



INSTITUTO  
UNIVERSITÁRIO  
DE LISBOA

---

## **Previsão dos Preços do Petróleo Brent com Modelos Univariados**

Mariana Coelho Silvestre

Mestrado em Ciência de Dados,

Orientador(a):

Doutora Diana Aldea Mendes, Professora Associada,  
ISCTE - Instituto Universitário de Lisboa

Outubro, 2022



Departamento de Métodos Quantitativos para Gestão e Economia

Departamento de Ciências e Tecnologia da Informação

## **Previsão dos Preços do Petróleo Brent com Modelos Univariados**

Mariana Coelho Silvestre

Mestrado em Ciência de Dados,

Orientador(a):

Doutora Diana Aldea Mendes, Professora Associada,  
ISCTE - Instituto Universitário de Lisboa

Outubro, 2022





*Dedico esta tese aos meus avós por me mostrarem diariamente que é necessário querer para atingir se atingir os objetivos, eles são um exemplo de superação e persistência. Espero que estejam orgulhosos de mim, incluindo a minha estrelinha que me está a guiar lá de cima.*





## AGRADECIMENTO

Em primeiro lugar, gostava de agradecer à minha orientadora, professora Diana Mendes, obrigada por nunca me ter deixado desistir, especialmente quando eu achava que já não era possível terminar esta dissertação este ano. Obrigada por todo apoio, todas as reuniões e todas as opiniões que me ajudaram a produzir este trabalho.

Aos meus pais que sempre se esforçaram para me dar tudo o que podiam, sem eles não estaria a realizar este mestrado. Obrigada aos dois por me apoiarem e incentivarem a alcançar os meus objetivos.

Ao meu namorado, agradeço o facto de me teres apoiado durante todo este processo principalmente quando só me apetecia chorar e desistir de tudo. Sem dúvida que o teu apoio foi fundamental para conseguir ter motivação para ultrapassar todos os desafios impostos que esta dissertação me trouxe.

Aos meus avós, que sempre me apoiaram e sempre acreditaram que eu iria conseguir enfrentar este desafio. Obrigada por perguntarem todos os dias como é que estava a correr a faculdade e quando é que terminava o curso, a vossa preocupação motivava-me. À minha avó estrelinha, obrigada por me guiares todos os dias aí de cima, espero que estejas orgulhosa da minha caminhada.

À minha família, obrigada a todos por me incentivarem e apoiarem sempre em todos os momentos, sem vocês isto não seria possível.

Aos meus amigos, agradeço a compreensão por faltar a alguns eventos para que conseguisse concluir com sucesso este trabalho. Vocês foram incríveis, senti sempre o vosso apoio durante esta missão (quase) impossível.

Aos meus colegas de mestrado que se tornaram amigos, sem dúvida que o vosso apoio foi fundamental uma vez que como estavam a passar pelo mesmo que eu sentiam todas as minhas dores. Isso facilitou-me a motivar-me e perceber que todos íamos conseguir terminar o curso juntos. Obrigada por enfrentarem os obstáculos comigo e em conjunto vencermos esta corrida.



## RESUMO

**Resumo:** O objetivo deste estudo é a previsão da série temporal de preços do petróleo Brent através de diversos modelos econométricos e de *Machine Learning* de forma a identificar qual é o que obtém um melhor ajuste e performance. As métricas de avaliação da performance que auxiliaram na comparação entre os modelos foram o *Mean Absolute Error* (MAE), o *Mean Absolute Percentage Error* (MAPE), o *Mean Squared Error* (MSE) e o *Root Mean Squared Error* (RMSE). Com isto, conseguiu-se perceber que existe uma tendência, sendo o modelo ARIMA (*Auto Regressive Integrated Moving Average*) e o modelo LSTM (*Long short-term memory*) os mais estudados na literatura e os que obtiveram melhores previsões em todas as métricas utilizadas. Em suma, verificou-se que tem existido um crescimento gradual da literatura desta temática, que a presente dissertação vai ao encontro dos resultados obtidos por outros autores e que ainda há caminho para novas investigações.

**Palavras-Chave:** Previsão; Redes Neurais; Séries Temporais; Petróleo Brent; Métricas de *Performance*



## ABSTRACT

**Abstract:** This study aims to forecast the Brent crude oil price series over time using various forecasting models belonging to classical econometrics and Machine Learning to determine which model produces the best adjustment. The performance metrics that aided in the model comparison were the Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE), Mean Squared Error (MSE), and Root Mean Squared Error (RMSE) (RMSE). As a result, it was possible to detect a trend, with the models ARIMA (Auto Regressive Integrated Moving Average) and LSTM (Long Short-Term Memory) being the most studied in the literature and yielding the best predictions across all metrics. Overall, it was concluded that there had been a gradual growth in the literature on this topic, that this dissertation results agree with the one found in the recent literature, and that there is still room for developing new research.

**Keywords:** Prediction; Neuronal Networks; Temporal Series; Brent Crude Oil; Performance Metrics



# ÍNDICE

Agradecimento	iii
Resumo	v
Abstract	vii
Abreviaturas	xv
Introdução	1
Capítulo 1. Revisão da Literatura	3
Capítulo 2. Metodologia CRISP-DM	11
2.1. Análise e Preparação dos Dados	11
2.2. Modelos de Previsão	17
2.2.1. Autoarima	17
2.2.2. Random Walk	19
2.2.3. Prophet	19
2.2.4. Darts	20
2.2.5. LSTM	21
2.3. Métricas de Performance	22
2.3.1. MAE	22
2.3.2. MAPE	22
2.3.3. MSE	23
2.3.4. RMSE	23
Capítulo 3. Resultados e discussão	25
3.1. Resultados obtidos por cada modelo	25
3.2. Consolidação dos resultados obtidos	35
Conclusões	37
Referências Bibliográficas	41



## ÍNDICE DE FIGURAS

Figura 1: Número de citações dos artigos publicados nos últimos 5 anos	6
Figura 2: Modelos utilizados pelo menos duas vezes nos artigos analisados	7
Figura 3: Métricas utilizados pelo menos duas vezes nos artigos analisados	8
Figura 4: Metodologia CRISP-DM - Woman Data Science La Paz, 2022	11
Figura 5: Frequência dos Preços do Petróleo Brent - Europa	13
Figura 6: Diagrama de caixa da variável CrudeOilPrice	13
Figura 7: Série Temporal dos Preços do Petróleo	14
Figura 8: Histogramas da série original e da série logaritmizada	16
Figura 9: Diagrama dos componentes da LSTM	21
Figura 10: Série Temporal dos Preços Atuais e Preditos	26
Figura 11: Série Temporal dos Valores Preditos e Atuais	28
Figura 12: Séries Temporais com a previsão dos modelos utilizados com o package DARTS para um conjunto de 205 dias	31
Figura 13: Exemplo de arquitetura de Rede Neural LSTM - Arden Dertat, 2017	32
Figura 14: Série Temporal com a previsão sobre o conjunto de validação com o modelo LSTM	33
Figura 15: Série Temporal com a previsão sobre o conjunto de teste com o modelo LSTM	34
Figura 16: Aproximação da previsão sobre o conjunto de teste com o modelo LSTM	34
Figura 17: Valores Reais e Valores Preditos pelos diferentes modelos	36



