



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

Anexos

Gonçalo Martins Peres

2021

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.

Índice de Anexos

ÍNDICE DE ANEXOS	V
A. CRONOGRAMA	1
A.1. PREVISTO	2
A.2. REAL	3
B. EXTRAÇÃO DOS DADOS	4
B.1. PREÇO	5
B.2. PROCURA	6
B.3. PRODUÇÃO	8
B.4. CLIMA	10
C. RESULTADOS COMPUTACIONAIS	19
C.1. ANO 2019 – A	21
C.2. ANOS 2018-2019 – B	25
C.3. ANOS 2010-2019 – C	29
D. AVALIAÇÃO DE MODELOS	33
D.1. BACK-TEST	34
D.2. MEDIDAS DE PERFORMANCE	37
E. DECISÃO MULTI-ATRIBUTO	41
E.1. ANO 2019 – A	43
E.2. ANOS 2018-2019 – B	44
E.3. ANOS 2010-2019 – C	45
E.4. GERAL	46
F. MODELOS DE PREVISÃO METEOROLÓGICA	47
F.1. MODELOS GLOBAIS	48
F.2. MODELOS REGIONAIS	50

Esta página foi intencionalmente deixada em branco.

A.Cronograma

Neste anexo apresentamos dois cronogramas relativos à dissertação: o previsto (A.1.) e o real (A.2.).

A.1. Previsto

- **Tarefa 1** – Introdução.
- **Tarefa 2** – Trabalho Relacionado.
- **Tarefa 3** – Proposta de Trabalho.
- **Tarefa 4** – Resultados Computacionais.
- **Tarefa 5** – Conclusões.
- **Tarefa 6** – Escrita da Dissertação e Tarefas Administrativas.

A tabela abaixo mostra o cronograma de atividades para a realização do trabalho proposto.

Tabela A.1 Tarefas previstas (janeiro 2020 – janeiro 2021).

Tarefas	<i>m1</i>	<i>m2</i>	<i>m3</i>	<i>m4</i>	<i>m5</i>	<i>m6</i>	<i>m7</i>	<i>m8</i>	<i>m9</i>	<i>m10</i>	<i>m11</i>	<i>m12</i>	<i>m13</i>
1	█												
2		█											
3			█										
4				█									
5					█								
6	█												

A.2. *Real*

- **Tarefa 1** – Introdução.
- **Tarefa 2** – Trabalho Relacionado.
- **Tarefa 3** – Proposta de Trabalho.
- **Tarefa 4** – Resultados Computacionais.
- **Tarefa 5** – Conclusões.
- **Tarefa 6** – Escrita da Dissertação e Tarefas Administrativas.

A tabela abaixo mostra o cronograma de atividades para a realização do trabalho proposto.

Tabela A.2. Tarefas previstas (janeiro 2020 – abril 2021).

<i>Tarefas</i>	<i>m1</i>	<i>m2</i>	<i>m3</i>	<i>m4</i>	<i>m5</i>	<i>m6</i>	<i>m7</i>	<i>m8</i>	<i>m9</i>	<i>m10</i>	<i>m11</i>	<i>m12</i>	<i>m13</i>	<i>m14</i>	<i>m15</i>	<i>m16</i>	<i>m17</i>
<i>1</i>	■	■			■	■	■	■	■	■	■						
<i>2</i>		■			■	■	■	■	■	■	■	■					
<i>3</i>					■	■	■	■	■	■	■	■	■				
<i>4</i>		■			■	■	■	■	■	■	■	■	■	■			
<i>5</i>					■	■	■	■	■	■	■	■	■	■	■	■	
<i>6</i>	■	■			■	■	■	■	■	■	■	■	■	■	■	■	■

B.Extração dos Dados

Neste anexo apresentamos o processo de extração para as várias categorias de variáveis explicatórias a serem utilizadas na dissertação, com exceção das cronológicas.

B.1. Preço

Os dados relativos aos preços de Eletricidade no Mercado Spot (Portugal e Espanha), foram extraídos diretamente da aplicação web: em <http://www.mercado.ren.pt/PT/Electr/InfoMercado/InfOp/MercOmel/Paginas/Precos.aspx>

Nesta, em seleccionou-se “Exportar Dados”



Figura B.1. Sistema de Informação de Mercados de Energia da REN.

Depois seleccionou-se intervalos de tempo correspondentes a um ano, para fazer os intervalos de tempo a serem analisados, e extraiu-se os dados.




Figura B.2. Sistema de Informação de Mercados de Energia da REN – Seleccionar o intervalo de tempo.

B.2. Procura

Para transferir os dados da procura, recorreu-se ao seguinte código em Python:

```
# importing webdriver from selenium
from selenium import webdriver
from datetime import timedelta, date
import time
from selenium.common.exceptions import NoSuchElementException,
ElementNotInteractableException, ElementClickInterceptedException

def daterange(start_date, end_date):
    for n in range(int((end_date - start_date).days)):
        yield start_date + timedelta(n)

start_date = date(2009, 12, 31)
end_date = date(2020, 1, 1)

for single_date in daterange(start_date, end_date):
    while True:
        try:
            print(single_date.strftime("%Y-%m-%d"))

            # Use Chromedriver (download here - https://chromedriver.chromium.org/)
            driver = webdriver.Chrome("C:/Users/goncalo/Desktop/chromedriver/chromedriver.exe")

            split_single_date = single_date.strftime("%Y-%m-%d").split("-")

            # URL of website (/1 is for Demanda, /2 is for Generación, /3 is for Emisiones)
            demanda = "1"
            generacion = "2"
            emisiones = "3"
            url = "https://demanda.ree.es/visiona/peninsula/demanda/tablas/"+split_single_date[0]+"-"+
            split_single_date[1]+"-"+split_single_date[2]+"/"+demanda+""
```

```
"""
['https:', ', ', 'demanda.ree.es', 'visiona', 'peninsula', 'demanda', 'tablas', '2020-07-09',
'1']
"""

# Use different selectors depending on the last value of the array
# and then click on the button
last_value = split_url[-1]
if last_value == "1":
    #print("The url has 1 in the end")
    button = driver.find_element_by_css_selector("#tabla_evolucion > thead > tr > th
> span.export-csv > a")
    button.click()
    time.sleep(3)
    driver.close()
elif last_value == "2":
    #print("The url has 2 in the end")
    button = driver.find_element_by_css_selector("#tabla_generacion > thead > tr >
th > div > span.export-csv > a")
    button.click()
    time.sleep(3)
    driver.close()
elif last_value == "3":
    #print("The url has 3 in the end")
    button = driver.find_element_by_css_selector("#tabla_emision > thead > tr > th >
span.export-csv > a")
    button.click()
    time.sleep(3)
    driver.close()
else:
    print("Problem in the url.")
    time.sleep(5)
except NoSuchElementException:
    continue
except ElementNotInteractableException:
    continue
except ElementClickInterceptedException:
    continue
break
```

