



Universidade Aberta
Departamento de Ciências e Tecnologias



Universidade de Trás-os-Montes e Alto Douro

Mestrado em Engenharia Informática e Tecnologia Web

PREVISÃO MULTI-ATRIBUTO DO PREÇO NO MERCADO IBÉRICO DE ELETRICIDADE

Gonçalo Martins Peres

Esta página foi intencionalmente deixada em branco.



Universidade Aberta
Departamento de Ciências e Tecnologias



Universidade de Trás-os-Montes e Alto Douro

Mestrado em Engenharia Informática e Tecnologia Web

PREVISÃO MULTI-ATRIBUTO DO PREÇO NO MERCADO IBÉRICO DE ELETRICIDADE

Gonçalo Martins Peres

Dissertação orientada pelo
Professor Doutor Luís Manuel Pereira Sales Cavique Santos

2021

Esta página foi intencionalmente deixada em branco.

Resumo

A eletricidade tem vindo a adquirir uma maior presença nas nossas vidas e estima-se que o futuro seja cada vez mais elétrico.

Hoje em dia temos acesso a quantidades enormes de dados que acabam por não ter grande valor acrescentado se não puderem ser utilizados para suportar tomadas de decisão ou planear antecipada e corretamente sistemas.

As previsões são instrumentos fundamentais para apoiar tomadas de decisão.

A eletricidade é considerada uma *commodity* muito especial, pois embora tenha havido diversos progressos relativos ao desempenho de baterias, a eletricidade é, largamente, um bem não armazenável. Nesse sentido, o preço de eletricidade apresenta características únicas que torna a sua previsão uma tarefa difícil.

Acreditamos ser possível recorrer a dados disponíveis na Internet para efetuar previsões de preços de eletricidade que possam ser usadas por decisores no setor.

Neste trabalho apresentamos um processo de previsão quantitativa e, por forma a compreender as previsões de preço de eletricidade, investigamos a previsão multi-passos e multi-atributo.

Consideramos diversas séries temporais de dados disponíveis abertamente em diversas fontes. Os dados utilizados inserem-se em cinco categorias: cronológicos, preço, procura, produção e clima.

O estudo compreende três intervalos de tempo 1 de janeiro de 2019 (00:00) a 31 de dezembro de 2019 (23:00), 1 de janeiro de 2018 (00:00) a 31 de dezembro de 2019 (23:00) e 1 de janeiro de 2010 (00:00) a 31 de dezembro de 2019 (23:00).

Aos resultados, aplicamos um método de apoio à tomada de decisão multi-atributo, o *TOPSIS*.

Palavras-chave: Previsão de Preços, Mercado Ibérico de Eletricidade (MIBEL), AutoML, Decisão Multi-Atributo.

Abstract

Electricity has been acquiring a greater presence in our lives and it is estimated that the future will be increasingly electric.

Nowadays we have access to enormous amounts of data that end up not having much added value if they cannot be used to support decision making or plan systems in advance and correctly.

Forecasts are key tools to support decision-making.

Electricity is considered a very special commodity, because although there have been several advances regarding the performance of batteries, electricity is largely a non-storable commodity. In this sense, the price of electricity presents unique characteristics that make its forecasting a difficult task.

We believe it is possible to resort to data available on the Internet to make electricity price forecasts that can be used by decision makers in the sector.

In this paper we present a quantitative forecasting process and, in order to understand electricity price forecasting, we investigate multi-step and multi-attribute forecasting.

We consider several time series of openly available data from various sources. The data used fall into five categories: chronological, price, demand, production and weather.

The study comprises three time intervals 1 January 2019 (00:00) to 31 December 2019 (23:00), 1 January 2018 (00:00) to 31 December 2019 (23:00) and 1 January 2010 (00:00) to 31 December 2019 (23:00).

To the results, we applied a multi-attribute decision support method, TOPSIS.

Keywords: Price Forecasting, Iberian Electricity Market (MIBEL), AutoML, Multi-Attribute Decision.

Agradecimentos

Esta dissertação foi resultado do contributo, direto ou indireto, de diversas entidades, às quais sou humildemente grato. Não sendo possível particularizar todos, dirijo um agradecimento especial...

... a Deus, que está sempre comigo (Mateus 28:20), e cuja graça me sustenta desde o início.

... ao meu orientador Professor Doutor Luís Cavique pela sua disponibilidade e entrega na orientação competente deste trabalho, pautada por esforço e exigência, com reuniões e troca de emails constantes.

... aos meus pais, Edmaro Peres e Nídia Peres, por oferecerem tudo, sem reterem nada; protegerem, sem sufocarem; perdoarem, sem pedir nada em troca; esperarem pacientemente e com confiança. Muito agradecido pela educação que me proporcionaram e as condições criadas para que fosse possível chegar até aqui.

... à restante família: irmãos (Bárbara Peres, Tiago Peres), avós (Graciete Peres, Esmeralda Martins),..., que comigo partilham momentos enriquecedores e com os quais aprendo bastante. Grato por todo o vosso esforço, apoio e carinho.

... à Tangent Works, pelo acesso à ferramenta TIM, pelo interesse neste trabalho e pela disponibilidade em esclarecer dúvidas que foram surgindo no uso da mesma.

... aos meus colegas de curso pela caminhada conjunta e pela partilha de impressões, conhecimentos e experiências. Especial atenção aos meus colegas de grupos de trabalho, tanto pelas conquistas obtidas, como pela ajuda ao longo deste percurso.

Obrigado.

Índice

1. INTRODUÇÃO.....	1
1.1. MOTIVAÇÕES E CONTRIBUIÇÕES FUNDAMENTAIS	2
1.2. OBJETIVOS	6
1.3. METODOLOGIA DE INVESTIGAÇÃO	7
1.4. ORGANIZAÇÃO DA DISSERTAÇÃO.....	8
2. TRABALHOS RELACIONADOS.....	9
2.1. INTELIGÊNCIA OPEN SOURCE (OSINT).....	10
2.2. MERCADOS DE ELETRICIDADE	14
2.3. SÉRIES TEMPORAIS	23
2.4. CIÊNCIA DE DADOS	24
2.5. PREVISÃO.....	28
2.6. GEOMETRIA DA INFORMAÇÃO.....	39
2.7. DECISÃO MULTI-ATRIBUTO (MADM).....	40
3. CONJUNTOS DE DADOS	41
3.1. DAS FONTES DE DADOS AOS DADOS A ANALISAR	42
3.2. CARACTERIZAÇÃO DOS DADOS	43
4. MODELOS E PLANEAMENTO DE EXPERIÊNCIAS.....	48
4.1. TANGENT INFORMATION MODELLER (TIM)	49
4.2. MODELOS.....	55
5. RESULTADOS COMPUTACIONAIS E DISCUSSÃO.....	65
5.1. RESULTADOS.....	66
5.2. DESEMPENHO.....	71
5.3. DECISÃO MULTI-ATRIBUTO.....	78
5.4. ARGUMENTAÇÃO FINAL.....	83
6. CONCLUSÃO.....	92
6.1. TRABALHO FUTURO.....	95
7. REFERÊNCIAS BIBLIOGRÁFICAS.....	97
8. ANEXOS.....	107

Índice de Figuras

Figura 2.1. Estrutura corporativa do grupo do Operador do Mercado Ibérico (“Informação OMI OMI”, sem data).....	21
Figura 2.2. Previsão Multi-Passos – Diferentes Estratégias e relações entre elas.....	31
Figura 2.3. Previsão Multi-Passos – Desafio – Estratégia Recursiva (Miller, 2021).	32
Figura 2.4. Processo de Previsão Quantitativa.	37
Figura 3.1. Modelo das Fontes de Dados aos Dados a Analisar.	42
Figura 4.1. TIM – Arquitetura do serviço web (Miller, 2021).	50
Figura 4.2. TIM Studio versão 2.0.	52
Figura 4.3. Arquitetura do TIM RTInstantML.....	52
Figura 4.4. TIM – Abordagem para a previsão Multi-Passos (Miller, 2021).....	55
Figura 4.5. Back-test – Ilustração da divisão em Treino e Teste (Hyndman, & Athanasopoulos, 2021).	60
Figura 5.1 Algoritmo do método TOPSIS.....	80
Figura 5.2. M3B – 70-30 – Visualização das séries e da previsão.....	84
Figura 5.3. M3B – 70-30 – Aproximação da visualização das séries e da previsão.	85
Figura 5.4. M3B – 70-30 – Visualização do primeiro valor previsto e valores do intervalo probabilístico.	85
Figura 5.5. M3B – 70-30 – Diagrama Sunburst.	86
Figura 5.6. M3B – 70-30 – Diagrama Sunburst –10:00h.	87
Figura 5.7. M3B – 70-30 – Importância dos Atributos.	89

Índice de Tabelas

Tabela 3.1. Variáveis explicatórias dos modelos a serem utilizados.....	45
Tabela 4.1. TIM Engine – Mecanismos de Implementação com base em requisitos de negócios (Miller, 2021).	51
Tabela 4.2. Modelos a serem implementados e as respectivas variáveis de entrada.....	58
Tabela 4.3. Limites do TIM (“TIM Tangnt Information Modeller— Input Data — Data properties”, sem data).	64
Tabela 4.4. Tamanho do modelo e valor a utilizar para treino-teste, com base nas % a considerar.....	64
Tabela 5.1. Resultados computacionais relativos ao intervalo A (2019).	68
Tabela 5.2. Resultados computacionais relativos ao intervalo B (2018-2019).	69
Tabela 5.3. Resultados computacionais relativos ao intervalo C (2010-2019).	70
Tabela 5.4. A – Modelos com um tempo de execução menor.....	72
Tabela 5.5. A – Modelo com um MAE menor.	72
Tabela 5.6. A – Modelo com um MAPE menor.....	72
Tabela 5.7. A – Modelo com um RMSE menor.....	73
Tabela 5.8. B – Modelos com um tempo de execução menor.....	74
Tabela 5.9. B – Modelo com um MAE menor.	74
Tabela 5.10. B – Modelo com um MAPE menor.....	74
Tabela 5.11. B – Modelo com um RMSE menor.....	74
Tabela 5.12. C – Modelo com um tempo de execução menor.	75
Tabela 5.13. C – Modelo com um MAE menor.	75
Tabela 5.14. C – Modelo com um MAPE menor.....	75
Tabela 5.15. C – Modelo com um RMSE menor.	76
Tabela 5.16. Modelos mais rápidos (com tempo de execução menor).....	77
Tabela 5.17. Modelos com um MAE menor.	77
Tabela 5.18. Modelos com um MAPE menor.	78
Tabela 5.19. Modelos com um RMSE menor.	78
Tabela 5.20. TOPSIS – A – Melhor modelo.	89
Tabela 5.21. TOPSIS – B – Melhor modelo.....	90
Tabela 5.22. TOPSIS – C – Melhor modelo.....	90

Lista de Abreviaturas, Siglas e Acrónimos

€/MWh – Euro por Megawatt hora.

°C – Graus Celsius

API – *Application Programming Interface*.

AutoML – *Automated Machine Learning*.

CRISP-DM – *Cross-Industry Standard Practice for Data Mining*.

CSV – *Comma-separated values*.

DAEPF – modelos de previsão de preços de eletricidade para o dia seguinte, em inglês, *Day-Ahead Electricity Price Forecasting*.

DPP – *Data Processing Pipelines*

DS – Ciência de Dados, do inglês *Data Science*.

ECMWF – European Centre for Medium-Range Weather Forecasts.

EMA – Erro Absoluto Médio, ou *Mean Absolute Error* (ver MAE).

EPAM – Erro Percentual Absoluto Médio, ou *Mean Absolute Percentage Error* (ver MAPE).

EPF – Previsão de Preços de Eletricidade, do inglês *electricity price forecasting*.

Eq – Equação (plural Eqs).

ERA-5 – Quinta geração de análises ECMWF para o clima e clima global durante as últimas 4 a 7 décadas.

HDF5 – *Hierarchical Data Format*, versão 5.

ICT – Tecnologias de Informação e Comunicação, do inglês *Information and Communication Technologies* (ver TIC).

IDC – International Data Corporation.

IFS – *Integrated Forecasting System*.

IG – Geometria da Informação, do inglês *Information Geometry*.

IoT – Internet das Coisas, do inglês *Internet of Things*.

J m⁻² – Joules por metro quadrado.

K – Kelvin.

m – Metro.

m s⁻¹ – Metro por segundo.

MADM – tomada de Decisão Multi-Atributo, do inglês *Multi Attribute Decision Making*.

MAE – Erro Absoluto Médio, ou *Mean Absolute Error* (ver EMA).

MAPE – Erro Percentual Absoluto Médio, ou *Mean Absolute Percentage Error* (ver EPAM).

LISTA DE ABREVIATURAS, SIGLAS E ACRÓNIMOS

MCDM – Tomada de Decisão Multi-Critério, do inglês *Multi Criteria Decision Making* (ver MADM).

MIBEL – Mercado Ibérico de Eletricidade.

MIMO – *Multi-Input Multi-Output*.

ML – Aprendizagem Automática, do inglês *Machine Learning*.

MW – Megawatt.

MWh – Megawatt hora.

OGD – Open Government Data.

OLR – Radiação de Ondas Longas de Saída, do inglês *Outgoing Longwave Radiation*.

OMI – Operador do Mercado Ibérico.

OMIE – Operador do Mercado Ibérico de Energia – Polo Español.

OMIP – Operador do Mercado Ibérico de Energia – Pólo Português.

ONG – Organização Não Governamental (plural ONGs).

OSINT – *Open-Source Intelligence*.

REE – Rede Elétrica de Espanha.

REN – Rede Elétrica Nacional.

REQM – Raiz do Erro Quadrático Médio, ou *Root Mean Squared Error* (ver RMSE).

RMSE – Raiz do Erro Quadrático Médio, ou *Root Mean Squared Error* (ver REQM).

RTInstantML – *Real-Time InstantML*.

SaaS – Software como um serviço, do inglês *software as a service*.

SEMMA – *Sample, Explore, Modify, Model and Assess*

SQL – *Structured Query Language*.

SVM – Support *Vector Machine*

TIC – Tecnologias de Informação e Comunicação, do inglês *Information and Communication Technologies* (ver ICT).

TIM – *Tangent Information Modeler*

TOPSIS – *Technique of Order Preference Similarity to the Ideal Solution*

TSO – Operador de Sistema de Transmissão, do inglês *Transmission System Operators*.

TWh – Terawatt *hora*.

UA – Universidade Aberta.

UTAD – Universidade de Trás-os-Montes e Alto Douro.

W m⁻² – Watts por metro quadrado.

ZB – Zettabytes.

1. Introdução

*I am only one, but I am one.
I cannot do everything, but I can do something.
And because I cannot do everything,
I will not refuse to do something that I can do.*

Edward Everett Hale (1902)

Esta é uma proposta de trabalho, para uma dissertação de mestrado, realizada no âmbito do mestrado em Engenharia Informática e Tecnologias Web oferecido pela Universidade Aberta (UAb) e Universidade de Trás-os-Montes e Alto Douro (UTAD).

Esta dissertação enquadra-se na área de Extração de Conhecimento de Dados, nomeadamente na previsão multi-passos e multi-atributo do preço diário de eletricidade no Mercado Ibérico de Eletricidade (MIBEL).

1.1. Motivações e contribuições fundamentais

O mundo passou por transições significativas neste novo milénio. Uma dessas foi a transição para uma sociedade de conhecimento, onde a indústria mais lucrativa é a produção e gestão de informação, os dados. Segundo o *The Economist*, os dados são o petróleo dos nossos tempos (Hawken, Han, & Pettit, 2020). Estima-se que em 2024 cheguemos a cerca de 149 Zettabytes, que corresponde a perto de 2.5 vezes mais a quantidade de dados de 2020 (“*Total data volume worldwide 2010-2024 | Statista*”, 2020).

A digitalização, que pode ser vista como o aumento de aplicações de Tecnologias de Informação e Comunicação (TIC), do inglês *Information and Communication Technologies* (ICT) ao longo da economia e sociedade, associada à produção e disponibilização de dados, é responsável por uma parte considerável do consumo energético. Estima-se que em 2012 cerca de 4.7% do consumo mundial de energia elétrica (eletricidade) foi associado às TIC (Gelenbe & Caseau, 2015). Embora haja uma esperança que a digitalização venha reduzir o consumo de energia, esta ainda não foi justificada, pois trouxe um consumo de energia adicional. Estes aumentos têm sido maiores que os efeitos de redução de energia (aumento da eficiência energética e mudança setorial), pelo que o aumento do consumo de energia é suscetível de persistir (Lange, Pohl, & Santarius, 2020).

A energia é utilizada para todos os bens e serviços fornecidos (Marques, 2011). A energia elétrica (eletricidade) tem vindo a adquirir uma maior presença nas nossas vidas, nomeadamente nas últimas décadas, onde o seu consumo aumentou de 7.3TWh em 1980 para 21.8TWh em 2016 (“*World electricity consumption / Statista*”, 2021). Segundo a Agência Internacional da Energia, o futuro será cada vez mais elétrico (“*Conheça o nosso mercado / OMIE*” 2019).

A energia elétrica é uma *commodity* muito especial, pois, embora tenha havido diversos progressos relativos ao desempenho de baterias, esta é, largamente, um bem não armazenável (Maciejowska & Weron, 2019). Como tal, e face aos diversos riscos bastante altos para as diversas partes envolvidas, os mercados de eletricidade são caracterizados pela grande volatilidade de preços (Moreira, Bessa., & Gama, 2016).

A incerteza associada a muitos fenómenos temporais não permite o conhecimento exato do seu comportamento no futuro, o que nos leva a ter que proceder a previsões. As previsões desempenham um papel fundamental no processo de planeamento, tomada de decisão e controlo em qualquer organização (Caiado, 2016).

Nos mercados de eletricidade, assim como em diversas áreas do conhecimento, há que lidar com incerteza (falta de informação perfeita) na tomada de decisão (Conejo, Carrión, & Morales, 2010). Se obtida antecipadamente a previsão do preço de energia elétrica constitui informação muito útil para lidar com a incerteza, sendo uma mais-valia para qualquer agente envolvido num mercado destes (Monteiro, Ramirez-Rosado, Fernandez-Jimenez, & Ribeiro, 2018). A relevância da previsão de preços de eletricidade é vista também pela quantidade de pesquisa muito ativa nos últimos 15 anos (Monteiro et al, 2018a).

Previsões variam amplamente nos seus horizontes de tempo, fatores que determinam os resultados reais, tipos de padrões de dados e muitos outros aspetos. Os métodos de previsão podem ser simples, como usar a observação mais recente como uma previsão (que é chamado de método *naïve*), ou altamente complexos, como redes neurais e sistemas econométricos de equações simultâneas. A escolha do método depende de quais dados estão disponíveis e da previsibilidade da quantidade a ser prevista (Hyndman & Athanasopoulos, 2018).

O campo de Previsão de Preços de Eletricidade, do inglês *electricity price forecasting* (EPF), visa prever os preços nos mercados grossistas, quer num cenário pontual ou probabilístico. Contudo, dada a diversidade das regulamentações comerciais disponíveis em todo o mundo, a EPF tem sempre de ser adaptada ao mercado específico (Lago, Marcjasz, De Schutter, & Weron, 2020). Nesse sentido, e pela proximidade geográfica, optou-se por estudar o Mercado Ibérico de Energia Elétrica (MIBEL).

Na literatura relativa de EPF, é recorrente usarem-se os termos “short” (curto), “medium” (médio) e “long” (longo) prazos, no entanto estes não têm definições comumente aceites. Horizontes de curto-prazo variam entre minutos a dias e são, principalmente, relevantes para operações de mercado e estabilidade do sistema (Maciejowska & Weron, 2019). As previsões de preço de energia a curto tempo são de extrema importância para operações de mercados diários (Weron, 2014). Em anos recentes tem sido feito um esforço significativo no desenvolvimento de modelos de previsão de preços de eletricidade para o dia seguinte, em inglês, *Day-Ahead Electricity Price Forecasting* (DAEPF). Modelos DAEPF são essencialmente baseados em modelos clássicos de séries temporais ou modelos de inteligência computacional, embora alguns combinem ambas as abordagens (Monteiro et al, 2018a). Modelos DAEPF clássicos de series temporais descritos na literatura recorrem a uma variedade de técnicas. Alguns descrevem a aplicação de apenas uma técnica, enquanto outros aplicam um conjunto de técnicas para desenvolver vários modelos e comparar os resultados das previsões. As técnicas incluem alisamento exponencial (Cruz, Muñoz, Zamora, & Espínola, 2011), regressões múltiplas (Conejo, Contreras, Espínola, & Plazas, 2005; Bordignon, Bunn, Lisi, & Nan, 2013) regressão variável com o tempo (Karakatsani & Bunn, 2008; Jonsson, Pinson, Nielsen, Madsen, & Nielsen, 2013), Box-Jenkins e modelos derivados (Ziel, 2016; Koopman, Ooms, & Carnero, 2007; Dong, Wang, Jiang, & Wu, 2011), modelos econométricos (Knittel & Roberts, 2005), GARCH (*Generalized Auto-Regressive Conditional Heteroskedasticity*) (Tan, Zhang, Wang, & Xu, 2010; Girish, 2016), entre outros. Usualmente, as técnicas mais simples são usadas para desenvolver modelos com propósito de comparação (Weron & Misiorek, 2008). Modelos DAEPF de inteligência computacional são principalmente baseados em redes neuronais artificiais (*artificial neural networks*) (Yamin, Shahidehpour, & Li, 2004; Lin, Gow, & Tsai, 2010; Singhal & Swarup, 2011), sistemas difusos (*fuzzy systems*) (Amjady, 2006; Li, Liu, Mattson, & Lawarree, 2007) e *Support Vector Machine* (SVM) (Ghasemi, Shayeghi, Moradzadeh, & Nooshyar, 2016; Alamaniotis, Bargiotas, Bourbakis, & Tsoukalas, 2015).

Acreditamos ser possível recorrer à grande quantidade de dados disponível online por forma a efetuar previsões de preços de eletricidade que podem ser utilizadas para lidar com a incerteza na tomada de decisão. Os preços da eletricidade para o consumidor estão a aumentar, atualmente, mais que nunca (“*Global energy prices/ Statista*”, 2020), e nós cremos que ao ajudar a reduzir incertezas com a obtenção de previsões fiáveis do preço da eletricidade possa ser uma forma de ajudar na redução do preço de eletricidade para o consumidor.

O campo de Previsão de Preços de Eletricidade sofre de vários problemas que impedem ter uma investigação reproduzível e estabelecer conclusões fortes sobre quais os métodos que funcionam melhor (Lago et al, 2020).

Por forma a lidar com alguns dos problemas no campo de EPF, consideramos, em seguida, alguns desses, como indicados em (Lago et al, 2020), e a forma como os combatemos:

Tamanho do período de teste

É prática comum avaliar novos métodos de previsão em intervalos de teste pequenos, o que pode ser problemático por várias razões ilustradas em 14. Nesse sentido, para evitar este problema, recorreremos a diversos intervalos de tempo, onde no maior intervalo de tempo, consideramos sempre um intervalo de teste superior a um ano. Isto permite assegurar que os métodos de previsão são avaliados considerando um conjunto completo de efeitos que têm lugar durante o ano.

Métricas de avaliação

Encontramos diversos artigos que apresentam apenas uma métrica. Uma vez que há diversas vantagens e desvantagens associadas à utilização de métricas específicas, como MAE, MAPE e RMSE, apresentamos um conjunto de diversas métricas de erro.

Tempo de computação

Diversos artigos que encontramos não têm em consideração o tempo de computação, métrica que julgamos ser relevante. Nesse sentido, a par das métricas MAE, MAPE e RMSE, incluímos o tempo de execução (em segundos).

Reprodutibilidade

Alguns estudos carecem de detalhes suficientes para replicar a investigação. Assim, recorreremos a dados disponíveis abertamente, indicando as fontes dos mesmos, partilhando ainda o código utilizado para a extração dos dados.

Contaminação de dados

Outra questão recorrente na literatura da EPF é a contaminação de dados, que aparece quando parte do conjunto de dados de formação é utilizada para testes. Como tal, por forma a prevenir que os modelos sobreajustem ao conjunto de dados de teste, que pode levar os modelos a não generalizar bem na presença de novos dados, o conjunto de dados de teste inclui sempre a última parte do conjunto de dados, evitando, assim, a contaminação dos dados. Esta consideração é particularmente relevante quando se trabalha com dados de séries cronológicas.

Em adição, as variáveis de entrada dos modelos são definidas explicitamente, ponto que consideramos importante para a reprodutibilidade do estudo. Recorreremos a um conjunto extenso de variáveis de entrada que consistem em séries temporais de valores históricos horários de preço, produção de energia, procura, variáveis relacionadas com o clima, como a precipitação total, bem como dados cronológicos.

Como resultado esperado pretendemos desenvolver modelos que permitam realizar a previsão multi-atributo do preço de eletricidade no mercado diário do Mercado Ibérico de Energia (MIBEL), para as 24 horas do dia seguinte (Multi-Passos).

1.2. Objetivos

O presente trabalho pretende fornecer um enquadramento teórico à tarefa de previsão, nomeadamente à previsão multi-passos de preço de eletricidade, com recurso a múltiplos atributos. Esses servem de base para a componente prática de planear e desenvolver modelos de previsão para o preço diário de eletricidade no MIBEL para as vinte e quatro horas seguintes ao último ponto da série temporal.

Para atingir o objetivo principal desta dissertação, existem algumas dependências que precisam de ser abordadas:

- Estudar e compreender o Mercado Ibérico de Eletricidade e o seu funcionamento.
- Estudar e compreender Previsões, em especial: Previsões de Séries Temporais, Previsão de Preço de Eletricidade e Previsões Multi-Passos.
- Estudar e compreender o Processo de Modelação e Planeamento de Experiências.
- Estudar e compreender o desempenho de Previsões obtidas pelos nossos resultados computacionais, incluindo recorrendo a métodos de Decisão Multi-Atributo.

1.3. Metodologia de investigação

A metodologia de investigação para esta dissertação centra-se no *Design Science Research* (DSR). A DSR é utilizada para desenvolver novas tecnologias e/ou para resolver problemas. O processo de investigação de *Design Science* inclui os seguintes passos: identificação do problema e motivação, definição dos objetivos para a proposta de solução, planeamento e desenvolvimento, demonstração dos resultados, avaliação e comunicação. O objetivo final terá presente a criação de um artefacto tecnológico (Peffer, Tuunanen, Rothenberger, & Chatterjee, 2007).

Está prevista a utilização de técnicas de Ciência de Dados, nomeadamente de previsão multi-passos e multi-atributo, com recurso a dados abertos, e, ainda, métodos de decisão multi-atributo.

Por forma a clarificar a definição do(s) problema(s) a tratar, começamos por fazer um levantamento do Estado da Arte.

No que toca à metodologia do levantamento do Estado da Arte, efetua-se duas abordagens: de cima para baixo e de baixo para cima. Isto é, alterna-se entre começar no nível de situação de domínio superior, analisando palavras-chave com recurso a ferramentas de mapeamento bibliográfico que permitiram encontrar novos artigos/livros relevantes e as suas relações/importâncias (cima para baixo). Ou, a partir dos artigos/livros, encontrar palavras-chave relevantes (e outras referências) para o domínio superior da dissertação (baixo para cima). Este processo, acontece, de certo modo, de forma iterativa.