## ÍNDICE DE TABELAS

Tabela 1: Resultados obtidos com a query por intervalos de anos	5
Tabela 2: Resultados obtidos nos testes ADF, PP e KPSS da série temporal	15
Tabela 3: Resultados obtidos nos testes ADF, PP e KPSS da série logaritmizada	15
Tabela 4: Resultados obtidos nos testes ADF, PP e KPSS da série logaritmizada diferenciada	16
Tabela 5: Resultados obtidos com o modelo ARIMA sobre o conjunto de teste e treino	26
Tabela 6: Resultados obtidos com o modelo Random Walk sobre o conjunto de teste e treino	27
Tabela 7: Resultados obtidos no modelo Prophet sobre o conjunto de teste e treino	28
Tabela 8: Resultados obtidos com o pacote Darts sobre o conjunto de teste de 545 dias	29
Tabela 9: Resultados obtidos com o pacote Darts sobre o conjunto de teste de 205 dias	30
Tabela 10: Resultados obtidos com o modelo LSTM sobre o conjunto de validação e teste	33
Tabela 11: Consolidação dos resultados obtidos em todos os modelos	35



## ABREVIATURAS

MAE – *Mean Absolute Error*

MAPE – *Mean Absolute Percentage Error*

MSE – *Mean Squared Error*

RMSE – *Root Mean Squared Error*

ARIMA – *Auto Regressive Integrated Moving Average*

LSTM – *Long Short-Term Memory*

SVM – *Support Vector Machine*

BPNN – *Back Propagation Neural Network*

SVR – *Support Vector Regression*

ARMA – *Auto Regressive Moving Average*

GARCH – *Generalized Autoregressive Conditional Heteroskedasticity*

ANN – *Artificial Neural Network*

LSSVR – *Least Squares Support Vector Regression*

SLR – *Systematic Literature Review*

RNN – *Recurrent neural network*

$R^2$  – *R-squared*

GA-SVR – *Genetic Algorithm - Support Vector Regression*

CRISP-DM – *Cross Industry Standard Process for Data Mining*

FRED – *Federal Reserve Economic Data*

OPEC – *Organization of Petroleum Exporting Countries*

ADF – *Augmented Dickey-Fuller*

KPSS – *Kwiatkowski-Phillips-Schmidt-Shin*

PP – *Phillips-Perron*

SARIMA – *Seasonal Auto Regressive Integrated Moving Average*

*AIC – Akaike’s Information Criteria*

*BIC – Bayesian Information Criteria*

*NLP – Natural Language Processing*

## INTRODUÇÃO

Atualmente, é considerada um questão retórica o facto de o mundo girar à volta da economia global pois com o passar dos anos os países têm mostrado cada vez mais uma maior dependência com a sua economia. Esta dependência embora possa ter algumas desvantagens, também apresenta algumas vantagens visto que é através do estudo da economia que se consegue avaliar a qualidade de vida da população de maneira a combater a pobreza e elevando o nível de riqueza.

No entanto, existem diversos fatores que têm impacto na estrutura económica de um país, sendo um dos mais relevantes, o preço do petróleo. O petróleo tem desempenhado um papel cada vez mais significativo no sistema económico global como a principal fonte de energia (Ling *et al.*, 2014). Este fator é bastante volátil, sendo impactado por diversas ações despoletadas pela humanidade, como crises políticas, mais recentemente a guerra da Ucrânia, entre outros.

Para além disso, o preço do petróleo tem influência noutros fatores, como preços de transporte, preço de produtos/serviços, assim com os aumentos na volatilidade dos preços do petróleo gerou-se muita preocupação entre consumidores, empresas e governos devido ao importante papel desempenhado na economia mundial (Francesco *et al.*, 2020, como citado em Baumeister *et al.*, 2013; Elder *et al.*, 2010; Wang *et al.*, 2012).

Adicionalmente, o aumento dos preços dos produtos/serviços provocam alterações na vida quotidiana da população uma vez que existe uma elevação do nível de vida que pode não ser suportado por todos. No entanto, o inverso também se pode suceder pelo que é importante agir em conformidade com cada situação.

Assim, estas flutuações suscitaram o interesse de serem analisadas e preditas não só como peça fundamental à economia como também por estudantes que se interessam por esta temática. Esta dissertação foca-se assim na previsão de um dos índices de petróleo mais importantes do mundo, segundo os autores Zhongpei e Jun (2019), nomeadamente o Brent.

Contudo, a análise desta série temporal não é propriamente fácil devido a todas as influências externas a que pode ser sujeita bem como a variabilidade de modelos de previsão que já existem atualmente e tendem a aumentar. Ainda assim, pretende-se com esta dissertação realizar um estudo com um leque de modelos com a finalidade de perceber qual o que apresenta um melhor ajuste e uma melhora capacidade de previsão tendo em conta as métricas de previsão utilizadas para comparação dos mesmos.

Portanto, uma previsão precisa do preço do petróleo é extremamente importante para garantir um desenvolvimento estável no mercado internacional de petróleo e, conseqüentemente, no mercado económico global (Ling *et al.*, 2014).

As previsões efetuadas das séries temporais do petróleo oferecem a possibilidade de se estar preparado para as oscilações futuras e precaver recessões económicas drásticas que possam vir a acontecer. Claramente, dominar as tendências dos preços do petróleo é um pré-requisito para a tomada de decisões e planeamento de investimentos (Ranran *et al.*, 2021). Embora nem sempre seja fácil a tomada de decisões e ainda exista um longo caminho nesse sentido já é uma vantagem conseguir-se estar um passo à frente.

Como a análise das séries temporais em geral tem vindo a ser um tópico cada vez mais estudado a nível mundial, provavelmente no futuro existirão progressos promissores que elevam a *performance* das previsões alcançadas atualmente e ofereçam melhores resultados e indicadores que facilitem as decisões tomadas para melhorar a economia global.

Posto isto, nesta dissertação serão abordados os seguintes tópicos: na secção 1 será realizada a análise de literatura com a finalidade de sintetizar todo o trabalho que já foi realizado/estudado/analísado anteriormente, na secção 2 será descrita a metodologia aplicada assim como os modelos de previsão e as métricas de performance utilizados nesta análise, na secção 3 serão demonstrados os resultados que se obteve ao desenvolver este estudo e por fim serão apresentadas as principais conclusões e possíveis trabalhos futuros.<sup>1</sup>

---

<sup>1</sup> O código produzido para o desenvolvimento desta dissertação será disponibilizado caso seja efetuado algum pedido.

## REVISÃO DA LITERATURA

Considerando que as técnicas tradicionais de previsão (definidas maioritariamente por expressões lineares e para variáveis estacionárias) atingiram a sua limitação em aplicações sobre conjuntos de dados com padrões não-lineares, como por exemplo - os índices de ações, um grande número de aplicações bem-sucedidas mostrou que modelos de *machine learning* podem ser uma técnica muito útil para modelação e previsão de séries temporais (Jingming, SiHang, Qiang, Xinwang e Jianping, 2019). Em particular, os algoritmos baseados em redes neurais artificiais (ANN) tiveram um sucesso significativo nos problemas de previsão provenientes de várias áreas de conhecimento. As ANN são modelos orientados para dados e são não paramétricos (Chi-Jie, Chih-Hsiang, Chien-Yu, Chih-Chou e Tian-Shyug, 2009; David *et al.*, 2014), variando em termos da sua arquitetura e do método de aprendizagem.

O desenvolvimento de modelos de previsão para séries temporais financeiras é considerado um problema difícil, uma vez que estas são muito complexas devido ao facto de serem irregulares, devido à sua volatilidade e serem corrompidas de ruído (Ricardo, Germano e Tiago, 2007). Foram realizados muitos esforços para o desenvolvimento de modelos e técnicas capazes de prever o comportamento futuro de uma determinada série temporal financeira com base no comportamento do presente e do passado (Ricardo, Germano e Tiago, 2007).

As técnicas de *deep learning* estão a desenvolver-se muito rápido e a sua capacidade de construir modelação não-linear de dados complexos é óbvia para todos, portanto, acredita-se que tenha uma ampla perspectiva de aplicação no mercado financeiro (Yiran *et al.*, 2019).

