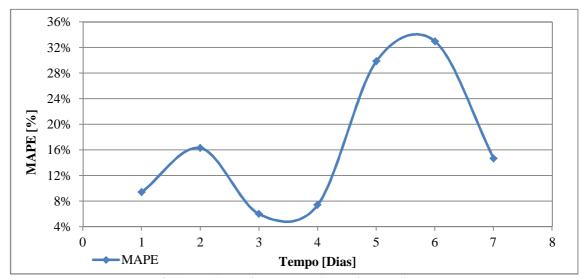


Figura 6.29 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.30 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	sto MAPE EMA QM		QME	U
1	9,41%	5,11	62,33	1,48
2	16,31%	8,97	102,99	2,01
3	6,00%	3,03	16,37	0,66
4	7,42%	3,67	22,11	0,77
5	29,89%	16,19	326,02	4,70
6	32,99%	17,98	429,65	4,93
7	14,69%	7,39	79,54	2,57

# • Série de dados com um ano e um número de observações de 9072

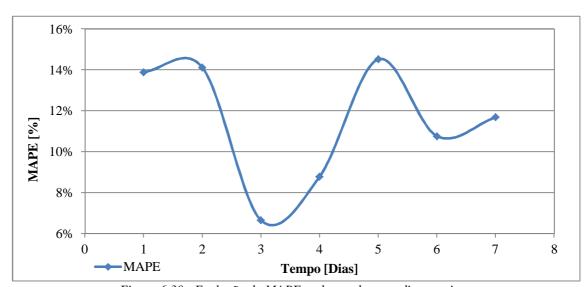


Figura 6.30 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.31 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	EMA QME	
1	13,90%	6,39	55,12	1,89
2	14,12%	7,46	69,39	1,66
3	6,66%	3,23	17,27	0,74
4	8,79%	4,59	32,98	0,95
5	14,52%	7,58	78,20	2,38
6	10,77%	5,63	59,20	1,88
7	11,69%	5,40	37,18	1,92

# • Série de dados com um ano e meio e um número de observações de 12768.

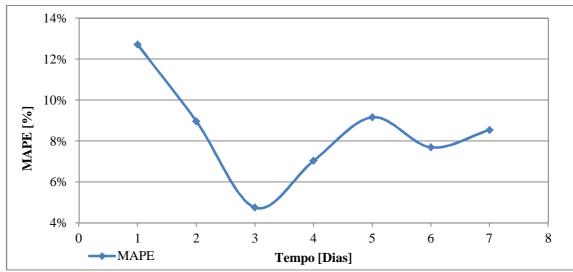


Figura 6.31 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.32 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	12,71%	6,30	53,28	1,74
2	8,97%	5,03	32,71	1,08
3	4,75%	2,28	9,33	0,54
4	7,04%	3,64	21,86	0,75
5	9,16%	4,63	30,07	1,54
6	7,70%	4,08	30,27	1,32
7	8,55%	3,97	19,41	1,38

# • Série de dados com dois anos e um número de observações de 17136.

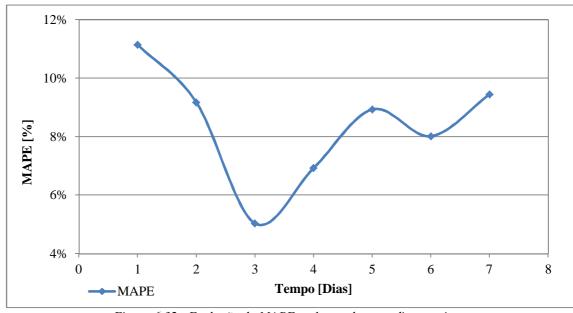


Figura 6.32 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.33 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	11,14%	5,44	41,74	1,57
2	9,17%	5,19	35,82	1,10
3	5,03%	2,98	12,64	0,53
4	6,93%	3,58	19,82	0,74
5	8,93%	4,52	28,53	1,49
6	8,02%	1,88	7,75	1,40
7	9,45%	4,44	22,87	1,49

# •Série de dados com dois anos e meio e um número de observações de 20160.

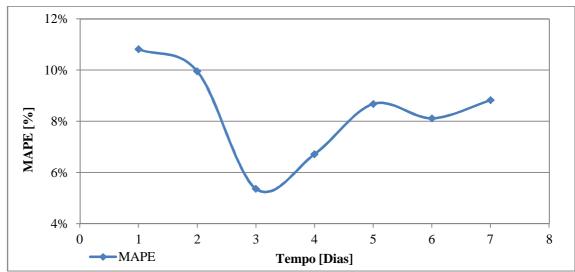


Figura 6.33 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.34 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE EMA QME		U	
1	10,82%	5,29	40,18	1,54
2	9,95%	5,63	41,49	1,20
3	5,37%	2,55	8,93	1,00
4	6,72%	3,47	18,90	0,72
5	8,69%	4,41	26,91	1,44
6	8,12%	4,29	36,60	1,46
7	8,83%	4,14	20,01	1,40

# • Série de dados com três anos e um número de observações de 25872.

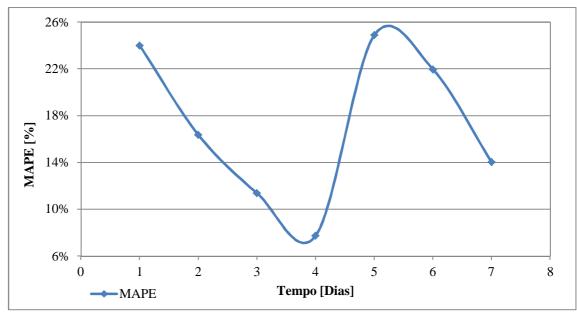


Figura 6.34 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.35 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U	
1	24,00%	12,36	267,90	3,36	
2	16,37%	8,67	93,89	1,88	
3	11,39%	3,96	25,89	1,20	
4	7,75%	3,62	21,15	0,83	
5	24,89%	13,42	250,00	4,06	
6	21,96%	11,80	264,66	3,88	
7	14,03%	6,67	76,90	2,58	

# • Série de dados com três anos e meio e um número de observações de 30408.

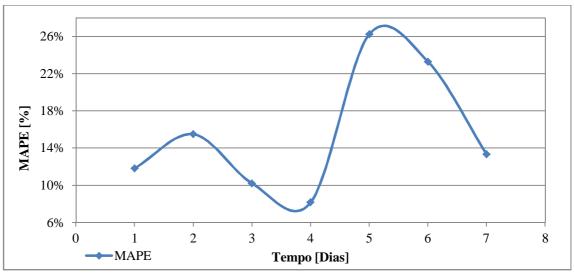


Figura 6.35 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.36 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	11,84%	6,18	66,87	1,64
2	15,49%	8,21	84,10	1,80
3	10,23%	5,01	45,51	1,05
4	8,18%	3,76	20,08	0,88
5	26,25%	14,20	272,43	4,24
6	23,29%	12,61	286,11	4,03
7	13,35%	1,91	5,49	2,48

## • Série de dados com quatro anos e um número de observações de 35448.

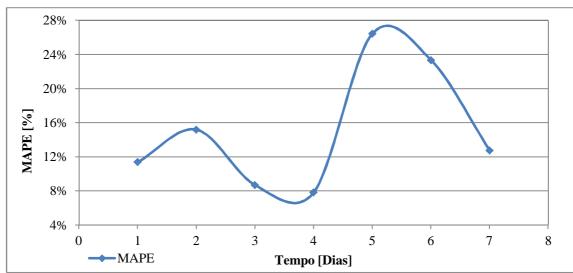


Figura 6.36 - Evolução do MAPE ao longo dos sete dias previstos

Tabela 6.37 - Erros de previsão ao longo dos sete dias previstos

Dia Previsto	MAPE	EMA	QME	U
1	11,39%	6,02	65,46	1,59
2	15,20%	8,18	80,87	1,74
3	8,71%	4,32	35,52	0,92
4	7,85%	3,73	19,64	0,84
5	26,45%	14,41	289,97	4,36
6	23,36%	12,82	305,95	4,14
7	12,78%	6,09	64,88	2,35

Da Figura 6.37 à Figura 6.54, apresentam-nos, para as séries de tamanho 4032 (dois modelos, ambos com seis meses de dados mas diferenciados no tempo), 9072, 12768, 17136, 20160, 25872, 30408 e 35448 observações, os melhores e piores resultados de previsão diária efetuada. Tendo como critério de seleção na escolha da melhor previsão, o valor do MAPE.