Com base nas palavras-chave, procura-se artigos de diversas formas:

- Recorrendo a ferramentas de mapeamento bibliográfico que requerem importação de dados bibliográficos, nomeadamente o VOSViewer¹ e o CiteSpace². Os dados bibliográficos foram obtidos com recurso ao Dimensions³ e ao Publons⁴.
- Recorrendo a uma ferramenta que mapeia a bibliografia que não requer importar dados bibliográficos, para além de indicar o nome do artigo ou alguma palavra-chave: Connected Pappers⁵.
- ResearchGate⁶, Springer⁷, arXiv.org⁸, Google Scholar⁹ (tomando partido da parceria que a UAb tem, utilizando o VPN da UAb¹⁰), Wiley¹¹, entre outros repositórios de artigos/livros/jornais científicos.

Por forma a facilitar a gestão de referências, recorreremos a duas plataformas: Zotero¹² e Mendeley¹³.

1.4. Organização da dissertação

O presente documento descreve o trabalho a ser desenvolvido e está organizado em oito capítulos. Após a introdução, iremos abordar:

- Trabalhos Relacionados;
- Conjuntos de Dados;
- Modelos e Planeamento de Experiências;
- Resultados Computacionais e Discussão;
- Conclusão.

No final poderemos aceder às Referências Bibliográficas e aos Anexos. Uma vez que os anexos são extensos, optou-se por colocá-los num documento à parte.

¹ <https://www.vosviewer.com/> (VOSViewer, sem data).

² <https://citespace.podia.com/download> (“Download CiteSpace”, sem data).

³ <https://www.dimensions.ai/> (Dimensions, sem data).

⁴ <https://publons.com> (Publons, sem data).

⁵ <https://www.connectedpapers.com> (Connected Papers, sem data).

⁶ <https://www.researchgate.net/> (ResearchGate, sem data).

⁷ <https://www.springer.com/> (Springer, sem data) e <https://link.springer.com/> (Springer Link, sem data) sendo que nesta última podemos encontrar conteúdos onde as palavras-chave aparecem.

⁸ <https://arxiv.org/> (ArXiv.org, sem data).

⁹ <https://scholar.google.com/> (Google Scholar, sem data).

¹⁰ <https://vpn.uab.pt/> (VPN UAb, sem data).

¹¹ <https://www.wiley.com/> (Wiley, sem data).

¹² <https://www.zotero.org/> (Zotero, sem data).

¹³ <https://www.mendeley.com/> (Mendeley, sem data).

2. Trabalhos Relacionados

*If I have seen further, it is by standing on the
shoulders of Giants.*

Isaac Newton

Neste capítulo é feita uma breve síntese de alguns conceitos que são considerados importantes para ajudar na compreensão do trabalho desenvolvido. A informação exposta está relacionada com mercados de eletricidade (2.2.), séries temporais (2.3.), ciências de dados (2.4.), previsão (2.5.), geometria de informação (2.6.) e decisão multi-atributo (2.7.).

2.1. *Inteligência Open Source (OSINT)*

Embora organizações governamentais tenham acesso a mais recursos e poderes legislativos adicionais comparadas com organizações de setor privado, quantidades significativas de informação estão disponíveis como *Open-Source Intelligence* (OSINT) (Talbot & Jakeman, 2009).

OSINT refere-se a toda a informação que está disponível publicamente. Não há informação específica relativamente à data de quando o termo foi primeiramente proposto, no entanto um termo relativo provavelmente tem sido utilizado há centenas de anos para descrever o ato de obter inteligência ao explorar recursos disponíveis de forma pública. (Hassan, Hijazi, 2018).

Métodos e ferramentas de OSINT concentram-se na construção de uma compreensão profunda de como explorar técnicas, métodos e ferramentas para adquirir informações de fontes online disponíveis publicamente para apoiar a análise de inteligência. Os dados recolhidos podem ser usados em diferentes cenários, como investigações financeiras, criminais e de terrorismo, bem como em tarefas mais regulares, como análise de concorrentes de negócios, verificação de antecedentes e aquisição de inteligência sobre indivíduos e outras entidades (Hassan, Hijazi, 2018).

Muitas estimativas mostram que grande parte das informações úteis adquiridas por serviços de inteligência vêm de fontes públicas (por outras palavras, fontes OSINT) (Hassan, Hijazi, 2018).

As fontes OSINT diferenciam-se de outras formas de inteligência porque devem ser legalmente acessíveis ao público, sem violar quaisquer direitos autorais ou leis de privacidade. Essa distinção torna a capacidade de reunir fontes OSINT aplicáveis a mais do que apenas serviços de segurança. Por exemplo, as empresas podem se beneficiar da exploração desses recursos para obter inteligência sobre seus concorrentes (Hassan, Hijazi, 2018).

À medida que a tecnologia se prolifera e o volume de dados disponíveis aumenta, departamentos governamentais, organizações não governamentais (ONGs) e empresas estão a começar a confiar em grande parte em OSINT, ao invés de em informações privadas e classificadas (Hassan, Hijazi, 2018).

OSINT inclui todas as fontes de informação acessíveis ao público. Essas informações podem ser encontradas online ou offline, embora as fontes online sejam o segmento maior de OSINT (Hassan, Hijazi, 2018).

Em contexto de OSINT e no âmbito deste trabalho, é importante esclarecer alguns pontos:

- Distinguir entre dados, informação e conhecimento.
- Volume de dados digitais (*Big Data*).
- Ética e Legalidade.
- Dados abertos, o tipo de OSINT disponível online que recorreremos para a componente prática deste trabalho.

2.1.1. Dados, Informação, Conhecimento

Embora estes três termos sejam, muitas vezes, utilizados intercambiavelmente, cada um tem um significado diferente, embora interajam entre eles.

- **Dados:** É o conjunto de factos que descreve algo sem explicação adicional ou análise. Por exemplo, “O preço de eletricidade é 50€/MWh”.
- **Informação:** É um tipo de dados que foi interpretado corretamente para dar um significado útil dentro de um contexto específico. Por exemplo, “O preço de eletricidade desceu de 60€/MWh para 50€/MWh numa semana”.

- **Conhecimento:** É uma combinação de informação, experiência e percepção que foi aprendida ou inferida após alguma experimentação. Por exemplo, “Quando o preço de eletricidade desce 30%, isto significa que é fim de semana.” (Hassan, Hijazi, 2018).

2.1.2. Volume de Dados Digitais (Big Data)

Hoje vivemos na era da informação onde muitos editores, universidades e empresas estão a alterar os processos de negócios para formatos digitais. O número de utilizadores em sites de redes sociais continuará a aumentar e o número de dispositivos de Internet das Coisas (IoT) intensificar-se-á, levando a um grande aumento no volume de dados digitais provenientes de milhões de sensores e máquinas no mundo todo. (Hassan, Hijazi, 2018).

O volume de dados digitais está a explodir rapidamente. De acordo com a International Data Corporation (IDC), até ao ano de 2020, a quantidade total de dados digitais criados em todo o mundo chegará a 44ZB, e o número aumentará mais rapidamente em cinco anos para chegar a 180ZB em 2025 (Hassan, Hijazi, 2018).

Associado a este aumento explosivo de dados globais, surgiu o termo *Big Data*, usado principalmente para descrever conjuntos de dados enormes que não podem ser compreendidos, adquiridos, geridos e processados por ferramentas tradicionais num intervalo de tempo aceitável (Chen, Mao, Zhang, & Leung, 2014). Este termo é subjetivo, pois assume-se que à medida que a tecnologia avança, o tamanho dos conjuntos de dados que se qualificam como *Big Data* também aumentam. Para além disso, esta definição pode variar por setor, dependendo das ferramentas que estão disponíveis e dos tamanhos dos conjuntos de dados nessa indústria em particular (“*Big data: The next frontier for innovation, competition, and productivity | McKinsey*”, 2011).

Os números referidos no segundo parágrafo desta secção devem dar uma ideia de como será o futuro próximo na era digital. O volume de dados disponíveis online, juntamente com o aumento do número de pessoas que usam a Internet para realizar os seus trabalhos, farão das fontes online a principal fonte de OSINT para governos e empresas no futuro (Hassan, Hijazi, 2018).

2.1.3. Ética e Legalidade

Apesar da grande importância de OSINT, ele apresenta preocupações jurídicas quando analisado ou capturado em muitos casos. Por exemplo, se alguém adquire fontes OSINT por meios ilegais para justificar um caso honesto, como é que o sistema legal deve lidar com isso? (Hassan, Hijazi, 2018).

Por forma a garantir ética e legalidade no que toca aos dados que analisaremos ao longo do trabalho, recorreremos apenas a dados abertos, um tipo de OSINT disponível *online* que abordaremos de seguida.

2.1.4. Dados Abertos (*Open Data*)

Open Data diz respeito a dados que não apresentam barreiras na sua (re)utilização (Loenen, Vancauwenberghe., & Crompvoets, 2018), podendo ser acedidos, utilizados, modificados e compartilhados livremente para qualquer finalidade (sujeito, no máximo, aos requisitos que preservam a procedência e a abertura) (“*The Open Definition—Open Definition—Defining Open in Open Data, Open Content and Open Knowledge*”, sem data).

Dados abertos têm como objetivo otimizar o acesso, a partilha e o uso de dados numa perspectiva técnica, jurídica, financeira e intelectual. Os dados determinam cada vez mais a maneira como as pessoas vivem as suas vidas hoje. Atualmente, é difícil imaginar uma vida sem informações do jornal diário ou informação meteorológica. Ao mesmo tempo, os próprios cidadãos estão constantemente a partilhar dados e informações por meio de muitos dispositivos e sistemas de redes sociais diferentes (Loenen, Vancauwenberghe., & Crompvoets, 2018).

Os dados abertos requerem que os conjuntos de dados sejam de domínio público ou distribuídos por meio de uma licença aberta. Os dados devem ser fornecidos como um todo, gratuitamente e, de preferência, para descarregar pela Internet, incluindo quaisquer informações adicionais que possam ser necessárias para cumprir os termos da licença aberta. A abertura requer que os dados sejam fornecidos num formato prontamente legível e o formato também deve ser aberto, o que significa que não impõe nenhuma restrição ao seu

uso e que os arquivos nesse formato podem ser processados com ferramentas de software de código aberto (Loenen, Vancauwenberghe., & Crompvoets, 2018).

De acordo com os princípios da Open Government Data (OGD), que são indiscutivelmente fundamentais na compreensão do conceito de Open Data, os dados devem ser:

- Completos;
- Primários;
- Atuais;
- Acessíveis;
- Processáveis em Máquinas;
- Não discriminatórios;
- Não proprietários;
- Livres de licença.

A conformidade com os princípios do OGD precisa de ser demonstrável, ou seja, deve haver medidas de responsabilidade em vigor para permitir a revisão da adesão aos princípios acima. (Loenen, Vancauwenberghe., & Crompvoets, 2018).

No contexto deste trabalho consideramos que dados abertos podem implicar um registo para aceder aos mesmos, apenas se o registo for aberto a todos os utilizadores com acesso à Internet.

2.2. *Mercados de Eletricidade*

Os mercados de eletricidade pertencem a um grande grupo de mercados de energia. Os mercados de combustíveis, por exemplo, petróleo, gás, carvão e os seus subprodutos, são os mercados de energia mais antigos a nível de mercado grossista (Ferreira, 2017b).

Neste subcapítulo apresentamos uma visão geral dos mercados de eletricidade e algumas das características que os distinguem dos outros mercados de energia.

2.2.1. Incapacidade de Armazenamento

Central a quase todos os aspetos da eletricidade é a questão do armazenamento. Enquanto a maioria das *commodities* possa absorver as variações de produção e procura, isso não se aplica à eletricidade (Harris, 2006).

Embora haja vários métodos que equivalem ao armazenamento, como a conversão numa forma de energia armazenável que permita uma transformação, posterior, em corrente elétrica (Ferreira, 2017b), considera-se que a eletricidade deve ser consumida à medida que é produzida (Harris, 2006).

2.2.2. Fases do Abastecimento de Eletricidade

A incapacidade de armazenamento característica da eletricidade torna a eficiência dos mercados de eletricidade um grande desafio, requerendo serviços adicionais de balanceamento e recursos de reserva, para além dos serviços de produção e distribuição.

As fases essenciais no ciclo de energia elétrico são as seguintes:

i. Fornecimento de energia.

Começando com a fonte de energia, um ativo natural sob (inicialmente) propriedade comum deve ser explorado para gerar eletricidade. Essa fonte pode estar no subsolo (como o combustível nuclear ou fóssil), ser colhida de forma renovável (como colheitas de energia) ou de forma natural (como o vento e a água). A atividade de fornecimento pode exigir várias atividades após a recolha inicial, como o processamento e refino, e depois entregue a uma estação elétrica (Harris, 2006).

ii. Geração de energia.

Neste processo, uma fonte de energia *in situ* é convertida em eletricidade e entregue à infraestrutura de transporte, ou diretamente a uma carga de *host*. Para gerar energia é necessário, para além de uma fonte de energia, acessos físicos e económicos, razoáveis, junto da infraestrutura completa da fonte de energia, que pode incluir gasoduto, ferrovia, estradas ou portos. Da mesma forma, o gerador requer acesso físico e económico, razoável, para o cliente consumidor (Harris, 2006).

Devido à incapacidade de armazenamento e o baixo nível de resposta dinâmica dos geradores de energia, a quantidade de eletricidade produzida deve ser, em cada instante, igual à quantidade de energia consumida. É necessário que os geradores de energia tenham um nível extremamente alto de flexibilidade, como, resposta de curto prazo em tempo e volume, para lidar com variações repentinas na procura e/ou falhas no gerador e na rede (Ferreira, 2017b).

iii. Transporte na rede, divisão em alta e baixa voltagem.

Transmitir e distribuir energia requer requisitos de acesso extensos e, possivelmente, intrusivos, ao equipamento físico de postes, linhas de transmissão e distribuição, transformadores e outros equipamentos. Isso requer direitos de propriedade que seriam impossíveis sem o apoio dos governos locais e nacionais. O transporte é um monopólio natural e, como tal, está sujeito a preços regulamentados (Harris, 2006).

O setor de fornecimento de eletricidade é impulsionado pelo carácter de tempo-espaço da eletricidade: é entregue instantaneamente por longas distâncias com altas variações na taxa de entrega. Considerações de rede, como ineficiências, resistência elétrica e reactância elétrica, são cruciais no *design* dos mercados de eletricidade. Linhas de transmissão, linhas de distribuição, transformadores e outros equipamentos são necessários para transmitir e distribuir a eletricidade (Ferreira, 2017b).

iv. Gestão do abastecimento.

Os serviços de balanceamento são segurados pelo sistema e pelos operadores do mercado. O operador do sistema é o gestor de energia do sistema, que garante o equilíbrio perfeito e contínuo da procura e da oferta, além da estabilidade da transmissão da rede. As operações de mercado envolvem acordos comerciais de energia e capacidade comercial entre participantes e o operador do sistema (Ferreira, 2017b).

A eletricidade é entregue à maioria dos consumidores como um produto de retalho “empacotado”, isto é, os consumidores pagam aos fornecedores pelo produto e os fornecedores organizam tudo o resto (Harris, 2006).

v. Consumo.

Para além destes, há ainda:

vi. Operação do Sistema.

A Operação do Sistema é a gestão elétrica do mesmo, principalmente a curto prazo (menos de um dia). Devido à necessidade de obter uma correspondência, perfeita e contínua, entre procura e oferta (a uma resolução de frações de segundo), a curto prazo, não há tempo para interações multilaterais, pelo que um único operador de sistema deve coordenar (Harris, 2006).

vii. Operação do Mercado.

A Operação de Mercado envolve acordos comerciais de energia e negociação de capacidade entre os participantes e o operador do sistema, e a coordenação desses acordos comerciais entre os participantes. (Harris, 2006).

viii. Medição (*Metering*).

Embora o custo seja incorrido em todos os pontos da cadeia de valores, há apenas uma fonte de receita – o consumidor. Para pagar pela eletricidade, o consumidor deve ter um preço e um valor definitivos para pagar. O medidor é, claramente, a fonte de informação, mas na prática os processos são altamente complicados. Portanto, consideramos a medição uma parte importante e distinta do abastecimento de eletricidade (Harris, 2006).

E, finalmente, algo que não pode ser ignorado:

ix. Descarga e impacte ambiental.

Isto pode ser visto como a última face do ciclo de vida da eletricidade, um subproduto da produção de eletricidade ou um fator de entrada. Embora o impacte ocorra predominantemente no setor de geração de energia, ele é inevitável pelo ato de consumo (Harris, 2006).

2.2.3. Mercado Grossista (*Wholesale*)

Os mercados convencionais não exigem nenhuma organização especial, isto é, não há coordenação central entre compradores e vendedores. A organização dos mercados de eletricidade é, no entanto, essencial para garantir a combinação perfeita de oferta e procura a qualquer momento. Qualquer variação de procura num dia, hora ou minuto deve ser perfeitamente equilibrada pela oferta. Qualquer desequilíbrio entre a oferta e procura pode ser muito dispendioso e levar a amplos apagões (Ferreira, 2017b).

Nos mercados do dia-seguinte, a eletricidade é negociada a cada hora do dia seguinte e pode ser vista como um mercado a prazo com entrega no dia seguinte. Usando as informações do mercado no dia seguinte, o operador do sistema estabelece quais unidades geradas devem ser programadas e despachadas para atender à procura a cada hora do dia seguinte, da forma mais económica. A procura real e a capacidade de gerar podem mudar próximo do tempo real de entrega, e podem ser necessários ajustes nos cronogramas do dia seguinte. Isso é realizado através dos mercados intra-diários (conhecidos por mercados de compensação em tempo real), onde compradores e vendedores podem ajustar as suas posições horas e minutos antes da operação. Esses ajustes são feitos alternando o envio de geradores comprometidos no mercado do dia-seguinte (Ferreira, 2017b).

Os mercados do dia-seguinte são organizados com diferentes graus de centralização: mercados bilaterais, *exchanges* e *pools* (Ferreira, 2017b).

Nos mercados bilaterais, as negociações são estabelecidas diretamente entre compradores e vendedores, sem nenhuma coordenação externa. Essas negociações bilaterais são então recolhidas pelo operador de transmissão, que é uma entidade externa que garante a sua viabilidade técnica, ou seja, a entrega física não sobrecarregará nenhuma linha de transmissão ou outro equipamento no sistema (Ferreira, 2017b).

Uma *power exchange* é um mercado centralizado que reúne lances de procura preço-quantidade simples e fornece ofertas durante cada hora do dia seguinte. Em seguida, as *exchanges* determinam a quantidade de compensação de mercado cruzando curvas de oferta e procura. O preço de compensação do mercado é normalmente único, sendo pago por todos

as licitações aprovadas (*cleared bids*) a todas as ofertas aprovadas (*cleared offers*) (Ferreira, 2017b).

Os *pools* diferem das *exchanges* principalmente por aceitarem ofertas mais complexas de geradores. Para além do preço, as licitações podem incluir custos de inicialização, custos sem carga, taxas de rampa e tempos mínimos de execução. A geração está programada para atender à procura do sistema, minimizando a oferta total de compra, definindo o preço no último preço de oferta aceite. Embora o preço da compensação nem sempre seja suficiente para cobrir os custos de partida e sem carga, as unidades de geração podem estar programadas para operar. Quando isso ocorre, o *pool* fornece pagamentos paralelos para garantir que a geração programada seja lucrativa (Ferreira, 2017b).

Dentro dos mercados bilaterais, os participantes podem ajustar os termos do contrato de acordo com as suas necessidades individuais. No entanto, as trocas bilaterais podem ser estabelecidas ao lado de *pools* ou *exchanges* recorrendo a contratos para diferenças. Por outro lado, os mercados bilaterais têm uma programação de produção ineficiente e desvantagens na gestão dos constrangimentos de transmissão. A eficiência é melhor alcançada através da coordenação de agrupamentos de energia, que simultaneamente observa todos os horários de energia, custos de compromisso das unidades geradoras e capacidade de transmissão disponível. Tendo um grau médio de centralização entre mercados bilaterais e *pools*, as trocas de energia partilham alguns benefícios e desvantagens de ambos (Ferreira, 2017b).

De notar que, assim como Uniejewski, Nowotarski, & Weron, (2016), estamos a usar os termos *spot* e *day-ahead* de forma alternada. Em adição, recorreremos à tradução em português, como, neste caso, “diário”. Nos EUA o *mercado spot* está associado ao *real-time market* e o *day-ahead* ao *forward market* (Burger, Graeber, Schindlmayr, 2014).

2.2.4. Mercado Ibérico de Eletricidade

Neste subcapítulo apresentaremos uma visão geral do MIBEL e do grupo Operador do Mercado Ibérico (OMI). Para informações mais detalhadas, consultar (Monteiro et al, 2018a;

Lago et al, 2020; Cruz, Muñoz, Zamora& Espínola, 2011). Por fim, abordaremos os operadores do sistema de transmissão.

O Mercado Ibérico de Energia Elétrica constitui uma iniciativa conjunta entre os governos de Portugal e Espanha que visa a construção de um mercado regional de eletricidade. O protocolo de colaboração entre os dois países foi assinado em outubro de 2014, tendo, o MIBEL, sido lançado em 1 de julho de 2007 (MIBEL, sem data).

O MIBEL permite a interação de vários tipos de compradores, como retalhadores de referência, revendedores, consumidores diretos e vendedores (produtores de energia elétrica) (Ferreira, 2017a), num regime livre de concorrência (OMIP, sem data).

O ativo subjacente a todos os contratos futuros é um nocional fornecido/recebido da energia elétrica a uma potência constante de 1MWh durante todas as horas do período de entrega. Esses contratos são cotados em Euros por MWh e os prazos de entrega disponíveis são dia, fim de semana, semana, mês, trimestre e ano. O preço de entrega é calculado usando um índice de referência de preço *spot* (Ferreira, 2017a).

2.2.4.1. OMI

O grupo Operador do Mercado Ibérico está estruturado em duas sociedades acionistas, OMEL e OMIP SGPS. Cada uma destas sociedades possui cerca de 50% das duas sociedades gestoras do mercado elétrico da Península Ibérica: OMIE, gestora dos mercados diário e intra-diário, e OMIP, gestora do mercado a prazo. As sociedades têm, por sua vez, uma participação de 50% na sociedade OMIClear (“*Informação OMI / OMF*”, sem data).

Adicionalmente, as sociedades holding OMEL e OMIP SGPS participam com 20% e com 10%, respetivamente, na MIBGAS, S.A., operado do mercado grossista de gás natural da Península Ibérica (“*Informação OMI / OMF*”, sem data). Segue abaixo uma figura (figura 2.1.) com a estrutura corporativa do grupo OMI:

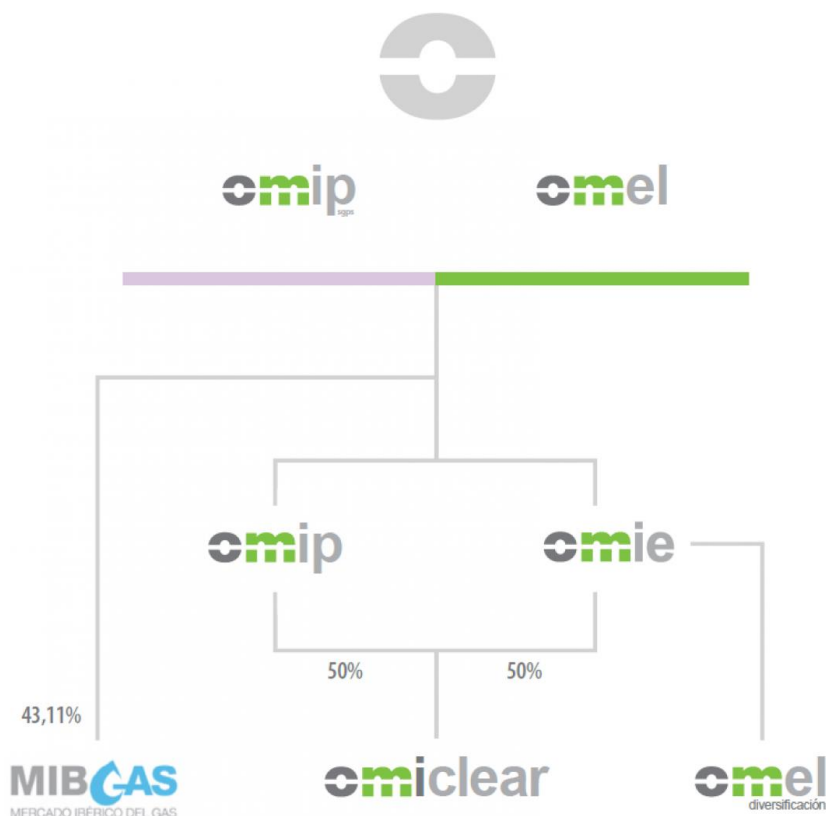


Figura 2.1. Estrutura corporativa do grupo do Operador do Mercado Ibérico (“Informação OMI | OMI”, sem data).

OMIE (Spot Market)

O Operador do Mercado Ibérico de Energia – Polo Español S. A. (OMIE) é o “Nominated Electricity Market Operator” (NEMO) para a Península Ibérica (“Mercado Spot OMIE / OMI”, sem data) e gere os mercados diários (SDAC) (*Mercado da electricidade | OMIE*”, sem data) e intra-diários de eletricidade, em Espanha e Portugal.

O mercado diário define os preços de eletricidade para as vinte e quatro horas do dia seguinte (*day-ahead*). Os preços e volumes são determinados pelo equilíbrio entre oferta e procura para cada hora do dia anterior (*marginal pricing model*) (OMIE, sem data). Quando a eletricidade trocada excede a capacidade da rede entre Portugal e Espanha, o mecanismo de divisão do mercado entra em atividade e estabelece preços diferentes para cada país (Ferreira, 2017a). A viabilidade técnica do calendário do mercado diário é garantida pelo operador do sistema. Ajustes ao calendário final viável são possíveis nos mercados intra-diários. Quando o mercado diário fecha, são feitas seis sessões dos mercados intra-diários, onde os agentes de mercado podem ajustar as suas posições até quatro horas do tempo real de entrega (OMIE, sem data).

OMIP (Derivatives Market)

O Operador do Mercado Ibérico de Energia – Pólo Português (OMIP) gere o Mercado de Derivados da Energia Elétrica oferecendo serviços de negociação em contínuo de diversos produtos derivados, registo de operações bilaterais e serviços de distribuição de dados (*Mercado a prazo OMIP / OMF*, sem data).

Os membros negociadores podem negociar produtos derivados, como futuros, opções, *swaps* e outros contratos a termo, cujo ativo subjacente é a eletricidade e gás natural (OMIP, sem data).

O OMIP oferece ainda serviços de desenvolvimento, implantação, gestão e operação de soluções de mercado em diversas áreas, como leilões para atribuição de diversos ativos (OMIP, sem data).