Esta dissertação tem como objetivo analisar a utilização de modelos de previsão na série temporal dos preços do petróleo. A escolha desta série é justificada pela quantidade e variabilidade dos dados e pela dificuldade em encontrar padrões gerais, sendo a variável tempo e os eventos extremos que impactam os preços um desafio de real interesse.

De forma a conseguir interpretar a evolução deste tópico, deu-se uma maior importância aos modelos que utilizam redes neuronais e às respetivas métricas de performance utilizadas. Interessa fazer o *trade-off* entre a interpretabilidade dos valores preditos (e a tomada de decisão), o tempo de execução dos modelos/algoritmos e a minimização dos erros de previsão.

As séries temporais financeiras apresentam padrões bastante variados que não podem ser generalizados facilmente por um único algoritmo ou por apenas uma métrica de avaliação da *performance* preditiva. A intervenção deste estudo, debruça-se então sobre a realização de um ensaio acerca destes problemas, que apesar de serem muito frequentes estão a ser pouco estudados com rigor e clareza.

Assim sendo, é de realçar que os modelos ainda carecem de muitas melhorias, pelo que esta área terá ainda muito por explorar futuramente.

Esta revisão de literatura foi desenvolvida com o intuito de analisar quais os modelos e métricas utilizados na literatura para o conjunto dos preços de petróleo *Brent*<sup>2</sup>. Para tal, seguiu-se uma Revisão Sistemática da Literatura (SLR) que é um método amplamente utilizado para identificar, avaliar e interpretar os objetivos numa determinada área (Thyago *et al.*, 2019), neste caso, a área de *machine learning*. De acordo com esta metodologia, seguiu-se os seguintes passos:

- I. Identificação das questões em estudo;
- II. Identificação da estratégia de pesquisa;
- III. Definição dos critérios de inclusão;
- IV. Análise dos artigos selecionados.

Posto isto, esta dissertação procura responder às seguintes questões:

- **Questão A:** Quais os modelos que apresentam um melhor ajuste à série temporal dos preços do petróleo *Brent* ?
- **Questão B:** Quais as métricas que melhor avaliam o desempenho dos modelos de previsão ?

De seguida, iniciou-se a pesquisa de artigos sobre o tema a ser analisado numa das maiores plataforma de literatura científica, o *Scopus*. Esta é uma base de dados internacional de artigos publicados do mundo inteiro (Wondimagegn *et al.*, 2020, como citado em María *et al.*, 2019).

A pesquisa teve por base o filtro por *queries* que foram incrementadas com palavras-chave importantes no estudo de séries temporais de forma a restringir o número de artigos analisados e garantir que os artigos finais retratavam exatamente aquilo que se procurava, pelo que a *query* final utilizada foi a seguinte: (("*forecasting*" OR "*prediction*" ) AND "*time series*" AND "*crude oil price*" AND "*Brent*" ).

Posto isto, através das palavras-chave selecionadas foi possível encontrar os artigos que abordavam modelos de previsão de séries temporais dos preços de petróleo *Brent*, a pesquisa resultou em 38 artigos realizados entre 2008 e 2022.

---

<sup>2</sup> *Brent* é considerado um fluxo de petróleo misturado produzido na região do Mar do Norte que serve como referência ou "marcador" para precificar vários outros fluxos de petróleo ("Table Definitions, Sources, and Explanatory Notes", 2022).

Os critérios de inclusão que se teve em conta foram os seguintes:

- I. Artigos que incluíssem métodos de previsão de séries temporais;
- II. Utilização de modelos de *machine learning*;
- III. Previsão da série temporal de preços do petróleo *Brent*;
- IV. Inclusão de métricas de *performance*.

Na Tabela 1, verifica-se a divisão dos artigos obtidos por intervalos de anos de forma a analisar-se a evolução deste tema.

Tabela 1: Resultados obtidos com a query por intervalos de anos

ANOS	2008-2010	2011-2013	2014 - 2016	2017 - 2019	2020 - 2022
<b>NÚMERO DE ARTIGOS</b>	3	3	4	12	16

Em complemento da Tabela 1, de acordo com os autores Hooman e Seyed (2020), fica fortalecida a informação do que vários artigos sobre a previsão do preço do petróleo foram publicados nos últimos anos.

Através de uma análise geral dos artigos, verificou-se um aumento gradual do número dos artigos ao longo dos anos e observou-se que nas últimas duas décadas, os modelos de *data mining* e de *machine learning* atraíram uma maior atenção e foram aplicados com sucesso na previsão de séries temporais (Zeynep *et al.*, 2019).

Para além disso, é notável que o número de artigos aumentou não só devido à aplicabilidade dos modelos de *machine learning*, mas também devido ao aumento quase-exponencial dos preços do petróleo *Brent*. Estes preços têm suscitado muito interesse de previsão, especialmente nos últimos dois anos, também devido às influências externas que têm ocorrido no mundo, como a Covid-19 e a guerra da Ucrânia.

O problema da previsão do preço do petróleo é considerado uma das questões interessantes e necessárias em inteligência artificial, pois apresenta grande influência em diversas áreas da sociedade (Anh, Trang e Tuong, 2020).

Na Figura 1, também é visível a escalabilidade deste tema através do número de citações existentes nos últimos 5 anos, uma vez que têm vindo a aumentar. Em relação aos artigos publicados em 2021 e 2022, acredita-se que ainda não atingiram o seu auge visto serem relativamente recentes daí conterem menos citações que os restantes.

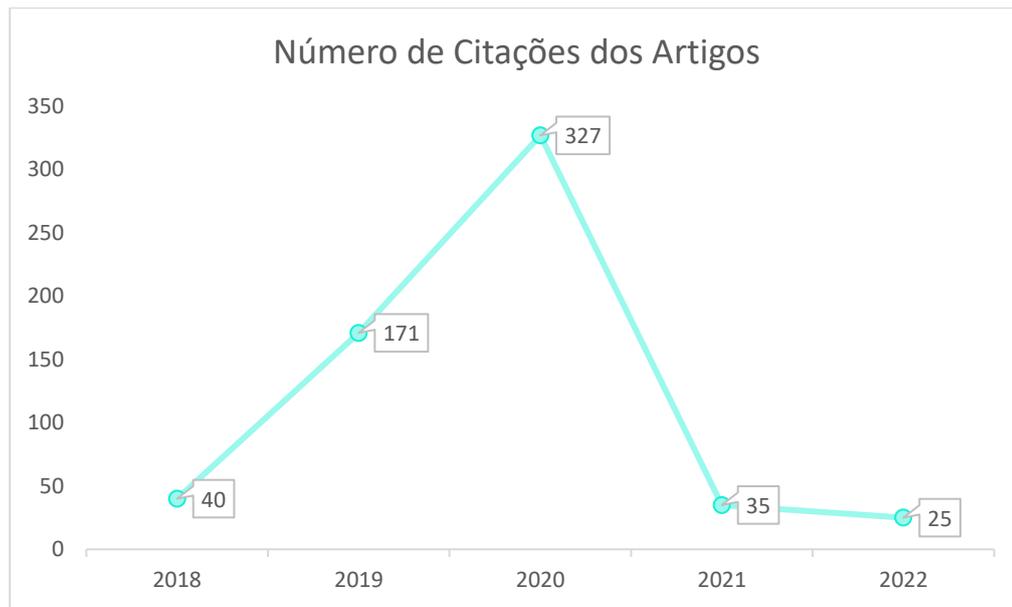


Figura 1: Número de citações dos artigos publicados nos últimos 5 anos

Dos 38 artigos obtidos, exclui-se 8 artigos no geral devido a alguns não estarem disponíveis online de forma gratuita e outros artigos por não realizarem a previsão dos preços do petróleo *Brent*, mas sim a análise da série temporal a nível estatístico. Com esta exclusão, ficou-se com 30 artigos a serem utilizados na contabilização dos modelos mais utilizados na Figura 2 e na contabilização das métricas na Figura 3.