B.3. *Produção*

Para transferir os dados da produção de energia, recorreu-se ao seguinte código em Python:

```
# importing webdriver from selenium
from selenium import webdriver
from datetime import timedelta, date
import time
from selenium.common.exceptions import NoSuchElementException,
ElementNotInteractableException, ElementClickInterceptedException

def daterange(start_date, end_date):
    for n in range(int((end_date - start_date).days)):
        yield start_date + timedelta(n)

start_date = date(2009, 12, 31)
end_date = date(2020, 1, 1)

for single_date in daterange(start_date, end_date):
    while True:
        try:
            print(single_date.strftime("%Y-%m-%d"))

            # Use Chromedriver (download here - https://chromedriver.chromium.org/)
            driver = webdriver.Chrome("C:/Users/goncalo/Desktop/chromedriver/chromedriver.exe")

            split_single_date = single_date.strftime("%Y-%m-%d").split("-")

            # URL of website (/1 is for Demanda, /2 is for Generación, /3 is for Emisiones)
            demanda = "1"
            generacion = "2"
            emisiones = "3"
            url = "https://demanda.ree.es/visiona/peninsula/demanda/tablas/"+split_single_date[0]+"-"+split_single_date[1]+"-"+split_single_date[2]+"/"+generacion+""
```

```
"""
[https:', ', 'demanda.ree.es', 'visiona', 'peninsula', 'demanda', 'tablas', '2020-07-09',
'1']
"""

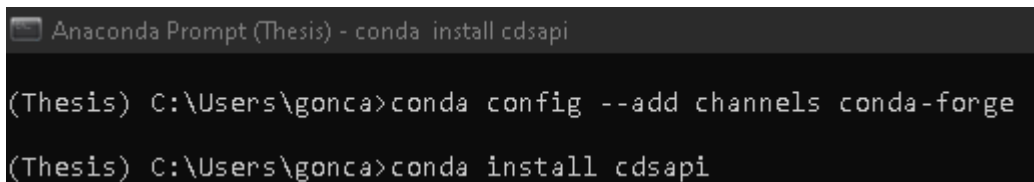
# Use different selectors depending on the last value of the array
# and then click on the button
last_value = split_url[-1]
if last_value == "1":
    #print("The url has 1 in the end")
    button = driver.find_element_by_css_selector("#tabla_evolucion > thead > tr > th
> span.export-csv > a")
    button.click()
    time.sleep(3)
    driver.close()
elif last_value == "2":
    #print("The url has 2 in the end")
    button = driver.find_element_by_css_selector("#tabla_generacion > thead > tr >
th > div > span.export-csv > a")
    button.click()
    time.sleep(3)
    driver.close()
elif last_value == "3":
    #print("The url has 3 in the end")
    button = driver.find_element_by_css_selector("#tabla_emision > thead > tr > th >
span.export-csv > a")
    button.click()
    time.sleep(3)
    driver.close()
else:
    print("Problem in the url.")
    time.sleep(5)
except NoSuchElementException:
    continue
except ElementNotInteractableException:
    continue
except ElementClickInterceptedException:
    continue
break
```

B.4. Clima

Pré-requisitos

- 1 Criar uma conta no Climate Data Store (<https://cds.climate.copernicus.eu/user/register>).
2. Python e pip instalados na máquina com instalação e diretório do script em PATH.
3. Instalar CDS API no Conda Prompt relativo ao ambiente virtual que estamos a trabalhar, ao correr os seguintes comandos:

```
conda config --add channels conda-forge  
conda install cdsapi
```



```
Anaconda Prompt (Thesis) - conda install cdsapi  
(Thesis) C:\Users\gonca>conda config --add channels conda-forge  
(Thesis) C:\Users\gonca>conda install cdsapi
```

Figura B.3. Configurar ambiente virtual na Anaconda.

Guia passo a passo

1. Login no Climate Data Store (CDS) e aceder ao perfil de utilizador para verificar a chave API (UID e API Key).
2. Aceder a <https://cds.climate.copernicus.eu/api-how-to#install-the-cds-api-key> e copiar o código abaixo de “Install the CDS API key”, mas substituir o UID e a API KEY pelos dados associados ao utilizador. Para consultar isso, com o Login efetuado, aceder a <https://cds.climate.copernicus.eu/user> .

```
url: https://cds.climate.copernicus.eu/api/v2  
key:[ADICIONAR UID]:[ADICIONAR A API KEY]
```

3. Colocar essa informação no Notepad e guardar com o nome `.cdsapirc` e como tipo “All types (*.*)” para criar um ficheiro ponto.




Figura B.4. Gravar o ficheiro com um formato específico.

4. De seguida, se testarmos com o código demo disponível em (<https://cds.climate.copernicus.eu/api-how-to>) na secção “Use the CDS API cliente for data access”. Usando o pedido de exemplo para *Glaciers*, temos:

```
import cdsapi
c = cdsapi.Client()
c.retrieve("insitu-glaciers-elevation-mass",
{
"variable": "all",
"product_type": "elevation_change",
"file_version": "20170405",
"format": "tgz"
},
"download.tar.gz")
```

Obtemos a seguinte Exception:

Exception: Client has not agreed to the required terms and conditions. To access this resource, you first need to accept the terms of 'UZH Glaciers licence' at <https://cds.climate.copernicus.eu/cdsapp#!/terms/uhz-glaciers>

5. Acedendo ao link que encontramos na Exception, obtemos uma página como a seguinte:

UZH Glaciers licence

UZH Glaciers licence

"You are free to: Share — copy and redistribute the material in any medium or format; Adapt — remix, transform, and build upon the material for any purpose, even commercially. The licensor cannot revoke these freedoms as long as you follow the license terms.

Under the following terms:

Attribution

You must give appropriate credit, provide a link to the license, and indicate if changes were made. You may do so in any reasonable manner, but not in any way that suggests the licensor endorses you or your use.

** Citation**

(a) Glacier distribution, V2:

RGI Consortium (2017). Randolph Glacier Inventory – A Dataset of Global Glacier Outlines: Version 6.0: Technical Report, Global Land Ice Measurements from Space, Colorado, USA. Digital Media. DOI: <https://doi.org/10.7265/N5-RGI-60>

(b) Glacier mass and elevation changes, V4:

WGMS (2018); Fluctuations of Glaciers Database, World Glacier Monitoring Service, Zurich, Switzerland. Digital Media. DOI:10.5904/wgms-fog-2018-11. Online access: <http://dx.doi.org/10.5904/wgms-fog-2018-11>

No additional restrictions — You may not apply legal terms or technological measures that legally restrict others from doing anything the license permits.

Notices:

You do not have to comply with the license for elements of the material in the public domain or where your use is permitted by an applicable exception or limitation. No warranties are given. The license may not give you all of the permissions necessary for your intended use. For example, other rights such as publicity, privacy, or moral rights may limit how you use the material.

License full text: <https://creativecommons.org/licenses/by/4.0/legalcode/>

[Open PDF version](#)

Confirm your acceptance of these terms by ticking this box and submitting.

[Submit](#)

Figura B.5. Climate Data Store – Licença.

Onde temos que confirmar que aceitamos os termos ao selecionar a caixa “Confirm your acceptance of these terms by ticking this box and submitting” e submeter.

6. Voltar a correr o código do passo 4, que irá transferir um ficheiro com o nome download.tar.

7. Ao extrair o ficheiro e iremos encontrar ficheiros diferentes com o mesmo nome, mas formatos diferentes (incluindo em .csv).

download

Name	Date modified	Type	Size
_C3S_ELEVATION_CHANGE_DATA_201704...	12/04/2017 11:02	Microsoft Excel C...	719 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	CPG File	1 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	DBF File	3 266 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	PRJ File	1 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	SBN File	17 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	SBX File	1 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	SHP File	51 KB
_C3S_ELEVATION_CHANGE_SERIES_20170...	12/04/2017 13:28	SHX File	15 KB

Figura B.6. Sistema de ficheiros com os dados em formaos diferentes.

8. Ao abrir o .csv, temos um dataset normal, como o seguinte:

SURVEY_ID	SURVEY_DATE	REFERENCE_DATE	AREA_SURVEY_YEAR	AREA_COVERAGE	ELEVATION	INVESTIGATION
1	2007	20070101	2007	100%	100	...
2	2007	20070101	2007	100%	100	...
3	2007	20070101	2007	100%	100	...
4	2007	20070101	2007	100%	100	...
5	2007	20070101	2007	100%	100	...
6	2007	20070101	2007	100%	100	...
7	2007	20070101	2007	100%	100	...
8	2007	20070101	2007	100%	100	...
9	2007	20070101	2007	100%	100	...
10	2007	20070101	2007	100%	100	...
11	2007	20070101	2007	100%	100	...
12	2007	20070101	2007	100%	100	...
13	2007	20070101	2007	100%	100	...
14	2007	20070101	2007	100%	100	...
15	2007	20070101	2007	100%	100	...
16	2007	20070101	2007	100%	100	...
17	2007	20070101	2007	100%	100	...
18	2007	20070101	2007	100%	100	...
19	2007	20070101	2007	100%	100	...
20	2007	20070101	2007	100%	100	...
21	2007	20070101	2007	100%	100	...
22	2007	20070101	2007	100%	100	...
23	2007	20070101	2007	100%	100	...
24	2007	20070101	2007	100%	100	...
25	2007	20070101	2007	100%	100	...
26	2007	20070101	2007	100%	100	...
27	2007	20070101	2007	100%	100	...
28	2007	20070101	2007	100%	100	...
29	2007	20070101	2007	100%	100	...
30	2007	20070101	2007	100%	100	...
31	2007	20070101	2007	100%	100	...
32	2007	20070101	2007	100%	100	...
33	2007	20070101	2007	100%	100	...
34	2007	20070101	2007	100%	100	...
35	2007	20070101	2007	100%	100	...
36	2007	20070101	2007	100%	100	...
37	2007	20070101	2007	100%	100	...
38	2007	20070101	2007	100%	100	...
39	2007	20070101	2007	100%	100	...
40	2007	20070101	2007	100%	100	...
41	2007	20070101	2007	100%	100	...
42	2007	20070101	2007	100%	100	...
43	2007	20070101	2007	100%	100	...
44	2007	20070101	2007	100%	100	...
45	2007	20070101	2007	100%	100	...
46	2007	20070101	2007	100%	100	...
47	2007	20070101	2007	100%	100	...
48	2007	20070101	2007	100%	100	...
49	2007	20070101	2007	100%	100	...
50	2007	20070101	2007	100%	100	...