OMICLEAR

A OMIClear, C.C., S.A. é uma empresa sediada em Portugal que presta serviços de compensação e liquidação relativamente a contratos de derivados de energia negociados e/ou registados no Mercado de Derivados OMIP, desde 3 de julho de 2006 (OMIP, sem data; OMIClear, sem data). Esta desempenha o papel de Câmara de Compensação (OMIClear, sem data).

2.2.4.2. Operadores de Sistema de Transmissão (TSO)

Um Operador de Sistema de Transmissão, do inglês *Transmission System Operator* (TSO) é uma entidade responsável pelo transporte de energia sob a forma de gás natural ou eletricidade, num nível nacional ou regional, recorrendo a infraestrutura fixa.

Os TSO português e espanhol responsáveis pelo transporte de eletricidade são, respetivamente, a Rede Elétrica Nacional (REN)¹⁴ e a Rede Elétrica de España (REE)¹⁵.

¹⁴ <https://www.ren.pt> (REN, sem data).

¹⁵ <https://www.ree.es> (Red Eléctrica de España, sem data).

2.3. Séries Temporais

Uma série temporal é uma sequência de observações tomadas sequencialmente no tempo. Muitos conjuntos de dados aparecem como séries cronológicas: uma sequência mensal da quantidade de mercadorias enviadas de uma fábrica, uma série semanal do número de acidentes rodoviários, quantidades de chuva diárias, observações horárias feitas sobre o rendimento de um processo químico, e assim por diante. Uma característica intrínseca de uma série cronológica é que, tipicamente, as observações adjacentes são dependentes. A natureza desta dependência entre as observações de uma série cronológica é de considerável interesse prático. A análise de séries cronológicas diz respeito a técnicas para a análise desta dependência. Isto requer o desenvolvimento de modelos estocásticos e dinâmicos para dados de séries cronológicas e a utilização de tais modelos em áreas importantes de aplicação (Box, Jenkins, Reinsel, & Ljung, 2015).

Os valores que uma série temporal pode tomar são:

- Contínuos: Uma série temporal é contínua quando as observações são feitas continuamente ao longo do tempo, mesmo quando a variável medida só pode tomar um conjunto discreto de valores. Por exemplo, um processo binário em tempo contínuo é uma série temporal contínua.
- Discretos ou Simbólicos: Uma série temporal é discreta quando as observações são tomadas apenas em momentos específicos, normalmente igualmente espaçadas, mesmo a variável medida é uma variável contínua (Li, 2013). Por sua vez, a dinâmica simbólica é um método para estudar sistemas não lineares de tempo discreto, tomando uma trajetória previamente codificada usando cordas de símbolos de um conjunto finito, também chamado alfabeto (Risso, 2017).

Vamos concentrar-nos mais nas séries cronológicas discretas, o foco do nosso trabalho. As séries cronológicas discretas podem surgir de várias maneiras:

- Amostradas: Dada uma série cronológica contínua, poderíamos ler os valores em intervalos de tempo iguais para dar uma série cronológica discreta, por vezes chamada de série amostrada. O intervalo de amostragem entre leituras sucessivas deve ser cuidadosamente escolhido de modo a perder pouca informação.
- Agregado: Agregar os valores em intervalos de tempo iguais de uma série cronológica contínua. Por exemplo, exportações mensais e chuvas diárias (Li, 2013).

A forma clássica, em termos matemáticos, para formalizar uma série temporal é considerá-la como um processo estocástico (2.3.1.).

2.3.1. Processos Estocásticos

A palavra “estocástico” é jargão para aleatório (Coleman, 1974). Um processo estocástico ou aleatório pode ser definido como um conjunto de variáveis aleatórias que é indexado por algum conjunto matemático, o que significa que cada variável aleatória do processo estocástico é unicamente associada a um elemento do conjunto (Parzen, 2015; Gikhman & Skorokhod, 1969). O conjunto usado para indexar as variáveis aleatórias é chamado de conjunto de índices. Historicamente, o conjunto de índices era algum subconjunto da linha real, tal como os números naturais, dando ao conjunto de índices a interpretação do tempo (Doob, 1990). Cada variável aleatória na coleção toma valores do mesmo espaço matemático conhecido como o espaço de estados. Este espaço de estados pode ser, por exemplo, os inteiros, a linha real ou n-espaço euclidiano n-dimensional (Gikhman & Skorokhod, 1969; Doob, 1990).

Um processo estocástico pode ter muitos resultados, devido à sua aleatoriedade, e um único resultado de um processo estocástico é chamado, entre outros nomes, uma função ou realização de amostra (Lamperti, 1977; Rogers & Williams, 2000).

2.4. Ciência de Dados

Embora a sua descrição possa variar, Ciência de Dados, em inglês *Data Science* (DS), pode ser vista como a análise sistemática de dados dentro de uma abordagem científica, isto é, a abordagem adaptativa, iterativa e em fases para análise de dados, realizada dentro de um enquadramento sistémico que permite revelar modelos ótimos ao avaliar os verdadeiros custos dos erros de previsão (Larose & Larose, 2019).

Esta combina a abordagem orientada a dados de análise de dados estatísticos (Estatística), o poder computacional e a perspicácia de programação da ciência da computação (Tecnologias de Informação) e inteligência de negócios de domínio específico (Negócios), a fim de

descobrir pedaços de informações úteis e lucrativos de grandes bases de dados (Larose & Larose, 2019). Todos os três aspetos são importantes e é a força dessa combinação de métodos e habilidades que está a produzir descobertas interessantes (Ahlemeyer-Stubbe & Coleman, 2018).

Por outras palavras, Ciência de Dados permite-nos extrair conhecimento acionável de bases de dados subutilizadas. Assim, os armazéns de dados que vêm acumulado poeira podem, agora, ser aproveitados para descobrir lucros ocultos e melhorar os resultados financeiros. A DS permite que as pessoas aproveitem grandes quantidades de dados e poder de computação para lidar com questões complexas. Os padrões podem surgir de dados que não poderiam ser descobertos de outra forma. Essas descobertas podem levar a resultados poderosos, como tratamento mais eficaz de pacientes médicos (Larose & Larose, 2019).

Extrair valor de dados requer a implementação de *Data Processing Pipelines* (DPP) que pode incluir diversas tarefas. Há diversas metodologias que ajudam os cientistas de dados a acompanhar em que fase da análise estão, como a *Cross-Industry Standard Practice for Data Mining* (CRISP-DM) e a *Sample, Explore, Modify, Model and Assess* (SEMMA). No contexto do nosso trabalho recorreremos a um conjunto de oito etapas, desenvolvido por nós, que apelidamos de Processo de Previsão Quantitativa e podemos encontrar em 2.5.3.

Vamos aproveitar esta secção para abordar algumas áreas relevantes de ciência de dados, nomeadamente: Engenharia de Dados (2.4.1.), Visualização de Dados (2.4.2.) e Aprendizagem Automática (2.4.3.).

2.4.1. Engenharia de Dados

Engenharia de Dados é o nome dado à transformação de dados em bruto para um formato passível de ser analisado (Romero, & Wrembel, 2020).

A Engenharia de Dados refere-se principalmente à Gestão de Dados, ou seja, ingestão, armazenamento, modelação, processamento e consulta de dados, mas abrange também aspetos de construção de sistemas, por exemplo, a criação de serviços e orquestração. Como relatado por peritos na matéria, até 80% do tempo dedicado à construção de um DPP é gasto

em pré-processamento de dados. Isto porque tais tarefas ainda não foram padronizadas e os profissionais estão a abordá-las de forma casuística (Romero, & Wrembel, 2020).

Esta envolve diversos formatos de dados, bem como a transformação, movimento e armazenamento dos dados.

2.4.2. Visualização de Dados

Os sistemas de visualização baseados em computador fornecem representações visuais de conjuntos de dados concebidos para ajudar as pessoas a realizar tarefas de forma mais eficaz. A visualização é adequada quando existe a necessidade de aumentar as capacidades humanas em vez de substituir as pessoas por métodos computacionais de tomada de decisão (Munzner, 2014).

A visualização de dados é a apresentação de dados em formato pictórico ou gráfico, e uma ferramenta de visualização de dados é o *software* que gera esta apresentação. A visualização de dados proporciona aos utilizadores meios intuitivos para explorar e analisar dados interactivamente, permitindo-lhes identificar eficazmente padrões interessantes, inferir correlações e causalidades, e apoiar atividades de criação de sentidos (Bikakis, 2018).

Com uma grande quantidade de dados, torna-se fundamental o seu resumo de uma forma que seja rápida e fácil de entender. Isso permitirá que exploremos e compreendemos os dados, por forma a auxiliar na tomada de decisões por meio de evidências. Há muitas formas de visualizar dados: por meio de tabelas, gráficos e animações. O tipo de visualização de dados a ser usada dependerá do tipo de dados a serem resumidos. A facilidade de implementação é certamente um atributo atraente das técnicas de visualização de dados, mas também pode levar ao seu uso indevido. As técnicas visuais podem ser implementadas de uma forma que não ajudem a resumir os dados ou forneçam resultados errados (Rivera, 2020).

As variáveis quantitativas são sintetizadas de forma diferente das variáveis categóricas. Dependendo do tipo de variáveis quantitativas (discretas ou contínuas) e dos objetivos da análise, seleccionamos o tipo de propriedades dos dados que pretendemos sumarizar. Estas

propriedades tendem a estar associadas à distribuição dos dados, que indicam o quão frequente são os valores diferentes da variável (Rivera, 2020).

2.4.3. Aprendizagem Automática

Mitchell (1997) define Aprendizagem Automática, do inglês *Machine Learning* (ML), de forma ampla, incluindo qualquer programa informático que melhore o desempenho em alguma tarefa através da experiência. Colocando de forma mais precisa, diz-se que um programa de computador aprende com a experiência E em relação a alguma classe de tarefas T e medida de desempenho P se o seu desempenho em tarefas T , tal como medido por P , melhorar com a experiência E (Mitchell, 1997).

A ideia por trás de ML é a programação de computadores para otimizar um critério de desempenho utilizando dados de exemplo ou experiência passada. Temos um modelo definido até alguns parâmetros, e aprendizagem é a execução de um programa de computador para otimizar os parâmetros do modelo utilizando os dados de treino ou experiência passada (Alpaydin, 2014).

Considerando que o foco de Aprendizagem Automática é “Aprendizagem”, há diversos tipos de aprendizagem com as quais nos podemos encontrar. Alguns tipos descrevem subcampos inteiros de estudo compostos de muitos tipos diferentes de algoritmos, tais como “Aprendizagem Supervisionada”. Outros descrevem técnicas que podemos utilizar, tais como aprendizagem de transferência (*transfer learning*).

Machine Learning utiliza a teoria da estatística na construção de modelos matemáticos, porque a tarefa principal é fazer inferências a partir de uma amostra. O papel da ciência da computação é duplo: Em primeiro lugar, no treino, precisamos de algoritmos para resolver o problema de otimização, bem como para armazenar e processar a enorme quantidade de dados que geralmente temos. Em segundo lugar, uma vez que um modelo é aprendido, a sua representação e solução algorítmica para a inferência também precisa de ser eficiente. Em certas aplicações, a eficiência do algoritmo de aprendizagem ou de inferência, nomeadamente, a sua complexidade espacial e temporal, pode ser tão importante como a sua precisão preditiva (Alpaydin, 2014).

Aprendizagem Automática é uma palavra popular na tecnologia atual, mas a construção de modelos artesanais por especialistas, nem sempre é suficientemente ágil para encontrar soluções que conduzam a decisões e operações comerciais em tempo real. Nesse sentido, *Automated Machine Learning* (AutoML) automatiza parcialmente o processo de construção de modelos para superar alguns destes desafios e aumentar a agilidade.

2.4.3.1. *AutoML*

Para reduzir os custos de desenvolvimento, surgiu uma nova ideia de automatizar todo o *pipeline* de Aprendizagem Automática, ou seja, *Automated Machine Learning* (AutoML).

Existem várias definições de AutoML. Por exemplo, de acordo com Zöller & Huber (2021), AutoML foi concebido para reduzir a procura por parte dos cientistas de dados e permitir aos peritos de domínio construir automaticamente aplicações ML sem grandes exigências de conhecimento estatístico e ML.

Em (Yao et al, 2019), AutoML é definido como uma combinação de automatização e ML. Podemos ver AutoML como envolvendo a construção automática de um *pipeline* ML num orçamento computacional limitado (He, Zhao, & Chu, 2021).

AutoML é uma abordagem que torna o ML mais amplamente acessível através da automatização do processo de criação de modelos ML, e acelerou recentemente tanto a investigação ML como a aplicação do ML a problemas do mundo real. Por exemplo, o trabalho inicial de pesquisa da arquitetura neural permitiu avanços na visão computacional, tais como NasNet, AmoebaNet, e EfficientNet, e no processamento de linguagem natural, tal como Evolved Transformer. Mais recentemente, o AutoML também foi aplicado aos dados tabulares (“Using AutoML for Time Series Forecasting”, 2020).

2.5. *Previsão*

Previsão é uma tarefa de Ciência de Dados comum (Rýzko, 2020) e consiste na tentativa de extrapolar o comportamento futuro a partir das condições atuais, utilizando dados históricos.

Nos métodos quantitativos de previsão pressupõe-se que as condições no presente, mesmo as que se ignoram, se vão manter inalteradas no futuro (Caiado, 2016).

O objetivo da previsão é melhorar a tomada de decisão em face à incerteza. Por forma a conseguir isso, as previsões devem fornecer uma estimativa imparcial sobre o que é mais provável de acontecer, a par de uma medida de incerteza. Estas informações facilitarão as decisões e ações adequadas (Petropoulos, 2020).

A previsão deve ser um exercício objetivo, baseado em factos, raciocínio sólido e métodos sólidos. Mas, como as previsões são criadas em ambientes sociais, são influenciadas por políticas organizacionais e agendas pessoais. Como consequência, as previsões geralmente refletem aspirações, em vez de projeções não definidas (Petropoulos, 2020).

A previsão é necessária em muitas situações: decidir se construirá outra central de produção de energia nos próximos cinco anos requer previsões da procura futura; gerir o calendário de uma equipa numa central de atendimento para a semana seguinte requer previsões de volumes de chamadas; armazenar um *stock* requer previsões de necessidades de *stock* (Hyndman & Athanasopoulos, 2018).

Quanto ao horizonte temporal, as previsões dependem quer dos objetivos da empresa quer da natureza dos produtos comercializados. Os horizontes podem ser de curto, médio e longo prazos (Caiado, 2016). As previsões podem ser exigidas com vários anos de antecedência (para o caso de investimentos de capital), ou apenas alguns minutos antes (para encaminhamento de telecomunicações). Quaisquer que sejam as circunstâncias ou horizontes de tempo envolvidos, a previsão é uma ajuda importante para um planeamento eficaz e eficiente (Hyndman & Athanasopoulos, 2018).

Algumas coisas são mais fáceis de prever do que outras. A hora do nascer do Sol de amanhã de manhã pode ser prevista com precisão. Por outro lado, os números e as estrelas do Euromilhões não podem ser previstos com precisão. A previsibilidade de um evento ou quantidade depende de vários fatores, incluindo:

- quão bem entendemos os fatores que contribuem para isso;
- quantos dados estão disponíveis;

- se as previsões podem afetar o que estamos a tentar prever (Hyndman & Athanasopoulos, 2018).

No contexto deste trabalho, iremos considerar previsões de curto prazo que são feitas para períodos até três meses (diário, semanal, quinzenal e mensal) e estão associadas a produtos de grande consumo sujeitos a oscilações sazonais e conjeturais de procura e de oferta (Caiado, 2016), que é o caso dos mercados de eletricidade.

2.5.1. Previsão de Séries Temporais

A previsão de séries temporais é difícil. Ao contrário dos problemas mais simples de classificação e regressão, os problemas de série temporal aumentam a complexidade da ordem ou a dependência temporal entre as observações. Isso pode ser difícil, pois o manuseio especializado dos dados é necessário ao ajustar e avaliar os modelos (Brownlee, 2018).

Essa estrutura temporal também pode ajudar na modelação, fornecendo estrutura adicional como tendências e sazonalidade que podem ser aproveitadas para melhorar a qualidade do modelo.

Para além de curto prazo, as previsões que faremos neste trabalho são multi-passos (2.5.1.1.).

2.5.1.1. Previsão Multi-Passos

As previsões multi-passos são aquelas em que os horizontes de previsão incluem mais pontos a prever. As previsões multiponto são necessárias em muitos verticais industriais. Por exemplo, pode ser necessário prever o preço de uma mercadoria às 9 da manhã para cada hora desse dia das 10 da manhã às 9 da manhã do dia seguinte, o que resulta num total de 24 pontos.

Tanto quanto sabemos, foram propostas cinco alternativas (ou estratégias) na literatura para enfrentar uma tarefa de previsão de H-passos à frente: Estratégias Recursiva, Direta, DirRec, MIMO e DIRMO (Taieb, Bontempi, Atiya, & Sorjamaa, 2012).

A figura 2.2. mostra as diferentes estratégias de previsão com setas que indicam as suas relações. A estratégia DirRec é uma combinação da estratégia Direta e Recursiva, enquanto a estratégia DIRMO é uma combinação da estratégia Direta e da estratégia MIMO.

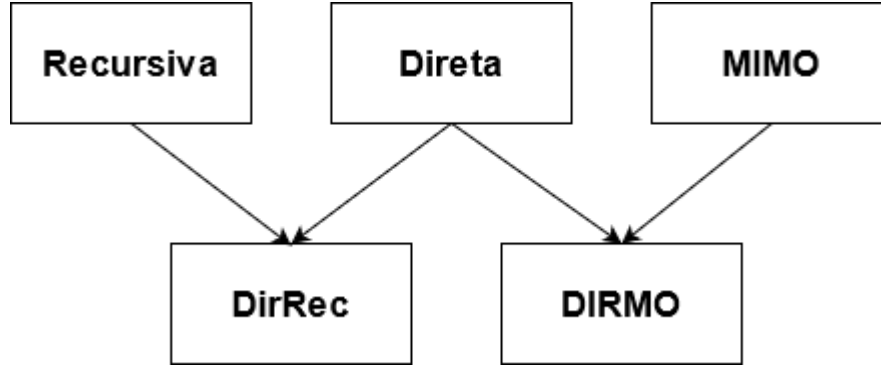


Figura 2.2. Previsão Multi-Passos – Diferentes Estratégias e relações entre elas.

Estratégia Recursiva

A estratégia de previsão mais antiga e intuitiva é a estratégia Recursiva (também chamada Iterativa ou Multi-Etapa). Nesta estratégia, um único modelo é treinado para realizar um único passo em frente, ou seja

$$y_{t+1} = f(y_t, \dots, y_{t-d+1}) + w \quad (2.1.)$$

com $t \in \{d, \dots, N - 1\}$.

Ao prevermos os H passos à frente, primeiro prevemos o primeiro passo ao aplicar o modelo. Subsequentemente, utilizamos o valor apenas para a previsão como parte das variáveis de entrada para prever o próximo passo (utilizando o mesmo modelo de um passo à frente). Continuamos desta forma até termos previsto todo o horizonte. Que o modelo treinado de um passo à frente seja \hat{f} . Depois as previsões são dadas por:

$$\hat{y}_{N+h} \begin{cases} \hat{f}(y_N, \dots, y_{N-d+1}) & \text{se } h = 1, \\ \hat{f}(\hat{y}_{N+h-1}, \dots, \hat{y}_{N+1}, y_N, \dots, y_{N-d+1}) & \text{se } h \in \{2, \dots, d\}, \\ \hat{f}(\hat{y}_{N+h-1}, \dots, \hat{y}_{N+h-d}) & \text{se } h \in \{d + 1, \dots, H\}. \end{cases} \quad (2.2.)$$

Dependendo do ruído presente na série cronológica e do horizonte de previsão, a estratégia Recursiva pode sofrer de baixo desempenho em tarefas de previsão com vários passos de antecedência. De facto, isto é especialmente verdade se o horizonte de previsão h exceder a dimensão de incorporação d , uma vez que em algum momento todos os inputs são valores previstos em vez de observações reais (Eq. 2.2). A razão para a potencial inexatidão é que a estratégia Recursiva é sensível à acumulação de erros com o horizonte de previsão. Os erros

presentes nas previsões intermédias propagar-se-ão à medida que estas previsões forem sendo utilizadas para determinar as previsões subsequentes. Apesar destas limitações, a estratégia Recursiva tem sido utilizada com sucesso para prever muitas séries temporais do mundo real, utilizando diferentes modelos de aprendizagem de máquinas, como redes neurais recorrentes e vizinhas mais próximas (Taieb et al, 2012).




Figura 2.3. Previsão Multi-Passos – Desafio – Estratégia Recursiva (Miller, 2021).

Estratégia Direta

A estratégia Direta (também chamada Independente) consiste na previsão de cada horizonte independentemente dos outros. Por outras palavras, H modelos f_h são aprendidos (um para cada horizonte) da série temporal $[y_1, \dots, y_N]$ onde

$$y_{t+h} = f(y_t, \dots, y_{t-d+1}) + w \quad (2.3.)$$

com $t \in \{d, \dots, N - H\}$ e $h \in \{1, \dots, H\}$.

As previsões são obtidas utilizando os H modelos \hat{f}_h aprendidos da seguinte forma:

$$\hat{y}_{N+h} = \hat{f}_h(y_N, \dots, y_{N-d+1}) \quad (2.4.)$$

Isto implica que a estratégia Direta não utiliza quaisquer valores aproximados para calcular as previsões (Eq. 2.4.), ficando então imune à acumulação de erros.

No entanto, os modelos H são aprendidos independentemente, induzindo uma independência condicional das previsões H . Isto afeta a precisão das previsões, pois impede a estratégia de considerar dependências complexas entre as variáveis \hat{y}_{N+h} . Por exemplo, considerar um caso em que a melhor previsão é uma tendência linear ou ligeiramente não linear. O método direto poderia produzir uma curva quebrada devido à forma "não cooperativa" como as previsões H são geradas. Além disso, esta estratégia exige um grande tempo computacional uma vez que existem tantos modelos a aprender como o tamanho do horizonte (Taieb et al, 2012).

Diferentes modelos de aprendizagem mecânica têm sido utilizados para implementar a estratégia Direta para tarefas de previsão com múltiplas etapas, por exemplo, redes neurais, vizinhos mais próximos e árvores de decisão (Taieb et al, 2012).

Estratégia DirRec

A estratégia DirRec combina as arquiteturas e os princípios subjacentes às estratégias Direta e Recursiva. O DirRec calcula as previsões com modelos diferentes para cada horizonte (como a estratégia Direta) e, em cada etapa, amplia o conjunto de entradas adicionando variáveis correspondentes às previsões da etapa anterior (como a estratégia Recursiva). Contudo, note-se que, ao contrário das duas estratégias anteriores, o tamanho de incorporação d não é o mesmo para todos os horizontes. Noutros termos, a estratégia DirRec aprende H modelos f_h da série temporal $[y_1, \dots, y_N]$ onde

$$y_{t+h} = f_h(y_{t+h-1}, \dots, y_{t-d+1}) + w \quad (2.5.)$$

com $t \in \{d, \dots, N - H\}$ e $h \in \{1, \dots, H\}$.

Para obter as previsões, os modelos aprendidos de H são utilizados da seguinte forma

$$\hat{y}_{N+h} \begin{cases} \hat{f}(y_N, \dots, y_{N-d+1}) & \text{se } h = 1, \\ \hat{f}(\hat{y}_{N+h-1}, \dots, \hat{y}_{N+1}, y_N, \dots, y_{N-d+1}) & \text{se } h \in \{2, \dots, H\}. \end{cases} \quad (2.6.)$$

Esta estratégia superou as estratégias Direta e Recursiva em duas séries temporais do mundo real: Conjuntos de dados de carga de eletricidade de Santa Fé e Polónia. Poucas investigações foram feitas em relação a esta estratégia, pelo que há necessidade de uma avaliação mais aprofundada. (Taieb et al, 2012).

Estratégia MIMO

As três estratégias anteriores (Recursiva, Direta e DirRec) podem ser consideradas como estratégias de saída única uma vez que modelam os dados como uma função de saída única (múltiplas entradas) (ver Eqs. 3.2, 3.4 e 3.6).

A introdução da estratégia *Multi-Input Multi-Output* (MIMO) (também chamada de estratégia conjunta) foi motivada pela necessidade de evitar a modelação do mapeamento

Single-Output, que negligencia a existência de dependências estocásticas entre valores futuros e conseqüentemente afeta a precisão da previsão.

A estratégia MIMO aprende um modelo de Saída Múltipla F da série temporal $[y_1, \dots, y_N]$ onde

$$[y_{t+H}, \dots, y_{t+1}] = F(y_t, \dots, y_{t-d+1}) + w \quad (2.7)$$

com $t \in \{d, \dots, N - H\}$, $F: \mathbb{R}^d \rightarrow \mathbb{R}^H$ é uma função valorizada por vetores, e $w \in \mathbb{R}^H$ é um vetor de ruído com uma covariância que não é necessariamente diagonal.

As previsões são devolvidas em uma etapa por um modelo \hat{F} de Saída Múltipla onde

$$[\hat{y}_{t+H}, \dots, \hat{y}_{t+1}] = \hat{F}(y_t, \dots, y_{t-d+1}) \quad (2.8)$$

A lógica da estratégia do MIMO é preservar, entre os valores previstos, a dependência estocástica que caracteriza as séries temporais. Esta estratégia evita a suposição de independência condicional feita pela estratégia Direta, bem como a acumulação de erros dos quais a estratégia Recursiva é vítima. Até agora, esta estratégia tem sido aplicada com sucesso a várias tarefas de previsão de séries temporais multi-passos do mundo real.

No entanto, a necessidade de preservar as dependências estocásticas usando um modelo tem um inconveniente, uma vez que limita todos os horizontes a serem previstos com a mesma estrutura de modelo. Esta restrição pode reduzir a flexibilidade da abordagem de previsão. Esta foi a motivação para a introdução de uma nova estratégia de Múltiplos-Produtos: DIRMO, apresentada a seguir (Taieb et al, 2012).

Estratégia DIRMO

A estratégia DIRMO visa preservar os aspectos mais atrativos tanto da estratégia Direta como da MIMO. Adotando uma abordagem intermédia, o DIRMO prevê o horizonte H em blocos, onde cada bloco é previsto de uma forma MIMO. Assim, a tarefa de previsão do horizonte H é decomposta em n Tarefas de Previsão de Multi-Passos ($n = \frac{H}{s}$), cada uma com um output de tamanho s ($s \in \{1, \dots, H\}$).

Quando o valor do parâmetro s é 1, o número de tarefas de previsão n é igual a H que corresponde à estratégia Direta. Quando o valor dos parâmetros é H , o número de tarefas de

previsão n é igual a 1, o que corresponde à estratégia MIMO. Existem configurações intermédias entre estes dois extremos, dependendo do valor de um parâmetro.

A afinação dos parâmetros permite-nos melhorar a flexibilidade da estratégia MIMO através da calibração da dimensionalidade das saídas (sem dependência no caso $s = 1$ e dependência máxima para $s = H$). Isto proporciona uma troca benéfica entre a preservação de um maior grau de dependência estocástica entre valores futuros e ter uma maior flexibilidade do preditor.