A previsão do preço do petróleo atraiu interesse significativo por décadas (Sabri, Zhenya e Yifan, 2022). A primeira vertente da literatura sobre o tema é baseada nos modelos tradicionais de séries temporais, como regressão linear, análise de cointegração e modelos GARCH (Sabri, Zhenya e Yifan, 2022 como citado em Ye *et al.* 2006; He *et al.* 2010; Mohammadi e Su 2010).

Por conseguinte, analisou-se a utilização dos modelos de previsão onde se pode verificar que até 2010 existia uma predominância de modelos híbridos e que atualmente, a maioria dos artigos utiliza modelos de *machine learning* (LSTM) e modelos clássicos de econometria (ARMA e GARCH).

Conforme se pode observar na Figura 2, os modelos mais predominantes nos artigos analisados foram precisamente o modelo ARIMA e a rede neuronal LSTM com 6 e 12 ocorrências, respetivamente. Posto isto, nesta dissertação utilizou-se estes dois modelos para verificar o seu desempenho com a série temporal de preços do petróleo *Brent*.

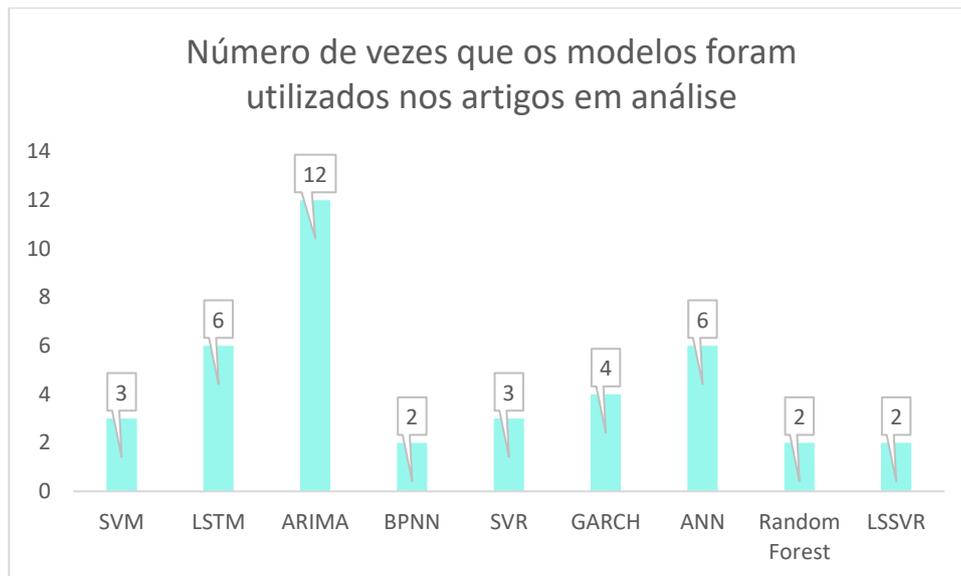


Figura 2: Modelos utilizados pelo menos duas vezes nos artigos analisados

As redes LSTM funcionam bem para uma ampla gama de tarefas e são o tipo mais popular de *recurrent neural network* (RNN) (Marat *et al.*, 2019). Enquanto, os métodos clássicos de análise de séries temporais, ARMA e GARCH, requerem uma amostra elevada e estacionária para obter uma melhor previsão (Altaf *et al.*, 2009).

Assim, os modelos de *machine learning* estabeleceram-se na última década como concorrentes aos modelos clássicos de econometria na área de previsão, pelo que existem numerosos estudos que comparam redes neurais com técnicas tradicionais de previsão e outros problemas econométricos (Nesreen, 2010).

Para além disso, as aplicações de redes neurais para previsão de séries temporais financeiras têm apresentado melhor desempenho em comparação com outras metodologias devido à sua natureza não linear e à sua capacidade de aprendizagem (Ghazali, 2008).

Em grande parte dos artigos, como forma de comparação dos modelos entre si são utilizadas métricas de *performance*. De acordo com a Figura 3, é possível verificar que as métricas mais utilizadas pela grande maioria dos autores dos artigos em estudo foram o MAE, o MAPE, o MSE, o RMSE e o  $R^2$ . Estas métricas com valores menores significam que existiu uma maior precisão na previsão (Bin e Jun, 2019). Ainda assim, o maior foco da maioria dos autores concentra-se no MAPE e no RMSE que foram utilizados cerca de 27% e 40%, respetivamente, nos artigos em causa.

### Número de vezes que os modelos foram utilizados nos artigos em análise

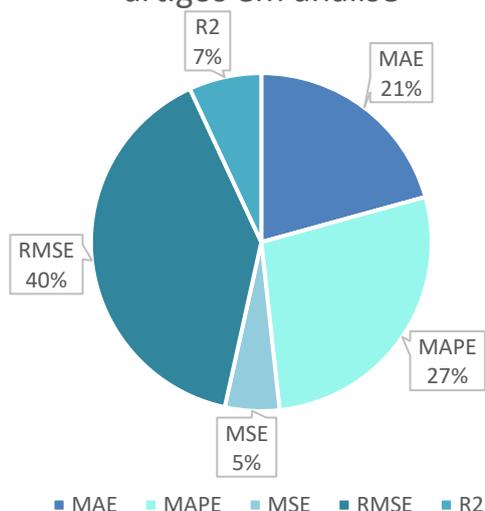


Figura 3: Métricas utilizados pelo menos duas vezes nos artigos analisados

Dos artigos em estudo, verificou-se que os melhores resultados com um RMSE de 0,188 e com o modelo LSTM foram obtidos pelos autores Sabri, Zhenya e Yifan, em 2022. O RMSE foi o comparador utilizado visto ser a única em comum com todos os artigos. Ainda assim, verificou-se que existiram outras aplicações deste modelo que obtiveram valores muito próximos. Enquanto o modelo ARIMA com um valor de RMSE mais promissor de aproximadamente 0,150 foi obtido pelos autores Sabri, Zhenya e Yifan, em 2022. Contudo, é de realçar que esta comparação não é muito direta devido aos intervalos temporais utilizados nos diversos artigos serem diferentes.

Os autores Yichun *et al.*, em 2022, realizaram um estudo bastante interessante em que em primeiro lugar avaliaram os modelos individuais onde verificaram que o que obteve piores resultados nas métricas MAE, MAPE, MSE e RMSE foi o ARIMA, enquanto o que obteve melhores resultados foi o GA-SVR (Genetic Algorithm - Support Vector Regression). Quando complementaram os modelos tornando-os híbridos verificaram que todos os modelos apresentaram melhorias bastante significativas.

Em 2017, os autores Nurull *et al.*, também já tinham concluído que com um modelo híbrido que utilizasse o ARIMA obteria melhores resultados que apenas a utilização do modelo individual ARIMA.

No entanto, os autores Sabri, Zhenya e Yifan, em 2022, também previram os preços do petróleo *Brent* com os modelos ARIMA e LSTM onde o modelo que apresentou melhores resultados foi precisamente o ARIMA. Adicionalmente, também aplicaram o modelo *Random Walk* no entanto não obteve tão boas previsões em comparação com o ARIMA, mas registou um RMSE ligeiramente inferior à rede neuronal LSTM.

Curiosamente, os autores Didem e Erdemalp, em 2020, aplicaram o modelo LSTM e *Prophet* com a finalidade de prever a longo prazo os preços do petróleo, comparando os dois modelos verificaram que a rede neuronal obteve melhores resultados uma vez que o *Prophet* não se conseguiu ajustar muito bem à volatilidade dos últimos anos do período em causa. Este estudo torna-se interessante devido às diferenças existentes entre estes dois modelos que são muito promissores a previsões de longo-prazo.