# • Série de dados com seis meses e um número de observações de 4032, referentes a Outubro de 2011 até Março de 2012

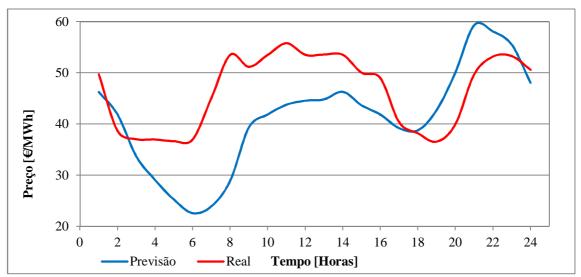


Figura 6.37 - Valores reais e previstos referentes ao melhor dia previsto (sexto dia)

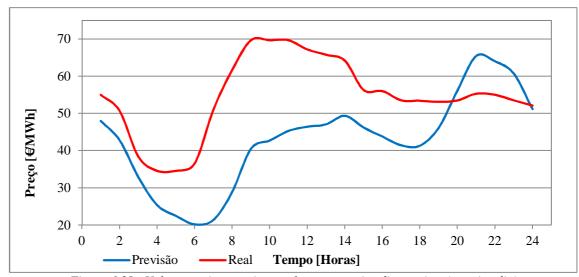


Figura 6.38 - Valores reais e previstos referentes ao pior dia previsto (terceiro dia)

# •Série de dados com seis meses e um número de observações de 4032, referentes a Junho de 2012 até Novembro de 2012

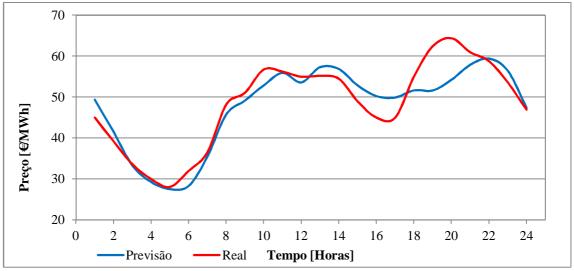


Figura 6.39 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

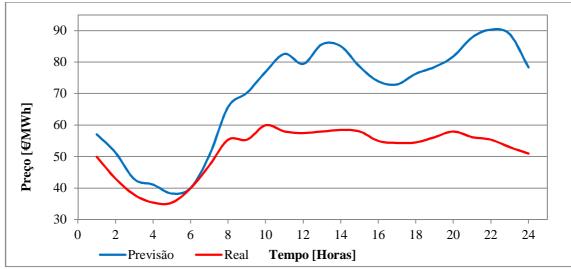


Figura 6.40 - Valores reais e previstos referentes ao pior dia previsto (sexto dia)

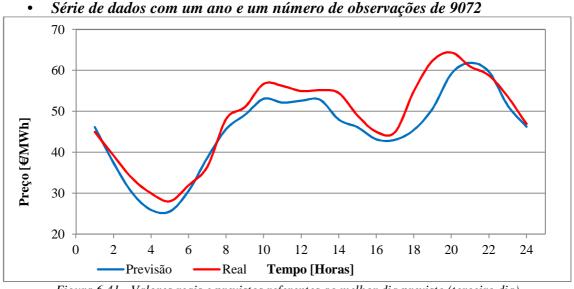


Figura 6.41 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

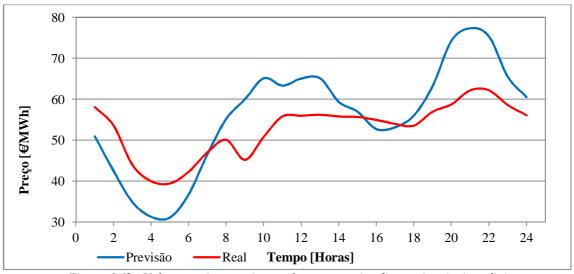


Figura 6.42 - Valores reais e previstos referentes ao pior dia previsto (quinto dia)

# •Série de dados com um ano e meio e um número de observações de 12768.

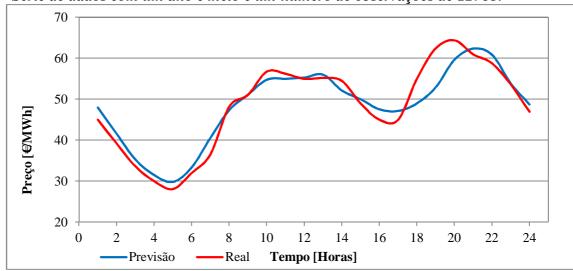


Figura 6.43 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

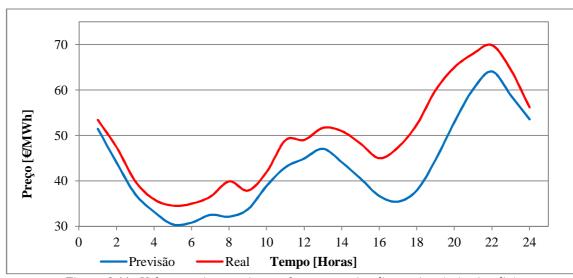


Figura 6.44 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

# • Série de dados com dois anos e um número de observações de 17136.

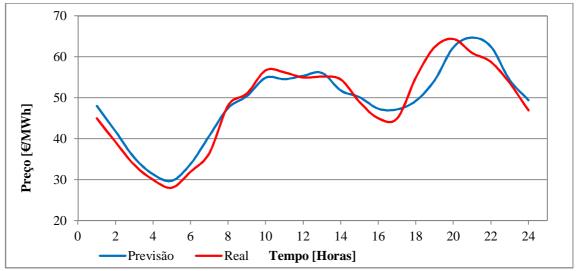


Figura 6.45 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

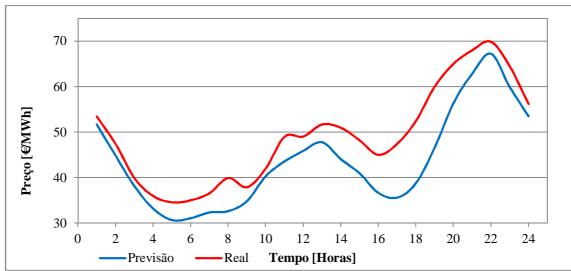


Figura 6.46 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

# • Série de dados com dois anos e meio e um número de observações de 20160.

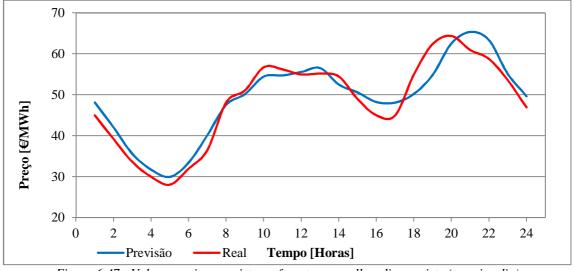


Figura 6.47 - Valores reais e previstos referentes ao melhor dia previsto (terceiro dia)

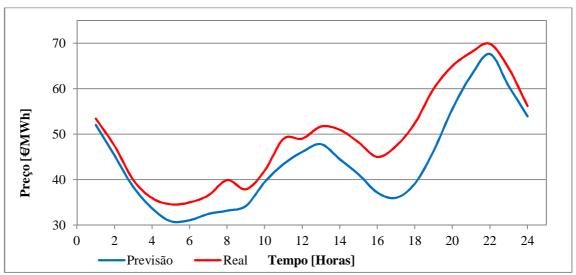


Figura 6.48 - Valores reais e previstos referentes ao pior dia previsto (primeiro dia)

• Série de dados com três anos e um número de observações de 25872.

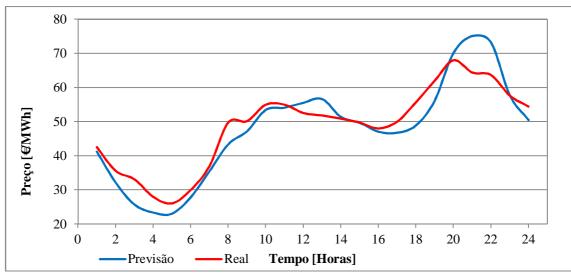


Figura 6.49 - Valores reais e previstos referentes ao melhor dia previsto (quarto dia)

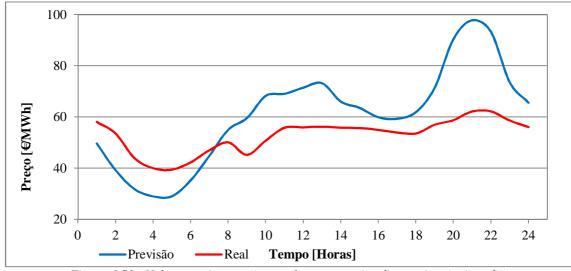


Figura 6.50 - Valores reais e previstos referentes ao pior dia previsto (quinto dia)

# • Série de dados com três anos e meio e um número de observações de 30408.

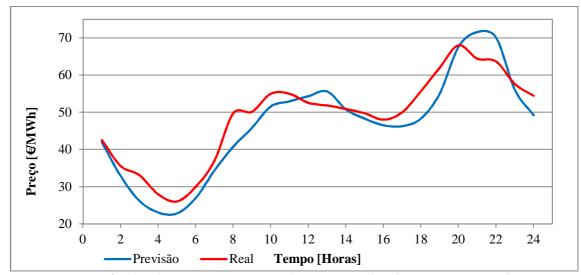


Figura 6.51 - Valores reais e previstos referentes ao melhor dia previsto (quarto dia)

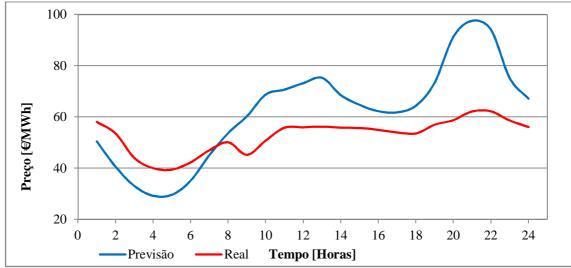


Figura 6.52 - Valores reais e previstos referentes ao pior dia previsto (quinto dia)

# •Série de dados com quatro anos e um número de observações de 35448.

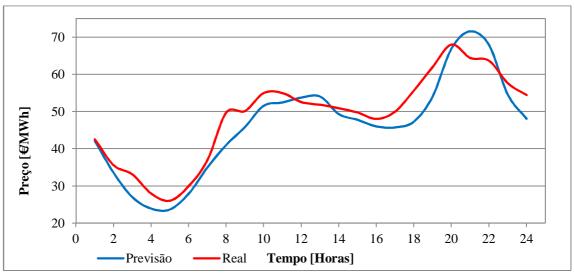


Figura 6.53 - Valores reais e previstos referentes ao melhor dia previsto (quarto dia)

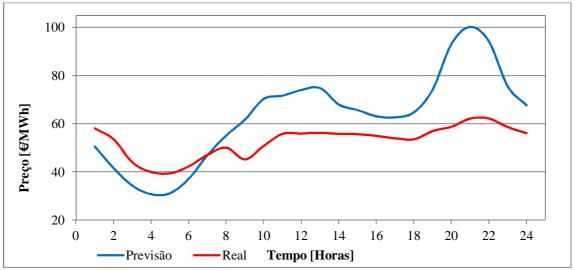


Figura 6.54 - Valores reais e previstos referentes ao pior dia previsto (quinto dia)

# 6.3.2.2 Comparação do erro MAPE.

De modo a que seja feita uma melhor análise dos resultados a Figura 6.55 e Figura 6.56, e a Tabela 6.38 apresentam-nos, para diversos tamanho de séries, os valores dos erro MAPE para os diversos modelos. Seguindo o prossuposto em 5.5 e como referido avalia-se que quanto mais próximo de zero esteja o valor do MAPE mais adequados será o método em estudo, refira-se ainda que este é um dos indicadores mais utilizados para aferir a qualidade de um modelo proposto, bem como para estabelecer comparações entre diferentes modelos.