A estratégia DIRMO, anteriormente chamada estratégia MISMO (renomeada por razões de clareza), aprende n modelos F_p da série temporal $[y_1, \dots, y_N]$ onde

$$[y_{t+p*s}, \dots, y_{t+(p-1)*s+1}] = F_p(y_t, \dots, y_{t-d+1}) + w \quad (2.9)$$

com $t \in \{d, \dots, N - H\}$, $p \in \{1, \dots, n\}$ e $F_p: \mathbb{R}^d \rightarrow \mathbb{R}^s$ é uma função valorizada por vetor se $s > 1$.

As previsões H são devolvidas pelos n modelos aprendidos como se segue:

$$[\hat{y}_{N+p*s}, \dots, \hat{y}_{N+(p-1)*s+1}] = \hat{F}_p(y_N, \dots, y_{N-d+1}) \quad (2.10)$$

A estratégia do DIRMO foi aplicada com sucesso em dois concursos de previsão: ESTSP'07 e NN3 (Taieb et al, 2012).

2.5.2. Previsão de Preços de Eletricidade

Em muitos países do mundo, a eletricidade é agora comercializada segundo as regras do mercado, utilizando contratos à vista e derivados. No entanto, a eletricidade é uma mercadoria muito especial. É economicamente não armazenável, e a estabilidade do sistema energético requer um equilíbrio constante entre produção e consumo. Ao mesmo tempo, a procura de eletricidade depende do tempo (temperatura, velocidade do vento, precipitação, etc.) e da intensidade do negócio e das atividades diárias (em horário de pico versus fora de pico, dias de semana versus fins de semana, feriados versus quase-férias, etc). Por um lado, estas características únicas e específicas levam a dinâmicas de preços não observadas em qualquer outro mercado, exibindo sazonalidade aos níveis diário, semanal e anual, e picos de preços abruptos, de curta duração e geralmente imprevistos. Por outro lado, encorajaram

os investigadores a intensificar os seus esforços no desenvolvimento de melhores técnicas de previsão (Weron, 2014).

A nível empresarial, as previsões de preços de eletricidade tornaram-se um input fundamental para o mecanismo de tomada de decisão das empresas de energia (Weron, 2014).

Como o campo de EPF é bastante diverso, há vários artigos de referência que podem ser utilizados para facilitar a compreensão do mesmo. Achamos relevante mencionar os seguintes:

1. Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030–1081. <https://doi.org/10.1016/j.ijforecast.2014.08.008> (Weron, 2014).
2. Nowotarski, J., & Weron, R. (2018). Recent advances in electricity price forecasting: A review of probabilistic forecasting. *Renewable and Sustainable Energy Reviews*, 81, 1548–1568. <https://doi.org/10.1016/j.rser.2017.05.234> (Nowotarski & Weron, 2018).
3. Lago, J., Marcjasz, G., De Schutter, B., & Weron, R. (2020). Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. *ArXiv:2008.08004 [Cs, q-Fin, Stat]*. <http://arxiv.org/abs/2008.08004> (Lago et al, 2020)

No primeiro artigo, publicado em 2014, são analisados os 15 anos da área de EPF, sistematizando o corpo de literatura e a esmagadora diversidade de métodos. Para além disso, foram feitas especulações a respeito das direções que o EPF para a próxima década.

O segundo artigo pode ser visto como uma atualização ou uma extensão adicional da revisão da literatura proposta no artigo 1, com foco na previsão probabilística.

No terceiro artigo encontramos uma visão geral de três famílias de métodos: métodos estatísticos, *Machine Learning* e métodos híbridos, propostos para previsão pontual no mercado com um dia de antecedência, a partir de 2014 – ano em que foi publicado o artigo 1. No entanto, de notar que, a nosso ver, os métodos de *Machine Learning* também têm por base estatística, pelo que não concordamos totalmente com a estrutura apresentada, embora compreendemos que possa facilitar a discussão.

O campo de Previsão de Preços de Eletricidade visa prever os preços nos mercados grossistas, quer num cenário pontual ou probabilístico. Contudo, dada a diversidade das regulamentações comerciais disponíveis em todo o mundo, a EPF tem sempre de ser adaptada ao mercado específico (Lago et al, 2020). O foco deste trabalho é o Mercado Ibérico de Eletricidade (2.2.4).

2.5.3. Processo de Previsão Quantitativa

Há diversas metodologias para a análise de dados que ajudam os cientistas de dados a acompanhar em que fase da análise estão, como a CRISP-DM e a SEMMA. No contexto do nosso trabalho, cujo foco é a previsão quantitativa de séries temporais, recorreremos a conjunto de oito etapas, desenvolvido por nós, e que podemos consultar na figura 2.4.

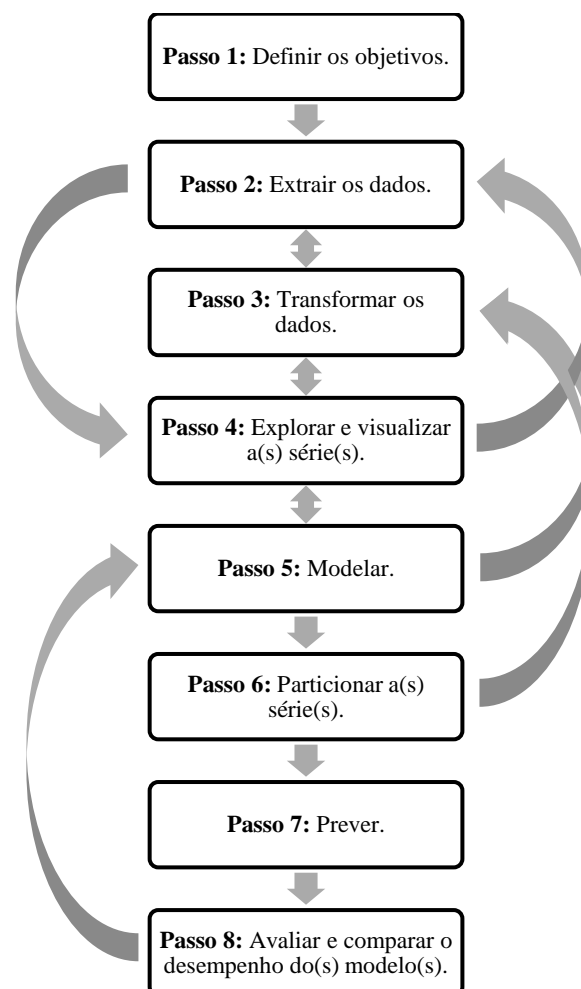


Figura 2.4. Processo de Previsão Quantitativa.

Por forma a facilitar a compreensão do processo ilustrado na figura 2.4., passemos a uma análise a cada um dos passos.

1. Definir os objetivos

O primeiro passo consiste em definir os objetivos a serem atingidos, como o índice de desejado, o horizonte de previsão, isto é, o quão longe no futuro as previsões serão feitas.

2. Obter os Dados

Recolha rigorosa de dados históricos. Esta fase é fundamental, pois não será possível trabalhar sem dados. Estes podem ser obtidos de diversas formas, como a partir de armazéns ou lagos de dados a que tenhamos acesso. No entanto, no contexto deste trabalho, iremos procurar diversas fontes digitais e proceder à extração dos mesmos.

3. Transformar os Dados

Neste passo iremos efetuar pré-processar os dados de acordo com os objetivos. Um exemplo comum é encontrar dados que não estão disponíveis na escala temporal pretendida, pelo que teremos de fazer os ajustes necessários.

4. Explorar e Visualizar a(s) Série(s)

Explorar a(s) série(s) por forma a saber, entre outros pontos, se há dados em falta ou observações anómalas (*outliers*). A inspeção gráfica da série é fundamental e pode ajudar a identificar movimentos de tendência, sazonalidade, cíclicos ou pontos de viragem (mudança de estrutura). Se necessário, voltar a processar os dados ou extrair novos dados.

5. Modelar

Criação e seleção dos modelos que permitam efetuar as previsões. Se necessário, voltar ao Passo 3 ou 4.

6. Particionar a(s) série(s)

Dividir a(s) série(s) em duas. A primeira partição, que é mais longa na maioria das vezes, será usada para construir o modelo. A segunda será usada para avaliar o desempenho inicial do modelo. Se necessário, voltar ao Passo 4.

7. Prever

Prever a evolução futura da(s) série(s) com base no seu comportamento passado ou com base no comportamento passado de outras variáveis.

8. Avaliar e comparar o desempenho do(s) modelo(s)

O desempenho de previsões do(s) modelo(s) é avaliado. Se necessário, são feitas alterações no modelo.

2.6. Geometria da Informação

O campo da Geometria da Informação, do inglês *Information Geometry* (IG) foi historicamente motivado pelo fornecimento de algumas estruturas diferencial-geométricas aos modelos estatísticos, a fim de raciocinar geometricamente sobre os problemas estatísticos com o objetivo de geometrizar a estatística matemática (Nielsen, 2020).

O Professor Shun-ichi Amari, o fundador da moderna geometria da informação, definiu a geometria da informação no prefácio do seu último livro (Amari, 2016) como: um método de exploração do mundo da informação por meio da geometria moderna. Em suma, a IG investiga geometricamente as ciências da informação. É um esforço matemático para definir e delimitar o termo geometria em si, uma vez que a geometria é um termo aberto. Muitas vezes, começamos por estudar a invariância de um problema (por exemplo, invariância da distância entre distribuições de probabilidade) e obtemos como resultado uma nova estrutura geométrica (por exemplo, um “*statistical manifold*”). Contudo, uma estrutura geométrica é “pura” e, portanto, pode ser aplicada a outras áreas de aplicação para além do âmbito do problema original (por exemplo, utilização da estrutura dualista dos *statistical manifolds* na programação matemática (Kakihara, Ohara, & Tsuchiya, 2013)): o método de geometria (Amari & Nagaoka, 2007) produz assim um padrão de abdução (*pattern of abduction*) (Nielsen, 2020; Schurz, 2008).

Uma definição mais restrita da geometria da informação pode ser declarada como o campo que estuda a geometria da tomada de decisões. Esta definição inclui também a adaptação do modelo (inferência) que pode ser interpretada como um problema de decisão;

nomeadamente, decidir qual o parâmetro de modelo a escolher de uma família de modelos paramétricos. Este quadro foi defendido por Abraham Wald que considerou todos os problemas estatísticos como problemas de decisão estatística. As dissemelhanças (também chamadas vagamente distâncias entre outras) desempenham um papel crucial não só para medir a adequação dos dados ao modelo (por exemplo, probabilidade em estatísticas, funções de perda de classificadores no ML, funções objetivas na programação matemática ou pesquisa de operações, etc.) mas também para medir a discrepância (ou desvio) entre modelos (Nielsen, 2020).

2.7. *Decisão Multi-Atributo (MADM)*

Desde que o mundo existe, as pessoas têm-se visto envolvidas na tomada de decisões que dizem respeito à sua vida quotidiana. Há muitos anos que os investigadores se interessam pela análise da forma como o ser humano realiza esta tarefa. Neste sentido, é necessária uma modelização do contexto em que devemos mover-nos, ou seja, de tal forma que simplifique (represente) o sistema real, e com a condição de ser facilmente compreendido e de ser fácil de implementar. Assim, estudamos as alternativas que podemos escolher, bem como os critérios sobre os quais essas alternativas devem ser avaliadas. Isto, que à primeira vista parece ser simples, faz parte de toda a disciplina a que se chama Tomada de Decisão Multi-Critério (MCDM, do inglês *Multi Criteria Decision Making*) (Sánchez-Lozano, Teruel-Solano, Soto-Elvira, & García-Cascales, 2013).

A Tomada de Decisão Multicritério, frequentemente chamada de tomada de Decisão Multi-Atributo, do inglês *Multi Attribute Decision Making* (MADM) é o ramo mais conhecido da tomada de decisão. É um ramo da classe geral de modelos de Investigação Operacional que lidam com problemas de decisão sob a presença de uma série de critérios de decisão (Triantaphyllou, Shu, Sanchez, & Ray, 1998).

A finalidade ou objetivo de um método de MCDM é investigar uma série de alternativas à luz de múltiplos critérios e objetivos contraditórios (Voogd, 1982), encontrando a melhor alternativa do conjunto (Sánchez-Lozano et al, 2013).

3. Conjuntos de Datos

Fall in love with your data and not only with your model.

Gwilym Jenkins (1970)

Este capítulo aborda o modelo das fontes de dados aos dados a analisar (3.1.) e, por fim, consideramos algumas propriedades dos conjuntos de dados (3.2.) a serem utilizados.

3.1. Das Fontes de Dados aos Dados a Analisar

Nesta secção apresentaremos uma arquitetura de alto-nível do modelo das Fontes de Dados à Análise de Dados.

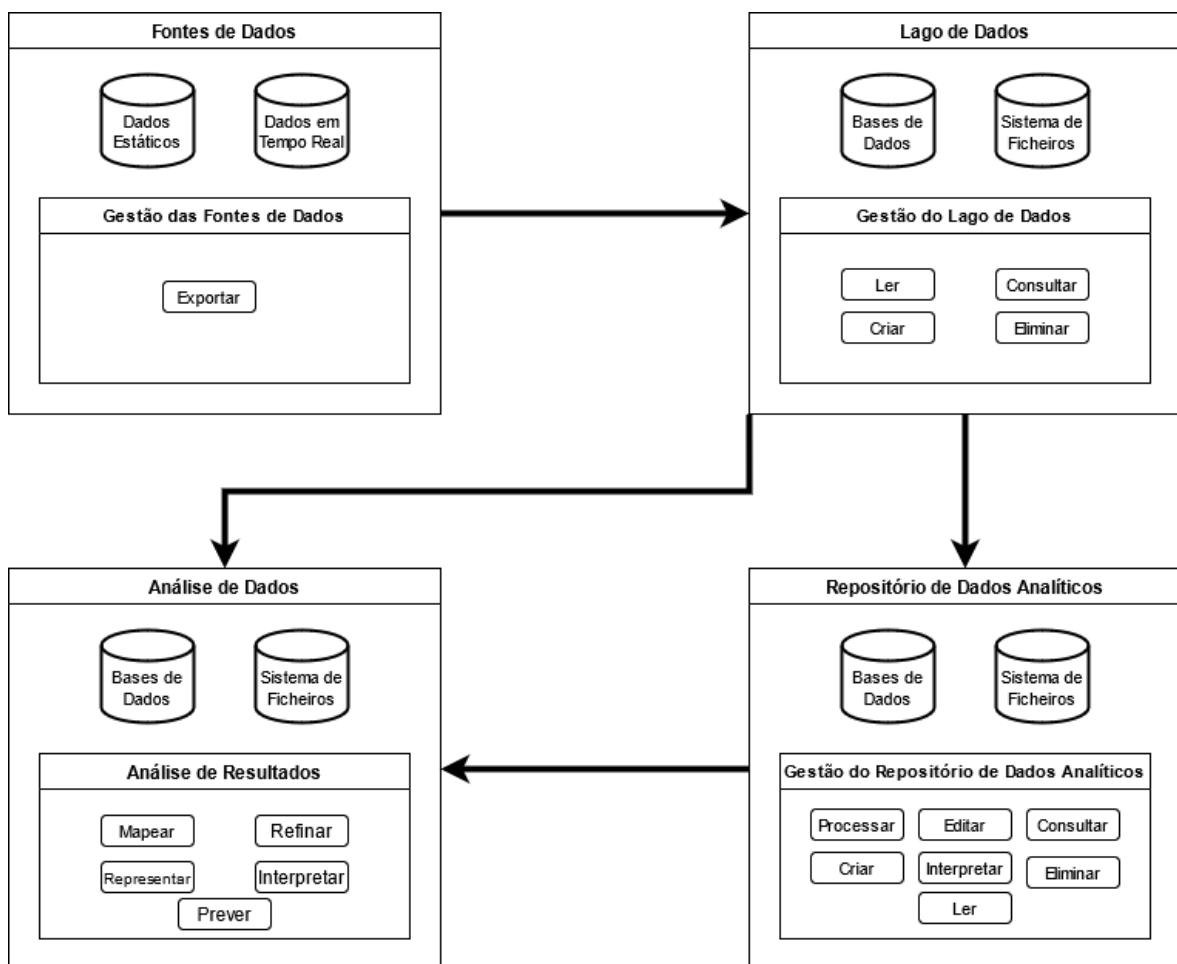


Figura 3.1. Modelo das Fontes de Dados aos Dados a Analisar.

Como podemos ver no modelo, teremos quatro locais distintos: **Fontes de Dados**, **Lago de Dados**, **Repositório de Dados Analíticos** e **Análise de Dados**.

No que toca à **Fonte de Dados**, a única operação que nos interessa fazer é extrair os conjuntos de dados, que podem ser estáticos ou dinâmicos, para colocar no Lago de Dados. No contexto desta dissertação, consideramos apenas Dados Estáticos e, para efeitos de reprodutibilidade, consideramos apenas dados que estão acessíveis a quaisquer pessoas com acesso à Internet (dados abertos). Consultar o capítulo 3.2., onde, para cada categoria de variáveis, indicamos os locais onde estas podem ser extraídas. O processo de extração dos dados difere consoante a Fonte e o código utilizado pode ser consultado no anexo B.

Uma vez no **Lago de Dados**, os conjuntos de dados podem ser lidos, consultados, eliminados e, ainda, criados. Os dados que se encontram aqui podem ser enviados para o Repositório de Dados Analíticos ou diretamente para a Análise de Dados.

No **Repositório de Dados Analíticos** os dados podem ser processados, editados, consultados, criados, interpretados, eliminados ou lidos. No que toca ao processamento, que também pode ser chamado de transformação, os dados podem ser filtrados, agregados, entre outros. Há espaço para serem criados novos dados para serem utilizados na Análise de Dados, fruto do processamento.

Por sua vez, na **Análise de Dados**, os dados podem ser mapeados, refinados, representados, interpretados e, ainda, usados em modelos de previsão.

Os dados serão armazenados no Sistema de Ficheiros, nos formatos HDF5 e CSV.

3.2. *Caracterização dos Dados*

Para o desenvolvimento dos modelos de previsão de preços horários consideremos diferentes tipos de variáveis explicatórias, inspirado na sugestão de Monteiro, C., Fernandez-Jimenez, L., e Ramirez-Rosado, I. (Monteiro, Fernandez-Jimenez, & Ramirez-Rosado, 2015), mais especificamente:

1. Dados Cronológicos: Ano, Mês, Dia, Hora, Dia da Semana, Feriado (em Espanha ¹).
2. Preços horários do mercado de eletricidade (MIBEL), disponíveis no operador de mercado (OMIE) ou no Sistema de Informação de Mercados de Energia do TSO português ².
3. Dados de previsões da procura: Procura Real, Procura Prevista e Procura Programada. Estes dados são provenientes do TSO espanhol, a REE ³.
4. Dados do sistema de produção: Eólica, Nuclear, Carvão, Ciclo Combinado, Hidráulica, Solar, Intercâmbios internacionais. Estes dados foram obtidos a partir do TSO espanhol, a REE ⁴. Uma vez que as variáveis de produção alteraram de 2015-04-30 para 2015-05-01, consideramos que Solar engloba (Solar Fotovoltaica e Solar Térmica).
5. Dados do Clima (Meteorologia): ERA-5, provenientes da Climate Data Store ⁵ na Península Ibérica. Considerou-se, por Península Ibérica, a região delimitada pelas seguintes coordenadas geográficas:

Norte: 44°

Oeste: -9.6°

Sul: 36°

Este: 3.5°

¹ Os feriados em Espanha foram criados com base neste *script*: <https://github.com/goncaloperes/TimeSeries/blob/master/IsItHoliday/Spain/SpainBusinessCalendar.py> (“Goncaloperes/TimeSeries”, 2020).

² <https://www.mercado.ren.pt/PT/Electr/InfoMercado/InfOp/MercOmel/Paginas/Precos.aspx> (“SIMEE - Diário e Intradiário—Preços”, sem data).

³ <https://demanda.ree.es/visiona/peninsula/demanda/> (“Electricity demand tracking in real time, associated generation mix and CO2 emissions”, sem data).

⁴ <https://demanda.ree.es/visiona/peninsula/demanda/tablas/2> (“Generation mix (MW)”, sem data).

⁵ <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=form> (“ERA5 hourly data on single levels from 1979 to present”, 2021).

Tabela 3.1. Variáveis explicatórias dos modelos a serem utilizados.

Variável	Explicativa	Descrição	Intervalo de Variação e Unidades
V1	Cronológica	Ano	2010-2019
V2	Cronológica	Mês	1-12
V3	Cronológica	Dia	1-31
V4	Cronológica	Hora	1-24
V5	Cronológica	Dia da Semana	1-7 (1 é segunda e 7 é domingo)
V6	Cronológica	Feriado	0 ou 1 (0 não é feriado, 1 é feriado)
V7	Preços	Preço Horário	€/MWh
V8	Procura	Procura Real	MW
V9	Procura	Procura Prevista	MW
V10	Procura	Procura Programada	MW
V11	Produção	Eólica	MW
V12	Produção	Nuclear	MW
V13	Produção	Carvão	MW
V14	Produção	Ciclo Combinado	MW
V15	Produção	Hidráulica	MW
V16	Produção	Intercâmbios Internacionais	MW
V17	Produção	Produção Solar	MW
V18	Clima	Temperatura de Ponto de Orvalho a 2m	K
V19	Clima	Temperatura a 2m	K
V20	Clima	10m u-componente de vento	m s ⁻¹
V21	Clima	10m v-componente de vento	m s ⁻¹
V22	Clima	Radiação solar líquida superior	J m ⁻²
V23	Clima	Radiação termal líquida superior	J m ⁻²
V24	Clima	Cobertura total de nuvens	0-1
V25	Clima	Precipitação total	m
V26	Clima	Radiação Total do Céu à Superfície	J m ⁻²

Para esta dissertação consideraremos os seguintes intervalos de tempo:

- A. 1 de janeiro de 2019 (00:00) a 31 de dezembro de 2019 (23:00).
- B. 1 de janeiro de 2018 (00:00) a 31 de dezembro de 2019 (23:00).
- C. 1 de janeiro de 2010 (00:00) a 31 de dezembro de 2019 (23:00).

Como tal, a variável 1, o Ano, varia em função do intervalo a analisar. Na tabela 3.1. apresentamos a informação relativa ao intervalo C, que corresponde aos dados desde 1 de janeiro de 2010 (00:00) a 31 de dezembro de 2019 (23:00).

Quando falamos em Preço Horário (V7), falamos apenas na parte Espanhola do MIBEL. A decisão de trabalhar apenas a parte espanhola do MIBEL deveu-se ao facto de no processo de extração de dados termos encontrado problemas com dados de produção provenientes do TSO português (REN)⁶, onde só haviam dados a partir de 1-12-2019, e, ainda, ao facto da REN não ter respondido às mensagens que deixámos.

⁶ <https://www.centrodeinformacao.ren.pt/EN/Pages/CIHomePage.aspx> (“Real Time Information REN”, 2021).

Relativamente à temperatura, a variável 18 refere-se à temperatura a que o ar, a 2 metros acima da superfície da Terra, teria de ser arrefecido para que a saturação ocorresse. É uma medida da humidade do ar. A V19 refere-se à temperatura do ar a 2m acima da superfície da terra, do mar ou das águas interiores. Ambas as variáveis de temperatura são medidas em Kelvin, pelo que podem ser convertida em graus Celsius ($^{\circ}\text{C}$), subtraindo 273,15.

No que toca ao vento, a V20 diz respeito à componente Este do vento de 10m. É a velocidade horizontal do ar que se move em direção a Este, a uma altura de dez metros acima da superfície da Terra, em metros por segundo. Por sua vez, a V21 é a componente Norte do vento de 10m. É a velocidade horizontal do ar que se move em direção ao Norte, a uma altura de dez metros acima da superfície da Terra, em metros por segundo.

Consideramos três variáveis relativas à radiação: V22, V23 e V26. A V22 é a radiação solar de entrada (também conhecida como radiação de onda curta) menos a radiação solar de saída no topo da atmosfera. É a quantidade de radiação que passa através de um plano horizontal. A radiação solar de entrada é a quantidade recebida do Sol. A radiação solar de saída é a quantidade refletida e dispersa pela atmosfera e superfície da Terra. A V23 diz respeito à radiação térmica (também conhecida como terrestre ou de ondas longas) emitida para o espaço no topo da atmosfera é geralmente conhecida como a Radiação de Ondas Longas de Saída (OLR). A radiação térmica de rede superior (este parâmetro) é igual ao negativo de OLR. Por fim, a V26 é a quantidade de radiação solar direta (também conhecida como radiação de ondas curtas) que atinge a superfície da Terra. É a quantidade de radiação que passa através de um plano horizontal. A radiação solar na superfície pode ser direta ou difusa. A radiação solar pode ser dispersa em todas as direções por partículas na atmosfera, algumas das quais atingem a superfície (radiação solar difusa). Alguma radiação solar atinge a superfície sem ser dispersa (radiação solar direta). Para converter para Watts por metro quadrado (W m^{-2}), os valores acumulados devem ser divididos pelo período de acumulação expresso em segundos.

A V24 refere-se à proporção de uma caixa de grelha coberta por uma nuvem. A cobertura total de nuvens é um campo de nível único calculado a partir da nuvem que ocorre a diferentes níveis do modelo através da atmosfera. São feitas suposições sobre o grau de sobreposição/aleatoriedade entre nuvens a diferentes alturas. As frações de nuvens variam de 0 a 1.

Para terminar a análise às variáveis, a 25 refere-se à água líquida acumulada e congelada, incluindo chuva e neve, que cai na superfície da Terra. É a soma da precipitação em grande escala e da precipitação convectiva. A precipitação em grande escala é gerada pelo esquema de nuvens no ECMWF Integrated Forecasting System (IFS). Este parâmetro não inclui o nevoeiro, o orvalho ou a precipitação que evapora na atmosfera antes de aterrar na superfície da Terra. É a profundidade que a água teria se estivesse distribuída uniformemente numa caixa de grelha.

Por forma a realizar diversas experiências e, por conseguinte, obter uma estimativa mais robusta do desempenho dos modelos, vamos, para cada intervalo de tempo considerado, efetuar múltiplas divisões em treino e teste (ver anexo D), mais especificamente as seguintes percentagens de treino-teste:

1. 70-30
2. 80-20
3. 90-10

Embora, no parágrafo anterior, tenhamos feito referência à abordagem a ser utilizada para avaliação do desempenho dos modelos, iremos considerá-la mais ao detalhe no próximo capítulo.

4. Modelos e Planejamento de Experiências

*a model is a tool to help us understand the complexities
of the universe, and never a substitute for the
universe itself.*

Nate Silver (2012)

Com o problema bem definido, os dados obtidos e preparados, e a análise exploratória efetuada, segue-se a etapa de planeamento experimental e modelação.

Começamos o capítulo por introduzir o método utilizado, TIM (4.1.), um AutoML que tem por base Geometria de Informação. Terminamos o capítulo com uma abordagem aos modelos (4.2.), onde consideramos o planeamento de experiências a ser efetuado, a forma como o desempenho será avaliado e, por fim, considerações relativas à implementação.

4.1. *Tangent Information Modeller (TIM)*

O TIM, ou *Tangent Information Modeler*, é uma solução de AutoML projetada para previsão de séries temporais e deteção de anomalias desenvolvida pela Tangent Works (*“TIM Tangnt Information Modeller— Overview”*, sem data).