## CAPÍTULO 2

# METODOLOGIA CRISP-DM

Hoje em dia, a grande maioria dos projetos que trabalham com dados utilizam como base uma metodologia, a qual muitas das vezes é a metodologia *CRoss Industry Standard Process for Data Mining* (CRISP-DM). Esta funciona como um modelo de processo independentemente da indústria (Christoph, Felix e Jorge, 2021).

A metodologia CRISP-DM é composta por 6 fases: análise do negócio, análise dos dados, preparação dos dados, modelação, avaliação e implementação (Andrea Cirillo, 2017) que estão visíveis na Figura 4. Embora exista uma ordem sequencial, muitas vezes é necessário voltar atrás para fazer alinhamentos importantes que não se tiveram em conta anteriormente.

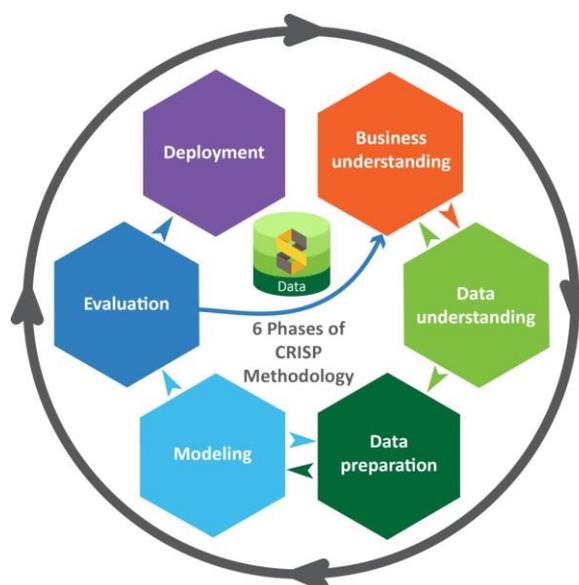


Figura 4: Metodologia CRISP-DM - Woman Data Science La Paz, 2022

Nas próximas secções, faz-se referência a algumas funções de *Python* que foram utilizadas durante os desenvolvimentos de código para analisar/preparar os dados e durante a aplicação dos modelos de previsão.

### 2.1. ANÁLISE E PREPARAÇÃO DOS DADOS

Atualmente, considera-se o petróleo uma das matérias-primas mais valiosas do mercado, uma vez que é fundamental para a vida quotidiana da maioria da população. O preço do petróleo tem um impacto significativo na economia global e tenta fornecer sinais importantes sobre a direção da economia (Sanjay Kr. Mandal, 2020).

Esta análise baseia-se na previsão uni-variada dos preços do petróleo, mas é de senso comum que a sua variação é influenciada por diversos fatores. A crise económica, o aparecimento da Covid-19 que parou o mundo e a guerra da Ucrânia são fortes exemplos que provocaram tanto uma drástica queda como um forte aumento nos preços. Em suma, as cotações do petróleo são afetadas por variáveis económicas, ambientais, políticos e sociais.

Quando o preço aumenta, o valor dos produtos e dos serviços também dispara tornando o custo de vida mais alto (Kimberly Amadeo, 2022). Para que as economias se preparem da melhor forma para enfrentarem estas oscilações, os estudos de previsão são uma mais-valia.

Nesta dissertação iremos estudar dados em formato de series temporais, parte fundamental da ciência de dados, dedicada em especial para responder aos desafiantes problemas de previsão ao longo de intervalos temporais. As séries temporais são sequências de dados registados de acordo com um intervalo de tempo, por exemplo, existem registos diários, mensais, anuais, entre outros (Selva Prabhakaran, 2021). Posto isto, o conjunto de dados analisado é uma série temporal com registos diários.

Face aos últimos acontecimentos que têm ocorrido no mundo, especialmente na Europa, o conjunto de dados escolhidos para analisar foram os preços do petróleo *Brent* – Europa. Estes foram extraídos do site *Federal Reserve Economic Data* (FRED) e contemplam registos diários de doze anos, ou seja, desde dia 11 de abril de 2000 a 11 de abril de 2022. Os valores registados representam o preço em dólares por barril.

Assim sendo, o *dataset* é composto por 5.740 entradas, das quais 150 não apresentavam valores pelo que se procedeu à substituição dos valores nulos pelo valor do registo diário anterior. Para além disso, renomeou-se o nome da variável de "DCOILBRETEU" para "CrudeOilPrice" e mudou-se o tipo de inteiro de base 64 para *float* de forma a tratar as casas decimais corretamente.

Primeiramente, através da Figura 5 analisou-se a frequência dos preços do petróleo em dólares por barril e constatou-se que os preços mais frequentes eram 71,3 dólares tendo sido registado 7 vezes e 108,98 e 70,71 com 6 registos cada. A maioria dos restantes valores apresentaram uma frequência de 4 a 5 registos cada neste período de 12 anos.



Figura 5: Frequência dos Preços do Petróleo Brent - Europa

Para verificar a dispersão dos dados e se existiam valores considerados *outliers*, construiu-se o diagrama de extremos e quartis no qual se observou (ver Figura 6) que o valor mais baixo é de 9,12 dólares e o valor máximo é 143,95 dólares, sendo considerado de um ponto de vista estatístico um *outlier*. Ainda assim, a sua remoção não faria sentido uma vez que estes dados tratam de registos diários e mensurações reais dos preços do petróleo, pelo que este valor não foi excluído da amostra. A média dos preços ronda os 62,73 dólares por barril.

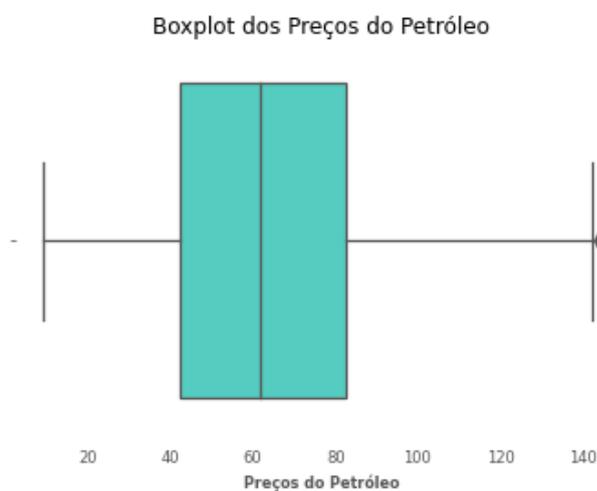


Figura 6: Diagrama de caixa da variável CrudeOilPrice

Através da observação direta do gráfico da série temporal, constatou-se a existência de elevadas oscilações no valor do preço por barril. Conforme se referiu anteriormente, a enorme queda visível no gráfico abaixo ocorreu entre 2008 e 2009 o que corresponde ao período em que se iniciou a crise do *subprime*. A crise financeira deu origem ao maior declínio dos preços do petróleo (Neha e Kristian, 2015), sendo que o valor baixou aproximadamente 100 dólares por barril.

Segundo Evan Tarver (2022), o preço do petróleo é influenciado por 5 fatores: mudanças no valor do dólar da US, mudanças nas políticas da *Organization of Petroleum Exporting Countries* (OPEC), mudanças nos níveis de produção e *stock* do petróleo, saúde da economia global e implementação ou colapso de acordos internacionais. Posto isto, assumiu-se que a descida de preço em 2015 ocorreu devido ao aumento dos níveis de produção e diminuição dos níveis de consumo, aumentando assim o *stock* existente (Hannah, 2016).