Figura B.7. Ficheiro CSV.

Caso de Teste

Supondo que pretendemos transferir dados sobre a variável “2m temperature” relativos ao ERA5 para a Península Ibérica para os anos 2009-2020, todos os meses e dias, com intervalos de uma hora.

1. Acedemos ao site:

<https://cds.climate.copernicus.eu/cdsapp#!/dataset/reanalysis-era5-single-levels?tab=form>

2. Seleccionamos a variável “2m temperature”:

▼ Temperature and pressure

<input type="checkbox"/> 2m dewpoint temperature	<input checked="" type="checkbox"/> 2m temperature
<input type="checkbox"/> Ice temperature layer 1	<input type="checkbox"/> Ice temperature layer 2
<input type="checkbox"/> Ice temperature layer 3	<input type="checkbox"/> Ice temperature layer 4
<input type="checkbox"/> Maximum 2m temperature since previous post-processing	<input type="checkbox"/> Mean sea level pressure
<input type="checkbox"/> Minimum 2m temperature since previous post-processing	<input type="checkbox"/> Sea surface temperature
<input type="checkbox"/> Skin temperature	<input type="checkbox"/> Surface pressure

[Select all](#) [Clear all](#)

Figura B.8. CDS – Preenchimento do formulário de pedido (1).

3. Seleccionar o intervalo de anos, os meses, os dias e as horas:

Year

<input type="checkbox"/> 1979	<input type="checkbox"/> 1980	<input type="checkbox"/> 1981	<input type="checkbox"/> 1982	<input type="checkbox"/> 1983	<input type="checkbox"/> 1984
<input type="checkbox"/> 1985	<input type="checkbox"/> 1986	<input type="checkbox"/> 1987	<input type="checkbox"/> 1988	<input type="checkbox"/> 1989	<input type="checkbox"/> 1990
<input type="checkbox"/> 1991	<input type="checkbox"/> 1992	<input type="checkbox"/> 1993	<input type="checkbox"/> 1994	<input type="checkbox"/> 1995	<input type="checkbox"/> 1996
<input type="checkbox"/> 1997	<input type="checkbox"/> 1998	<input type="checkbox"/> 1999	<input type="checkbox"/> 2000	<input type="checkbox"/> 2001	<input type="checkbox"/> 2002
<input type="checkbox"/> 2003	<input type="checkbox"/> 2004	<input type="checkbox"/> 2005	<input type="checkbox"/> 2006	<input type="checkbox"/> 2007	<input type="checkbox"/> 2008
<input checked="" type="checkbox"/> 2009	<input checked="" type="checkbox"/> 2010	<input checked="" type="checkbox"/> 2011	<input checked="" type="checkbox"/> 2012	<input checked="" type="checkbox"/> 2013	<input checked="" type="checkbox"/> 2014
<input checked="" type="checkbox"/> 2015	<input checked="" type="checkbox"/> 2016	<input checked="" type="checkbox"/> 2017	<input checked="" type="checkbox"/> 2018	<input checked="" type="checkbox"/> 2019	<input checked="" type="checkbox"/> 2020

[Select all](#) [Clear all](#)

Month

<input checked="" type="checkbox"/> January	<input checked="" type="checkbox"/> February	<input checked="" type="checkbox"/> March	<input checked="" type="checkbox"/> April	<input checked="" type="checkbox"/> May	<input checked="" type="checkbox"/> June
<input checked="" type="checkbox"/> July	<input checked="" type="checkbox"/> August	<input checked="" type="checkbox"/> September	<input checked="" type="checkbox"/> October	<input checked="" type="checkbox"/> November	<input checked="" type="checkbox"/> December

[Clear all](#)

Day

<input checked="" type="checkbox"/> 01	<input checked="" type="checkbox"/> 02	<input checked="" type="checkbox"/> 03	<input checked="" type="checkbox"/> 04	<input checked="" type="checkbox"/> 05	<input checked="" type="checkbox"/> 06
<input checked="" type="checkbox"/> 07	<input checked="" type="checkbox"/> 08	<input checked="" type="checkbox"/> 09	<input checked="" type="checkbox"/> 10	<input checked="" type="checkbox"/> 11	<input checked="" type="checkbox"/> 12
<input checked="" type="checkbox"/> 13	<input checked="" type="checkbox"/> 14	<input checked="" type="checkbox"/> 15	<input checked="" type="checkbox"/> 16	<input checked="" type="checkbox"/> 17	<input checked="" type="checkbox"/> 18
<input checked="" type="checkbox"/> 19	<input checked="" type="checkbox"/> 20	<input checked="" type="checkbox"/> 21	<input checked="" type="checkbox"/> 22	<input checked="" type="checkbox"/> 23	<input checked="" type="checkbox"/> 24
<input checked="" type="checkbox"/> 25	<input checked="" type="checkbox"/> 26	<input checked="" type="checkbox"/> 27	<input checked="" type="checkbox"/> 28	<input checked="" type="checkbox"/> 29	<input checked="" type="checkbox"/> 30
<input checked="" type="checkbox"/> 31					

[Clear all](#)

Figura B.9. CDS – Preenchimento do formulário de pedido (2).

Time

<input checked="" type="checkbox"/> 00:00	<input checked="" type="checkbox"/> 01:00	<input checked="" type="checkbox"/> 02:00	<input checked="" type="checkbox"/> 03:00	<input checked="" type="checkbox"/> 04:00	<input checked="" type="checkbox"/> 05:00
<input checked="" type="checkbox"/> 06:00	<input checked="" type="checkbox"/> 07:00	<input checked="" type="checkbox"/> 08:00	<input checked="" type="checkbox"/> 09:00	<input checked="" type="checkbox"/> 10:00	<input checked="" type="checkbox"/> 11:00
<input checked="" type="checkbox"/> 12:00	<input checked="" type="checkbox"/> 13:00	<input checked="" type="checkbox"/> 14:00	<input checked="" type="checkbox"/> 15:00	<input checked="" type="checkbox"/> 16:00	<input checked="" type="checkbox"/> 17:00
<input checked="" type="checkbox"/> 18:00	<input checked="" type="checkbox"/> 19:00	<input checked="" type="checkbox"/> 20:00	<input checked="" type="checkbox"/> 21:00	<input checked="" type="checkbox"/> 22:00	<input checked="" type="checkbox"/> 23:00

[Clear all](#)

Figura B.10. CDS – Preenchimento do formulário de pedido (3).

4. Selecionar a região geográfica que se pretende. Neste caso, como é a Península Ibérica, adicionaremos manualmente as coordenadas associadas aos limites a Norte, Sul, Este e Oeste.

4.1. Para vermos isso, acedemos ao Google Maps (<https://www.google.com/maps/>).

4.2. Uma vez no Google Maps, selecionamos a região específica do mapa com um clique em cima e aparece uma pop-up com coordenadas.





Figura B.11. Analisar as coordenadas com recurso ao Google Maps.