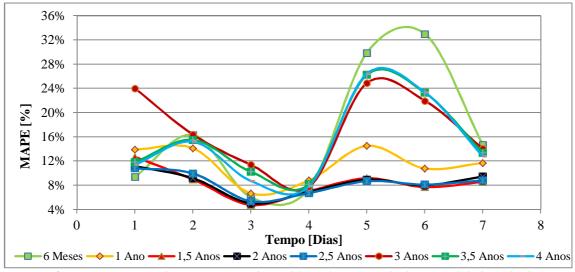


Figura 6.55 - Comparação dos erros MAPE do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados com várias séries de tempo diferenciadas no tempo.

Tabela 6.38 - Erros e média de erros MAPE do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados com várias séries de tempo diferenciadas no tempo.

Dia Previsto	6 Meses	1 Anos	1,5 Anos	2 Anos	2,5 Anos	3 Anos	3,5 Anos	4 Anos
1	9,41%	13,90%	12,71%	11,14%	10,82%	24,00%	11,84%	11,39%
2	16,31%	14,12%	8,97%	9,17%	9,95%	16,37%	15,49%	15,20%
3	6,00%	6,66%	4,75%	5,03%	5,37%	11,39%	10,23%	8,71%
4	7,42%	8,79%	7,04%	6,93%	6,72%	7,75%	8,18%	7,85%
5	29,89%	14,52%	9,16%	8,93%	8,69%	24,89%	26,25%	26,45%
6	32,99%	10,77%	7,70%	8,02%	8,12%	21,96%	23,29%	23,36%
7	14,69%	11,69%	8,55%	9,45%	5,89%	14,03%	13,35%	12,78%
Média	16,67%	11,49%	8,41%	8,38%	7,94%	17,20%	15,52%	15,11%

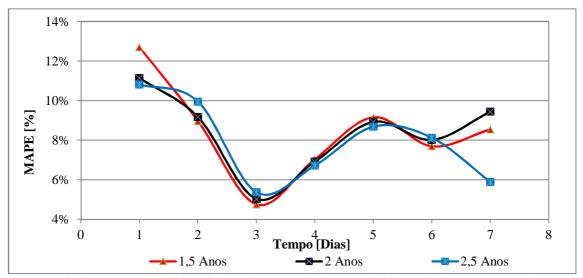


Figura 6.56 - Comparação do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados dos melhores resultados.

# 6.3.2.3 Intervalo de confiança

Os intervalos de confiança foram calculados para todos os modelos e suas diversas variantes seguindo o pressuposto no subcapítulo 5.6. Neste subcapítulo apenas são apresentados, intervalos de confiança para os modelos que apresentam um melhor desempenho na previsão, sendo eles os *Holt-Winters* dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados referentes às séries de tempo de um ano e meio, dois anos e ainda dois anos e meio de dados. Da Figura 6.57 à Figura 6.62, apresentam-se os intervalos de confiança das previsões efetuadas, para um valor de 95%, das séries de tamanho 12768, 17136 e 20160 observações, referindo-se aos melhores e piores dias previstos.

# • Série de dados com um ano e meio e um número de observações de 12768.

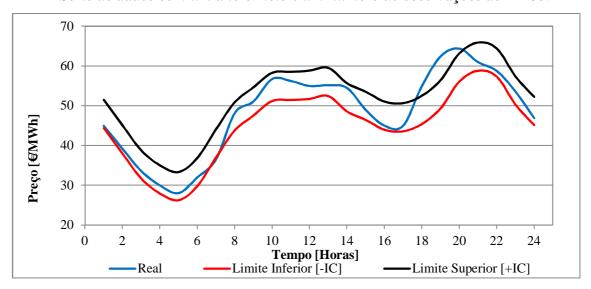


Figura 6.57 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia)

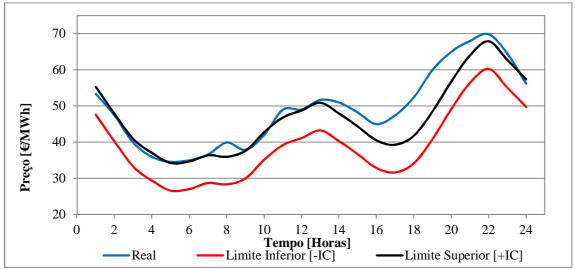


Figura 6.58 - Intervalo de confiança de 95% para o pior dia previsto (primeiro dia)

# •Série de dados com dois anos e um número de observações de 17136

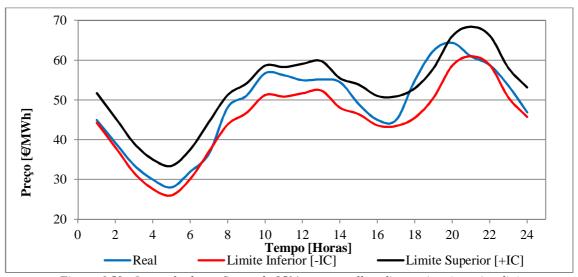


Figura 6.59 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia)

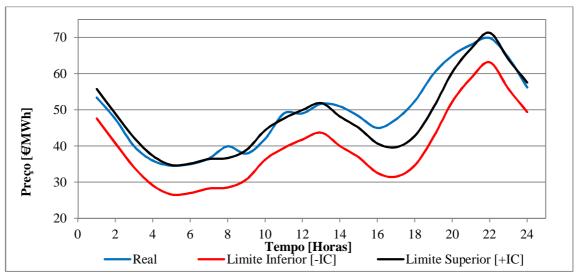


Figura 6.60 - Intervalo de confiança de 95% para o pior dia previsto (primeiro dia)

# Série de dados com dois anos e meio e um número de observações de 20160.

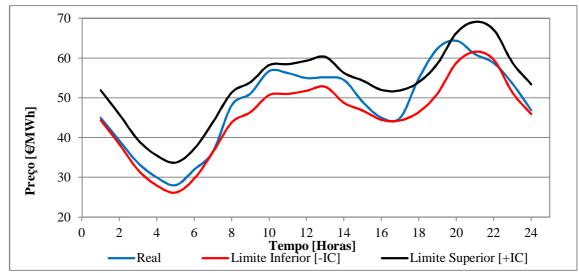


Figura 6.61 - Intervalo de confiança de 95% para o melhor dia previsto (terceiro dia)

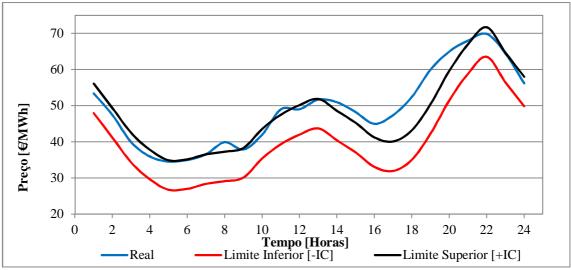


Figura 6.62 - Intervalo de confiança de 95% para o pior dia previsto (primeiro dia)

# 6.3.2.4 Evolução horária do erro quadrático (QE)

De modo a efetuar uma análise que permita retirar ilações acerca das horas mais difíceis de prever ao longo do dia, da Figura 6.63 à Figura 6.65 apresentam a evolução horária do erro quadrático (QE), respetivamente referentes:

- Ao longo do conjunto dos sete dias previstos do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados para as séries de tamanho 12768, 17136 e 20160 observações.
- Terceiro dia previso do modelo *Holt-Winters* dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados para diversos tamanhos de séries.
- Três dias previstos distintos do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados para a série de tamanho 20160 observações.

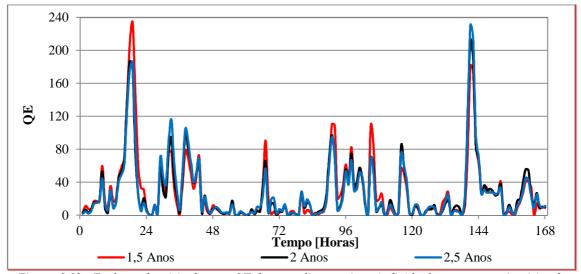


Figura 6.63 - Evolução horária do erro QE dos sete dias previstos individualmente, com três séries de tempo diferentes para o modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados

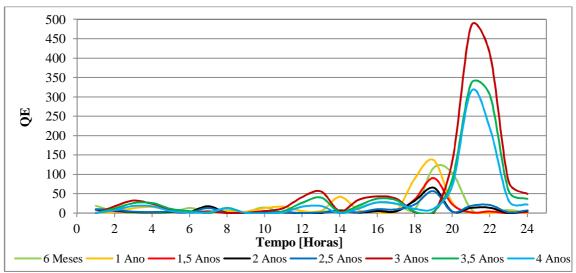


Figura 6.64 - Evolução horária do erro QE do terceiro dia previsto para o modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados para diversos tamanhos de série.