Existem duas formas de efetuar previsões com o TIM:

- A abordagem InstantML que é composta pela construção de modelo como uma primeira etapa e, em seguida, usar o modelo para criar uma previsão como uma segunda etapa. Com o modelo construído pode ser usado para fazer previsões repetidamente.
- A abordagem RTInstantML (*Real-Time InstantML*) na qual a construção do modelo e a criação de uma previsão ocorrem em apenas uma etapa. O processo é repetido sempre que uma nova previsão é desejada, portanto, cada modelo é utilizado apenas para uma previsão e depois descartado (*“TIM Forecasting — Overview”*, sem data).

Podemos consultar a arquitetura de alto nível do serviço web TIM na Figura 4.1. No *background*, o TIM gere constantemente alguns *workers* que podem facilitar todos os pedidos possíveis. A escalabilidade é uma característica muito importante desta arquitetura, conseguida através da distribuição computacional às unidades de *workers* do TIM.

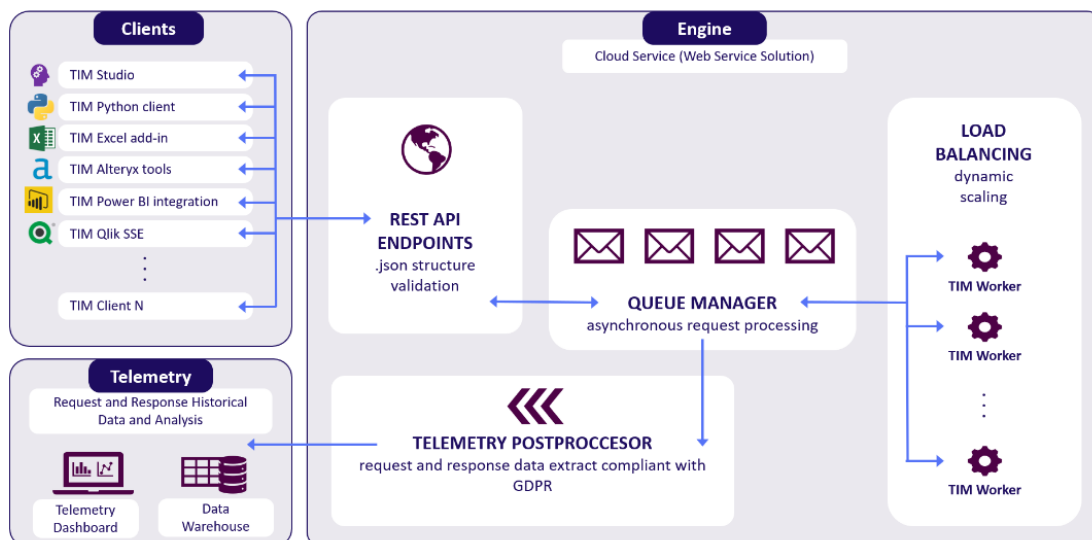


Figura 4.1. TIM – Arquitetura do serviço web (Miller, 2021).

Abaixo iremos considerar a arquitetura da solução TIM: o TIM Engine (4.1.1.), o TIM API, isto é, a interface de programação de aplicações TIM (4.1.2.), e o TIM Studio, a interface de utilizador baseada na *web* do TIM (4.1.3.). Por fim, abordaremos como o TIM trata a previsão multi-passos (4.1.4.).

4.1.1. TIM Engine

O TIM Engine é construído sobre um campo da matemática chamado de geometria da informação, um campo interdisciplinar que utiliza técnicas de geometria diferencial difusa para estudar teoria da probabilidade e estatística (consultar subcapítulo 2.6. para mais informações sobre Geometria de Informação).

O TIM Engine é totalmente contentorizado e pode ser utilizado como um serviço de nuvem, na sua própria nuvem, nas instalações, ou num dispositivo da Internet das Coisas (IoT) (ver Tabela 4.1).

Tabela 4.1. TIM Engine – Mecanismos de Implementação com base em requisitos de negócios (Miller, 2021).

	SaaS	Própria licença de nuvem	On Premises (Nas Instalações)	On the Edge
Como	Recorrendo à Tangent Works Cloud.	Integrando o próprio serviço de nuvem com o TIM.	Instalar o TIM Engine na própria infraestrutura.	Instalar num equipamento IoT.
Quando	Pretendemos algo rápido, seguro e escalável.	Temos um ambiente na nuvem e pretendemos controlo total na infraestrutura.	Temos uma infraestrutura, pretendemos controlo total e não nos importamos com o TCO (<i>Total Costo of Ownership</i>)	Temos uma arquitetura distribuída/ <i>edge computing</i> e pretendemos trazer <i>Machine Learning</i> aos dados.

4.1.2. TIM API

Todas as funcionalidades do TIM podem ser acedidas através de uma única API de transferência de estado de representação aberta (REST). Este API é mantido em funcionamento a todo o momento, escalando automaticamente em função do número de pedidos recebidos. Como todas as funcionalidades (construção de modelos, previsão, deteção de anomalias, etc.) são acessíveis através de um único API, o TIM é muito fácil de utilizar (Miller, 2021).

4.1.3. TIM Studio (versão 2.0)

TIM Studio é uma aplicação *web* fácil de usar que oferece uma interface intuitiva para uma tecnologia de *Machine Learning* para dados de séries temporais, o TIM (“*TIM Studio — Overview*”, sem data).

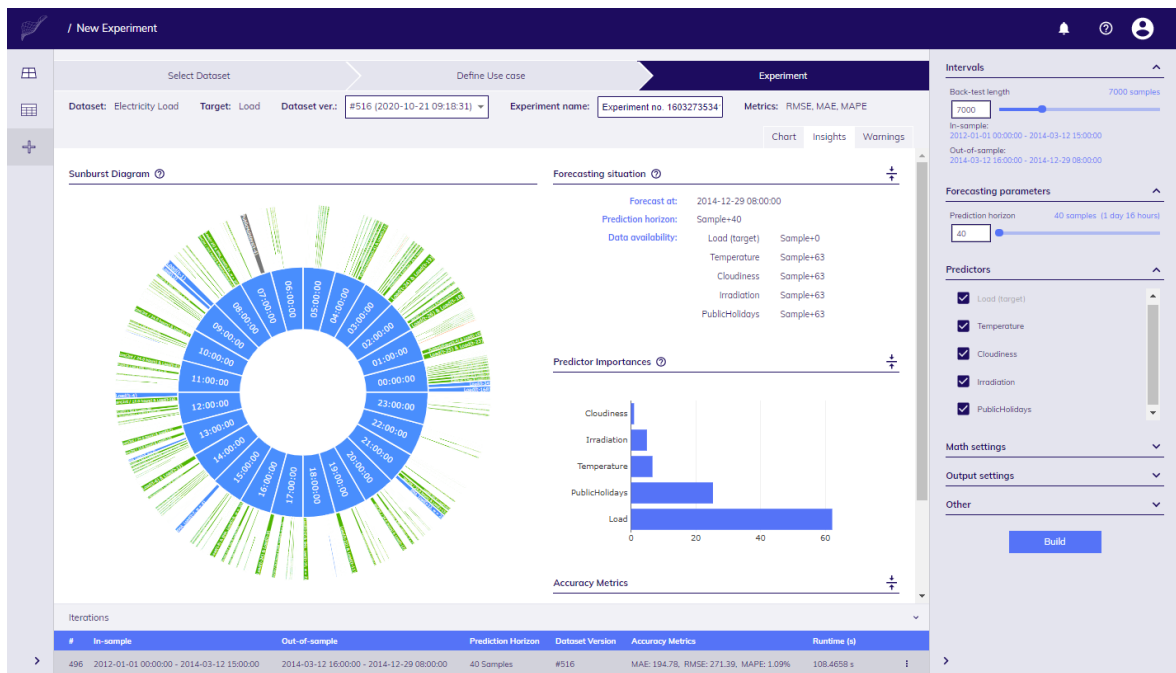


Figura 4.2. TIM Studio versão 2.0.

O TIM Studio torna a experiência tão intuitiva quanto possível. É possível seguir com os parâmetros padrão ou, se estiver interessado em afinações matemáticas, ou outras afinações, é igualmente possível (“TIM Studio — Experiments — What is an Experiment”, sem data).

O TIM Studio versão 2.0 efetua as previsões com base na abordagem RTInstantML.

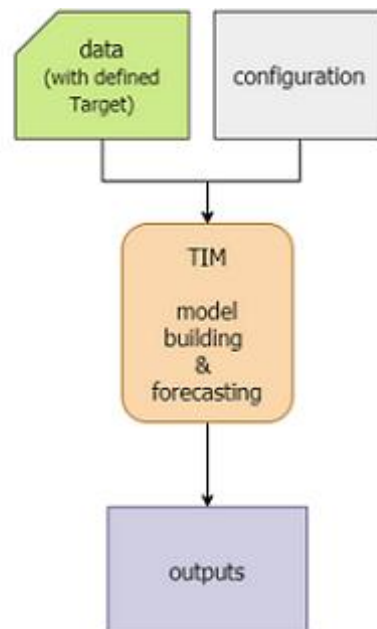


Figura 4.3. Arquitetura do TIM RTInstantML.

Os seguintes *inputs* são necessários para criar uma previsão RTInstantML:

- Dados (“Data”) – dados históricos usados para construir um modelo. Leia mais sobre as propriedades necessárias na seção Propriedades de dados²².
- Configuração – configurações matemáticas e outros parâmetros de configuração²³.

Os *inputs* são processados pelo TIM *Engine* na fase de construção do modelo seguida por uma fase de previsão onde a previsão desejada é criada. As previsões resultantes e outras saídas são descritas na seção *outputs*²⁴.

Uma vez que o RTInstantML da TIM permite construir um modelo completamente novo cada vez que é necessária uma previsão, não há necessidade de estabelecer um cenário particular de disponibilidade de dados. O TIM analisa a disponibilidade dos dados tal como estão no conjunto de dados no momento da previsão e depois constrói um modelo baseado nestes dados e aplica o modelo numa única passagem através dos dados, entregando uma previsão usando todos os dados disponíveis da previsão em apenas segundos a minutos (Miller, 2021).

Esta abordagem resolve o problema dos dados (inesperadamente) indisponíveis. Também aproveita a oportunidade que é fornecida no caso de haver mais dados disponíveis do que o esperado (Miller, 2021).

Uma vez que tencionamos efetuar previsões multi-passos, nomeadamente, prever o preço de eletricidade para as 24 horas seguintes, o TIM, para cada ponto no horizonte de previsão, cria um modelo separado. Ao fazê-lo, não é necessário fazer otimizações contraditórias porque cada modelo precisa de ser otimizado para apenas uma saída. Uma vez que não são utilizados resultados na criação de outros resultados, o risco de propagação de erros (e, portanto, de resultados rapidamente divergentes) é também eliminado. Todos os modelos que o TIM cria neste cenário são montados num chamado modeloZOO. O TIM despacha

22 Para mais informações a respeito das propriedades dos dados: <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Input-data/Data-properties/> (“TIM Tangent Information Modeller— Input Data — Data properties”, sem data).

23 Para mais informações a respeito das possíveis configurações: <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Configuration/Overview/> (“TIM Forecasting — Configuration — Overview”, sem data).

24 Para mais informações acerca dos *outputs* disponíveis no TIM: <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Outputs/Overview/> (“TIM Forecasting — Outputs — Overview”, sem data).

automaticamente o modelo correto a partir do modelZOO cada vez que se pretende uma previsão. Esta abordagem requer a criação de múltiplos (por vezes muitos) modelos, pelo as capacidades de geração de modelos rápidos e escaláveis do TIM tornam-se fundamentais (Miller, 2021).

4.1.4. Previsões no TIM

Neste subcapítulo iremos analisar previsões no TIM, nomeadamente a previsão probabilística e intervalos de previsão (4.1.4.1.) e, por fim, a previsão multi-passos (4.1.4.2.).

4.1.4.1. *Previsão probabilística e intervalos de previsão*

Os intervalos de previsão servem o propósito de expressar a incerteza nas previsões. São matematicamente um pouco diferentes dos intervalos de confiança, mas servem o mesmo propósito de melhorar as suas previsões com previsões probabilísticas para lidar com a incerteza (*“The difference between prediction intervals and confidence intervals | Rob J Hyndman”*, 2013; *“TIM Forecasting — Probabilistic forecasting and prediction intervals”*, sem data).

Para obter intervalos de previsão de 95% e 5% o TIM calcula quantis a partir dos resíduos entre o alvo e a previsão obtida para os dados utilizados na formação de modelos (*“TIM Forecasting — Probabilistic forecasting and prediction intervals”*, sem data).

Esta funcionalidade está disponível apenas para pedidos RTInstantML. Os intervalos de previsão são devolvidos apenas se solicitados na configuração. Os intervalos de previsão são então devolvidos como uma das saídas do TIM (*“TIM Forecasting — Probabilistic forecasting and prediction intervals”*, sem data).

4.1.4.2. *Multi-Passos*

Como é que o TIM aborda a necessidade de previsões multi-passos?

Tendo em conta que a estratégia recursiva pode produzir previsões tendenciosas e a estratégia direta pode ter previsões de alta variância com séries temporais curtas ou horizontes de previsão longos (Taieb & Hyndman (2012), o TIM adota uma abordagem diferente. Para cada ponto no horizonte de previsão, o TIM cria um modelo separado. Ao fazê-lo, não é necessário fazer otimizações contraditórias porque cada modelo precisa de ser otimizado para apenas uma saída. Uma vez que não são utilizados resultados na criação de outros resultados, o risco de propagação de erros (e, portanto, de resultados rapidamente divergentes) é também eliminado (Miller, 2021).

Todos os modelos que a TIM cria neste cenário são montados num chamado modeloZOO. O TIM envia então automaticamente o modelo correto a partir do modelZOO cada vez que uma previsão é desejada. Esta abordagem requer a criação de modelos múltiplos (por vezes muitos) (Miller, 2021).



Figura 4.4. TIM – Abordagem para a previsão Multi-Passos (Miller, 2021).

4.2. Modelos

Os modelos que propomos, permitem efetuar a previsão multi-ponto dos preços diários de energia elétrica no MIBEL. Tais modelos podem ser benéficos para as operações de mercados diários.

Para efetuar as previsões recorreremos ao TIM, um AutoML que tem por base Geometria de Informação (consultar 4.1. para mais informações relativamente ao TIM).

Abaixo iremos encontrar o planejamento experimental efetuado (4.2.1.), o processo de avaliação a utilizar (4.2.2.) e, por fim, umas considerações relativas à implementação dos modelos (4.2.3.).

4.2.1. Planejamento de Experiências

O planejamento experimental foi inspirado nos artigos do professor Cláudio Monteiro:

- Monteiro, C., Ramirez-Rosado, I. J., Fernandez-Jimenez, L. A., & Ribeiro, M. (2018). New probabilistic price forecasting models: Application to the Iberian electricity market. *International Journal of Electrical Power & Energy Systems*, 103, 483–496. <https://doi.org/10.1016/j.ijepes.2018.06.005> (Monteiro et al, 2018a).
- Monteiro, C., Ramirez-Rosado, I., Fernandez-Jimenez, L., & Conde, P. (2016). Short-Term Price Forecasting Models Based on Artificial Neural Networks for Intraday Sessions in the Iberian Electricity Market. *Energies*, 9(9), 721. <https://doi.org/10.3390/en9090721/> (Monteiro, Ramirez-Rosado, Fernandez-Jimenez, & Conde, 2016).
- Monteiro, C., Ramirez-Rosado, I., & Fernandez-Jimenez, L. (2018). Probabilistic Electricity Price Forecasting Models by Aggregation of Competitive Predictors. *Energies*, 11(5), 1074. <https://doi.org/10.3390/en11051074/> (Monteiro, Ramirez-Rosado, & Fernandez-Jimenez, 2018).

Assim como nesses artigos, recorreremos a diversos tipos de variáveis explicatórias e cada modelo está associado a uma variação das mesmas, de forma que seja possível efetuar comparações.

Ao contrário do que acontece nos artigos acima, onde foram considerados um intervalo de tempo e um tipo de divisão em treino-teste, neste trabalho consideraremos três intervalos de tempo e múltiplas divisões em treino-teste.

Os modelos a serem criados têm por base a tabela 4.2. Ao longo deste trabalho serão desenvolvidos um total de 225 modelos, cujas respectivas variações prendem-se com os intervalos de tempo a serem considerados (75 modelos por cada intervalo de tempo), as

percentagens das amostras de treino e teste (25 modelos por cada divisão treino-teste), e as variáveis utilizadas.

Tabela 4.2. Modelos a serem implementados e as respectivas variáveis de entrada.

Explicativa	Variável	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15	M16	M17	M18	M19	M20	M21	M22	M23	M24	M25	
Cronológica	V1 – Ano	
	V2 – Mês	
	V3 – Dia	
	V4 – Hora	
	V5 – Dia da Semana		
	V6 – Feriado				.																					.	.
Preço	V7 – Preço Horário	
Procura	V8 – Real				.																					.	
	V9 – Prevista					.																					.
	V10 – Programada						.																				.
Produção	V11 – Eólica							.							.											.	
	V12 – Nuclear								.						.												.
	V13 – Carvão									.					.												.
	V14 – Ciclo Combinado										.				.												.
	V15 – Hidráulica											.			.												.
	V16 – Intercâmbios Internacionais												.		.												.
	V17 – Solar												.		.												.
Meteorologia	V18 – 2m dew temperatura															.									.	.	
	V19 – 2m temperatura																.								.	.	
	V20 – 10 uc wind																	.							.	.	
	V21 – 10 vc wind																		.						.	.	
	V22 – Top net solar radiation																			.					.	.	
	V23 – Top net termal radiation																				.				.	.	
	V24 – Total Cloud Cover																					.			.	.	
	V25 – Total Precipitation																						.		.	.	
	V26 – Total Sky Radiation at Surface																							.	.	.	

4.2.2. Avaliação

Qual será o melhor método de previsão de preços? Como o futuro é desconhecido, só é possível dar resposta a esta questão depois de conhecer os resultados dos preços futuros. Assim, na prática, o responsável pela previsão deve escolher o método que produzir menores erros de previsão sobre as últimas observações conhecidas da série observada (Caiado, 2016).

Ao avaliar um modelo de previsão de séries cronológicas, estamos interessados no desempenho do modelo sobre dados que não foram utilizados para o seu treino. Podemos fazer isto de várias formas, num processo conhecido de *back-test* (4.2.2.1.) (Brownlee, 2020).

Por fim, analisaremos medidas de desempenho a serem consideradas (4.2.2.2.).

4.2.2.1. *Back-test*

Na previsão de séries temporais, a avaliação de modelos sobre dados históricos chama-se "backtesting". Em alguns domínios das séries cronológicas, tais como a meteorologia, a isto chama-se *hindcasting*. Analisaremos três métodos diferentes que podem ser utilizados para testar modelos em problemas de séries temporais. São eles:

1. Divisão Treino-Teste que respeita a ordem temporal das observações.
2. Múltiplas divisões Treino-Teste que respeitem a ordem temporal das observações.
3. *Walk-Forward Validation* onde um modelo pode ser atualizado cada vez que são recebidos novos dados (Brownlee, 2020).

Podemos ler acerca destas formas de *Back-test* no anexo D, no entanto, aqui, refletiremos acerca da divisão Treino-Teste e da abordagem a ser utilizada neste trabalho: Múltiplas divisões Treino-Teste. Cerqueira, Torgo e Mozetic (Cerqueira, Torgo, & Mozetic, 2019) mostraram que *repeated holdout* (divisões múltiplas treino-teste) obtiveram melhores resultados com séries temporais não estacionárias.

Treino-Teste

É importante avaliar a precisão da previsão usando previsões genuínas. Consequentemente, o tamanho dos resíduos não é uma indicação fiável de quão grandes são os erros de previsão reais (Hyndman, & Athanasopoulos, 2021).

Ao escolher modelos, é prática comum separar os dados disponíveis em duas partes, treino e teste, onde os dados de treino são usados para estimar quaisquer parâmetros de um método de previsão e os dados de teste são usados para avaliar a sua precisão. Como os dados de teste não são usados para determinar as previsões, devem fornecer uma indicação fiável de quão bem o modelo é suscetível de prever em novos dados (Hyndman, & Athanasopoulos, 2021).



Figura 4.5. Back-test – Ilustração da divisão em Treino e Teste (Hyndman, & Athanasopoulos, 2021).

O tamanho do conjunto de teste depende do quão longa é a amostra e de quanto tempo se pretende prever. O conjunto de teste deve ser, idealmente, pelo menos tão grande quanto o horizonte de previsão máximo exigido. Os seguintes pontos devem ser observados (Hyndman, & Athanasopoulos, 2021).

- Um modelo que se ajuste bem aos dados de treino não será necessariamente uma boa previsão.
- Um ajuste perfeito pode sempre ser obtido através da utilização de um modelo com parâmetros suficientes.
- A adaptação excessiva de um modelo aos dados é tão má como a não identificação de um padrão sistemático nos dados (Hyndman, & Athanasopoulos, 2021).

Algumas referências descrevem o conjunto de teste como o "hold-out set", porque estes dados são "mantidos fora" dos dados utilizados para o ajuste. Outras referências chamam ao conjunto de treino "in-sample data" e ao conjunto de teste "dados fora da amostra". Preferimos utilizar "dados de treino" e "dados de teste" neste trabalho.

Múltiplas divisões Treino-Teste

Podemos repetir o processo de dividir as séries cronológicas em conjuntos de treino e conjuntos de testes várias vezes. Isto exigirá a formação e avaliação de múltiplos modelos, mas esta despesa computacional adicional fornecerá uma estimativa mais robusta do desempenho esperado do método escolhido e da configuração em dados não vistos (Brownlee, 2020).

Com esta abordagem será possível ganhar confiança nos dados, e/ou modelos, poderemos obter diversas informações úteis, como quais os preditores que desempenham um papel vital e em que momentos, como é que o modelo muda quando o intervalo de treino muda, se o modelo funciona bem em diferentes intervalos da amostra, entre outros pontos.

4.2.2.2. *Medidas de Desempenho*

As medidas de previsão de desempenho das séries temporais fornecem um resumo da perícia e capacidade do modelo de previsão que fez as previsões. Há muitas medidas de desempenho diferentes por onde escolher. Pode ser confuso saber qual a medida a utilizar e como interpretar os resultados. Neste subcapítulo apresentaremos as medidas que serão utilizadas para a avaliação dos modelos neste trabalho: Tempo de execução, *Mean Absolute Error*, ou MAE, *Mean Absolute Percentage Error*, ou MAPE, *Root Mean Squared Error*, ou RMSE (Brownlee, 2020).

Tempo de Execução

O tempo de execução, medido em segundos, corresponde ao tempo que leva ao *engine* TIM para treinar o modelo e efetuar as previsões.

Erro Absoluto Médio (EAM ou MAE)

O Erro Absoluto Médio, ou *Mean Absolute Error* (MAE), é calculado como a média dos valores de erro da previsão, em que todos os valores da previsão são forçados a ser positivos. Forçar os valores a serem positivos é chamado torná-los absolutos. Isto é assinalado pela função absoluta `abs()` ou mostrado matematicamente como: $|\text{valor}|$.

Sendo \hat{y}_i o valor previsto da i -ésima amostra e y_i o correspondente valor correto, então o MAE estimado em $n_{amostras}$ é definido como

$$\text{MAE}(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} |y_i - \hat{y}_i| \quad (4.1)$$

Um erro médio absoluto de zero indica que não há erro (Brownlee, 2020).

O MAE está na mesma escala que os dados.

Raiz do Erro Quadrático Médio (REQM ou RMSE)

A Raiz do Erro Quadrático Médio, ou *Root Mean Squared Error* (RMSE) está nas mesmas unidades que as previsões. Tal como no caso do MSE, um RMSE de zero indica que não há erro (Brownlee, 2020).

Sendo \hat{y}_i o valor previsto da i -ésima amostra e y_i o correspondente valor correto, então a RMSE estimado em $n_{amostras}$ é definido como

$$\text{RMSE}(y, \hat{y}) = \sqrt{\frac{1}{n_{samples}} \sum_{i=0}^{n_{samples}-1} (y_i - \hat{y}_i)^2} \quad (4.2)$$

A RMSE está na mesma escala que os dados.

Erro Percentual Absoluto Médio (EPAM ou MAPE)

O Erro Percentual Absoluto Médio, ou *Mean Absolute Percentage Error* (MAPE) é a média dos erros percentuais absolutos das previsões. O erro é definido como o valor real, ou observado, menos o valor previsto. Os erros percentuais são somados sem considerar o sinal para calcular o MAPE. Esta medida é fácil de compreender porque fornece o erro em termos de percentagens. Além disso, porque são utilizados erros percentuais absolutos, o problema dos erros positivos e negativos que se anulam mutuamente é evitado. Consequentemente, a MAPE tem recurso de gestão e é uma medida comumente utilizada em previsões.

Sendo \hat{y}_i o valor previsto da i -ésima amostra e y_i o correspondente valor correto, então o MAPE estimado em $n_{amostras}$ é definido como

$$\text{MAPE}(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \quad (4.3)$$

onde ϵ é um número arbitrário pequeno, mas estritamente positivo para evitar resultados indefinidos quando y é zero.

Quanto menor for a MAPE, melhor é a previsão (Swamidass, 2000).

Os erros percentuais têm a vantagem de não conterem unidades, pelo que são frequentemente utilizados para comparar os desempenhos previstos entre conjuntos de dados (Hyndman, & Athanasopoulos, 2021).

4.2.3. Implementação

Há diferentes interfaces de utilizador através a partir dos quais as capacidades do TIM podem ser consumidas, como o TIM Studio versão 2.0, que iremos utilizar. Este, é apenas um nível de abstração entre o utilizador (nós) e a API do TIM (4.1.2.).

O TIM Studio versão 2.0 apresenta algumas limitações, nomeadamente no tamanho e formato de dados a serem importados e, ainda, no número de linhas e colunas permitidas.

No que toca ao formato e tamanho de dados a utilizar, o TIM Studio só permite importar ficheiros em formato CSV ou SQL, com um tamanho máximo de 50MB.

No que ao limite de linhas e colunas concerne, de acordo com cálculos internos efetuados pela Tangent Works, os conjuntos de dados têm de respeitar intervalos de número de linhas e colunas apresentado na Tabela 4.3.

Tabela 4.3. Limites do TIM (“TIM Tangnt Information Modeller— Input Data — Data properties”, sem data).

Número de Linhas	Número de Colunas
12 500 000	1
1 250 000	10
125 000	100
12 500	1000

De onde vemos que se um conjunto de dados tiver uma coluna, podemos analisar um máximo de 12500000 linhas, se tiver 100 colunas, pode conter um máximo de 125000 linhas.

Num outro ponto, caso haja linhas duplicadas que nos tenha passado na limpeza dos dados, o TIM procede à sua limpeza, removendo os duplicados. Foi algo pelo qual passamos com um dos modelos (M24C), não nos tendo apercebido numa fase inicial. No entanto, quando foi para usar esses dados na criação do modelo M25C, este último ficava com uma dimensão bastante superior aos 87638 esperados, pelo que procedemos à correção de ambos.