4.3. Neste caso, consideraremos apenas o continente, excluindo as ilhas portuguesas e espanholas, obtendo os seguintes limites:


North: 44 | West: -9.6 | South: 36 | East: 3.5

5. Com os valores encontrados acima, selecionamos a Sub-região.

Geographical area 

Whole available region

With this option selected the entire available area will be provided

Sub-region extraction 

North
44

West
-9.6

East
36

South
3.5

Figura B.12. CDS – Preenchimento do formulário de pedido (4).

6. Recorrendo ao formato NetCDF, aceitamos os Termos de utilização e submetemos o formulário.

Format

GRIB NetCDF (experimental) Clear all

Terms of use

Licence to use Copernicus Products [View terms](#)

Show API request Show Toolbox request Submit Form

Figura B.13. CDS – Preenchimento do formulário de pedido (5).

7. Ao submeter o formulário, somos redirecionados para uma página onde encontramos informações sobre o pedido que efetuamos.

Product	Submission date	End date	Duration	Size	Status
ERAS hourly data on single levels from 1979 to present	2020-07-15 08:46:42		0:00:12		In progress

Figura B.14. CDS – Formulário submetido (1).

Product	Submission date	End date	Duration	Size	Status
ERAS hourly data on single levels from 1979 to present	2020-07-15 08:46:42		0:01:33		In progress
<p>Open request form Request ID: 7220f067-daf9-463e-8653-2c16d876f922</p> <p>Product type: Reanalysis</p> <p>Variable: 2m dewpoint temperature</p> <p>Year: 2008, 2009, 2010, 2011, 2012, 2013, 2014, 2015, 2016, 2017, 2018, 2019, 2020</p> <p>Month: January, February, March, April, May, June, July, August, September, October, November, December</p> <p>Day: 01, 02, 03, 04, 05, 06, 07, 08, 09, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31</p> <p>Time: 00:00, 01:00, 02:00, 03:00, 04:00, 05:00, 06:00, 07:00, 08:00, 09:00, 10:00, 11:00, 12:00, 13:00, 14:00, 15:00, 16:00, 17:00, 18:00, 19:00, 20:00, 21:00, 22:00, 23:00</p> <p>Sub-region extraction: North 44°, West -9.6°, South 36°, East 3.5°</p>					

Figura B.15. CDS – Formulário submetido (2).

8. A partir desta podemos abrir o formulário do pedido que submetemos (“Open request form”) e, no fundo da página, exibir o API ao pressionar “Show API request”. No nosso caso, temos o seguinte código, que podemos utilizar no Python:

```
import cdsapi
import xarray as xr

c = cdsapi.Client()

c.retrieve(
    'reanalysis-era5-single-levels',
    {
        'product_type': 'reanalysis',
        'variable': '2m_dewpoint_temperature',
        'year': [
            '2008', '2009', '2010',
            '2011', '2012', '2013',
            '2014', '2015', '2016',
            '2017', '2018', '2019',
            '2020',
        ],
        'month': [
            '01', '02', '03',
            '04', '05', '06',
            '07', '08', '09',
            '10', '11', '12',
        ],
        'day': [
            '01', '02', '03',
            '04', '05', '06',
            '07', '08', '09',
            '10', '11', '12',
            '13', '14', '15',
            '16', '17', '18',
            '19', '20', '21',
            '22', '23', '24',
            '25', '26', '27',
            '28', '29', '30',
            '31',
        ],
        'time': [
            '00:00', '01:00', '02:00',
            '03:00', '04:00', '05:00',
            '06:00', '07:00', '08:00',
            '09:00', '10:00', '11:00',
            '12:00', '13:00', '14:00',
            '15:00', '16:00', '17:00',
```

```

        '18:00', '19:00', '20:00',
        '21:00', '22:00', '23:00',
    ],
    'area': [
        44, -9.6, 36,
        3.5,
    ],
    'format': 'netcdf',
},
'download.nc')

```

9. Correndo o script no Python vamos transferir um ficheiro .nc.

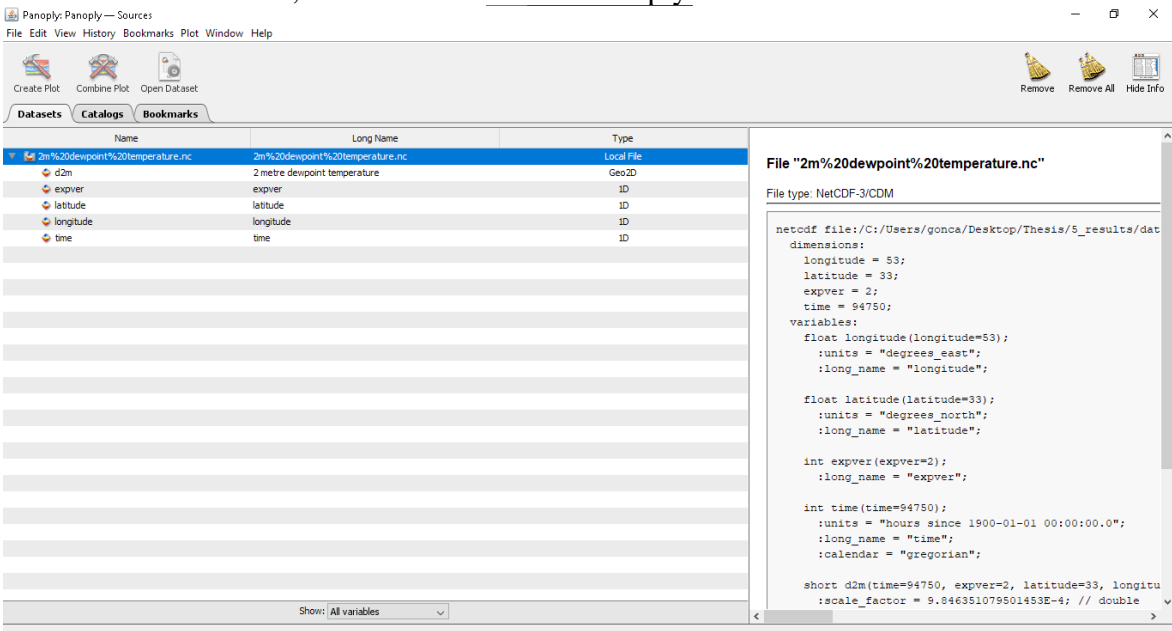
```

2020-07-16 11:44:36,781 INFO Welcome to the CDS
2020-07-16 11:44:36,782 INFO Sending request to https://
cds.climate.copernicus.eu/api/v2/resources/reanalysis-era5-single-levels
2020-07-16 11:44:37,195 INFO Request is queued
2020-07-16 11:44:38,254 INFO Request is running

```

Figura B.16. Transferir ficheiro .nc com recurso ao Python.

10. Com o ficheiro .nc, abrimos o mesmo no Panoply¹.



The screenshot shows the Panoply application window with the following details:

- Dataset Table:**

Name	Long Name	Type
2m%20dewpoint%20temperature.nc	2m%20dewpoint%20temperature.nc	Local File
d2m	2 metre dewpoint temperature	Geo2D
expver	expver	ID
latitude	latitude	ID
longitude	longitude	ID
time	time	ID
- File Information Panel:**

File "2m%20dewpoint%20temperature.nc"
File type: NetCDF-3/CDM

```

netcdf file:/C:/Users/gonca/Desktop/Thesis/5_results/dat
dimensions:
  longitude = 53;
  latitude = 33;
  expver = 2;
  time = 94750;
variables:
  float longitude (longitude=53);
    :units = "degrees_east";
    :long_name = "longitude";

  float latitude (latitude=33);
    :units = "degrees_north";
    :long_name = "latitude";

  int expver (expver=2);
    :long_name = "expver";

  int time (time=94750);
    :units = "hours since 1900-01-01 00:00:00.0";
    :long_name = "time";
    :calendar = "gregorian";

short d2m (time=94750, expver=2, latitude=33, longitu
:scale_factor = 9.846351079501453E-4; // double

```

Figura B.17. Abrir o ficheiro .nc no Panoply.

11. De seguida, seleccionamos a componente que pretendemos, neste caso é o tipo Geo2D, pressionamos com o botão do lado direito do rato e geramos o CSV ao pressionar “Export CSV...”.