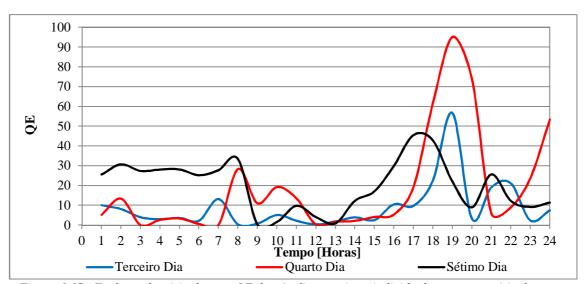


Figura 6.65 - Evolução horária do erro QE de três dias previstos individualmente, com série de tempo com 2 anos e meios para o modelo Holt-Winters dupla sazonalidade multiplicativa com tendência suavizada e erros estruturados

Através da análise da Figura 6.63 à Figura 6.65 verifica-se que nos diferentes dias para os quais se efetuaram previsões, o valor do QE é semelhante e de maior amplitude no intervalo de horas aproximadamente compreendido entre as 17h e as 23h. Uma possível explicação para este acontecimento, é o fato que nesse intervalo de horas corresponder aproximadamente ao designado por, horas de ponta da tarde do consumo de energia elétrica, tornando o valor do preço da energia elétrica ainda mais volátil e incerto.

#### 6.3.3 Previsão Semanal Seleção de Modelos.

# 6.3.3.1 Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva.

Os fatores de ciclo iniciais serão determinados seguindo o procedimento descrito no ponto 5.4.4, e considerando o modelo proposto no subcapítulo 5.4.1.

Neste caso de estudo o modelo foi desenvolvido com uma série de dados referentes a um ano de dados horários desde Novembro de 2011 até Outubro de 2012 com um número de observações de 8400, e ainda o mesmo modelo mas com uma série de dados referentes a dois anos e meio de dados horários desde Agosto de 2010 até Outubro de 2012 com um número de observações de 19488. O número de observações apresentado corresponde só ao primeiro modelo criado para a primeira semana a prever, sendo que o número de observações irá aumentar para cada modelo ao longo de cada semana a prever. É de referir ainda que foi necessário otimizar o modelo de cada semana que se pretendia prever, obtendo assim valores diferentes para os parâmetros de amortecimento para cada um dos modelos.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme Tabela 6.39 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis.

Tabela 6.39 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência aditiva, referentes à primeira semana prevista

	U	$\mathbb{R}^2$	MAPE	EMA	QME
HW M (1 Anos)	0,000777	0,999999	0,044472%	0,008466	0,000086
HW M (2,5 Anos)	0,000061	1,000000	0,009537%	0,002850	0,000011

Após a execução e otimização destes modelos, é efetuada a previsão das cinco semanas seguintes individualmente a cada semana (168h). As semanas previstas correspondem às seguintes semanas:

- 4 a 10 de Novembro de 2012
- 11 a 17 de Novembro de 2012
- 18 a 24 de Novembro de 2012
- 25 de Novembro a 1 de Dezembro de 2012
- 2 a 8 de Dezembro de 2012

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos na Tabela 6.40 e Tabela 6.41 no que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 8400 e 19488 observações.

Tabela 6.40 - Parâmetros otimizados individualmente a cada semana com série de 1 ano de dados

Parâmetro	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Média
α	0,99954	0,99954	0,99954	0,99954	0,99954	0,99954
γ	0,00011	0,00012	0,00012	0,00013	0,00011	0,00012
δ	0,18090	0,20706	0,11112	0,00645	0,18090	0,13729
ω	0,42981	0,22701	0,22954	0,32628	0,42981	0,32849

Tabela 6.41 - Parâmetros otimizados individualmente a cada semana com série de 2,5 anos de dados

Parâmetro	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
δ	0,13470	0,13129	0,12751	0,12571	0,12288	0,12842
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010

A Figura 6.66 e Figura 6.67 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de semanas previstas, respetivamente, para as séries de tamanho 8400 e 19488observações. Um resumo dos erros obtidos no conjunto dos dias previstos é apresentado na Tabela 6.42 e Tabela 6.43.

## • Série de dados com um ano e um número de observações de 8400.

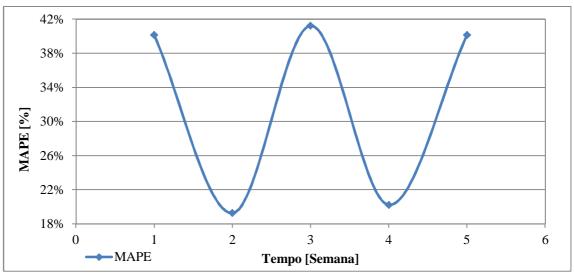


Figura 6.66 - Evolução do MAPE ao longo das cinco semanas previstas

Tabela 6.42 - Erros de previsão ao longo das cinco semanas previstas

Semana Prevista	MAPE	EMA	QME	U
1	40,16%	9,64	140,70	0,65
2	19,28%	7,74	86,48	1,46
3	41,23%	9,44	128,81	1,36
4	20,24%	6,82	69,89	1,93
5	40,16%	9,64	140,70	1,83

# Série de dados com dois anos e meio e um número de observações de 19488.

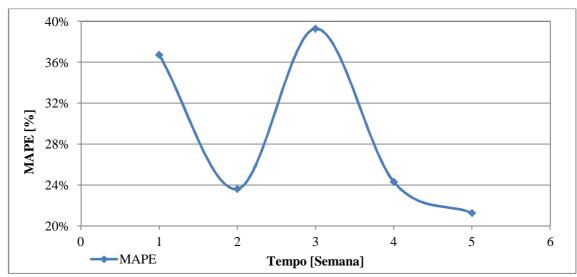


Figura 6.67 - Evolução do MAPE ao longo das cinco semanas previstas

Tabela 6.43 - Erros de previsão ao longo das cinco semanas previstas

Semana Prevista	MAPE	EMA	QME	U
1	36,74%	10,16	168,24	0,59
2	23,64%	9,01	124,13	1,83
3	39,30%	10,74	183,86	1,05
4	24,32%	8,93	123,17	1,81
5	21,28%	9,63	152,78	3,15

A Figura 6.68 e Figura 6.69, Figura 6.70 e Figura 6.71 apresentam-nos, respetivamente, para as séries de tamanho 8400 e 19488, os melhores e piores resultados de previsão semanal efetuada. Tendo como critério de seleção na escolha da qualidade de previsão, o valor do MAPE.

# Série de dados com um ano e um número de observações de 8400.

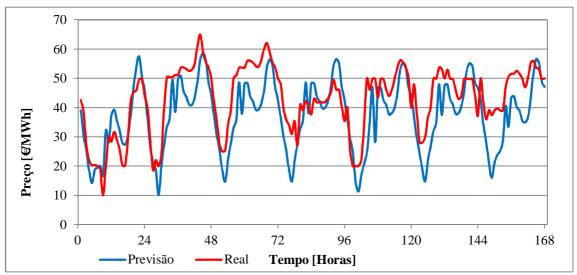


Figura 6.68 - Valores reais e previstos referentes à melhor semana prevista (segunda semana)

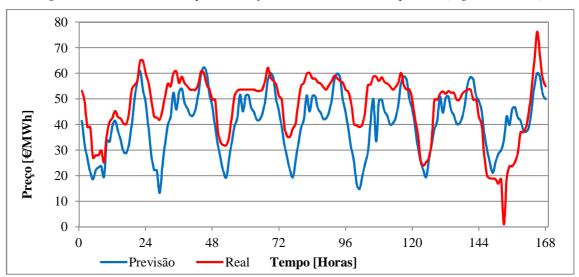


Figura 6.69 - Valores reais e previstos referentes à pior semana prevista (terceira semana)

# Série de dados com dois anos e meio e um número de observações de 19488.

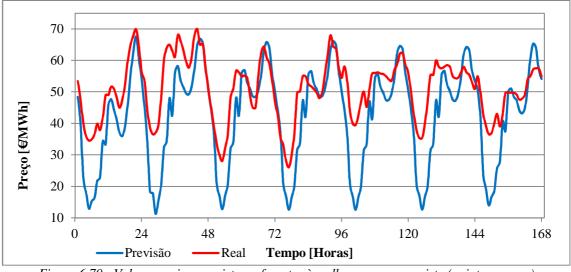


Figura 6.70 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)

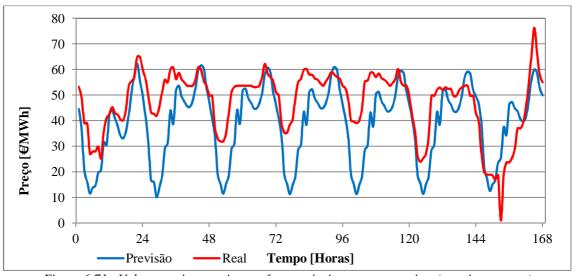


Figura 6.71 - Valores reais e previstos referentes à pior semana prevista (terceira semana)

# 6.3.3.2 Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida.

Neste caso de estudo o modelo foi desenvolvido identicamente ao ponto 6.3.3.1, apenas considerando o modelo proposto no subcapítulo 5.4.2.