Por fim, ao fazer as divisões das amostras em treino e teste, como só podemos recorrer a valores inteiros, se o valor obtido for decimal, como 875.9 ou 1751.8, recorreremos ao valor inteiro acima, como podemos ver na tabela 4.4.

Tabela 4.4. Tamanho do modelo e valor a utilizar para treino-teste, com base nas % a considerar.

Tamanho do conjunto de dados	Amostra Treino (%)	Tamanho do conjunto de dados com base na percentagem	Valor a utilizar
8759	30	2627.7	2628
8759	20	1751.8	1752
8759	10	875.9	876

5. Resultados Computacionais e Discussão

*It is far better to foresee even without certainty
than not to foresee at all.*

Poincaré (1908)

Neste capítulo apresentaremos a aplicação dos modelos descritos e planeados anteriormente (capítulo 4).

Por forma a evitar repetições de conteúdos, optou-se por disponibilizar as tabelas de resultados, para cada intervalo de tempo a ser considerado e cada divisão treino-teste, no anexo C, apresentando três tabelas que sumariam os resultados obtidos (5.1.).

Para além disso, trataremos a discussão dos resultados que será apresentada em três fases. Numa primeira instância, analisaremos o desempenho dos modelos (5.2.). De seguida, abordaremos o processo de tomada de decisão multi-atributo (5.3.) onde recorreremos a um método de tomada de decisão para seleccionar os melhores modelos. Por fim, apresentaremos a argumentação final, onde faremos um apanhado geral do abordado no capítulo (5.4.).

5.1. Resultados

No total foram criados 225 modelos de previsão usados para prever o preço de eletricidade no MIBEL para as 24 horas seguintes ao último ponto da série (previsão multi-passos).

Foram considerados 75 modelos para cada intervalo de tempo:

- Intervalo A – Onde analisaremos os dados de 1 de janeiro de 2019 (00:00) a 31 de dezembro de 2019 (23:00).
- Intervalo B – Onde analisaremos os dados de 1 de janeiro de 2018 (00:00) a 31 de dezembro de 2019 (23:00).
- Intervalo C – Onde analisaremos os dados de 1 de janeiro de 2010 (00:00) a 31 de dezembro de 2019 (23:00).

Por forma a evitar repetições de conteúdos, optou-se por disponibilizar as tabelas de resultados, para cada intervalo de tempo a ser considerado e cada divisão treino-teste, no anexo C.

Nesta secção, apresentaremos três tabelas agregando os valores obtidos para cada um dos intervalos considerados. Na tabela 5.1. apresentaremos os resultados computacionais relativos ao intervalo A. Os resultados computacionais obtidos no intervalo B serão apresentados na tabela 5.2. e, por fim, os resultados obtidos para o intervalo C serão disponibilizados na tabela 5.3.

As variáveis a serem ingeridas por cada modelo podem ser consultadas na Tabela 4.2. (capítulo 4.2.1.). As métricas obtidas são o tempo de execução (em segundos), Erro Absoluto Médio (MAE), Erro Percentual Absoluto Médio (MAPE) e Raiz do Erro Quadrático Médio (RMSE). Podemos ler mais acerca destas métricas em 4.2. ou no anexo D.

Tabela 5.1. Resultados computacionais relativos ao intervalo A (2019).

Treino-Teste	Métrica	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15	M16	M17	M18	M19	M20	M21	M22	M23	M24	M25
70-30	Tempo de execução (s)	6	6	7	7	6	7	6	7	8	7	7	7	7	9	6	7	6	7	6	7	7	6	6	9	13
	MAE (€/MWh)	5.43	5.63	5.35	5.48	5.62	5.48	5.53	5.43	5.24	5.42	5.89	5.43	5.69	7.85	5.83	5.27	5.47	5.65	5.47	5.47	5.39	5.32	5.47	6.11	6.91
	MAPE (%)	93.31	105.11	81.19	111.37	114.33	99.12	103.59	93.31	78.41	93.49	115.08	93.31	115.08	195.81	115.77	75.33	94.04	128.68	94.04	94.04	105.24	102.33	94.04	137.46	182.36
	RMSE (€/MWh)	8.04	8.26	7.67	8.02	8.20	7.96	7.96	8.04	7.72	7.92	8.46	8.04	8.37	11.8	8.64	7.69	8.10	8.41	8.10	8.10	7.94	7.89	8.10	8.78	10.0
80-20	Tempo de execução (s)	6	6	7	7	6	7	6	7	8	7	7	7	7	9	6	7	6	7	6	7	7	6	6	9	13
	MAE (€/MWh)	5.43	5.63	5.35	5.48	5.62	5.48	5.53	5.43	5.24	5.42	5.89	5.43	5.69	7.85	5.83	5.27	5.47	5.65	5.47	5.47	5.39	5.32	5.47	6.11	6.91
	MAPE (%)	93.31	105.11	81.19	111.37	114.33	99.12	103.59	93.31	78.41	93.49	115.08	93.31	115.08	195.81	115.77	75.33	94.04	128.68	94.04	94.04	105.24	102.33	94.04	137.46	182.36
	RMSE (€/MWh)	8.04	8.26	7.67	8.02	8.20	7.96	7.96	8.04	7.72	7.92	8.46	8.04	8.37	11.8	8.64	7.69	8.10	8.41	8.10	8.10	7.94	7.89	8.10	8.78	10.0
90-10	Tempo de execução (s)	7	6	8	8	6	7	7	7	9	8	7	7	6	10	13	8	6	8	6	7	6	7	7	10	13
	MAE (€/MWh)	5.20	5.20	5.34	5.46	5.37	5.26	5.26	5.20	5.17	5.21	6.11	5.20	5.20	5.33	5.15	5.49	5.20	5.15	5.20	5.12	5.07	5.19	5.20	5.03	6.50
	MAPE (%)	69.43	69.43	90.22	78.00	71.21	62.63	117.86	69.43	60.77	67.39	116.14	69.43	69.43	60.09	101.75	90.78	69.62	66.41	69.62	61.57	68.88	94.80	69.62	88.95	84.97
	RMSE (€/MWh)	7.69	7.69	7.54	7.86	7.79	7.70	7.57	7.69	7.59	7.66	9.23	7.69	7.69	7.65	7.41	7.89	7.69	7.49	7.69	7.52	7.44	7.69	7.69	7.30	9.46

Tabela 5.2. Resultados computacionais relativos ao intervalo B (2018-2019).

Treino-Teste	Métrica	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15	M16	M17	M18	M19	M20	M21	M22	M23	M24	M25
70-30	Tempo de execução (s)	13	13	14	15	13	16	16	13	14	14	14	13	13	20	15	15	14	16	13	14	13	14	14	16	25
	MAE (€/MWh)	3.86	3.86	3.82	3.89	3.90	3.91	3.87	3.86	3.88	3.86	3.97	3.86	3.86	4.06	4.16	3.87	3.87	4.06	3.87	3.85	3.91	3.82	3.87	4.02	4.49
	MAPE (%)	16.01	16.01	16.02	16.46	15.72	16.27	15.57	16.01	16.16	16.01	15.53	16.01	16.01	16.32	17.47	16.09	16.29	16.54	16.08	15.80	16.31	15.45	16.08	16.32	17.56
	RMSE (€/MWh)	5.30	5.30	5.18	5.34	5.32	5.36	5.29	5.30	5.33	5.30	5.41	5.30	5.30	5.51	5.64	5.32	5.36	5.51	5.29	5.28	5.39	5.26	5.29	5.48	6.04
80-20	Tempo de execução (s)	14	14	16	16	16	17	18	14	14	15	15	15	14	26	16	15	15	17	19	16	16	15	15	22	28
	MAE (€/MWh)	4.03	4.03	4.09	4.15	4.15	4.06	4.02	4.03	4.11	4.05	4.13	4.03	4.03	4.28	4.07	4.09	4.12	4.23	4.11	4.07	4.09	4.06	4.09	4.39	4.45
	MAPE (%)	20.75	20.74	22.79	23.38	22.07	21.67	20.40	20.74	21.50	20.81	20.15	20.74	20.74	20.20	20.88	21.00	21.16	20.37	20.88	19.88	20.76	19.72	21.00	20.73	20.89
	RMSE (€/MWh)	5.65	5.65	5.66	5.83	5.86	5.68	5.60	5.65	5.78	5.67	5.73	5.65	5.65	5.85	5.69	5.76	5.85	5.82	5.73	5.63	5.68	5.66	5.76	5.98	5.94
90-10	Tempo de execução (s)	17	18	20	17	16	18	19	16	17	18	16	16	17	24	18	17	20	20	20	17	19	18	19	26	43
	MAE (€/MWh)	4.69	4.69	4.60	4.74	4.83	4.75	4.78	4.69	4.70	4.82	4.72	4.69	4.77	5.02	4.64	4.68	4.72	4.67	4.63	4.63	4.58	4.68	4.68	5.26	4.84
	MAPE (%)	33.28	33.28	36.19	34.69	35.52	34.88	33.39	33.28	32.01	33.78	33.03	33.28	33.44	32.35	30.95	32.41	34.06	32.94	32.32	40.03	32.03	31.49	6.60	35.62	29.46
	RMSE (€/MWh)	6.66	6.66	6.38	6.72	6.90	6.76	6.69	6.66	6.62	6.70	6.66	6.66	6.74	6.87	6.49	6.60	6.76	6.62	6.54	6.52	6.46	6.58	32.41	7.24	6.64

Tabela 5.3. Resultados computacionais relativos ao intervalo C (2010-2019).

Treino-Teste	Métrica	M1	M2	M3	M4	M5	M6	M7	M8	M9	M10	M11	M12	M13	M14	M15	M16	M17	M18	M19	M20	M21	M22	M23	M24	M25
70-30	Tempo de execução (s)	128	128	151	128	118	142	146	126	149	139	119	130	137	194	128	134	133	140	133	141	131	128	135	197	319
	MAE (€/MWh)	4.19	4.19	4.18	4.15	4.19	4.18	4.31	4.19	4.85	4.31	4.21	4.15	4.17	4.80	4.30	4.25	4.20	4.17	4.26	4.22	4.20	4.23	4.21	4.38	4.86
	MAPE (%)	12.78	12.78	11.89	12.94	12.83	13.30	12.80	13.08	13.96	13.03	12.95	12.90	12.84	13.03	12.80	12.83	13.05	12.60	12.88	12.75	12.83	12.71	12.59	13.12	12.20
	RMSE (€/MWh)	5.70	5.70	5.64	5.69	5.71	5.71	5.86	5.73	6.37	5.84	5.72	5.66	5.70	6.39	5.84	5.76	5.75	5.69	5.78	5.77	5.74	5.76	5.74	5.93	6.44
80-20	Tempo de execução (s)	147	146	203	150	168	150	144	146	160	154	145	140	146	209	164	160	151	163	153	162	155	148	146	210	318
	MAE (€/MWh)	4.10	4.10	4.06	4.07	4.09	4.09	4.12	4.11	4.63	4.20	4.06	4.03	4.07	4.84	4.14	4.16	4.14	4.08	4.10	4.13	4.11	4.14	4.11	4.32	4.76
	MAPE (%)	14.16	14.16	13.99	14.22	13.83	14.69	14.11	14.42	14.69	14.28	14.38	14.05	14.24	14.40	13.94	13.92	14.64	13.42	14.09	14.44	13.61	13.77	14.44	14.74	13.23
	RMSE (€/MWh)	5.68	5.68	5.59	5.65	5.67	5.66	5.72	5.70	6.16	5.80	5.62	5.62	5.65	6.40	5.73	5.73	5.73	5.65	5.68	5.73	5.71	5.75	5.71	5.92	6.36
90-10	Tempo de execução (s)	145	135	222	152	170	180	165	163	201	168	162	163	162	251	189	172	182	184	173	173	168	159	170	229	351
	MAE (€/MWh)	3.95	3.95	3.90	3.96	3.93	3.96	3.93	3.96	4.11	3.92	3.91	3.92	3.92	4.24	3.94	3.99	3.96	3.93	3.96	3.93	3.91	3.93	3.96	3.92	4.15
	MAPE (%)	15.22	15.22	14.68	16.14	15.24	14.86	15.90	15.73	14.51	14.64	14.88	14.63	15.37	15.21	15.31	16.73	16.67	14.53	15.52	15.64	15.81	15.11	15.52	15.03	14.33
	RMSE (€/MWh)	5.41	5.41	5.32	5.42	5.39	5.43	5.41	5.43	5.53	5.38	5.37	5.40	5.39	5.74	5.40	5.44	5.43	5.39	5.42	5.39	5.40	5.40	5.42	5.38	5.52

5.2. Desempenho

Com base nos resultados obtidos, observamos vários caminhos para análise do desempenho dos modelos. Nesse sentido, optou-se por, para cada intervalo considerado, selecionar, o(s) modelo(s) que apresenta(m) melhor(es) resultado(s) numa métrica específica: tempo de execução, MAE, MAPE ou RMSE. De notar que por melhor resultado, aqui, entendemos que, para cada atributo, é um menor valor.

Como tal, começaremos por analisar o desempenho dos modelos no intervalo A (5.2.1.), de seguida no intervalo B (5.2.2.), passando pelo intervalo C (5.2.3.) e, por fim, uma análise do desempenho geral (5.2.4.) onde consideraremos todos os intervalos.

5.2.1. Ano 2019 – A

Começando pelo intervalo A, os modelos mais rápidos (tempo de execução menor) obtiveram um tempo de execução de 6 segundos (Tabela 5.4.).

Tabela 5.4. A – Modelos com um tempo de execução menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
A	90-10	M21	6	5.07	68.88	7.44
A	90-10	M2	6	5.20	69.43	7.69
A	90-10	M13	6	5.20	69.43	7.69
A	90-10	M17	6	5.20	69.62	7.69
A	90-10	M19	6	5.20	69.62	7.69
A	90-10	M5	6	5.37	71.21	7.79
A	70-30	M1	6	5.43	93.31	8.04
A	80-20	M1	6	5.43	93.31	8.04
A	70-30	M17	6	5.47	94.04	8.10
A	70-30	M19	6	5.47	94.04	8.10
A	70-30	M23	6	5.47	94.04	8.10
A	80-20	M17	6	5.47	94.04	8.10
A	80-20	M19	6	5.47	94.04	8.10
A	80-20	M23	6	5.47	94.04	8.10
A	70-30	M22	6	5.32	102.33	7.89
A	80-20	M22	6	5.32	102.33	7.89
A	70-30	M7	6	5.53	103.59	7.96
A	80-20	M7	6	5.53	103.59	7.96
A	70-30	M2	6	5.63	105.11	8.26
A	80-20	M2	6	5.63	105.11	8.26
A	70-30	M5	6	5.62	114.33	8.20
A	80-20	M5	6	5.62	114.33	8.20
A	70-30	M15	6	5.83	115.77	8.64
A	80-20	M15	6	5.83	115.77	8.64

No que toca aos modelos com um MAE menor, temos o Modelo 3, com treino-teste 90-10, cujo MAE obtido foi de 3.9 (segue abaixo).

Tabela 5.5. A – Modelo com um MAE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
A	90-10	M24	10	5.03	88.95	7.30

O modelo com um MAPE menor, correspondente a 11.89, foi o seguinte:

Tabela 5.6. A – Modelo com um MAPE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
A	90-10	M14	10	5.33	60.09	7.65

Analisando o modelo com o RMSE menor, temos o seguinte modelo:

Tabela 5.7. A – Modelo com um RMSE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
A	90-10	M24	10	5.03	88.95	7.30

Neste intervalo, no que toca ao tempo, a diferença entre os modelos foi relativamente reduzida, sendo que os mais rápidos tiveram um tempo de execução de 6 segundos e os mais lentos de 13 segundos. De notar que, no entanto, perto de 1/3 dos modelos deste intervalo demoraram 6 segundos a executar (24 para sermos mais precisos).

No que toca às restantes métricas (MAE, MAPE, RMSE), destacam-se dois modelos: M24 e M14, ambos com treino-teste 90-10. O Modelo 14 foi o que teve um MAPE menor e o Modelo 24 foi o melhor nas métricas MAE e RMSE.

Os modelos que obtiveram erros menores têm intervalos de treino maiores (treino-teste 90-10). Isto deve-se ao facto de, como o conjunto de dados é reduzido, uma amostra de treino superior consegue obter uma representação melhor da série e, por conseguinte, efetuar previsões mais próximas da realidade.

5.2.2. Anos 2018-2019 – B

Analisando agora o intervalo B, no que toca aos modelos mais rápido (tempo de execução menor), temos 8 modelos, todos com treino-teste 70-30 que obteve um tempo de execução de 13 segundos (Tabela 5.8.).

Tabela 5.8. B – Modelos com um tempo de execução menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
B	70-30	M5	13	3.90	15.72	5.32
B	70-30	M12	13	3.86	16.01	5.30
B	70-30	M8	13	3.86	16.01	5.30
B	70-30	M21	13	3.91	16.31	5.39
B	70-30	M19	13	3.87	16.08	5.29
B	70-30	M13	13	3.86	16.01	5.30
B	70-30	M2	13	3.86	16.01	5.30
B	70-30	M1	13	3.86	16.01	5.30

No que toca aos modelos com um MAE menor, temos o Modelo 3 e o Modelo 22, com treino-teste 70-30, cujo MAE obtido foi de 3.82 (segue abaixo).

Tabela 5.9. B – Modelo com um MAE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
B	70-30	M3	14	3.82	16.02	5.18
B	70-30	M22	14	3.82	15.45	5.26

O modelo com um MAPE menor, correspondente a 15.45, foi o seguinte:

Tabela 5.10. B – Modelo com um MAPE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
B	70-30	M22	14	3.82	15.45	5.26

Analisando o modelo com o RMSE menor, temos o seguinte modelo:

Tabela 5.11. B – Modelo com um RMSE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
B	70-30	M3	14	3.82	16.02	5.18

Neste intervalo, no que toca ao tempo, temos que a diferença entre os modelos foi de 30 segundos, sendo que o modelo mais lento, o Modelo 25 (que tem um número de atributos maior que os restantes).

Neste intervalo, sem dúvida que os Modelos 3 e 22 com treino-teste 70-30 se destacaram, obtendo ambos os melhores valores no que toca ao MAE (3.82). Para além disso, o Modelo 22 foi o que obteve o MAPE menor (15.45) e o Modelo 3 o que obteve o RMSE menor (5.18). Embora não tenham sido os mais rápidos, diferiram apenas um segundo dos mais rápidos tendo criando o modelo e efetuando as previsões em 14 segundos.

Os modelos mais rápidos apresentam um tempo de execução igual aos modelos mais lentos considerados no intervalo A, de 13 segundos. Como neste intervalo estão a ser considerados mais dados, era expectável que fosse mais moroso.

5.2.3. Anos 2010-2019 – C

Considerando apenas o intervalo C, no que toca ao modelo mais rápido (tempo de execução menor), temos o Modelo 3, com treino-teste 70-30 que obteve um tempo de execução de 151 segundos (segue abaixo).

Tabela 5.12. C – Modelo com um tempo de execução menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
C	70-30	M3	151	4.18	11.89	5.64

No que toca aos modelos com um MAE menor, temos o Modelo 3, com treino-teste 90-10, cujo MAE obtido foi de 3.9 (segue abaixo).

Tabela 5.13. C – Modelo com um MAE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
C	90-10	M3	222	3.90	14.68	5.32

O modelo com um MAPE menor, correspondente a 11.89, foi o seguinte:

Tabela 5.14. C – Modelo com um MAPE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
C	70-30	M3	151	4.18	11.89	5.64

Analisando o modelo com o RMSE menor, temos o seguinte modelo:

Tabela 5.15. C – Modelo com um RMSE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
C	90-10	M3	222	3.90	14.68	5.32

Neste intervalo, sem dúvida que o Modelo 3 se destacou, tendo o treino-teste 70-30 obtido melhores valores a nível do tempo de execução e do MAPE. Para além disso, o mesmo Modelo com treino-teste 90-10 foi o que obteve um MAE e um RMSE menores e, por conseguinte, melhores.

5.2.4. Geral

Por fim, procedemos a uma seleção, com base em todos os modelos (todos os intervalos), e selecionaremos o(s) modelo(s) que melhor resultados apresenta(m) numa métrica específica: tempo de execução, MAE, MAPE ou RMSE.

No que toca aos modelos mais rápidos (tempo de execução menor), obtiveram um tempo igual a 6 segundos e foram 24 (Tabela 5.16).

Tabela 5.16. Modelos mais rápidos (com tempo de execução menor).

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
A	90-10	M21	6	5.07	68.88	7.44
A	90-10	M2	6	5.20	69.43	7.69
A	90-10	M13	6	5.20	69.43	7.69
A	90-10	M17	6	5.20	69.62	7.69
A	90-10	M19	6	5.20	69.62	7.69
A	90-10	M5	6	5.37	71.21	7.79
A	70-30	M1	6	5.43	93.31	8.04
A	80-20	M1	6	5.43	93.31	8.04
A	70-30	M17	6	5.47	94.04	8.10
A	70-30	M19	6	5.47	94.04	8.10
A	70-30	M23	6	5.47	94.04	8.10
A	80-20	M17	6	5.47	94.04	8.10
A	80-20	M19	6	5.47	94.04	8.10
A	80-20	M23	6	5.47	94.04	8.10
A	70-30	M22	6	5.32	102.33	7.89
A	80-20	M22	6	5.32	102.33	7.89
A	70-30	M7	6	5.53	103.59	7.96
A	80-20	M7	6	5.53	103.59	7.96
A	70-30	M2	6	5.63	105.11	8.26
A	80-20	M2	6	5.63	105.11	8.26
A	70-30	M5	6	5.62	114.33	8.20
A	80-20	M5	6	5.62	114.33	8.20
A	70-30	M15	6	5.83	115.77	8.64
A	80-20	M15	6	5.83	115.77	8.64

Numa primeira observação, todos estes dizem respeito ao intervalo de tempo mais reduzido A, que corresponde apenas aos dados com informação relativa ao ano de 2019.

No que toca aos modelos com um MAE menor, dois dos modelos obtiveram um MAE igual, correspondente a 3.82 (seguem abaixo).

Tabela 5.17. Modelos com um MAE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
B	70-30	M22	14	3.82	15.45	5.26
B	70-30	M3	14	3.82	16.02	5.18

O modelo com um MAPE menor, correspondente a 11.89, foi o seguinte:

Tabela 5.18. Modelos com um MAPE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
C	70-30	M3	151	4.18	11.89	5.64

Analisando o modelo com o RMSE menor, temos o seguinte modelo:

Tabela 5.19. Modelos com um RMSE menor.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)
B	70-30	M3	14	3.82	16.02	5.18

Este modelo (M3) com treino-teste 70-30, considerando um intervalo de dois anos (B), curiosamente, foi um dos que obteve o MAE menor. Para além disso, este modelo (M3), com treino-teste (70-30), ao considerar um intervalo de tempo maior (C), foi o que obteve o MAPE menor.

Considerando a questão temporal, os modelos mais rápidos foram os que consideraram intervalos de tempo menores (A), algo que vai encontro ao esperado.

5.3. *Decisão Multi-Atributo*

Para além da análise de desempenho considerada em 5.2, aplicaremos um método de decisão multi-atributo para, dos 225 modelos, encontrar as melhores alternativas.

Por forma a adicionar o mínimo de subjetividade possível no processo de decisão, optámos por considerar o modelo TOPSIS (5.3.1.), onde a única subjetividade é adicionada no estabelecimento dos pesos associados a cada atributo a analisar.

5.3.1. TOPSIS

O TOPSIS, acrónimo que significa “*Technique of Order Preference Similarity to the Ideal Solution*”, foi proposto por Chen e Hwang em 1991 (Triantaphyllou et al, 1998).

No MCDM, uma série de alternativas têm de ser avaliadas e comparadas utilizando vários critérios, por forma a fornecer apoio ao decisor no processo de tomada de decisão entre alternativas. Desta forma, os problemas práticos são muitas vezes caracterizados por vários critérios contraditórios, e pode não haver solução que satisfaça todos os critérios em simultâneo, pelo que a solução é uma solução de compromisso de acordo com as preferências do decisor. Neste sentido, o TOPSIS baseia-se no conceito de que a alternativa escolhida deve ter a menor distância do ponto “ideal” (ou Zenith) e a mais distante do ponto “anti-ideal” (ou Nadir). A classificação final é obtida por meio do índice de proximidade (Sánchez-Lozano et al, 2013).

O método TOPSIS avalia a seguinte matriz de decisão que se refere às alternativas M que são avaliadas em termos de critérios N:

$$D = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1N} \\ x_{21} & x_{22} & \cdots & x_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ x_{M1} & x_{M2} & \cdots & x_{MN} \end{bmatrix}$$

onde x_{ij} denota a medida de desempenho da i -ésima alternativa em termos do critério j -ésimo (Triantaphyllou et al, 1998).

Para uma visão mais clara deste método, iremos apresentá-lo como uma série de etapas sucessivas (figura 5.1.).

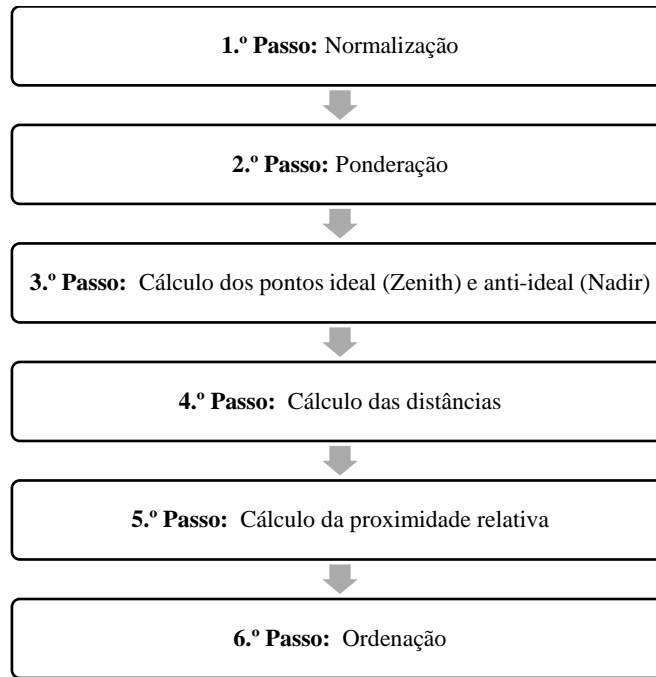


Figura 5.1 Algoritmo do método TOPSIS.

Por forma a facilitar a compreensão da figura 5.1., apresentamos, abaixo, o processo com maior detalhe.