¹ <https://www.giss.nasa.gov/tools/panoply/>

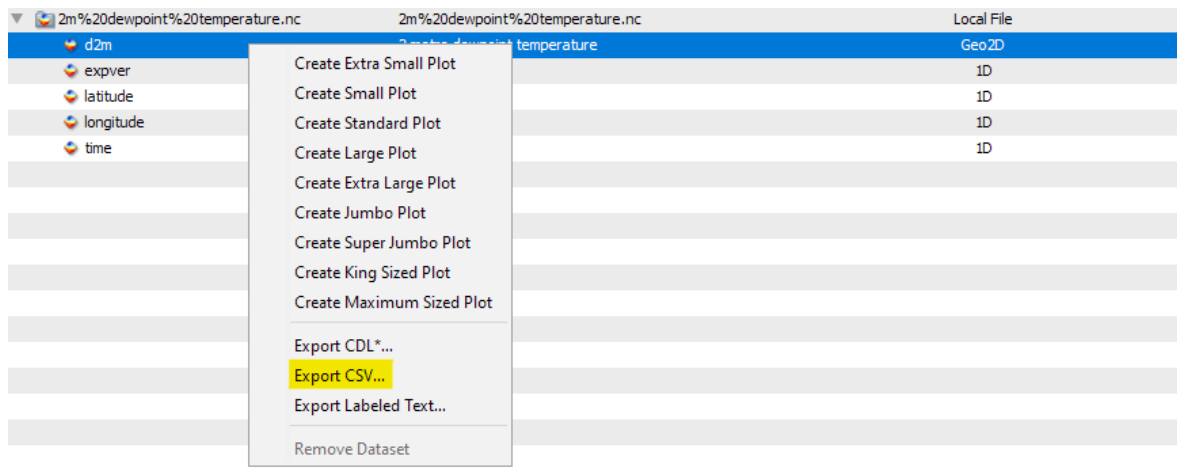


Figura B.18. Planoly – Exportar o CSV.

Com a exportação tratada, ficamos com um ficheiro CSV que é mais facilmente manuseável.

C.Resultados Computacionais

Ao longo deste trabalho 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 ao longo da dissertação, optou-se por disponibilizar as tabelas de resultados, para cada intervalo de tempo a ser considerado e cada divisão treino-teste, neste anexo.

Os resultados serão apresentados nas secções associadas aos respetivos intervalos de tempo considerado.

C.1. Ano 2019 – A

No primeiro cenário, iremos apresentar os resultados relativos ao intervalo de tempo A, entre 1 de janeiro de 2019 (00:00) e 31 de dezembro de 2019 (23:00).

Foram considerados três tipos de divisão em treino-teste: 70-30, 80-20 e 90-10, sendo que os resultados obtidos em cada uma constarão numa subsecção deste mesmo.

Na Tabela C.1. encontraremos os resultados considerando treino-teste 70-30.

Na Tabela C.2. indicaremos os resultados obtidos considerando o treino-teste igual a 80-20.

Por fim, na Tabela C.3. encontraremos os resultados obtidos considerando a percentagem de treino-teste 90-10.

Treino-Teste 70-30

Tabela C.1. Resultados computacionais relativos ao Ano 2019 (A) com treino-teste 70-30.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
	Preço	Preço
Procura	Horário
	Real
Produção	Previsão Programada
	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
Internacionais	Intercâmbios
	Solar
Clima	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	Tempo de execução (s)	6	7	8	7	6	6	6	6	7	7	6	7	7	8	6	7	6	7	8	6	6	7	6	7	12
MAE (€/MWh)	4.89	4.84	4.49	4.89	4.79	4.66	4.84	4.89	4.68	4.97	4.93	4.89	4.76	5.83	5.10	4.76	4.90	5.00	4.79	4.90	4.65	4.70	4.90	4.88	5.59	
MAPE (%)	94.0	75.3	54.0	80.9	80.1	68.4	69.0	94.0	78.5	67.4	100.2	94.0	64.9	158.4	85.2	59.2	94.0	81.3	78.2	94.0	74.3	78.6	94.0	92.0	129.2	
RMSE (€/MWh)	7.32	7.27	6.61	7.22	7.05	6.83	7.08	7.32	7.05	7.61	7.31	7.32	7.03	9.01	7.61	6.96	7.32	7.50	7.17	7.32	6.81	7.13	7.32	7.35	8.66	

Treino-Teste 80-20

Tabela C.2. Resultados computacionais relativos ao Ano 2019 (A) com treino-teste 80-20.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	2m dew temperatura
	2m temperatura
	10 uc wind
	10 vc wind
	Top net solar radiation
	Top net thermal radiation
	Total Cloud Cover
	Total Precipitation
	Total Sky Radiation at Surface
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 (%)	93.3	105.1	81.1	111.3	114.3	99.1	103.5	93.3	78.4	93.4	115.0	93.3	115.0	195.8	115.7	75.3	94.0	128.6	94.0	94.0	105.2	102.3	94.0	137.4	182.3	
RMSE (€/MWh)	1	1	9	7	3	2	9	1	1	9	8	1	8	1	7	3	4	8	4	4	4	4	3	4	6	6
	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	

Treino-Teste 90-10

Tabela C.3. Resultados computacionais relativos ao Ano 2019 (A) com treino-teste 90-10.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
Clima	Intercâmbios Internacionais
	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
Radiação solar líquida superior	
Radiação termal líquida superior	
Cobertura total de nuvens	
Precipitação total	
Radiação Total do Céu à Superfície	
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 (%)		69.4	69.4	90.2	78.0	71.2	62.6	117.8	69.4	60.7	67.3	116.1	69.4	69.4	60.0	101.7	90.7	69.6	66.4	69.6	61.5	68.8	94.8	69.6	88.9	84.9
RMSE (€/MWh)		3	3	2	0	1	3	6	3	7	9	4	3	3	9	5	8	2	1	2	7	8	0	2	5	7
		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

C.2. Anos 2018-2019 – B

Neste subcapítulo consideraremos o intervalo de tempo B, entre 1 de janeiro de 2018 (00:00) a 31 de dezembro de 2019 (23:00).

Para a obtenção dos resultados, foram considerados três tipos de divisão em treino-teste: 70-30, 80-20 e 90-10, sendo que os resultados obtidos em cada uma constarão numa subsecção deste mesmo.

Na Tabela C.4. encontraremos os resultados considerando treino-teste 70-30.

Na Tabela C.5. indicaremos os resultados obtidos considerando o treino-teste igual a 80-20.

Por fim, na Tabela C.6. encontraremos os resultados obtidos considerando a percentagem de treino-teste 90-10.

Treino-Teste 70-30

Tabela C.4. Resultados computacionais relativos aos anos 2018 e 2019 (B) com treino-teste 70-30.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de ventO
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	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	

Treino-Teste 80-20

Tabela C.5. Resultados computacionais relativos aos anos 2018 e 2019 (B) com treino-teste 80-20.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	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	

Treino-Teste 90-10

Tabela C.6. Resultados computacionais relativos aos anos 2018 e 2019 (B) com treino-teste 90-10.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	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	4.68	5.26
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	32.41	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	6.60	7.24	6.64	

C.3. Anos 2010-2019 – C

Neste subcapítulo consideraremos o intervalo de tempo C, entre 1 de janeiro de 2010 (00:00) a 31 de dezembro de 2019 (23:00).

Para a obtenção dos resultados, foram considerados três tipos de divisão em treino-teste: 70-30, 80-20 e 90-10, sendo que os resultados obtidos em cada uma constarão numa subsecção deste mesmo.

Na Tabela C.7. encontraremos os resultados considerando treino-teste 70-30.

Na Tabela C.8. indicaremos os resultados obtidos considerando o treino-teste igual a 80-20.

Por fim, na Tabela C.9. encontraremos os resultados obtidos considerando a percentagem de treino-teste 90-10.

Treino-Teste 70-30

Tabela C.7. Resultados computacionais relativos aos anos 2010 e 2019 (C) com treino-teste 70-30.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista
	Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	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	4.21	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	

Treino-Teste 80-20

Tabela C.8. Resultados computacionais relativos aos anos 2010 e 2019 (C) com treino-teste 80-20.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista
	Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	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	14.44	13.61	13.77	14.44	14.74
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	

Treino-Teste 90-10

Tabela C.9. Resultados computacionais relativos aos anos 2010 e 2019 (C) com treino-teste 90-10.