Resumidamente, o modelo foi desenvolvido com uma série de dados referentes a um ano de dados horários referentes a um número de observações de 8400, e ainda o mesmo modelo mas com uma série referente a dois anos e meio de dados horários relativos a um número de observações de 19488. É necessário otimizar o modelo de cada semana que se pretendia prever, obtendo assim valores diferentes para os parâmetros de amortecimento para cada um dos modelos.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme Tabela 6.44 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis.

Tabela 6.44 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida, referentes à primeiro semana prevista

	U	R <sup>2</sup>	MAPE	EMA	QME
HW TA (1 Anos)	0,000102	1,000000	0,001664%	0,000447	0,0000005
HW TA (2,5 Anos)	0,000100	1,000000	0,001520%	0,000344	0,0000002

Após a execução e otimização destes modelos, é feita a previsão das cinco semanas seguintes individualmente a cada semana (168h). As semanas previstas correspondem às seguintes semanas:

- 4 a 10 de Novembro de 2012
- 11 a 17 de Novembro de 2012
- 18 a 24 de Novembro de 2012
- 25 de Novembro a 1 de Dezembro de 2012
- 2 a 8 de Dezembro de 2012

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos na Tabela 6.45 e Tabela 6.46 no que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 8400 e 19488 observações.

Tabela 6.45 - Parâmetros otimizados individualmente a cada semana com série de 1 ano de dados

Parâmetro	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,00474	0,00051	0,00051	0,00088	0,00897	0,00312
δ	0,18094	0,20878	0,11089	0,00799	0,00010	0,10174
ω	0,42973	0,32827	0,32972	0,32782	0,22458	0,32802
Φ	0,02107	0,42100	0,42104	0,11718	0,01148	0,19836

Tabela 6.46 - Parâmetros otimizados individualmente a cada semana com série de 2,5 anos de dados

Parâmetro	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Média
α	0,99990	0,99990	0,99990	0,99990	0,99990	0,99990
γ	0,39877	0,39877	0,32842	0,32842	0,22793	0,33646
δ	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
Φ	0,00024	0,00024	0,00030	0,00030	0,00045	0,00030

A Figura 6.72 e Figura 6.73 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de semanas previstas, respetivamente, para as séries de tamanho 8400 e 19488 observações. Um resumo dos erros obtidos no conjunto das semanas previstas é apresentado na Tabela 6.47 e Tabela 6.48.

# Série de dados com um ano e um número de observações de 8400.

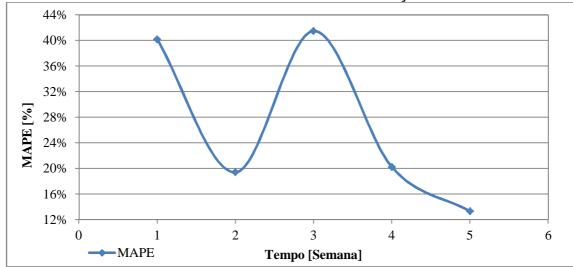


Figura 6.72 - Evolução do MAPE ao longo das cinco semanas previstas

Tabela 6.47 - Erros de previsão ao longo das cinco semanas previstas

Semana Prevista	MAPE	EMA	QME	U
1	40,20%	9,60	139,57	0,66
2	19,42%	7,79	88,81	1,49
3	41,49%	9,53	134,11	1,36
4	20,25%	6,83	69,96	1,92
5	13,33%	6,47	65,49	1,82

# Série de dados com dois anos e meio e um número de observações de 19488.

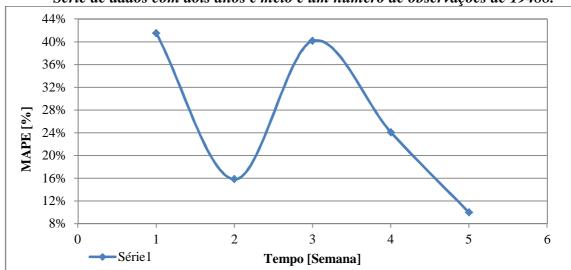


Figura 6.73 - Evolução do MAPE ao longo das cinco semanas previstas

Tabela 6.48 - Erros de previsão ao longo das cinco semanas previstas

Semana Prevista	MAPE	EMA	QME	U
1	41,53%	7,48	89,30	0,54
2	15,82%	5,82	46,55	1,26
3	40,16%	7,41	84,48	1,35
4	24,09%	6,97	78,09	3,28
5	9,98%	4,94	37,27	1,33

A Figura 6.74 e Figura 6.75, Figura 6.76 e Figura 6.77 apresentam-nos, respetivamente, para as séries de tamanho 8400 e 19488, os melhores e piores resultados das previsões semanais efetuadas. Tendo como critério de seleção na escolha da melhor qualidade da previsão, o valor do MAPE.

# • Série de dados com um ano e um número de observações de 8400.

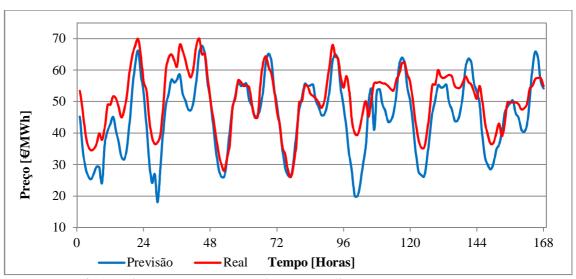


Figura 6.74 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)

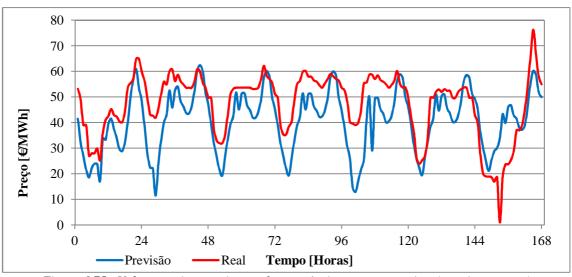


Figura 6.75 - Valores reais e previstos referentes à pior semana prevista (terceira semana)

## Série de dados com dois anos e meio e um número de observações de 19488.

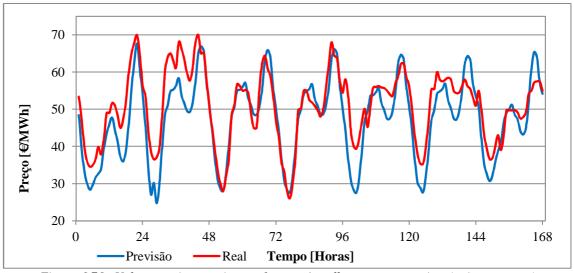


Figura 6.76 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)

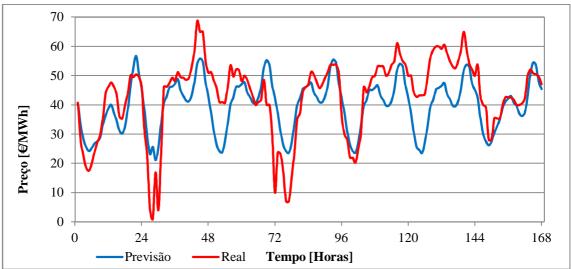


Figura 6.77 - Valores reais e previstos referentes à pior semana prevista (primeira semana)

# 6.3.3.3 Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados.

Neste caso de estudo o modelo foi desenvolvido identicamente ao ponto 6.3.3.1, apenas considerando o modelo proposto no subcapítulo 5.4.3.

Sinteticamente, o modelo foi desenvolvido com uma série de dados referentes a um ano de dados horários referentes a um número de observações de 8400, e ainda o mesmo modelo mas com uma série referente a dois anos e meio de dados horários relativos a um número de observações de 19488. É necessário otimizar o modelo de cada semana

que se pretendia prever, obtendo assim valores diferentes para os parâmetros de amortecimento para cada um dos modelos.

O ajuste do modelo foi realizado de acordo com o processo de otimização, pela minimização do somatório do erro percentual médio absoluto (MAPE) e apresenta as medidas de erro e ajuste conforme Tabela 6.49 abaixo indicada, onde através dos valores apresentados podemos observar que o modelo implementado possuí capacidade de produzir previsões confiáveis.

Tabela 6.49 - Medidas de erro e ajuste do modelo Holt-Winters dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados, referentes à primeiro semana prevista

	U	$\mathbb{R}^2$	MAPE	EMA	QME
HW TAEE (1 Anos)	1,000312	0,878823	12,262779%	2,697382	15,6255082
HW TAEE (2,5 Anos)	0,999982	0,873906	13,286532%	2,402037	14,8303755

Após a execução e otimização destes modelos, é feita a previsão das cinco semanas seguintes individualmente a cada semana (168h). As semanas previstas correspondem às seguintes semanas:

- 4 a 10 de Novembro de 2012
- 11 a 17 de Novembro de 2012
- 18 a 24 de Novembro de 2012
- 25 de Novembro a 1 de Dezembro de 2012
- 2 a 8 de Dezembro de 2012

Os resultados da previsão realizada com o modelo indicado, encontram-se expressos na Tabela 6.50 e Tabela 6.51 no que se refere aos parâmetros utilizados no decorrer das previsões bem como da sua média, nomeadamente para as séries de tamanho 8400 e 19488 observações.