Mais recentemente, em 2020, com o aparecimento da Covid-19 que colocou o mundo em confinamento os preços diminuíram acentuadamente visto que apenas se podia sair de casa para atividades essenciais. Após a queda provocada por Covid-19, observa-se um crescimento agreste nos preços do petróleo, atingindo os preços históricos mais altos, comparáveis com os existentes na altura da crise dos anos 2008-2009.

Assim sendo, com o passar dos anos nota-se que os preços do petróleo têm vindo a crescer face à valorização do mesmo nas economias e devido à influência deste nos custos de transporte de vários produtos. A Figura 7 representa a série temporal dos preços do petróleo *Brent* que será estudada ao longo desta dissertação.

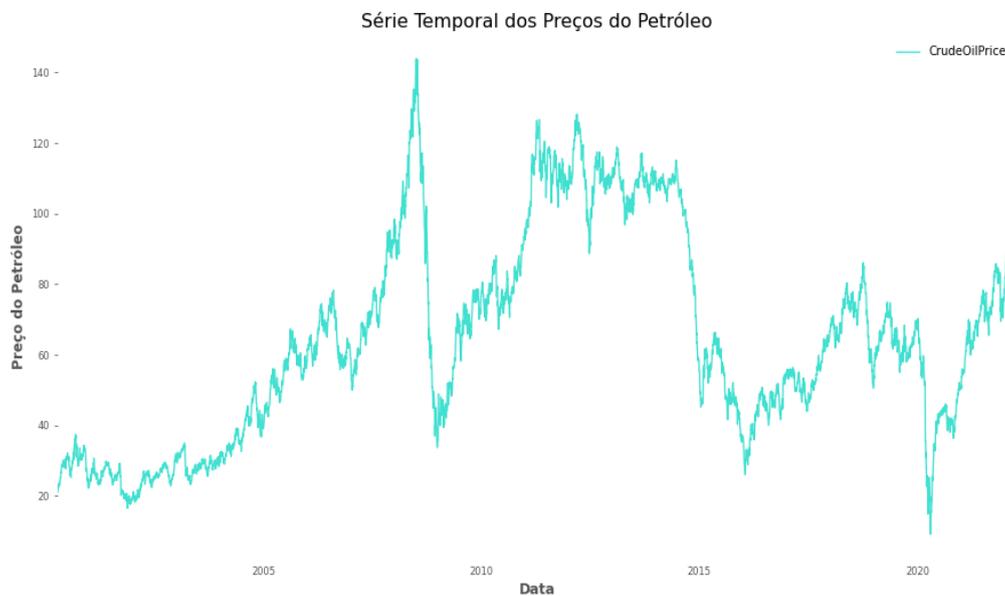


Figura 7: Série Temporal dos Preços do Petróleo

De forma a estudar a estacionaridade da série temporal, isto é, se a série apresenta média, variância e covariância constantes, procedeu-se à realização dos seguintes testes: *Augmented Dickey-Fuller* (ADF), *Kwiatkowski-Phillips-Schmidt-Shin* (KPSS) e *Phillips-Perron* (PP). O teste *Augmented Dickey-Fuller* avalia a não-estacionaridade através da presença de uma raiz unitária, ou seja, caso se detete estamos perante a hipótese nula que revela que a série é não-estacionária, caso contrário estamos perante a hipótese alternativa onde se conclui que a série é estacionária (Yugesh Verma, 2021). O teste *Kwiatkowski-Phillips-Schmidt-Shin* é um teste de estacionaridade, que verifica a estacionaridade de uma série temporal através de uma tendência determinística (Vijay, 2021). A hipótese nula diz-nos que a série segue uma tendência estacionária, enquanto a hipótese alternativa informa que a série é não-estacionária (Vijay, 2021). Por fim, o teste *Phillips-Perron* é mais um teste de raiz unitária, em que a hipótese nula representa a existência de raiz unitária, ou seja, a série é não-estacionária e a hipótese alternativa refere que não existe raiz unitária pelo que a série é considerada estacionária. Os resultados dos três testes concordam que a série é não-estacionária conforme se pode verificar na Tabela 2, sendo o *p-value* maior (menor) do que o nível de significância padrão (5%) para o teste de ADF, PP (KPSS).

Tabela 2: Resultados obtidos nos testes ADF, PP e KPSS da série temporal

	<b>ADF</b>	<b>PP</b>	<b>KPSS</b>
<b>P-VALUE</b>	0.164	0.212	0.010

Com estes resultados, procedeu-se à logaritmização da mesma e efetuou-se os mesmos testes onde continuaram todos a descrever a série como não-estacionária (Ver Tabela 3).

Tabela 3: Resultados obtidos nos testes ADF, PP e KPSS da série logaritmicada

	<b>ADF</b>	<b>PP</b>	<b>KPSS</b>
<b>P-VALUE</b>	0.149	0.104	0.010

Posto isto, aplicou-se na série logaritmizada o operador primeira diferença, a função *diff()* em Python, que gera uma nova séries com a diferença de valores de cada linha com a linha anterior, isto porque se assumiu a parametrização *default* que é 1, ou seja, estamos perante uma série diferenciada de ordem 1 (taxa de crescimento em economia ou retornos logaritmizados para séries financeiras). Nesta série os testes acima descritos concordaram que se tratava de uma série estacionária (Ver Tabela 4), e conclui-se então que a série temporal dos preços de petróleo é integrada de 1ª ordem.

Tabela 4: Resultados obtidos nos testes ADF, PP e KPSS da série logaritmizada diferenciada

	ADF	PP	KPSS
<b>P-VALUE</b>	4.614e <sup>-23</sup>	0.000	0.100

Com os histogramas da Figura 8 também é possível verificar que estamos perante dados multimodais na série dos preços, uma vez que apresentam mais do que um pico. A série logaritmizada apresenta um padrão de assimetria.

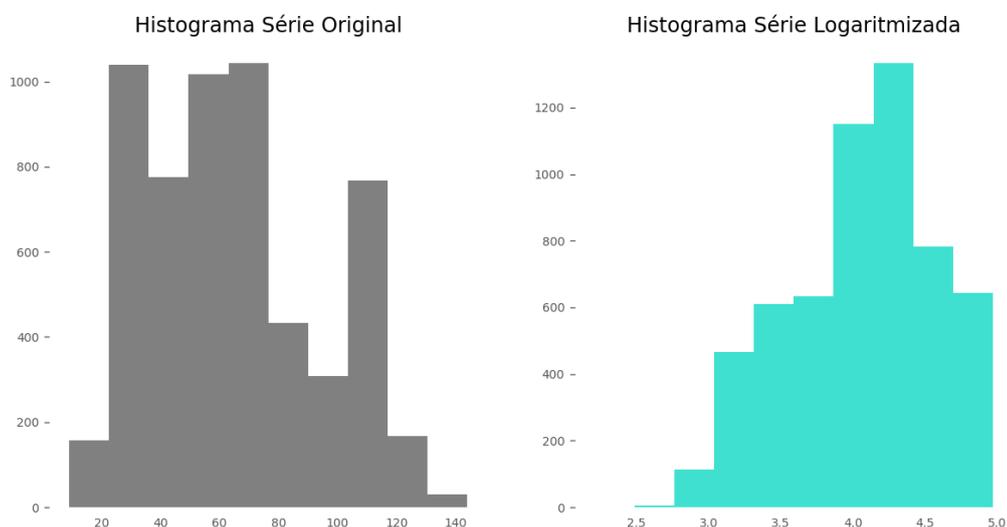


Figura 8: Histogramas da série original e da série logaritmizada

Adicionalmente, verificou-se a função de autocorrelação e de autocorrelação parcial da série logaritmizada e da série diferenciada (*log-returns*).