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	Ano
	Mês
	Dia
	Hora
	Dia da Semana
	Feriado
Preço	Preço Horário
Procura	Real
	Prevista
	Programada
Produção	Eólica
	Nuclear
	Carvão
	Ciclo
	Combinado
	Hidráulica
	Intercâmbios Internacionais
Clima	Solar
	Temperatura de Ponto de Orvalho a 2m
	Temperatura a 2m
	10m u-componente de vento
	10m v-componente de vento
	Radiação solar líquida superior
	Radiação termal líquida superior
	Cobertura total de nuvens
	Precipitação total
	Radiação Total do Céu à Superfície
	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	3.93	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	

D.Avaliação de Modelos

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).

Mas como é que se avalia um modelo de previsão?

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* (D.1.) (Brownlee, 2020).

Por fim, analisaremos medidas de performance (D.2.), onde visualizaremos diversas métricas.

D.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).

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 D.1. 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.

Neste processo, é possível obter diversas métricas de performance, que analisaremos em D.2.

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).

Walk-Forward Validation

Na prática, é muito provável que voltemos a aperfeiçoar o nosso modelo à medida que novos dados se tornem disponíveis. Isto daria ao modelo a melhor oportunidade de fazer boas previsões em cada passo. Podemos avaliar os nossos modelos sob esta suposição. Há poucas decisões a tomar:

1. Número mínimo de observações. Em primeiro lugar, devemos selecionar o número mínimo de observações necessárias para treinar o modelo. Isto pode ser pensado como a largura da janela se for utilizada uma *sliding window* (ver próximo ponto).
2. *Sliding Window* ou *Expanding Window*: Em seguida, temos de decidir se o modelo será treinado em todos os dados que temos disponíveis ou apenas nas observações mais recentes. Isto determina se será utilizada uma *sliding window* ou *expanding window*.

Depois de uma configuração sensata ser escolhida para a sua configuração de teste, os modelos podem ser treinados e avaliados.

1. A partir do início da série temporal, o número mínimo de amostras na janela é utilizado para treinar um modelo.
2. O modelo faz uma previsão para o próximo passo da série temporal.
3. A previsão é armazenada ou avaliada em relação ao valor conhecido.
4. A janela é expandida para incluir o valor conhecido e o processo é repetido (passo 1).

Como esta metodologia envolve mover-se ao longo da série temporal um passo de cada vez, é frequentemente chamada *Walk Forward Testing* ou *Walk Forward Validation*. Em adição, porque uma *sliding window* ou *expansion window* é utilizada para treinar um modelo, este método é também referido como *Rolling Window Analysis* ou *Rolling Forecast* (Brownlee, 2020).

D.2. Medidas de Performance

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 capítulo apresentaremos algumas medidas de desempenho para avaliar as previsões de séries temporais.

As séries cronológicas centram-se geralmente na previsão de valores reais, chamados problemas de regressão. Portanto, as medidas de desempenho neste tutorial centrar-se-ão em métodos para avaliar previsões com valores reais (Brownlee, 2020).

Erro de Previsão

Um erro de previsão, ou *forecast error*, é a diferença entre um valor observado e a sua previsão. Aqui "erro" não significa um erro, significa a parte imprevisível de uma observação. Pode ser escrito como

$$e_{T+h} = y_{T+h} - \hat{y}_{T+h|T} \quad (D.1)$$

onde os dados de treino são dados por $\{y_1, \dots, y_T\}$ e os dados de teste são dados por $\{y_{T+1}, \dots, y_{T+2}\}$ (Hyndman & Athanasopoulos, 2021)

Note-se que os erros de previsão são diferentes dos resíduos em duas maneiras. Primeiro, os resíduos são calculados sobre o conjunto de treino enquanto que os erros de previsão são calculados sobre o conjunto de teste. Em segundo lugar, os resíduos são baseados em previsões de uma etapa enquanto os erros de previsão podem envolver previsões em várias etapas (multi-ponto) (Hyndman & Athanasopoulos, 2021).

Podemos medir a precisão da previsão de diferentes maneiras. Apresentaremos de seguida cinco abordagens.

Erro Médio (or Forecast Bias)

O Erro Médio, também conhecido por *Mean Forecast Error* ou *Forecast Bias*, é calculado como a média dos valores de erro de previsão.

Um *Mean Forecast Error* de zero, ou um número muito pequeno perto de zero, mostra um modelo imparcial (Brownlee, 2020).

Este está na mesma escala que os dados.

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 Erro Absoluto Médio estimado em $n_{amostras}$ é definido como

$$\text{MAE}(y, \hat{y}) = \frac{1}{n_{amostras}} \sum_{i=0}^{n_{amostras}-1} |y_i - \hat{y}_i| \quad (D.2)$$

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

Este está na mesma escala que os dados.

Erro Quadrático Médio (EQM ou MSE)

O Erro Quadrático Médio, ou *Mean Squared Error* (MSE), é calculado como a média dos valores de erro de previsão ao quadrado. O quadrado dos valores de erro de previsão obriga-os a ser positivos; tendo também o efeito de dar mais peso a erros grandes. Os erros de previsão muito grandes ou mais antigos são ao quadrado, o que tem o efeito de arrastar a média dos erros de previsão ao quadrado para fora, resultando numa pontuação de erro ao quadrado de maior significado. Com efeito, a pontuação dá pior desempenho aos modelos que fazem grandes previsões erradas.

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

$$\text{RMSE}(y, \hat{y}) = \frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} (y_i - \hat{y}_i)^2 \quad (D.3)$$

Os valores de erro estão em unidades quadradas dos valores previstos. Um MSE de zero indica nenhum erro (Brownlee, 2020).

Raiz do Erro Quadrático Médio (REQM ou RMSE)

A Raiz do Erro Quadrático Médio, ou *Root Mean Squared Error* (MSE) 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 Raiz do Erro Quadrático Médio (RMSE) estimado em n_{amostras} é definido como

$$\text{RMSE}(y, \hat{y}) = \sqrt{\frac{1}{n_{\text{samples}}} \sum_{i=0}^{n_{\text{samples}}-1} (y_i - \hat{y}_i)^2} \quad (D.4)$$

Este 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 Erro Percentual Absoluto Médio (MAPE) estimado em n_{amostras} é definido como

$$\text{MAPE}(y, \hat{y}) = \frac{1}{n_{\text{amostras}}} \sum_{i=0}^{n_{\text{amostras}}-1} \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \quad (D.5)$$

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). Este está na mesma escala que os dados.

E. Decisão Multi-Atributo

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).

Por forma a adicionar o mínimo de subjetividade possível no processo de decisão, optámos por considerar o método *Technique for Order Preference by Similarity to na Ideal Solution*, ou TOPSIS, onde a única subjetividade é adicionada no estabelecimento dos pesos associados a cada critério a analisar.

E.1. Ano 2019 – A

Considerando apenas o intervalo A, ao recorrer ao TOPSIS, considerando os critérios MAE, MAPE, RMSE e Tempo de execução (s) critérios de custo e atribuindo um peso de 0.25 a cada um, obtemos a seguinte ordenação dos modelos:

De notar que a tabela E.1. apresenta apenas os primeiros 25 modelos ordenados, pois com os 225 tornava-se muito extensa.