1. Normalização

A fim de poder comparar diferentes tipos de critérios, o primeiro passo é torná-los sem dimensões, ou seja, eliminar as unidades dos critérios (Papathanasiou & Ploskas, 2018). Um elemento r_{ij} da matriz de decisão normalizada R pode ser calculado como se segue:

$$r_{ij} = \frac{x_{ij}}{\sqrt{\sum_{i=1}^M x_{ij}^2}} \quad (5.1)$$

(Triantaphyllou et al, 1998)

2. Ponderação

Os pesos são os únicos parâmetros subjetivos (em oposição a outras metodologias de apoio à decisão). Neste passo, é feita a multiplicação da matriz de decisão normalizada com o peso associado a cada um dos critérios (Papathanasiou & Ploskas, 2018). Um conjunto de pesos $W = w_1, w_2, w_3, \dots, w_N$ (onde: $\sum w_i = 1$) definido pelo decisor é acomodado na matriz de decisão para gerar a matriz normalizada ponderada V como se segue:

$$V = \begin{bmatrix} w_1 r_{11} & w_2 r_{12} & \cdots & w_N r_{1N} \\ w_1 r_{21} & w_2 r_{22} & \cdots & w_N r_{2N} \\ \vdots & \vdots & \ddots & \vdots \\ w_1 r_{M1} & w_2 r_{M2} & \cdots & w_N r_{MN} \end{bmatrix}$$

(Triantaphyllou et al, 1998)

3. Cálculo dos pontos ideal (Zenith) e anti-ideal (Nadir)

O Ponto Ideal tem como coordenadas os melhores valores dos critérios. O Ponto Anti-ideal tem como coordenadas os piores valores dos critérios (Papathanasiou & Ploskas, 2018).

As soluções ideal (A^*) e anti-ideal (A^-) são definidas da seguinte forma:

$$A_{i^*} = \{(\max v_{ij} | j_i \in J), (\min v_{ij} | j \in J) | i = 1, 2, 3, \dots, M\} = \{v_{1^*}, v_{2^*}, \dots, v_{N^*}\} \quad (5.2)$$

$$A_{i^-} = \{(\min v_{ij} | j_i \in J), (\max v_{ij} | j \in J) | i = 1, 2, 3, \dots, M\} = \{v_{1^-}, v_{2^-}, \dots, v_{N^-}\} \quad (5.3)$$

Onde: $J = \{j = 1, 2, 3, \dots, N | j \text{ associados a critérios de benefício}\}$,

$J = \{j = 1, 2, 3, \dots, N | j \text{ associados a critérios de custo}\}$

Para os critérios de benefício, o decisor quer ter um valor máximo entre as alternativas. Para os critérios de custo, o decisor quer ter um valor mínimo entre as alternativas. Obviamente, A^* indica a alternativa mais apreciável ou a solução ideal. Da mesma forma, A^- indica a alternativa menos preferível ou a solução anti-ideal (Triantaphyllou et al, 1998).

4. Cálculo das distâncias

Esta etapa trata do cálculo das distâncias de cada alternativa em relação à solução ideal (Papathanasiou & Ploskas, 2018).

O método de distância Euclidiana N-dimensional é aplicado em para medir as distâncias de separação de cada alternativa para a solução ideal e a solução anti-ideal.

$$S_{i^*} = \left(\sum (v_{ij} - v_{j^*})^2 \right)^{\frac{1}{2}}, i = 1, 2, 3, \dots, M, \quad (5.4)$$

onde S_{i^*} é a separação (num sentido Euclideano) de cada alternativa a partir da solução ideal.

$$S_{i^-} = \left(\sum (v_{ij} - v_{j^-})^2 \right)^{\frac{1}{2}}, i = 1, 2, 3, \dots, M, \quad (5.5)$$

onde S_{i^-} é a separação (num sentido Euclideano) de cada alternativa a partir da solução anti-ideal (Triantaphyllou et al, 1998).

5. Cálculo da proximidade relativa

A proximidade relativa de um A_i alternativo em relação à solução ideal A^* é definida da seguinte forma:

$$C_{i^*} = \frac{S_{i^-}}{(S_{i^*} + S_{i^-})}, 0 \leq 1, i = 1, 2, 3, \dots, M \quad (5.6)$$

Aparentemente, $C_{i^*} = 1$, se $A_i = A^*$, e $C_{i^-} = 0$, se $A_i = A^-$ (Triantaphyllou et al, 1998).

6. Ordenação

Finalmente, as alternativas são ordenadas de acordo com a classificação de preferência da C_{i^*} . Portanto, a melhor alternativa é a que tem a distância mais curta para a solução ideal. A relação das alternativas revela que qualquer alternativa que tenha a distância mais curta à solução ideal é garantidamente a que tem a distância mais longa para a solução anti-ideal (Triantaphyllou et al, 1998).

No que toca aos critérios a serem maximizados (critérios de benefício) e ou minimizados (critério de custo), no código disponibilizado em (Papathanasiou & Ploskas, 2018) é permitida apenas a inclusão de critérios de benefício. Embora possa ser intuitivo fazer as alterações adequadas para permitir também critérios de custo, recorreremos a uma abordagem diferente, que nos permitiu considerar os critérios de custo.

Os modelos foram ordenados, com base numa análise TOPSIS multi-critério, considerando os atributos de custo (a serem minimizados) tempo de execução (s), MAE, MAPE e RMSE para os diversos intervalos de forma individual e, por fim, fazendo uma ordenação dos modelos todos. Consultar anexo E para observar as tabelas com os resultados obtidos.

5.4. *Argumentação Final*

A divisão das séries cronológicas em múltiplos conjuntos de treino e teste, embora tenha exigido a formação e avaliação de múltiplos modelos, o que é de certo modo dispendioso, permite obter uma estimativa mais robusta do desempenho esperado para cada modelo.

O termos recorrido a diversas medidas de desempenho permite que a comparação entre artigos seja mais fácil de fazer. De salientar que um dos erros obtidos é percentual, nomeadamente a MAPE, e que o facto de não conter unidades torna-se vantajoso ao permitir que a comparação de desempenhos previstos entre conjuntos de dados seja mais facilitada. Pelo contrário, a MAE e RMSE podem não ser muito informativos.

Achamos relevante, ao propor modelos de previsão, que os tempos de computação sejam disponibilizados, que foi o que fizemos. E, numa análise aos resultados obtidos, podemos encontrar modelos que foram muito rápidos e obtiveram resultados satisfatórios.

Analisando o desempenho dos modelos relativos ao intervalo de tempo B, onde foram analisados dois anos (2018 e 2019) e, comparando com o artigo (Monteiro et al, 2018) que também considera um intervalo de dois anos, os valores do MAE obtidos por nós são inferiores aos apresentados, pelo que aparentam ser muito satisfatórios.

No tocante ao desempenho, considerando todos os intervalos de tempo (5.2.4.), notamos que os resultados com erros menores foram os que consideraram intervalos de tempo superiores a 1 ano, nomeadamente o B e o C. Isto é revelador de que para este contexto, com pelo menos dois anos de dados conseguimos proceder a uma modelação mais precisa.

Continuando a análise de desempenho geral, há um modelo que se destaca: o M3 que, a par de considerar as variáveis cronológicas Ano, Mês, Dia, Hora, como os restantes modelos todos, considera o Dia da Semana e Feriados. Os dias especiais, feriados, são uma métrica útil na previsão dos preços de eletricidade, na medida em que afetam comportamentos de consumo, como expectável, comportamentos estes que estão diretamente associados ao preço de energia, tendo em conta as suas características.

Ao inspecionar o M3 para o intervalo B com treino-teste 70-30, no TIM Studio versão 2.0, podemos observar as séries:

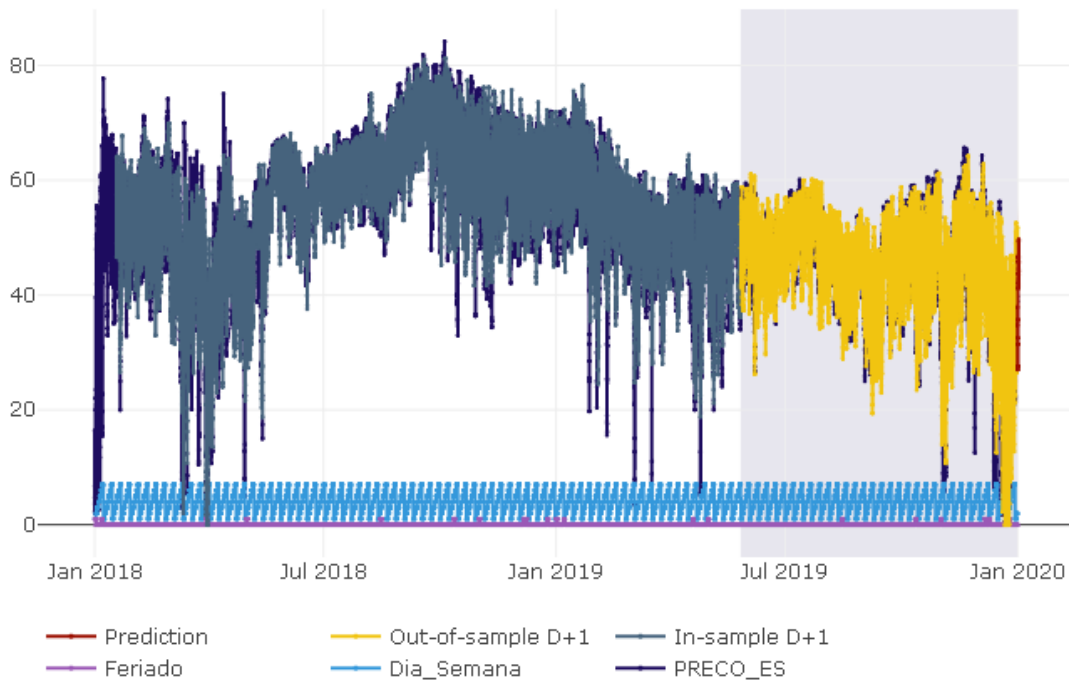


Figura 5.2. M3B – 70-30 – Visualização das séries e da previsão.

Se efetuarmos uma aproximação das séries, focando-nos na previsão, podemos ver a previsão e o respetivo intervalo de previsão. Os intervalos de previsão servem o propósito de expressar a incerteza nas previsões e é um dos pontos que o TIM possibilita.

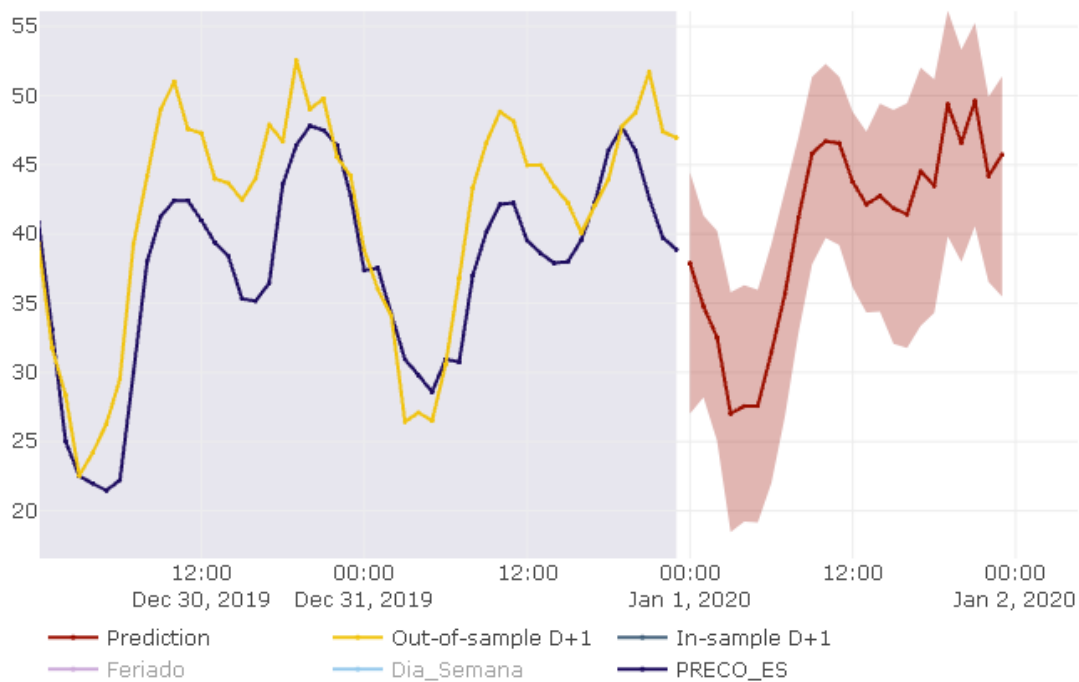


Figura 5.3. M3B – 70-30 – Aproximação da visualização das séries e da previsão.

Analisando, por exemplo, o primeiro valor previsto e o respetivo intervalo probabilístico, temos os seguintes valores:




Figura 5.4. M3B – 70-30 – Visualização do primeiro valor previsto e valores do intervalo probabilístico.

A obtenção de valores inferiores e superiores dos intervalos de previsão para o período desejado pode ser vantajosa para os decisores, na medida em que podem assumir mais risco nas decisões. Para obter um intervalo de previsão de 95 e 5 por cento, o TIM calcula quantis a partir dos resíduos entre o alvo e a previsão obtida para os dados utilizados na formação de modelos. Isto permite assegurar que o intervalo é fino para situações em que a incerteza

é pequena (por exemplo, previsão da produção solar a meio da noite) e vice-versa (por exemplo, previsão muito à frente).

Por forma a compreendermos melhor como o modelo está a funcionar, podemos analisar o diagrama *Sunburst* disponibilizado:

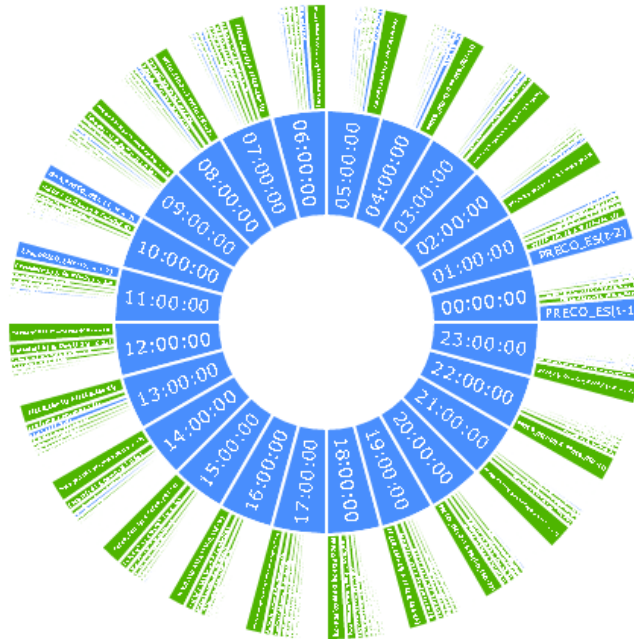


Figura 5.5. M3B – 70-30 – Diagrama *Sunburst*.

Com base neste podemos verificar que o TIM faz uma engenharia de atributos a partir das variáveis originais. Isto é feito através de conjuntos de transformações comuns que resultam em novos dicionários de características²⁵. Vamos, então, explorar, a título de exemplo, a combinação de variáveis usada pelo modelo para as previsões às 10:00:00.

²⁵ Por forma a compreender a nomenclatura utilizada e o que corresponde cada uma das expansões, podemos consultar a seguinte página web: <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Configuration/Dictionaries/> (“TIM Forecasting — Dictionaries”, sem data).

Feriado com *lag/delay/offset* igual a 6 e Dia da Semana com *lag/delay/offset* igual a 21, inferior a Sábado.

Um ponto-chave na previsão dos preços de eletricidade (EPF) é a escolha apropriada de variáveis explicativas. A abordagem típica tem sido a seleção de preditores de forma ad hoc, por vezes utilizando o conhecimento especializado (Uniejewski et al, 2016), como foi o caso do Monteiro, C., Ramirez-Rosado, I. J., Fernandez-Jimenez, L. A., & Ribeiro, M. (Monteiro et al, 2018) e (Monteiro et al, 2016). No contexto deste trabalho recorreu-se a uma abordagem diferente, fruto da mistura de conhecimento especializado, ao selecionar categorias de variáveis explicativas e respetivas variáveis, e um processo automático de expansão de variáveis que o TIM fornece. Este processo automático feito pelo TIM disponibiliza as variáveis usadas, expansões efetuadas e as suas importâncias. Isto permite prever séries temporais relativas a um contexto específico, como é o caso do MIBEL, com um conhecimento pouco especializado do funcionamento do mercado. Para além disso, esta funcionalidade permite a analistas que trabalham no mercado, encontrar outro tipo de combinações de atributos que podem efetuar, por forma a analisar se produz melhorias em termos de resultados.

Para além disso, há setores onde é legalmente obrigatório basear as decisões apenas na produção de modelos que possam ser explicados (“*TIM Documentation — Transparent models*”, sem data). Para esses casos, como foi possível verificar, o TIM pode ser uma boa solução, pois foi projetado para fornecer os benefícios dos modelos de caixa branca.

Num outro ponto, por forma a compreender como os atributos utilizados neste modelo contribuíram para explicar a variação do seu Alvo (no nosso caso, o Preço de Eletricidade) em relação a outros preditores, o TIM disponibiliza-nos um gráfico (figura abaixo), onde verificamos que o Dia da Semana teve uma importância de 3.5%, o Feriado de 14.22% e, a variável mais relevante para prever o preço foi o Preço de Energia (82.28%). De notar que a soma das importâncias individuais totaliza 100% ($3.5 + 14.22 + 82.28 = 100$).




Figura 5.7. M3B – 70-30 – Importância dos Atributos.

Ao analisar os resultados das tabelas apresentadas no capítulo 5.2.4., observamos que o modelo mais rápido não é necessariamente o que obtém um erro menor (quer MAE, quer MAPE ou quer RMSE), ou que o que tem um MAPE menor não é o mais rápido. Como tal, compreendemos que no mundo real, tomar partido de mais métricas pode ser benéfico para a seleção dos melhores modelos. Nesse sentido, por forma a facilitar o processo de tomada de decisão dos melhores modelos, aplicou-se o método de decisão multi-atributo TOPSIS (5.3.1.).

De notar que na análise TOPSIS, geralmente, as alternativas tendem a ser ordenadas por ordem decrescente da proximidade (C_i), no entanto, como considerámos o TOPSIS com uma mistura de critério benefício e custo, o fator custo acaba por, de alguma forma, “compensar” os valores da proximidade, resultando em modelos com bons valores de proximidade, mas com *rankings* bem diferentes.

Considerando os resultados obtidos no TOPSIS, no intervalo A, o melhor modelo foi o M6, com treino-teste 90-10:

Tabela 5.20. TOPSIS – A – Melhor modelo.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE(€/MWh)	MAPE (%)	RMSE(€/MWh)
A	90-10	M6	7	5.26	62.63	7.70

Considerando os resultados obtidos no TOPSIS, no intervalo B, o melhor modelo foi o M25, com treino-teste 90-10:

Tabela 5.21. TOPSIS – B – Melhor modelo.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE(€/MWh)	MAPE (%)	RMSE(€/MWh)
B	90-10	M25	43	4.84	29.46	6.64

Considerando os resultados obtidos no TOPSIS, no intervalo C o melhor modelo foi o M23, com treino-teste 90-10:

Tabela 5.22. TOPSIS – C – Melhor modelo.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE(€/MWh)
C	90-10	M23	170	3.96	15.52	5.42

Analisando os resultados com recurso ao modelo de tomada de decisão multi-atributo efetuado a todos os intervalos, temos que o melhor modelo foi o M7 com treino-teste 90-10:

Ao treinar um algoritmo de *Machine Learning* para jogar um jogo de "Go" ou como distinguir entre imagens de pulmões para detectar cancro do pulmão, mais amostras de dados, normalmente, melhoram o desempenho do modelo. Nesse sentido e, por forma a analisar se o mesmo se aplica às previsões do preço de eletricidade, surgiu o modelo 25. Neste recorreremos a um número grande de atributos, 26 para sermos mais precisos. Analisando os resultados obtidos, este modelo foi o que demorou mais a executar, não apresentando necessariamente melhores resultados. Ao recorrer à análise TOPSIS, no entanto, no intervalo B, onde foram considerados dois anos, este revelou ser o melhor modelo com uma divisão treino-teste de 90-10.

Esta página foi intencionalmente deixada em branco.

6. Conclusão

*There are far, far better things ahead than
any we leave behind.*

C.S. Lewis (1963)

Nos mercados de eletricidade, assim como em diversas áreas do conhecimento, há que lidar com incerteza (falta de informação perfeita) na tomada de decisão (Conejo et al, 2010). Se obtida antecipadamente a previsão do preço de energia elétrica constitui informação muito útil para lidar com a incerteza, sendo uma mais-valia para qualquer agente envolvido num mercado destes (Monteiro et al, 2018).

A relevância da previsão de preços de eletricidade é vista também pela quantidade de pesquisa muito ativa nos últimos 15 anos (Monteiro et al, 2018). Nestes últimos anos, foram apresentados na literatura científica modelos de previsão de preços de eletricidade para o dia seguinte, na sua maioria centrados em previsões pontuais de preços horários, que, infelizmente, não permitem compreender a variação do preço ao longo do dia – variação esta que sofre bastantes alterações em função da hora do dia. Nesse sentido, as previsões multi-passos resolvem essa limitação.

Obter modelos capazes de prever a evolução de sistemas multi-passos à frente recorrendo a multi-atributos são grandes desafios quando se lida com previsão de séries temporais.

Este trabalho trata a previsão horária multi-passos e multi-atributo do Preço de eletricidade no MIBEL, nomeadamente na parte espanhola, para as 24 horas do dia seguinte, recorrendo a dados abertos.

Estes modelos utilizam um conjunto muito extenso de variáveis de entrada, consistindo em grandes séries temporais de preços horários, previsões da procura (programada, prevista e real), geração de energia horárias (eólica, nuclear, carvão, ciclo combinado, hidráulica, solar, intercâmbios internacionais). Além disso, as variáveis de entrada incluem previsões meteorológicas, na região, bem como dados cronológicos (data, ano, mês, dia, hora, dia da semana, feriado).

A testagem é um ponto importante nas ciências da computação, assim como em outras engenharias, pois pretende-se que um determinado sistema que desenvolvemos faça o que realmente deve fazer. Nesse sentido, os modelos que desenvolvemos foram treinados e testados em vários períodos de tempo, com múltiplas divisões treino-teste.

A precisão das previsões dos modelos foi avaliada pelos indicadores MAE, MAPE e RMSE, tendo ainda sido considerado o tempo de execução (em segundos). Consideramos que a disponibilização da avaliação recorrendo a diversos indicadores torna-se útil para uma melhor comparação entre artigos da área.

O TIM, ferramenta utilizada para tratar as previsões, para além de resolver a questão de previsão multi-passos e multi-atributo, permite, ainda, obter intervalos de previsão, o que permite lidar melhor com a incerteza.

Um outro ponto importante de referir é a questão da interpretabilidade dos modelos. Ao contrário de muitos dos modelos de previsão, como as redes neuronais, onde a interpretabilidade é bastante reduzida, nos modelos apresentados neste trabalho podemos analisar as variáveis que mais afetam cada modelo, as expansões de atributos efetuadas e as suas importâncias para o modelo, em que hora é que cada uma das variáveis e/ou expansões têm mais importância. Esta possibilidade de explorar as diversas importâncias das variáveis, permite que se procedam aos ajustes do modelo e, por conseguinte, efetuar outros testes que podem levar a melhorias significativas. À medida que modelos estão a ser utilizados em aplicações cada vez mais sensíveis, a interpretabilidade e confiança dos mesmos é um ponto fundamental.

Os modelos de previsão de preço deste trabalho, o seu desempenho no MIBEL, principalmente em termos dos erros MAE, MAPE, RMSE e do tempo de execução (s), a análise da importância das suas variáveis de entrada, podem ser úteis para os agentes do mercado da eletricidade e outros agentes da indústria da energia elétrica.

Para além disso, recorreremos a um processo de tomada de decisão multi-atributo: TOPSIS. Consideramos que este é muito útil para análise de modelos em escala na medida em que permite ordenar os modelos com base em determinados pesos e critérios.

Há espaço para otimizações, nomeadamente no processo de extração e transformação dos conjuntos de dados. Nas fases iniciais do desenvolvimento, o design de uma solução pode alterar rapidamente e requerer grandes melhorias e/ou reorganizações do código base. Ao testar diferentes protótipos com pouca preocupação com a otimização, há espaço para dedicar mais tempo e energia na produção correta dos resultados e na fiabilidade do design. Daí quando se desenha/planeia soluções relacionados com desempenho, o primeiro passo é escrever o código com pouco, ou nenhum, cuidado por pequenas otimizações. Até porque, no fim de contas, quem pretende uma solução que seja rápida e dê resultados errados?

Há que aceitar as vantagens e limitações dos métodos de previsão e, o mais importante, evitar quaisquer expectativas exageradas. Os métodos de previsão não possuem poderes proféticos; eles, simplesmente, extrapolam padrões e relações estabelecidas para prever o futuro e avaliar a sua incerteza. A sua maior vantagem é a objetividade e a capacidade de extrapolação otimizada (Petropoulos, 2020).

6.1. Trabalho Futuro

- Neste trabalho as variáveis relativas ao preço estão associadas ao Mercado Diário. Seria interessante explorar se os preços relativos ao Mercado Intra-diário permite obter uma previsão melhor.
- No planeamento de modelos que se realizou, considerou-se como padrão a ingestão de variáveis do Modelo 1. No entanto, com base nos resultados observados, pode ser interessante considerar ainda a variável cronológica relativa ao Feriado nos restantes modelos e analisar o impacto que tem nos modelos.
- Neste caso considerou-se a variável “Feriado”, no entanto pode ser útil considerar uma variável Dias Livres, contendo 1 se for Sábado, Domingo ou Feriado e 0 se o contrário. Há espaço, ainda, para considerar apenas os Feriados nos quais é dado o dia de trabalho e não considerar os outros, por forma a analisar se há melhorias nos modelos.
- Obter os resultados recorrendo ao Python na *Cloud* do INCD, efetuando pedidos em paralelo, e comparar. Certamente, a obtenção dos resultados, no geral, como será feita em paralelo, será mais rápida.

- Ao contrário de outros modelos que requerem estacionaridade das séries, neste caso não foi necessário para obter resultados positivos. No entanto, seria interessante analisar os resultados recorrendo a séries estacionárias.
- O TIM tem a vantagem de permitir explorar os dados, conhecer as melhores combinações de atributos (há uma engenharia de atributos adaptando-os a um determinado *framework* temporal). Pode ser interessante utilizar o TIM apenas para engenharia de atributos e, de seguida, recorrer a métodos de previsão diferentes, como LSTM ou MLP.
- Neste caso usou-se o erro de previsão para as 24 horas do dia seguinte. Seria interessante saber, para cada hora do dia seguinte, qual o modelo que apresenta um resultado melhor.
- Para estes modelos, como as variáveis meteorológicas eram bastante extensas, para cada hora, tínhamos uma tabela de 33 linhas e 53 colunas relativas às posições geográficas, efetuamos uma média por linha e coluna. Seria, no entanto, interessante, avaliar a análise da previsão dos preços de eletricidade recorrendo aos dados meteorológicos completos e, idealmente, especificando as mesmas para considerar apenas as posições geográficas das fontes de produção de energia em especial de energias renováveis, por forma a perceber o impacto que a consideração dos dados geográficos tem, nas previsões. Para isso, poder-se-ia recorrer a outra tecnologia que não o TIM.
- Uma vez que o clima é um fenómeno bastante complicado, há espaço para que se recorra a modelos de previsão meteorológica diferentes (consultar anexo F), como a previsão numérica do tempo (NWP) modelo mesoescala WRFNMM, inicializado com as previsões fornecidas pelo modelo global GFS do NWP (“*Global Forecast System*”, sem data).
- Otimização com fronteira de Pareto bi-critério (considerando paralelamente as métricas MAE-tempo, RMSE-tempo e MAPE-tempo) e tomada de decisão com TOPSIS. Desta forma no TOPSIS teremos um número mais reduzido de modelos a considerar.
- Por fim, convém analisar, dos resultados mais positivos, como os podemos colocar em produção (a considerar: quando é que os dados, de onde foram extraídos, são atualizados e, ainda, que tecnologias usar para colocar em produção). No contexto deste trabalho, o foco não foi a questão da colocação dos modelos em produção, embora percebamos que, em termos práticos, o acesso a informação privilegiada, neste caso, previsões, se não for usado para tomadas de decisão, por si só, não tem grande valor.