Tabela 6.50 - Parâmetros otimizados individualmente a cada semana com série de 1 ano de dados

Parâmetro	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Média
α	0,97617	0,97441	0,97421	0,97301	0,97252	0,97406
γ	0,77037	0,74423	0,73706	0,72447	0,72412	0,74005
δ	0,00104	0,00085	0,00059	0,00065	0,00076	0,00078
ω	0,00796	0,00693	0,00507	0,00531	0,00644	0,00634
Φ	0,72825	0,70369	0,69785	0,68547	0,68392	0,69984
λ	0,44076	0,45857	0,46376	0,47015	0,47284	0,46122

Tabela 6.51 - Parâmetros otimizados individualmente a cada semana com série de 2,5 anos de dados

Parâmetro	Semana 1	Semana 2	Semana 3	Semana 4	Semana 5	Média
α=	0,79386	0,79386	0,79394	0,79393	0,79393	0,79390
γ=	0,63924	0,63921	0,63891	0,63889	0,63888	0,63903
δ=	0,00010	0,00010	0,00010	0,00010	0,00010	0,00010
ω=	0,00011	0,00011	0,00011	0,00011	0,00011	0,00011
Ф=	0,44869	0,44883	0,44901	0,44919	0,44924	0,44899
λ=	0,62137	0,62145	0,61688	0,61636	0,61638	0,61849

A Figura 6.78 e Figura 6.79 apresentam a evolução do erro percentual médio absoluto (MAPE) ao longo do conjunto de semanas previstas, respetivamente, para as séries de tamanho 8400 e 19488 observações. Um resumo dos erros obtidos no conjunto das semanas previstas é apresentado na Tabela 6.52 e Tabela 6.53.

# • Série de dados com um ano e um número de observações de 8400.

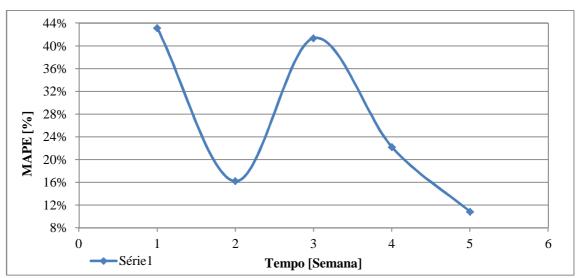


Figura 6.78 - Evolução do MAPE ao longo das cinco semanas previstas

Tabela 6.52 - Erros de previsão ao longo das cinco semanas previstas

Semana Prevista	MAPE	EMA	QME	U
1	43,14%	12,60	204,80	0,36
2	16,22%	6,49	58,46	1,18
3	41,38%	7,28	99,21	1,51
4	22,24%	6,69	69,26	3,00
5	10,86%	5,27	41,09	1,42

# • Série de dados com dois anos e meio e um número de observações de 19488.

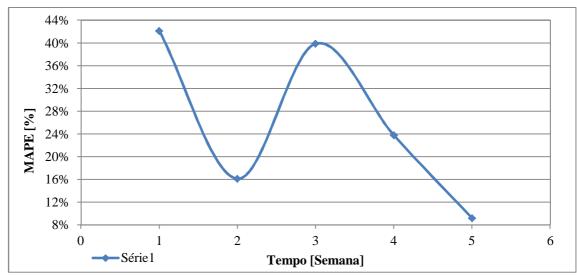


Figura 6.79 - Evolução do MAPE ao longo das cinco semanas previstas

Tabela 6.53 - Erros de previsão ao longo das cinco semanas previstas

Semana Prevista	MAPE	EMA	QME	U
1	42,17%	7,94	95,81	0,53
2	16,13%	5,87	47,08	1,28
3	39,89%	7,08	79,77	1,37
4	23,78%	6,79	74,59	3,29
5	9,20%	4,57	32,76	1,24

A Figura 6.80 e Figura 6.81, Figura 6.82 e Figura 6.83 apresentam-nos, respetivamente, para as séries de tamanho 8400 e 19488, os melhores e piores resultados de previsão semanal efetuada. Tendo como critério de seleção na escolha da qualidade da previsão, o valor do MAPE.

## • Série de dados com um ano e um número de observações de 8400

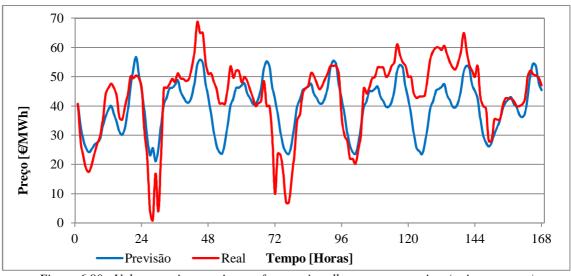


Figura 6.80 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)

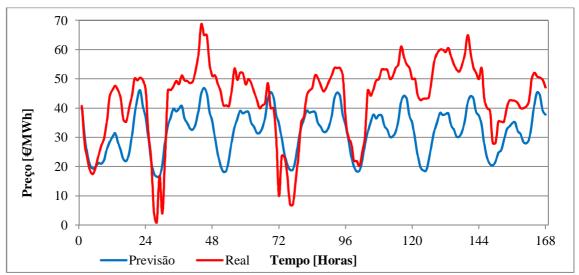


Figura 6.81 - Valores reais e previstos referentes à pior semana prevista (primeira semana)

# • Série de dados com dois anos e meio e um número de observações de 19488.

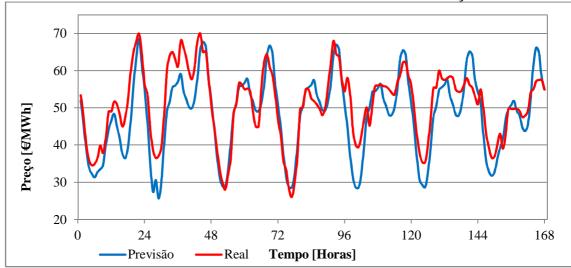


Figura 6.82 - Valores reais e previstos referentes à melhor semana prevista (quinta semana)

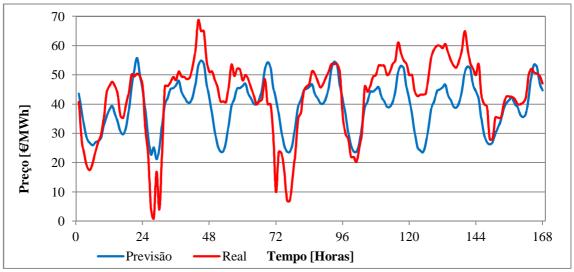


Figura 6.83 - Valores reais e previstos referentes à pior semana prevista (primeira semana)

# 6.3.3.4 Comparação do erro MAPE.

De modo a que seja feita uma melhor análise dos resultados a Figura 6.84 e Figura 6.85, e a Tabela 6.54 e Tabela 6.55 apresentam-nos, respetivamente, para as séries de tamanho 8400 e 19488 observações, os valores dos erros MAPE para os vários modelos. Seguindo o prossuposto em 5.5 e como referido avalia-se que quanto mais próximo de zero esteja o valor do MAPE mais adequados será o método em estudo, refira-se ainda que este é um dos indicadores mais utilizados para aferir a qualidade de um modelo proposto, bem como para estabelecer comparações entre diferentes modelos.

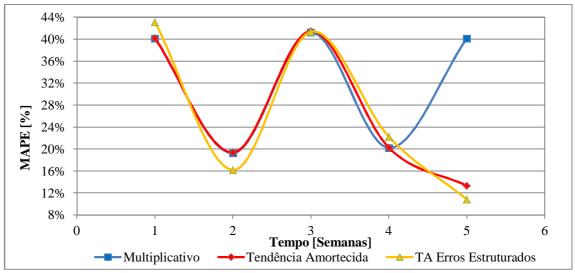


Figura 6.84 - Comparação dos modelos com uma série de dados de um ano (8400 observações)

Tabela 6.54 - Erros e média do erro MAPE das semanas previstos, ao longo das cinco semanas, para os três modelos de previsão com um ano de dados

Semana Prevista	Multiplicativo	Tendência Amortecida	TA Erros Estruturados
Semana 1	40,16%	40,20%	43,14%
Semana 2	19,28%	19,42%	16,22%
Semana 3	41,23%	41,49%	41,38%
Semana 4	20,24%	20,25%	22,24%
Semana 5	40,16%	13,33%	10,86%
Média	32,22%	26,94%	26,77%

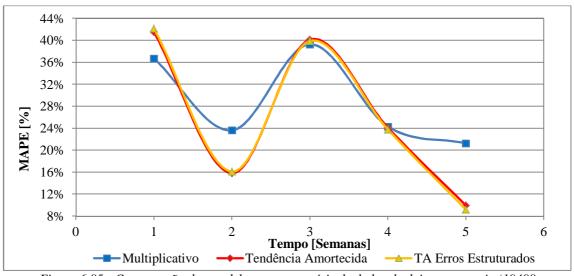


Figura 6.85 - Comparação dos modelos com uma série de dados de dois anos e meio (19488 observações)

Tabela 6.55 - Erros e média do erro MAPE das semanas previstos, ao longo das cinco semanas, para os três modelos de previsão com dois anos e meio de dados

Semana Prevista	Multiplicativo	Tendência Amortecida	TA Erros Estruturados
Semana 1	36,74%	41,53%	42,17%
Semana 2	23,64%	15,82%	16,13%
Semana 3	39,30%	40,16%	39,89%
Semana 4	24,32%	24,09%	23,78%
Semana 5	21,28%	9,98%	9,20%
Média	29,05%	26,32%	26,24%

# Capítulo 7

# **CONCLUSÕES**

Neste capítulo enuncia-se uma síntese do estudo e apresentam-se as principais conclusões retiradas deste trabalho, e propõem-se desenvolvimentos futuros.