Antes de entrar na modelização, dividiu-se o conjunto de dados em treino e em teste da seguinte forma: o conjunto de treino é composto pelos registos de dia 11 de abril de 2000 a 9 de março de 2020 e o conjunto de teste é composto pelos registos de dia 10 de março de 2020 a 11 de abril de 2022. Esta divisão teve por base, considerar o período de descida de preços correspondente ao aparecimento da Covid-19 e a subida agreste que segue em 2021, no conjunto de teste. Assim, o conjunto de treino é composto por 5.195 entradas e o de teste por 545 entradas.

## 2.2. MODELOS DE PREVISÃO

A modelação preditiva é uma técnica estatística que utiliza *machine learning* e *data mining* para prever dados futuros da variável target com base na utilização de dados históricos e correntes da mesma e com base em outras variáveis exógenas (Rami Ali, 2020). Este processo envolve a execução de um ou mais algoritmos num conjunto de dados onde será realizada a previsão (Asiah *et al.*, 2018).

A previsão pode ser efetuada em vários tipos de dados e utilizando diferentes tipos de modelos. Este estudo tem maior foco nos modelos de previsão de séries temporais, que serão descritos nas próximas secções.

Estas séries podem apresentar tendências e sazonalidade, isto é, ciclos que se repetem regularmente ao longo do tempo num padrão crescente ou decrescente, pelo que compreender as componentes das séries temporais pode melhorar o desempenho da modelação com *machine learning* (Jason Brownlee, 2016).

### 2.2.1. AUTOARIMA

O modelo ARIMA, abreviação de *Auto Regressive Integrated Moving Average*, é um algoritmo de previsão de séries temporais clássico, utilizado no treino dos valores históricos da variável target para depois prever os seus valores futuros (Ankur *et al*, 2021)(Selva Prabhakaran, 2021). Adequa-se para previsões de curto prazo, sendo um modelo linear e de memória curta.

Antes de mais, é importante realçar que ao longo desta secção são relacionados os conceitos teóricos com a aplicação prática do modelo ARIMA com a função “AutoArima”.

Em primeiro lugar, para utilizar o modelo ARIMA é necessário identificar a ordem do modelo, ou seja, o valor de  $p$ ,  $q$  e  $d$ . No entanto, com o AutoArima<sup>3</sup> essa identificação é feita automaticamente com técnicas de *tunning* de forma a classificar os termos com os valores ótimos. O valor de  $p$  é dado pelo número de termos autorregressivos (AR). O valor de  $d$ , termo Integrado (I), corresponde ao número de diferenças não sazonais necessárias para a estacionaridade da série temporal. Por fim, o valor  $q$ , conta os termos *Moving Average* (MA), correspondendo ao número de erros desfasados na equação da modelo ARIMA (Sushmitha Pulagam, 2020).

A seguinte equação define a expressão geral do modelo ARIMA onde podem ser identificados os 3 elementos descritos acima:

$$Y_t = \alpha + \beta_1 Y_{t-1} + \beta_2 Y_{t-2} + \dots + \beta_p Y_{t-p} + \epsilon_t + \phi_1 \epsilon_{t-1} + \phi_2 \epsilon_{t-2} + \dots + \phi_q \epsilon_{t-q} \quad (2.1)$$

Para a previsão de séries temporais sazonais, Box e Jenkins, em 1976, propuseram uma variação bastante bem-sucedida do modelo ARIMA chamada de modelo *Seasonal* ARIMA (SARIMA) (Peng Chen *et al.*, 2018). Este modelo apresenta o seguinte formato: ARIMA( $p, d, q$ )( $P, D, Q$ )[ $m$ ] onde ( $p, d, q$ ) corresponde à parte não sazonal e ( $P, D, Q$ )[ $m$ ] à parte sazonal em que o  $m$  representa o número de períodos por época (Peng Chen *et al.*, 2018).

Ao aplicar o AutoArima no conjunto de dados em estudo (treino), tendo-se obtido como melhor resultado o modelo ARIMA(0,1,1)(0,0,0)[0] devido a apresentar o valor AIC (*Akaike's Information Criteria*) mais baixo. O AIC e o BIC (*Bayesian Information Criteria*) são critérios de seleção que orientam na escolha do modelo ideal através do equilíbrio entre um bom ajuste e a complexidade do modelo (Louis Bademosi, 2020). Neste caso o critério utilizado pelo AutoArima é o modelo que apresentar um menor valor de AIC.

Posto isto, procedeu-se à previsão *step-by-step* dos preços de petróleo com base no melhor modelo, ou seja, cada ponto previsto era adicionado ao conjunto de treino para ser utilizado na previsão do ponto a seguir, sendo usado sempre o mesmo modelo e fazendo uma previsão de tantos pontos, quanto o comprimento do conjunto de teste. Usando esta metodologia, tendo-se verificado uma melhoria nos resultados uma vez que se prevê com uma maior precisão cada valor, comparando com uma previsão seja estática seja dinâmica de 545 observações de uma vez.

---

<sup>3</sup> Auto\_arima aplica tarefas de configuração automatizadas ao modelo *Auto Regressive Integrated Moving Average* (ARIMA)(Prasad, 2022).

### 2.2.2. RANDOM WALK

*Random Walk* é considerada uma distribuição mais desafiadora, mas igualmente imprevisível na previsão de séries temporais (Bex, 2021), tendo uma teoria associada a si (mercados eficientes) que refere que os preços, por exemplo, de ações apresentam a mesma distribuição e são independentes umas das outras, ou seja, a teoria assume que não é possível prever preços futuros com os valores antigos registados (Tim Smith, 2020).

O cálculo das previsões neste modelo baseiam-se no somatório do valor anterior com um *Random Walk* para cima ou para baixo, sendo representado da seguinte forma:

$$Y_t = Y_{t-1} + \omega_t \quad (2.2)$$

Na equação acima,  $Y_t$  e  $Y_{t-1}$  representam o valor atual e o valor anterior, enquanto  $\omega_t$  representa uma série de ruído branco. Neste estudo, fixou-se o conjunto com a função *seed()*, onde o valor utilizado foi *seed = 7* para obter sempre os mesmos resultados sempre que se corresse o modelo.

### 2.2.3. PROPHET

O *Prophet* é um modelo, desenvolvido pelo Facebook, utilizado na previsão de séries temporais que tem por base um modelo aditivo onde as tendências não lineares são ajustadas à sazonalidade e tem também atenção aos feriados (Sean e Benjamin, 2020). Assim, de acordo com os autores Sean e Benjamin, em 2020, este modelo é baseado numa função que combina os três principais componentes (tendência, sazonalidade e feriados) de uma série temporal:

$$Y_t = g_t + s_t + h_t + \epsilon_t \quad (2.3)$$

Na equação (2.3),  $g_t$  é a função da tendência que modela mudanças não periódicas nos valores da série temporal,  $s_t$  representa mudanças periódicas (neste caso, a sazonalidade diária da série temporal dos preços do petróleo),  $h_t$  representa o efeito dos feriados que ocorrem em horários potencialmente irregulares em um ou mais dias e o termo de erro ( $\epsilon_t$ ) representa quaisquer mudanças que não são englobadas pelo modelo (Sean e Benjamin, 2017).

#### 2.2.4. DARTS

DARTS é um pacote de código aberto desenvolvido pela Unit8<sup>4</sup>, que incorpora a maioria dos métodos de previsão de séries temporais amplamente usados que se conhece de pacotes *Python* (Heiko Onnen, 2021). Neste estudo foram analisados os modelos: *Naïve Drift*, *Exponential Smoothing*, *Theta Method*, *Neural Basis Expansion Analysis Time Series Forecasting* (N-Beats) e ARIMA.