Tabela E.1. A – TOPSIS – 25 Modelos melhor classificados.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)	TOPSIS Rank	TOPSIS
A	90-10	M6	7	5.26	62.63	7.70	1	0.177278
A	80-20	M3	7	5.35	81.19	7.67	2	0.237343
A	90-10	M11	7	6.11	116.14	9.23	3	0.138573
A	70-30	M23	6	5.47	94.04	8.10	4	0.270514
A	70-30	M21	7	5.39	105.24	7.94	5	0.271209
A	80-20	M8	7	5.43	93.31	8.04	6	0.220070
A	80-20	M6	7	5.48	99.12	7.96	7	0.220692
A	80-20	M17	6	5.47	94.04	8.10	8	0.197163
A	90-10	M5	6	5.37	71.21	7.79	9	0.177623
A	80-20	M19	6	5.47	94.04	8.10	10	0.194519
A	70-30	M13	7	5.69	115.08	8.37	11	0.310391
A	80-20	M16	7	5.27	75.33	7.69	12	0.197163
A	70-30	M16	7	5.27	75.33	7.69	13	0.300319
A	70-30	M4	7	5.48	111.37	8.02	14	0.745006
A	70-30	M17	6	5.47	94.04	8.10	15	0.294968
A	90-10	M13	6	5.20	69.43	7.69	16	0.115513
A	90-10	M2	6	5.20	69.43	7.69	17	0.183308
A	70-30	M10	7	5.42	93.49	7.92	18	0.350925
A	90-10	M1	7	5.20	69.43	7.69	19	0.183308
A	80-20	M14	9	7.85	195.81	11.80	20	0.203057
A	80-20	M1	6	5.43	93.31	8.04	21	0.241563
A	80-20	M10	7	5.42	93.49	7.92	22	0.207910
A	80-20	M25	13	6.91	182.36	10.00	23	0.183308
A	70-30	M7	6	5.53	103.59	7.96	24	0.475006
A	70-30	M2	6	5.63	105.11	8.26	25	0.811997

E.2. Anos 2018-2019 – B

Considerando apenas o intervalo B, ao recorrer ao TOPSIS, considerando os critérios MAE, MAPE, RMSE e Tempo de execução (s) critérios de custo e atribuindo um peso de 0.25 a cada um, obtemos a seguinte ordenação dos modelos:

De notar que a tabela E.2. apresenta apenas os primeiros 25 modelos, caso contrário tornava-se muito extensa.

Tabela E.2. B – TOPSIS – 25 Modelos melhor classificados.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)	TOPSIS Rank	TOPSIS
B	90-10	M25	43	4.84	29.46	6.64	1	0.022584
B	90-10	M21	19	4.58	32.03	6.46	2	0.022584
B	90-10	M17	20	4.72	34.06	6.76	3	0.026935
B	90-10	M8	16	4.69	33.28	6.66	4	0.058201
B	90-10	M19	20	4.63	32.32	6.54	5	0.024963
B	90-10	M6	18	4.75	34.88	6.76	6	0.077431
B	90-10	M7	19	4.78	33.39	6.69	7	0.070265
B	90-10	M24	26	5.26	35.62	7.24	8	0.022584
B	90-10	M13	17	4.77	33.44	6.74	9	0.037179
B	90-10	M15	18	4.64	30.95	6.49	10	0.032334
B	90-10	M10	18	4.82	33.78	6.70	11	0.047463
B	90-10	M23	19	4.68	32.41	6.60	12	0.022584
B	90-10	M22	18	4.68	31.49	6.58	13	0.022584
B	80-20	M15	16	4.07	20.88	5.69	14	0.169626
B	90-10	M3	20	4.60	36.19	6.38	15	0.110694
B	90-10	M9	17	4.70	32.01	6.62	16	0.052964
B	90-10	M11	16	4.72	33.03	6.66	17	0.040594
B	90-10	M4	17	4.74	34.69	6.72	18	0.096938
B	90-10	M20	17	4.63	40.03	6.52	19	0.023444
B	90-10	M16	17	4.68	32.41	6.60	20	0.028648
B	90-10	M12	16	4.69	33.28	6.66	21	0.038996
B	90-10	M18	20	4.67	32.94	6.62	22	0.025329
B	90-10	M14	24	5.02	32.35	6.87	23	0.032962
B	90-10	M5	16	4.83	35.52	6.90	24	0.090451
B	80-20	M3	16	4.09	22.79	5.66	25	0.312098

E.3. Anos 2010-2019 – C

Considerando apenas o intervalo C, ao recorrer ao TOPSIS, considerando os critérios MAE, MAPE, RMSE e Tempo de execução (s) critérios de custo e atribuindo um peso de 0.25 a cada um, obtemos a seguinte ordenação dos modelos:

Na tabela E.3. apresentamos apenas os primeiros 25 modelos ordenados.

Tabela E.3. C – TOPSIS – 25 Modelos melhor classificados

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)	TOPSIS Rank	TOPSIS
C	90-10	M23	170	3.96	15.52	5.42	1	0.128481
C	90-10	M22	159	3.93	15.11	5.40	2	0.128481
C	90-10	M11	162	3.91	14.88	5.37	3	0.153715
C	90-10	M21	168	3.91	15.81	5.40	4	0.128750
C	90-10	M25	351	4.15	14.33	5.52	5	0.123112
C	90-10	M7	165	3.93	15.90	5.41	6	0.172967
C	90-10	M4	152	3.96	16.14	5.42	7	0.191711
C	90-10	M15	189	3.94	15.31	5.40	8	0.140997
C	70-30	M17	133	4.20	13.05	5.75	9	0.331108
C	90-10	M6	180	3.96	14.86	5.43	10	0.183085
C	90-10	M20	173	3.93	15.64	5.39	11	0.131819
C	90-10	M24	229	3.92	15.03	5.38	12	0.126923
C	90-10	M14	251	4.24	15.21	5.74	13	0.142707
C	70-30	M9	149	4.85	13.96	6.37	14	0.402863
C	90-10	M9	201	4.11	14.51	5.53	15	0.158529
C	90-10	M12	163	3.92	14.63	5.40	16	0.152857
C	90-10	M13	162	3.92	15.37	5.39	17	0.151970
C	90-10	M16	172	3.99	16.73	5.44	18	0.140158
C	90-10	M10	168	3.92	14.64	5.38	19	0.156206
C	90-10	M8	163	3.96	15.73	5.43	20	0.160385
C	90-10	M18	184	3.93	14.53	5.39	21	0.139712
C	90-10	M19	173	3.96	15.52	5.42	22	0.137768
C	90-10	M17	182	3.96	16.67	5.43	23	0.139868
C	70-30	M15	128	4.30	12.80	5.84	24	0.351269
C	70-30	M3	151	4.18	11.89	5.64	25	0.688164

E.4. Geral

Considerando agora todos os modelos e intervalos, ao recorrer ao TOPSIS, considerando os critérios MAE, MAPE, RMSE e Tempo de execução (s) critérios de custo e atribuindo um peso de 0.25 a cada um, obtemos a seguinte ordenação dos modelos:

A tabela E.4. apresenta os primeiros 25 modelos ordenados.

Tabela E.4. TOPSIS – 25 Modelos melhor classificados.

Intervalo	Treino-Teste	Modelo	Tempo de execução (s)	MAE (€/MWh)	MAPE (%)	RMSE (€/MWh)	TOPSIS Rank	TOPSIS
A	90-10	M7	7	5.26	117.86	7.57	1	0.303853
A	80-20	M4	7	5.48	111.37	8.02	2	0.336674
A	90-10	M23	7	5.20	69.62	7.69	3	0.269469
A	70-30	M25	13	6.91	182.36	10.00	4	0.341594
A	70-30	M20	7	5.47	94.04	8.10	5	0.353269
A	80-20	M15	6	5.83	115.77	8.64	6	0.315848
A	80-20	M10	7	5.42	93.49	7.92	7	0.325712
A	90-10	M6	7	5.26	62.63	7.70	8	0.304268
B	70-30	M8	13	3.86	16.01	5.30	9	0.261918
A	90-10	M9	9	5.17	60.77	7.59	10	0.302013
A	70-30	M17	6	5.47	94.04	8.10	11	0.366083
A	90-10	M5	6	5.37	71.21	7.79	12	0.304268
A	70-30	M19	6	5.47	94.04	8.10	13	0.359766
A	70-30	M1	6	5.43	93.31	8.04	14	0.553643
A	70-30	M14	9	7.85	195.81	11.80	15	0.368542
B	70-30	M18	16	4.06	16.54	5.51	16	0.255304
A	80-20	M22	6	5.32	102.33	7.89	17	0.307562
A	70-30	M12	7	5.43	93.31	8.04	18	0.384859
A	90-10	M1	7	5.20	69.43	7.69	19	0.307562
A	80-20	M20	7	5.47	94.04	8.10	20	0.307984
A	80-20	M7	6	5.53	103.59	7.96	21	0.325737
A	80-20	M13	7	5.69	115.08	8.37	22	0.316767
A	80-20	M25	13	6.91	182.36	10.00	23	0.307562
A	70-30	M8	7	5.43	93.31	8.04	24	0.416941
A	70-30	M4	7	5.48	111.37	8.02	25	0.513487

F. Modelos de Previsão Meteorológica

O fenómeno meteorológico é bastante complicado, pelo que há diversos modelos de previsão meteorológica. Neste anexo iremos dividi-los em dois grandes grupos: Modelos Globais (F.1.) e Modelos Regionais (F.2.).