## 7 Conclusões

#### 7.1.1 Conclusões.

O estudo e realização deste trabalho tiveram como principal intenção a apresentação dos fundamentos, teóricos e práticos, por forma a responder aos objetivos propostos nesta dissertação.

O primeiro passo desta dissertação passou um estudo envolvendo várias temáticas em volta do preço da energia elétrica, conduzindo a um melhor conhecimento da área e provocando o aparecimento dos principais focos e problemas. Apresentando como principal deficiência o tema da previsão do preço da energia elétrica.

Para ser possível colmatar esse problema foi feito um estudo, análise e comparação de várias metodologias de previsão através dos métodos de *Holt-Winters* aferidos através de medidas de erro. Ainda, para um melhor ajuste e certezas do melhor método a utilizar nesta problemática foi analisada a conjugação entre tendência e sazonalidade, nas suas variantes, aditiva, multiplicativa, aditiva suavizada e multiplicativa suavizada, bem como diversos tamanhos de séries de dados. De referir ainda, que é notório a existência de duas sazonalidades sendo que todos os modelos se baseiam em dupla sazonalidade (sazonalidade diária e semanal).

Entre os vários tipos de métodos de *Holt-Winters* criados e simulados, as variantes de sazonalidade aditiva não foram apresentadas neste trabalho uma vez que apresentaram logo à partida resultados muito pouco satisfatórios, ao contrário da sazonalidade multiplicativa que se mostraram muito promissores. Dessa forma, todos os restantes modelos tiveram por base a sazonalidade multiplicativa, variando a conjugação da tendência. Todos os modelos criados, com dados históricos de um ano e dois anos e meio, apresentaram resultados aceitáveis apresentando valores médios de erro MAPE de 11,08% e 10,67% para a tendência aditiva e amortecida, respetivamente. Dado que a combinação entre sazonalidade multiplicativa e tendência amortecida forneceu resultados mais aceitáveis, foi desenvolvido ainda um novo modelo mais complexo por forma a melhorar os resultados, apresentando valores médios de erro MAPE de 9,93%. Conclui-se então que o melhor método é o de *Holt-Winters* dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados (HWTAEE).

Todos os modelos foram construídos através do método de HWTAEE com diversos tamanhos de dados históricos, desde seis meses de dados até quatro anos de dados. Os

resultados obtidos com seis meses, um ano, três anos, três anos e meio e quatro anos não são satisfatórios apresentando em média 16,30% de erro MAPE. Contrariamente existe um intervalo temporal de dados no qual se obtém os melhores resultados, sendo eles de um ano e meio, dois anos e dois anos e meio de dados apresentando em média 8,38% de erro MAPE.

Efetuando uma comparação geral dos resultados obtidos das previsões efetuadas para um horizonte temporal de um dia (24h) e para uma semana (168h), conclui-se que para a previsão do preço da energia elétrica é tanto mais difícil prever quanto maior for o horizonte temporal. Ainda, é possível retirar outra conclusão importante, sendo que em ambos os casos de previsão é notório uma maior dificuldade em prever determinadas horas do dia correspondendo às horas da chamada "ponta do consumo de energia elétrica".

Através da análise e comparação dos resultados obtidos, é possível concluir que se obtêm previsões reais e com algum grau de eficácia e fiabilidade. Feita a análise geral dos resultados, conclui-se que a melhor metodologia para a previsão do preço da energia elétrica a curto prazo são os modelos de *Holt-Winters* dupla sazonalidade multiplicativa com tendência amortecida e erros estruturados. Estes apresentam os melhores resultados das previsões efetuadas, nomeadamente, com séries históricas de dados relativamente a tamanhos de um ano e meio, dois anos e dois anos e meio de dados com valores erro percentual médio absoluto (MAPE) na ordem dos 8%.

Em função dos resultados obtidos, podemos apresentar as seguintes conclusões mais específicas observadas nesta dissertação.

#### Previsão diária, seleção de modelos:

• Verifica-se através da Tabela 6.1, Tabela 6.6 e Tabela 6.11 que os três modelos estudados apresentam bons valores de ajuste, possuindo assim competências expetáveis de produzir previsões confiáveis. De entre os três modelos, comparando todas as medidas de erros e ajuste dos modelos, o modelo HWTA é o que expõe as melhores medidas para ambos os tamanhos de série, sendo de um ano e dois anos e meio de dados. É de referir ainda que, de entre os dois tamanhos de dados utilizados nos modelos, os modelos de HWM e HWTA o tamanho de dois anos e meio apresenta melhores medidas de erros e ajuste, no modelo HWTAEE os dois tamanhos utilizados apresentam valores muito

- semelhantes sendo que as medidas variam entre melhores e piores (entre os dois tamanhos de série).
- Com a análise da Figura 6.26, Figura 6.27 e Tabela 6.16, Tabela 6.17 que representam a medida de erro MAPE da previsão efetuada através dos três modelos distintos e ainda com tamanhos diferentes de série de tempo (1 ano e dois anos e meio de dados), conclui-se que todos os modelos apresentam valores aceitáveis de previsão. Os melhores resultados da previsão efetuada recaem sobre o modelo HWTAEE com uma média de MAPE de 11,49% e 8,36% para ambos os tamanhos de série, respetivamente, 1 ano e dois anos e meio de dados.
- Em todas as previsões efetuadas, através dos modelos anteriormente apresentados, verifica-se que o primeiro dia previsto foi sempre o que apresentou o pior resultado de previsão (o pior valor verificado é referente ao modelo HWM e com um tamanho de série de um ano de dados, com um valor de MAPE de 20,47%), contrariamente, o terceiro dia previsto foi sempre o que apresentou o melhor resultado de previsão (o melhor valor verificado corresponde aos modelos HWM e HWTA e com um tamanho de série de dois anos e meio de dados, com um valor de MAPE de 4,81%).
- Os intervalos de confiança são uma ferramenta importante e ajudam a efetuar uma boa análise dos resultados obtidos, como tal através dos mesmos é possível concluir que resultados obtidos para dias previstos apresentam em algumas horas valores fora dos limites de confiança, mais concretamente no intervalo horário entre as 17h e as 23h, podendo ser explicado pelo fato esse intervalo de tempo corresponder aproximadamente ao designado horas de ponta da tarde de consumo de energia elétrica.

#### Previsão diária via modelos de erros estruturados:

- Através da Tabela 6.18 verifica-se que os modelos estudados apresentam bons valores de ajuste, possuindo assim competências expetáveis de produzir previsões confiáveis.
- Com a análise da Tabela 6.38 e Figura 6.55, Figura 6.56 que representam a medida de erro MAPE da previsão efetuada através dos vários modelos com tamanhos diferentes de série de tempo, conclui-se que os melhores resultados de previsão são obtidos com as séries de dados com tamanho referentes a um ano e meio, dois anos e ainda dois anos e meio de dados, respetivamente, com valores

de MAPE de 8,41%, 8,38% e 7,94%. Os modelos com o tamanho de série de 6 meses, um ano, três anos, três anos e meio e quatro anos de dados apresentam resultados pouco aceitáveis de previsão. Assim, conclui-se ainda que o intervalo de tamanho de série de dados para o qual se obtêm os melhores resultados é entre um ano e meio, e dois anos e meio de dados.

- A previsão efetuada com um série de dados de seis meses referentes tipicamente a meses húmidos (estação de inverno) na tentativa de melhorar a previsão efetuada, conclui-se que não apresenta bons resultados de previsão uma vez que possui valores de MAPE todos na ordem dos 20%.
- Em todas as previsões efetuadas, através dos modelos anteriormente apresentados, verifica-se uma alternância no pior dia previsto (o pior valor verificado é referente a um tamanho de série de seis meses de dados, com um valor de MAPE de 32,99%), contrariamente, o terceiro dia previsto foi o que apresentou o melhor resultado de previsão referente aos tamanhos de série até dois anos e meio de dados, e o quarto dia previsto para os tamanhos de série referente de 3 anos a 4 anos de dados (o melhor valor verificado corresponde a um tamanho de série de um ano e meio de dados, com um valor de MAPE de 4,75%).
- Efetuada uma análise da Figura 6.63 à Figura 6.65, onde está apresentado o erro quadrático (QE), conclui-se que se obtêm piores previsões em determinadas horas do dia, nomeadamente, no intervalo de horas aproximadamente compreendido entre as 17h e as 23h. Isto poderá dever-se ao fato de que nessas horas o preço da energia elétrica ser muito volátil e incerto, pois é corresponde a uma parte do dia denominada por horas de ponta da tarde do consumo de energia elétrica.
- Analisando os intervalos de confiança efetuados para as previsões é possível concluir que resultados obtidos para dias previstos apresentam em algumas horas valores fora dos limites de confiança, mais concretamente no intervalo horário entre as 17h e as 23h.

#### Previsão semanal, seleção de modelos:

 Verifica-se através da Tabela 6.39, Tabela 6.44 e Tabela 6.49 que os três modelos estudados apresentam bons valores de ajuste, possuindo assim competências expetáveis de produzir previsões confiáveis. Os modelos de HWM

- e HWTA, com os tamanhos de série de um ano e de dois anos e meio, possuem medidas de ajuste na mesma ordem de grandeza. O modelo de HWTAEE apresenta as piores medidas de ajuste, para ambos os tamanhos de séries, respetivamente, um ano e dois anos e meio de dados.
- Com a análise da Figura 6.84, Figura 6.85 e Tabela 6.54, Tabela 6.55 que representam a medida de erro MAPE da previsão efetuada através dos três modelos distintos e ainda com tamanhos diferentes de série de tempo (1 ano e dois anos e meio de dados), conclui-se que todos os modelos apresentam maus valores de previsão. Assim, a previsão semanal efetuada não corresponde à expetativa que apresenta nos ajustes do modelo e as previsões são pouco fiáveis. Isto poderá dever-se ao fato de que a previsão ser efetuada a 168h, e os valores das séries apresentar elevada volatilidade tornando a previsão bastante complexa.