7. Referências Bibliográficas

- Ahlemeyer-Stubbe, A., & Coleman, S. (2018). *Monetising Data: How to Uplift Your Business*. USA, New Jersey: John Wiley & Sons, Inc. ISBN: 9781119125136.
- Alamaniotis, M., Bargiotas, D., Bourbakis, N. G., & Tsoukalas, L. H. (2015). Genetic Optimal Regression of Relevance Vector Machines for Electricity Pricing Signal Forecasting in Smart Grids. *IEEE Transactions on Smart Grid*, 6(6), 2997–3005. <https://doi.org/10.1109/TSG.2015.2421900>.
- Alpaydin, E. (2014). *Introduction to Machine Learning*. ISBN: 978-0-262-028189. Obtido 5 de Abril de 2021, de <https://www.cmpe.boun.edu.tr/~ethem/i2ml3e/>.
- Amari, S. (2016). *Information Geometry and Its Applications*. Springer Japan. https://doi.org/10.1007/978-4-431-55978-8_14.
- Amari, S.; & Nagaoka, H. (2007). *Methods of Information Geometry*. ISBN: 978-0821843024. Obtido 5 de Abril de 2021, de <https://bookstore.ams.org/mmono-191>.
- Amjady, N. (2006). Day-ahead price forecasting of electricity markets by a new fuzzy neural network. *IEEE Transactions on Power Systems*, 21(2), 887–896. <https://doi.org/10.1109/TPWRS.2006.873409>.
- ArXiv.org. (sem data). Obtido 5 de Abril de 2021, de <https://arxiv.org/>.
- Big data: The next frontier for innovation, competition, and productivity* | McKinsey. (2011). Obtido 5 de Abril de 2021, de <https://www.mckinsey.com/business-functions/mckinsey-digital/our-insights/big-data-the-next-frontier-for-innovation>.
- Bikakis, N. (2018). Big Data Visualization Tools. *arXiv:1801.08336 [cs]*. <http://arxiv.org/abs/1801.08336>.
- Bordignon, S., Bunn, D. W., Lisi, F., & Nan, F. (2013). Combining day-ahead forecasts for British electricity prices. *Energy Economics*, 35, 88–103. <https://doi.org/10.1016/j.eneco.2011.12.001>.
- Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis*. ISBN: 978-1-118-67502-1.
- Brownlee, J. (2018). *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Obtido 5 de Abril de 2021, de <https://machinelearningmastery.com/deep-learning-for-time-series-forecasting/>.
- Brownlee, J. (2020). *Time Series Forecasting With Python*. (sem data). *Machine Learning Mastery*. Obtido 5 de Abril de 2021, de

- <https://machinelearningmastery.com/introduction-to-time-series-forecasting-with-python/>.
- Burger, M., Graeber, B., Schindlmayr, G. (2014). *Managing Energy Risk: An Integrated View on Power and other Energy Markets*. The Wiley Finance Series. John Wiley & Sons Ltd. ISBN: 978-1-118-61863-9.
- Caiado, J. (2016). Métodos de Previsão em Gestão. *Edições Sílabo, Lisboa*. ISBN: 978-972-618-857-5.
- Cerqueira, V., Torgo, L., & Mozetic, I. (2019). Evaluating time series forecasting models: An empirical study on performance estimation methods. *arXiv:1905.11744 [cs, stat]*. <http://arxiv.org/abs/1905.11744>.
- Chen, M., Mao, S., Zhang, Y., & Leung, V. C. (2014). *Big Data: Related Technologies, Challenges and Future Prospects*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-06245-7>.
- Coleman, R. (1974). What is a Stochastic Process? Em R. Coleman (Ed.), *Stochastic Processes* (pp. 1–5). Springer Netherlands. https://doi.org/10.1007/978-94-010-9796-3_1.
- Conejo, A. J., Carrión, M., & Morales, J. M. (2010). *Decision Making Under Uncertainty in Electricity Markets*. Springer US. <https://doi.org/10.1007/978-1-4419-7421-1>.
- Conejo, A. J., Contreras, J., Espínola, R., & Plazas, M. A. (2005). Forecasting electricity prices for a day-ahead pool-based electric energy market. *International Journal of Forecasting*, 21(3), 435–462. <https://doi.org/10.1016/j.ijforecast.2004.12.005>.
- Conheça o nosso mercado / OMIE.* (2019). <http://web.archive.org/web/20191224045842/http://www.omie.es/pt/principal/mercados-e-produtos/conheca-o-nosso-mercado>.
- Connected Papers. (sem data). Obtido 5 de Abril de 2021, de <https://www.connectedpapers.com/>.
- Cruz, A., Muñoz, A., Zamora, J. L., & Espínola, R. (2011). The effect of wind generation and weekday on Spanish electricity spot price forecasting. *Electric Power Systems Research*, 81(10), 1924–1935. <https://doi.org/10.1016/j.epsr.2011.06.002>.
- Dimensions (sem data). Obtido 5 de Abril de 2021, de <https://www.dimensions.ai/>.
- Dong, Y., Wang, J., Jiang, H., & Wu, J. (2011). Short-term electricity price forecast based on the improved hybrid model. *Energy Conversion and Management*, 52(8), 2987–2995. <https://doi.org/10.1016/j.enconman.2011.04.020>.
- Doob, J. L. (1990). *Stochastic processes*. ISBN: 978-0-471-52369-7.

- Download CiteSpace.* (sem data). Obtido 5 de Abril de 2021, de <https://citespace.podia.com/download>.
- Electricity demand tracking in real time, associated generation mix and CO2 emissions.* (sem data). Obtido 5 de Abril de 2021, de <https://demanda.ree.es/visiona/peninsula/demanda/>.
- ERA5 hourly data on single levels from 1979 to present.* (2021). Obtido 5 de Abril de 2021, de <https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=form>.
- Ferreira, M. (2017). The Iberian Electricity Market: Price Dynamics and Risk Premium in an Illiquid Market. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.2962283>.
- Ferreira, M. R. B. (2017). The Iberian Electricity Market: Price Dynamics and Forward Risk Premium. *The Iberian Electricity Market: Price Dynamics and Forward Risk Premium*. The Iberian Electricity Market: Price Dynamics and Forward Risk Premium. <https://estudogeral.sib.uc.pt/handle/10316/84764>.
- Gelenbe, E., & Caseau, Y. (2015). The impact of information technology on energy consumption and carbon emissions. *Ubiquity*, 2015(June), 1–15. <https://doi.org/10.1145/2755977>.
- Generation mix (MW).* (sem data). Obtido 5 de Abril de 2021, de <https://demanda.ree.es/visiona/peninsula/demanda/tablas/2>.
- Ghasemi, A., Shayeghi, H., Moradzadeh, M., & Nooshyar, M. (2016). A novel hybrid algorithm for electricity price and load forecasting in smart grids with demand-side management. *Applied Energy*, 177, 40–59. <https://doi.org/10.1016/j.apenergy.2016.05.083>.
- Gikhman, I. I., & Skorokhod, A. V. (1969). *Introduction to the Theory of Random Processes*. ISBN: 978-0-486-69387-3.
- Girish, G. P. (2016). Spot electricity price forecasting in Indian electricity market using autoregressive-GARCH models. *Energy Strategy Reviews*, 11–12, 52–57. <https://doi.org/10.1016/j.esr.2016.06.005>.
- Global energy prices| Statista.* (2020). Obtido 5 de Abril de 2021, de <https://www.statista.com/topics/1323/energy-prices/>.
- Global Forecast System.* (sem data). Obtido 5 de Abril de 2021, de https://nomads.ncep.noaa.gov/txt_descriptions/GFS_doc.shtml.

- Goncaloperes/TimeSeries. (2020). GitHub. Obtido 5 de Abril de 2021, de <https://github.com/goncaloperes/TimeSeries/blob/master/IsItHoliday/Spain/SpainBusinessCalendar.py>.
- Google Scholar. (sem data). Obtido 5 de Abril de 2021, de <https://scholar.google.com/>.
- Harris, C. (2006). *Electricity Markets: Pricing, Structures and Economics*. The Wiley Finance Series. John Wiley & Sons Ltd. ISBN: 978-0-470-01158-4.
- Hassan, N. A., Hijazi, R. (2018). *Open Source Intelligence Methods and Tools—A Practical Guide to Online Intelligence*. ISBN: 978-1-4842-3213-2.
- Hawken, S., Han, H., & Pettit, C. (Eds.). (2020). *Open Cities | Open Data: Collaborative Cities in the Information Era*. Springer Singapore. <https://doi.org/10.1007/978-981-13-6605-5>.
- He, X., Zhao, K., & Chu, X. (2021). AutoML: A survey of the state-of-the-art. *Knowledge-Based Systems*, 212, 106622. <https://doi.org/10.1016/j.knosys.2020.106622>.
- Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*, 2.^a Edição, OTexts: Melbourne, Australia. <https://OTexts.com/fpp2>.
- Hyndman, R.J., & Athanasopoulos, G. (2021). *Forecasting: principles and practice*. 3.^a Edição. OTexts: Melbourne, Austrália. Obtido 5 de Abril de 2021, de <https://Otexts.com/fpp3/>.
- Informação OMI | OMI. (sem data). Obtido 5 de Abril de 2021, de <https://www.grupoomi.eu/pt/informacao-omi>.
- Jonsson, T., Pinson, P., Nielsen, H. A., Madsen, H., & Nielsen, T. S. (2013). Forecasting Electricity Spot Prices Accounting for Wind Power Predictions. *IEEE Transactions on Sustainable Energy*, 4(1), 210–218. <https://doi.org/10.1109/TSTE.2012.2212731>.
- Kakihara, S., Ohara, A., & Tsuchiya, T. (2013). Information Geometry and Interior-Point Algorithms in Semidefinite Programs and Symmetric Cone Programs. *Journal of Optimization Theory and Applications*, 157(3), 749–780. <https://doi.org/10.1007/s10957-012-0180-9>.
- Karakatsani, N. V., & Bunn, D. W. (2008). Forecasting electricity prices: The impact of fundamentals and time-varying coefficients. *International Journal of Forecasting*, 24(4), 764–785. <https://doi.org/10.1016/j.ijforecast.2008.09.008>.
- Knittel, C. R., & Roberts, M. R. (2005). An empirical examination of restructured electricity prices. *Energy Economics*, 27(5), 791–817. <https://doi.org/10.1016/j.eneco.2004.11.005>.

- Koopman, S. J., Ooms, M., & Carnero, M. A. (2007). Periodic Seasonal Reg-ARFIMA–GARCH Models for Daily Electricity Spot Prices. *Journal of the American Statistical Association*, 102(477), 16–27. <https://doi.org/10.1198/016214506000001022>.
- Lago, J., Marcjasz, G., De Schutter, B., & Weron, R. (2020). Forecasting day-ahead electricity prices: A review of state-of-the-art algorithms, best practices and an open-access benchmark. *arXiv:2008.08004 [cs, q-fin, stat]*. <http://arxiv.org/abs/2008.08004>.
- Lamperti, J. (1977). *Stochastic Processes: A Survey of the Mathematical Theory*. Springer-Verlag. <https://doi.org/10.1007/978-1-4684-9358-0>.
- Lange, S., Pohl, J., & Santarius, T. (2020). Digitalization and energy consumption. Does ICT reduce energy demand? *Ecological Economics*, 176, 106760. <https://doi.org/10.1016/j.ecolecon.2020.106760>.
- Larose, C. D., & Larose, D. T. (2019). *Data Science Using Python and R*. USA, New Jersey: John Wiley & Sons, Inc. ISBN: 978-1-119-52681-0.
- Li, D. B. (2013). *Introduction to Time Series*. Obtido 5 de Abril de 2021, de <https://www.stat.purdue.edu/~boli/stat420/lectures/lecture1.pdf>.
- Li, G., Liu, C., Mattson, C., & Lawarree, J. (2007). Day-Ahead Electricity Price Forecasting in a Grid Environment. *IEEE Transactions on Power Systems*, 22(1), 266–274. <https://doi.org/10.1109/TPWRS.2006.887893>.
- Lin, W.-M., Gow, H.-J., & Tsai, M.-T. (2010). Electricity price forecasting using Enhanced Probability Neural Network. *Energy Conversion and Management*, 51(12), 2707–2714. <https://doi.org/10.1016/j.enconman.2010.06.006>.
- Loenen, B. van, Vancauwenberghe, G., & Crompvoets, J. (2018). *Open Data Exposed*. T.M.C. Asser Press. <https://doi.org/10.1007/978-94-6265-261-3>.
- Maciejowska, K., & Weron, R. (2019). *Electricity Price Forecasting*. Obtido 5 de Abril de 2021, de http://prac.im.pwr.edu.pl/~hugo/RePEc/wuu/wpaper/HSC_19_01.pdf.
- Marques, V. (2011). *Regulação Económica Sector Eléctrico e Sector do Gás Natural*.
- Mendeley (sem data). Obtido 5 de Abril de 2021, de <https://www.mendeley.com/>.
- Mercado a prazo OMIP | OMI. (sem data). Obtido 5 de Abril de 2021, de <https://www.grupoomi.eu/pt/mercado-prazo-omip>.
- Mercado da electricidade | OMIE. (sem data). Obtido 5 de Abril de 2021, de <https://www.omie.es/pt/mercado-de-electricidad>.

- Mercado Spot OMIE / OMI*. (sem data). Obtido 5 de Abril de 2021, de <https://www.grupoomi.eu/pt/mercado-spot-omie>.
- MIBEL (sem data). Obtido 5 de Abril de 2021, de <https://www.mibel.com/>.
- Miller, L. (2021). *Predictive Analytics for Time Series with InstantML For Dummies, Tangent Works Special Edition*. 76. Obtido 5 de Abril de 2021, de <https://www.tangent.works/wp-content/uploads/2020/11/Predictive-Analytics-For-Dummies-E-book-by-Tangent-Works-1.pdf>.
- Mitchell, T. M. (1997). *Machine Learning textbook*. Obtido 5 de Abril de 2021, de <https://www.cs.cmu.edu/~tom/mlbook.html>.
- Monteiro, C., Fernandez-Jimenez, L. A., & Ramirez-Rosado, I. J. (2015). Explanatory Information Analysis for Day-Ahead Price Forecasting in the Iberian Electricity Market. *Energies*, 8(9), 10464–10486. <https://doi.org/10.3390/en80910464>.
- Monteiro, C., Ramirez-Rosado, I. J., Fernandez-Jimenez, L. A., & Ribeiro, M. (2018). New probabilistic price forecasting models: Application to the Iberian electricity market. *International Journal of Electrical Power & Energy Systems*, 103, 483–496. <https://doi.org/10.1016/j.ijepes.2018.06.005>.
- Monteiro, C., Ramirez-Rosado, I., & Fernandez-Jimenez, L. (2018). Probabilistic Electricity Price Forecasting Models by Aggregation of Competitive Predictors. *Energies*, 11(5), 1074. <https://doi.org/10.3390/en11051074/>.
- Monteiro, C., Ramirez-Rosado, I., Fernandez-Jimenez, L., & Conde, P. (2016). Short-Term Price Forecasting Models Based on Artificial Neural Networks for Intraday Sessions in the Iberian Electricity Market. *Energies*, 9(9), 721. <https://doi.org/10.3390/en9090721/>.
- Moreira, R., Bessa, R., & Gama, J. (2016). Probabilistic forecasting of day-ahead electricity prices for the Iberian electricity market. *2016 13th International Conference on the European Energy Market (EEM)*, 1–5. <https://doi.org/10.1109/EEM.2016.7521226>.
- Munzner, T. (2014). *Visualization Analysis and Design*. A K Peters/CRC Press. <https://doi.org/10.1201/b17511>.
- Nielsen, F. (2020). An elementary introduction to information geometry. *Entropy*, 22(10), 1100. <https://doi.org/10.3390/e22101100>.
- Nowotarski, J., & Weron, R. (2018). Recent advances in electricity price forecasting: A review of probabilistic forecasting. *Renewable and Sustainable Energy Reviews*, 81, 1548–1568. <https://doi.org/10.1016/j.rser.2017.05.234>
- OMIClear (sem data). Obtido 5 de Abril de 2021, de <https://www.omiclear.pt/pt>.

- OMIE (sem data). Obtido 5 de Abril de 2021, de <https://www.omie.es/pt>.
- OMIP (sem data). Obtido 5 de Abril de 2021, de <https://www.omip.pt/>.
- Papathanasiou, J., & Ploskas, N. (2018). TOPSIS. Em J. Papathanasiou & N. Ploskas (Eds.), *Multiple Criteria Decision Aid: Methods, Examples and Python Implementations* (pp. 1–30). Springer International Publishing. https://doi.org/10.1007/978-3-319-91648-4_1.
- Parzen, E. (2015). *Stochastic Processes*. ISBN: 978-0-486-79688-8.
- Pefferers, K., Tuunanen, T., Rothenberger, M. A., & Chatterjee, S. (2007). A Design Science Research Methodology for Information Systems Research. *Journal of Management Information Systems*, 24(3), 45–77. <https://doi.org/10.2753/MIS0742-1222240302>.
- Petropoulos, F., Apiletti, D., Assimakopoulos, V., Babai, M. Z., Barrow, D. K., Bergmeir, C., Bessa, R. J., Boylan, J. E., Browell, J., Carnevale, C., Castle, J. L., Cirillo, P., Clements, M. P., Cordeiro, C., Oliveira, F. L. C., De Baets, S., Dokumentov, A., Fiszeder, P., Franses, P. H., ... Ziel, F. (2020). Forecasting: Theory and practice. *arXiv:2012.03854 [stat]*. <http://arxiv.org/abs/2012.03854>.
- Publons (sem data). Obtido 5 de Abril de 2021, de <https://publons.com>.
- Real Time Information REN*. (2021). Obtido 5 de Abril de 2021, de <https://www.centrodeinformacao.ren.pt/EN/Pages/CIHomePage.aspx>.
- Red Eléctrica de España (sem data). Obtido 5 de Abril de 2021, de <https://www.ree.es/>.
- REN (sem data). Obtido 5 de Abril de 2021, de <https://www.ren.pt/>.
- ResearchGate (sem data). Obtido 5 de Abril de 2021, de <https://www.researchgate.net/>.
- Risso, W. A. (2017). Symbolic Time Series Analysis and Its Application in Social Sciences. *Time Series Analysis and Applications*. <https://doi.org/10.5772/intechopen.70826>.
- Rivera, R. (2020). Principles of Managerial Statistics and Data Science. USA, New Jersey: John Wiley & Sons, Inc. ISBN: 9781119486428.
- Rogers, L. C. G., & Williams, D. (2000). *Diffusions, Markov Processes, and Martingales: Volume 1, Foundations*. ISBN: 978-1-107-71749-7.
- Romero, O., & Wrembel, R. (2020). Data Engineering for Data Science: Two Sides of the Same Coin. Em M. Song, I.-Y. Song, G. Kotsis, A. M. Tjoa, & I. Khalil (Eds.), *Big Data Analytics and Knowledge Discovery* (Vol. 12393, pp. 157–166). Springer International Publishing. https://doi.org/10.1007/978-3-030-59065-9_13.
- Ryzko, D. (2020). *Modern Big Data Architectures*. USA, New Jersey: John Wiley & Sons, Inc. ISBN: 978-1-119-59794-0.

- Sánchez-Lozano, J. M., Teruel-Solano, J., Soto-Elvira, P. L., & Socorro García-Cascales, M. (2013). Geographical Information Systems (GIS) and Multi-Criteria Decision Making (MCDM) methods for the evaluation of solar farms locations: Case study in south-eastern Spain. *Renewable and Sustainable Energy Reviews*, 24, 544–556. <https://doi.org/10.1016/j.rser.2013.03.019>.
- Schurz, G. (2008). Patterns of abduction. *Synthese*, 164(2), 201–234. <https://doi.org/10.1007/s11229-007-9223-4>.
- SIMEE - Diário e Intradiário—Preços. (sem data). Obtido 5 de Abril de 2021, de <https://www.mercado.ren.pt/PT/Electr/InfoMercado/InfOp/MercOmel/Paginas/Precos.aspx>.
- Singhal, D., & Swarup, K. S. (2011). Electricity price forecasting using artificial neural networks. *International Journal of Electrical Power & Energy Systems*, 33(3), 550–555. <https://doi.org/10.1016/j.ijepes.2010.12.009>.
- Springer (sem data). Obtido 5 de Abril de 2021, de <https://www.springer.com/>.
- Springer Link (sem data). Obtido 5 de Abril de 2021, de <https://link.springer.com/>.
- Swamidass, P. M. (2000). *Encyclopedia of Production and Manufacturing Management*. Springer US. <https://doi.org/10.1007/1-4020-0612-8>.
- Taieb, S. B., & Hyndman, R. J. (2012). *Recursive and direct multi-step forecasting: The best of both worlds*. Obtido 5 de Abril de 2021, de <https://robjhyndman.com/papers/rectify.pdf>.
- Taieb, S. B., Bontempi, G., Atiya, A. F., & Sorjamaa, A. (2012). A review and comparison of strategies for multi-step ahead time series forecasting based on the NN5 forecasting competition. *Expert Systems with Applications*, 39(8), 7067–7083. <https://doi.org/10.1016/j.eswa.2012.01.039>.
- Talbot, J., & Jakeman, M. (2009). *Security risk management body of knowledge*. Wiley. ISBN: 978-0-470-45462-6.
- Tan, Z., Zhang, J., Wang, J., & Xu, J. (2010). Day-ahead electricity price forecasting using wavelet transform combined with ARIMA and GARCH models. *Applied Energy*, 87(11), 3606–3610. <https://doi.org/10.1016/j.apenergy.2010.05.012>.
- The difference between prediction intervals and confidence intervals | Rob J Hyndman*. (2013). Obtido 5 de Abril de 2021, de <https://robjhyndman.com/hyndsight/intervals/>.
- The Open Definition—Open Definition—Defining Open in Open Data, Open Content and Open Knowledge*. (sem data). Obtido 5 de Abril de 2021, de <http://opendefinition.org/>.

- TIM Documentation — Transparent models.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/Introduction-to-TIM/Transparent-models/>.
- TIM Forecasting — Configuration — Overview.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Configuration/Overview/>.
- TIM Forecasting — Dictionaries.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Configuration/Dictionaries/>.
- TIM Forecasting — Outputs — Overview.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Outputs/Overview/>.
- TIM Forecasting — Overview.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/How-it-works/Overview/>.
- TIM Forecasting — Probabilistic forecasting and prediction intervals.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Getting-started/Probabilistic-forecasting-and-prediction-intervals/>.
- TIM Studio — Experiments — What is an Experiment.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Studio/Experiments/What-is-an-Experiment/>.
- TIM Studio — Overview.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Studio/Overview/>.
- TIM Tangnt Information Modeller— Input Data — Data properties.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/TIM-Forecasting/Input-data/Data-properties/>.
- TIM Tangnt Information Modeller— Overview.* (sem data). Obtido 5 de Abril de 2021, de <https://docs.tangent.works/TIM-Tangent-Information-Modeller/Overview/>.
- Total data volume worldwide 2010-2024 | Statista.* (2020). Obtido 5 de Abril de 2021, de <https://www.statista.com/statistics/871513/worldwide-data-created/>.
- Triantaphyllou, E., Shu, B., Sanchez, S. N., & Ray, T. (1998). *Multi-Criteria Decision Making: An Operations Research Approach*. Obtido 5 de Abril de 2021, de http://bit.csc.lsu.edu/trianta/EditedBook_CHAPTERS/EEEE1.pdf.

- Uniejewski, B., Nowotarski, J., & Weron, R. (2016). Automated Variable Selection and Shrinkage for Day-Ahead Electricity Price Forecasting. *Energies*, 9(8), 621. <https://doi.org/10.3390/en9080621>.
- Using AutoML for Time Series Forecasting. (2020). *Google AI Blog*. Obtido 5 de Abril de 2021, de <http://ai.googleblog.com/2020/12/using-automl-for-time-series-forecasting.html>.
- Voogd, J. H. (1982). *Multicriteria evaluation for urban and regional planning*. <https://doi.org/10.6100/IR102252>.
- VOSviewer (sem data). Obtido 5 de Abril de 2021, de <https://www.vosviewer.com/>.
- VPN UAb (sem data). Obtido 5 de Abril de 2021, de <https://vpn.uab.pt/>.
- Weron, R. (2014). Electricity price forecasting: A review of the state-of-the-art with a look into the future. *International Journal of Forecasting*, 30(4), 1030–1081. <https://doi.org/10.1016/j.ijforecast.2014.08.008>.
- Weron, R., & Misiorek, A. (2008). Forecasting spot electricity prices: A comparison of parametric and semiparametric time series models. *International Journal of Forecasting*, 24(4), 744–763. <https://doi.org/10.1016/j.ijforecast.2008.08.004>.
- Wiley (sem data). Obtido 5 de Abril de 2021, de <https://www.wiley.com/>.
- World electricity consumption | Statista*. (2021). Obtido 5 de Abril de 2021, de <https://www.statista.com/statistics/280704/world-power-consumption/>.
- Yamin, H. Y., Shahidehpour, S. M., & Li, Z. (2004). Adaptive short-term electricity price forecasting using artificial neural networks in the restructured power markets. *International Journal of Electrical Power & Energy Systems*, 26(8), 571–581. <https://doi.org/10.1016/j.ijepes.2004.04.005>.
- Yao, Q., Wang, M., Chen, Y., Dai, W., Li, Y.-F., Tu, W.-W., Yang, Q., & Yu, Y. (2019). Taking Human out of Learning Applications: A Survey on Automated Machine Learning. *arXiv:1810.13306 [cs, stat]*. <http://arxiv.org/abs/1810.13306>.
- Ziel, F. (2016). Forecasting Electricity Spot Prices Using Lasso: On Capturing the Autoregressive Intraday Structure. *IEEE Transactions on Power Systems*, 31(6), 4977–4987. <https://doi.org/10.1109/TPWRS.2016.2521545>.
- Zöller, M.-A., & Huber, M. F. (2021). Benchmark and Survey of Automated Machine Learning Frameworks. *arXiv:1904.12054 [cs, stat]*. <http://arxiv.org/abs/1904.12054>.
- Zotero (sem data). Obtido 5 de Abril de 2021, de <https://www.zotero.org/>.

8. Anexos

Dada a sua dimensão, os anexos foram colocados num documento à parte.