F.1. Modelos Globais

No que toca a modelos globais, apresentamos seis: ECMWF, GFS, ICON, UM, CFS e METEOBLUE.

ECMWF (European Centre for Medium-Range Weather Forecasts)

Este modelo é muito preciso e é providenciado pelo European Center for Medium-Range Weather Forecasts. Como o modelo é comercial, apenas algumas empresas do mundo disponibilizam-no.

Resolução: várias

Profundidade das Previsões: 10 dias

Passo: 3 horas

Frequência de Atualização: 2 vezes/dia

Website: <https://www.ecmwf.int/>

GFS (Global Forecast System)

Este modelo básico é gratuito e providenciado pelo National Oceanic and Atmospheric Administration (NOAA) com uma resolução não muito boa. Comparativamente com outros modelos, o GFS pode falhar em áreas montanhosas e ao prever nuvens e precipitação. Uma vez que o modelo é gratuito, a maioria das aplicações de tempo recorrem a este.

Resolução: 27km

Profundidade das Previsões: 10 dias

Passo: 1 hora

Frequência de Atualização: 4 vezes/dia

Website: <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/global-forecast-system-gfs> (ou https://www.emc.ncep.noaa.gov/emc_new.php)

ICON (Global German Standard)

Modelo de grande resolução desenvolvido e operado pela DWD alemã. É um dos modelos de previsão mais modernos a oferecer resultados muito bons na Europa.

Resolução: várias

Profundidade das Previsões: 5,1 dia

Passo: 1 hora

Frequência de Atualização: 4 vezes/dia

Website:

https://www.dwd.de/EN/research/weatherforecasting/num_modelling/01_num_weather_prediction_modells/icon_description.html

UM (United Kingdom Met Office)

O UM (Modelo Unificado), também frequentemente referido como UKMO, é um modelo global desenvolvido no Reino Unido. Este modelo funciona de 12 em 12 horas, com a sua produção a terminar em 3 dias. Devido à sua resolução, o UKMET é o modelo mais fiável para o Reino Unido. O modelo global é considerado fiável, e é uma base para alguns modelos regionais de pequena escala (por exemplo, Nova Zelândia).

Resolução: 1.5km (UK), 10km (Global)

Website: <https://www.metoffice.gov.uk/research/approach/modelling-systems/unified-model/index>

CFS (Climate Forecast System)

O CFS é um modelo numérico global. É produzido pela NOAA NCEP (National Centers for Environmental Prediction) dos EUA. O modelo é baseado em 11 anos de observações meteorológicas. Pode ter um fraco valor de previsão, mas parece útil para o planeamento a longo prazo.

Resolução: 108km

Profundidade das Previsões: 30 dias

Passo: 6 horas

Frequência de Atualização: 4 vezes/dia

Website oficial: <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/climate-forecast-system-version2-cfsv2>

METEOBLUE

Conjunto de vários modelos de previsão global e local recorrendo a Inteligência Artificial. Desenvolvido pela empresa Suíça Meeoblue, bate outros modelos em temperaturas e vento. É muito bom para a região dos Alpes.

Website: <https://www.meteoblue.com>

F.2. Modelos Regionais

A lista que apresentaremos de modelos regionais será mais extensa, contando com um total de 10 modelos.

WRF (Weather Research and Forecasting)

O WRF foi o resultado de um esforço de colaboração de várias agências e laboratórios em todo o mundo nos anos 80. É uma base de código para o processamento posterior do modelo de previsão. É aplicável globalmente e pode ter em conta a geografia e topografia locais. Tem uma vasta gama de parâmetros físicos diferentes e exige vastos recursos para processar. Este é usado por alguns institutos como base para desenvolver os seus próprios modelos regionais.

Resolução: Até aos 500m.

Profundidade das Previsões: 3 dias

Passo: 3 horas

Frequência de Atualização: 1 vez/dia

Website: <https://narac.llnl.gov/tools/operational-modeling/weather-research-forecast-model>

**ALADIN (*Aire Limitée Adaptation dynamique Développement InterNational*),
ARPEGE e AROME**

O ALADIN é um consórcio patrocinado pela Météo-France com alguns países da Europa Central e Oriental. Em 2015, o consórcio iniciou uma parceria com o HIRLAM, com o objetivo de uma gestão integrada dos dois modelos. Para além do chamado modelo ALADIN, desenvolveu a ARPEGE global (grealha 55km) e a AROME regional (1,25km) para a França e domínios. Estes dois modelos são considerados como bons modelos "químicos", uma vez que têm em conta os aditivos químicos. O AROME tem uma resolução muito boa, tendo assim em conta muitos parâmetros climáticos, o que o torna fiável na Europa.

Resolução: Várias

Website: <https://www.met.hu/en/omsz/tevekenysegek/idojarasmodellezes/modellek/>

NAM (North American Mesoscale)

O NAM é um modelo regional para a América do Norte produzido pelo Serviço Meteorológico Americano. Tem uma resolução muito melhor do que modelos globais como o GFS e tem em conta fenómenos meteorológicos de pequena escala, o que o torna o modelo mais eficaz naquela região.

Resolução: 12km

Profundidade das Previsões: 61 horas

Passo: 1 hora

Frequência de Atualização: 2 vezes/dia

Website: <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/north-american-mesoscale-forecast-system-nam>

HRRR (High Resolution Rapid Refresh)

O HRRR é um modelo atmosférico regional (EUA) em tempo real que é actualizado todas as horas e está em funcionamento desde Abril de 2017. É um modelo atmosférico de

resolução de nuvens, por convecção, inicializado por grelhas de 3km com uma assimilação de 3km por radar.

Resolução: 3km

Website: <https://rapidrefresh.noaa.gov/hrrr/>

GEM (Global Environmental Multiscale Model)

Na América do Norte, este modelo é frequentemente referido como o modelo CMC (Canadian Meteorological Centre). Devido à sua resolução e especialização, é o modelo mais preciso para previsões no Canadá.

Resolução: 2.5km (Canada), 25km (Global)

Website: https://collaboration.cmc.ec.gc.ca/science/rpn/gef_html_public/index.html

Skiron (University of Athens)

Um modelo meteorológico regional de alta resolução desenvolvido pela Universidade de Atenas, na base do WRF. É considerado um dos modelos mais fiáveis para o Mediterrâneo.

Resolução: 5km

Website: <https://forecast.uoa.gr/en/>

HIRLAM (High Resolution Limited Area Model)

O modelo regional cobre o Norte da Europa. Este modelo é o resultado da cooperação entre 10 institutos meteorológicos europeus, criados com o objectivo de criar um sistema numérico de previsão meteorológica de curto alcance, a ser operado por todos os institutos participantes.

Resolução: 2.5km

Website: <http://hirlam.org/index.php/hirlam-programme-53/welcome-to-hirlam>

ACCESS-G (The Australian Community Climate and Earth-System Simulator)

Este modelo global foi desenvolvido e testado pelo Gabinete de Meteorologia do Governo Australiano com base no Modelo Unificado do UK Met Office, que é um software de previsão meteorológica e modelação climática desenvolvido pelo Met Office e utilizado por muitas agências de previsão em todo o mundo.

Resolução: 25km

Website: http://www.bom.gov.au/australia/charts/about/about_access.shtml

RTOFS (Atlantic operational Real Time Ocean Forecasting System)

O RTOFS é um modelo de previsão das correntes do oceano Atlântico gerido pelo US National Weather Service.

Resolução: 9km

Website: https://luckgrib.com/models/rtofs_global/

COAMPS (Coupled Ocean Atmosphere Mesoscale Prediction System)

Este modelo meteorológico regional cobre certas regiões dos Estados Unidos e é gerido pela Marinha americana.

Resolução: 12km

Website: <https://www.cencoos.org/data/models/coamps>