#### 7.1.2 Desenvolvimentos Futuros

O tema abordado nesta dissertação é complexo e muito vasto, e como tal é possível estabelecer um conjunto de direções de futuras investigações que possam vir a melhorar este mesmo tema como algo dentro do mesmo.

Assim, salientam-se alguns possíveis desenvolvimentos futuros:

- Efetuar a previsão diária para um horizonte temporal maior, ou seja, numa parte
  deste trabalho foi efetuada a previsão diária para sete dias previstos
  individualmente e seria de todo o interesse efetuar essa previsão diária
  individual num horizonte temporal maior, como por exemplo de quinze, trinta
  dias.
- Elaborar a previsão em diversas alturas do ano, de modo a ter como início de previsão várias estações do ano.
- Ter por base uma série histórica unicamente com dias úteis, e efetuar a previsão igualmente só para os dias úteis.
- Identicamente ao ponto anterior, apenas ter por base só série histórica com dias de fim de semana e elaborar a previsão dos mesmos.
- Implementar uma nova metodologia dos modelos Holt-Winters adicionando mais uma sazonalidade ao modelo, ficando o modelo com tripla sazonalidade.

Existindo nesta dissertação o estudo com dupla sazonalidade (semanal e diária), seria introduzir ainda a sazonalidade anual.

• Eliminar parâmetros de alisamento dos modelos em que apresentem o valor zero ou unitário.

# **BIBLIOGRAFIA**

# 8 Bibliografia

- [1] J. P. S. Paiva, Redes de energia eléctrica Uma análise sistémica, IST Press, 2007.
- [2] Decreto Lei nº 182/95, 27 de Julho.
- [3] Decreto-Lei nº 187/95, 27 de Julho.
- [4] Decreto de Lei nº 29/2006, 15 de Fevereiro.
- [5] *Decreto-Lei nº 169/2005*, 24 de Outubro.
- [6] Decreto-Lei nº 172/2006, 23 de Agosto.
- [7] Decreto-Lei nº 264/2007, 24 de Julho.
- [8] *Diretiva nº 2003/54/CE*, 26 de Junho.
- [9] J. A. M. d. Sousa, Integração de mercados liberalizados de energia eléctrica com aplicações ao MIBEL, 2005.
- [10] C. d. R. d. MIBEL, Descrição do Funcionamento do MIBEL, 2009.
- [11] Protocolo de Colaboração entre as Administrações Portuguesa e Espanhola para a criação do Mercado Ibérico de Electricidade, 2001, 14 de Novembro.
- [12] "OMIP," [Online]. Available: http://www.omip.pt/OMIP/MIBEL/tabid/72/language/pt-PT/Default.aspx. [Acedido em 10 1 2013].
- [13] Resolução da Assembleia da República nº 23/2006, 23 de Março de 2006.
- [14] Conclusões da XXII<sup>a</sup> Cimeira Luso-Espanhola, Badajoz, 24 e 25 de Novembro de 2006.
- [15] "ERSE," [Online]. Available: http://www.erse.pt/pt/supervisaodemercados/Paginas/default.aspx. [Acedido em 12 11 2012].
- [16] ERSE, Tarifa e preços para a energia elétrica e outros serviçoes em 2013, Dezembro de 2012.

- [17] "ERSE," [Online]. Available: http://www.erse.pt/pt/electricidade/tarifaseprecos/Paginas/default.aspx. [Acedido em 15 11 2012].
- [18] R. Pino, D. D. L. Fuente, P. Priore e J. Parreño, *Short term forecasting of the electricity market of Spain using Neural Networks*, University of Oviedo. Spain.
- [19] J. C. Hull, Fundamentals of Futures and Options markets Fourth Edition, Prentice-Hall, 2002.
- [20] A. M. Shahidehpour e M., *Market Operations in Electric Power Systems*, Marcel Dekker, Inc., 2001.
- [21] P. L. Skantze e G. A. e. Ilic, "Bid-based Stochastic Model for Electricity Prices: The Impact of Fundamental Drivers on Market Dynamics", Massachusetts Institute of Technology, MIT EL 00-004, Novembro de 2002.
- [22] M. Benini, M. Marracci e A. Venturini, *Day-ahead Market Price Volatility Analysis in Deregulated Electricity Markets*, Proc. 2002 IEEE Power Engineering Society Summer Meeting, vol. 3, pp. 1354-1359, 21-25, Julho de 2002.
- [23] D. Menniti, N. Scordino, N. Sorrentino e A. Violi, *Short-term forecasting of day-ahead electricity market price*, IEEE, 2010.
- [24] G. Li, L. Chen, J. Lawaree, A. Venturini e M. Gallanti, *State of the Art of Electricity Price Forecasting*, University of Washington, CESI Italy: IEEE, 2005.
- [25] T. Jakaša, I. Andročec e P. Sprčić, Electricity price forecasting ARIMA model approach, Zagreb, Croatia: International Conference on the European Energy Market (EEM), Maio 2011.
- [26] G. Koroneff, A. Seppälä e M. Lehtonen, *Electricity Spot Price Forecasting as a Part of Energy Management in De-regulated Power Market*, Proc. EMPD'98 1998 International Conference on Energy Management and Power Delivery, pp. 223-228, Março de 1998.
- [27] J. Contreras, R. Espínola, F. J. Nogales e A. J. Conejo, ARIMA Models to Predict Next-Day Electricity Prices, IEEE Transactions on Power Systems, vol. 18, no. 3, pp. 1014-1020, Agosto de 2003.

- [28] R. C. Garcia e J. Contreras, A GARCH Forecasting Model to Predict Day-Ahead Electricity Prices, IEEE TRANSACTIONS ON POWER SYSTEMS, VOL. 20, NO. 2, Maio 2005.
- [29] F. Weron e A. Misiorek, Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models, International Journal of Forecasting 24 (2008) 744 763, 2008.
- [30] C. Nunes, A. Pacheco e T. Silva, *Statistical Models to Predict Electricity Prices*, IEEE, 2008.
- [31] C. Herui e Y. Li, *Short-Term Electricity Price Forecast Based on Improved Fractal Theory*, North China Electric Power University: International Conference on Computer Engineering and Technology, 2009.
- [32] D. Menniti, N. Scordino e N. Sorrentino, *Forecasting Next-Day Electricity Prices by a Neural Network Approach*, International Conference on the European Energy Market (EEM), Maio 2011.
- [33] T. Jónsson, P. Pinson, H. Nielson, H. Madsen e T. Nielsen, *Forecasting Electricity Spot Prices Accounting for Wind Power Predictions*, IEEE TRANSACTIONS ON SUSTAINABLE ENERGY, Janeiro 2013.
- [34] B. L. Bowerman e R. O'Connel, Forecasting and time series: an applied approach, Miami University, Ohio: Duxbury Press, 1993.
- [35] J. R. Afonso, Previsão de consumo de energia eléctrica empregando modelos ARIMA, 2007.
- [36] J. W. Taylor, L. M. Menezes e P. Mcsharry, A Comparison of Univariate Methods for Forecasting Electricity Demand Up to a Day Ahead, International Journal of Forecasting, 22,1-16..
- [37] "OMIE," [Online]. Available: http://www.omie.es/aplicaciones/datosftp/datosftp.jsp?path=/marginalpdbcpt/. [Acedido em 18 1 2013].
- [38] "REN (Mercado Omel)," [Online]. Available: http://www.mercado.ren.pt/InfOp/MercOmel/Paginas/Precos.aspx. [Acedido em 17

- 12 2012].
- [39] P. Silva, O Sector da Energia Eléctrica na União Europeia Evolução e Perspectivas, Coimbra: Imprensa da Universidade de Coimbra, 2007.
- [40] C. Miranda, R. Souza, L. Menezes e J. Lazo, *Previsão de dados de alta frequência* para carga elétrica usando Holt-Winters com dois ciclos, XLI SBPO 2009 Pesquisa Operacional na Gestão do Conhecimento, 2009.
- [41] J. W. Taylor, "Short-Term Electricity Demand Forecasting Using Double Seasonal Exponential Smoothing," *Journal of Operational Research Society*, 2003.
- [42] R. C. Souza, M. Barros e C. V. Miranda, *Previsão horária de carga elétrica usando Holt-Winters*, 2006.
- [43] J. W. Taylor e P. E. McSharry, *Short-Term Load Forecasting Methods: An Evaluation Based on European Data*, IEEE Transactions on Power Systems, 22, 2213-2219, 2008.
- [44] C. Camus, A Metaheuristic Approach to the Holt-Winters Optimal Short Term Load Forecast, 2008.
- [45] G. d. P. Falco, *Técnicas Univariadas Aperfeiçoadas para a Previsão de Curtíssimo Prazo a partir de Dados Horários*, 2005.
- [46] F. R. Maurício, *Aplicação de um modelo de previsão da demanda total nos credenciados belgo pronto*, Universidade Federal de Juiz de fora, 2006.
- [47] A. O. Cutrim e A. d. C. Rebouças, *Aplicação do método de Holt na previsão da dados de água da cidade de Rondonópolis-MT*.
- [48] G. o. W. A. Department of Treasury and Finance, *Forecasting Accuracy of the ACT Budget Estimates*, Review of Revenue Forecasting, 2008.