**Naïve Drift:** este modelo é uma variação do método *Naïve* que permite que as previsões aumentem ou diminuam ao longo do tempo, onde a quantidade de mudança ao longo do tempo (*drift*) é definida como a mudança média vista nos dados históricos (Rob e George, 2018).

**Exponential Smoothing:** é um método de previsão de séries temporais para dados univariados que podem ser estendidos para suportar dados com tendência ou componente sazonal (Jason Brownlee, 2018).

**Theta Method:** é um método de previsão para dados univariados que através de um coeficiente “*Theta*” ( $\theta \in \mathbb{R}$ ) altera a curvatura da série temporal, onde as novas linhas geradas mantém a média e inclinação da curvatura da série original (V. Assimakopoulos e K. Nikolopoulos, 2000), (Grzegorz Dudek, 2019).

**N-beats:** este modelo consiste numa sequência de pilhas, que combinam com vários blocos (Heiko Onnen, 2022). De acordo com o autor, estes conectam-se com redes *feedforward* por *forecast* e *backcast links*, definindo assim o erro residual dos blocos anteriores gerando uma previsão parcial. O autor refere que a pilha agrega as previsões parciais nos blocos que ela compreende e, em seguida, entrega o resultado para a próxima pilha e no fim, as previsões parciais são reunidas numa previsão global no nível do modelo. Os parâmetros aplicados neste modelo que obtiveram melhores resultados foram os seguintes:

- Comprimento de entrada de 200;
- Comprimento de saída de 20;
- Cada pilha é combinada com 4 blocos (*num\_blocks*);
- 2 camadas que precedem as camadas finais (*num\_layers*);
- 100 épocas que o modelo treina (*n\_epochs*).

---

<sup>4</sup> Unit8 é uma empresa com sede na Suíça, especializada em análise de dados e inteligência artificial (Heiko Onnen, 2021).

Para além dos modelos descritos acima, também se utilizou o modelo ARIMA, através do pacote DARTS, tendo sido o modelo que apresentou os piores resultados na grande maioria das métricas de performance calculadas.

### 2.2.5. LSTM

O algoritmo *Long Short-Term Memory* (LSTM) foi desenvolvido por (Sepp e Jürgen, 1997) e apresenta uma arquitetura baseada nas redes neuronais recorrentes (RNN) que tem sido muito utilizada em processamento de linguagem natural (NLP – *Natural Language Processing*) e em previsão de séries temporais (Nurul *et al.*, 2022). Os mesmos autores referem ainda que este tipo de rede neural tenta solucionar o problema de previsão através de resultados passados, pois, como o próprio nome refere, admite e analisa memórias de longo e de curto prazo.

Este modelo possui redes com *loop* para passar informações de uma etapa para outra e suportar informações para persistir, sendo composta por uma célula, uma porta de entrada, uma porta de saída e uma porta de esquecimento (Nurul *et al.*, 2022) conforme se pode verificar na Figura 9.

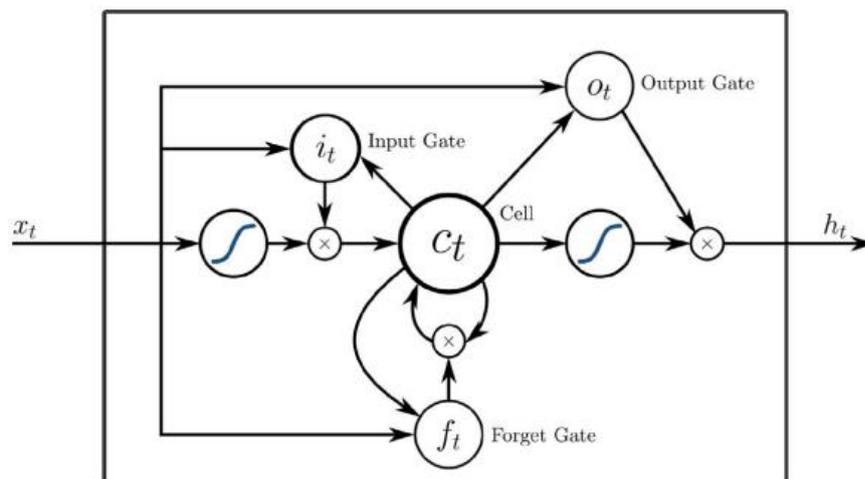


Figura 9: Diagrama dos componentes da LSTM

Antes de se aplicar o modelo *Long Short-Term Memory*, definiu-se alguns parâmetros iniciais:

- Percentagem dos dados correspondente ao conjunto de teste;
- Percentagem dos dados correspondente ao *cross-validation*;
- Número de unidades do espaço de saída = 100;
- Probabilidade de entradas que podem ser descartadas (*Dropout\_prob* = 0,5);

- Optimizador Adam<sup>5</sup>;
- Número de épocas = 50;
- Quantidade de dados que alimentam a rede (*batch\_size* = 150).

Para além destes parâmetros e à semelhança do que se desenvolveu em modelos anteriores, também se fixou uma *seed* de 101 para a rede LSTM, de forma a se obter sempre os mesmos resultados durante as corridas executadas no desenvolver deste estudo.

## 2.3. MÉTRICAS DE PERFORMANCE

As métricas de *performance* são amplamente utilizadas para avaliar a eficiência dos modelos de previsão. Existem várias métricas que podem ser usadas para medir a precisão e a eficácia de um modelo de previsão de séries temporais (Ajitesh Kumar, 2022). Assim, avaliou-se a *performance* dos modelos através das seguintes métricas: *Mean Absolute Percentage Error* (MAPE), *Mean Absolute Error* (MAE), *Root Mean Squared Error* (RMSE) e *Mean Squared Error* (MSE).

### 2.3.1. MAE

O *Mean Absolute Error* (MAE) é a base do erro *Mean Absolute Percentage Error* (MAPE), a grande diferença entre eles é que o MAPE retorna a percentagem e este indica-nos através do valor a discrepância do erro. O MAE é a média sobre a amostra de teste das diferenças absolutas entre a previsão ( $\hat{y}_t$ ) e observação real ( $y_t$ ) onde todas as diferenças individuais têm peso igual (Jilmun, 2016).

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (2.4)$$

### 2.3.2. MAPE

O *Mean Absolute Percentage Error* (MAPE) é uma medida relativa que dimensiona o desvio absoluto médio (MAD) para resultar em unidades percentuais em vez de unidades da variável, ainda assim utiliza valores absolutos para evitar que os erros positivos e negativos se cancelem e utiliza erros relativos para permitir a comparação da previsão entre modelos de séries temporais (“MAPE (*Mean Absolute Percentage Error*),” 2022).

---

<sup>5</sup> Adaptive Moment Estimation é um algoritmo de técnica de otimização para gradiente descendente. O método é realmente eficiente ao trabalhar com grandes problemas envolvendo muitos dados ou parâmetros (GeeksforGeeks, 2020).

A equação (2.5) mostra o cálculo do erro MAPE através dos valores reais e previstos de cada ponto, onde  $n$  é o número de pontos treinados,  $y_t$  representa o valor real e  $\hat{y}_t$  o valor predito (Stephanie, 2022).

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (2.5)$$

### 2.3.3. MSE

O *Mean Squared Error* (MSE) é uma métrica que nos retorna a diferença média ao quadrado entre os valores previstos e os valores reais (Zach, 2021). À semelhança do *Root Mean Squared Error* (RMSE), neste caso também se considera o melhor modelo aquele que resultar num valor de MSE mais baixo.

Posto isto, o MSE é medido de acordo com a seguinte equação:

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (2.6)$$

### 2.3.4. RMSE

O *Root Mean Squared Error* (RMSE) é uma regra de pontuação quadrática que também mede a magnitude média do erro, ou seja, é a raiz quadrada da média das diferenças quadradas entre previsão e observação real (Jilmun, 2016).

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (2.7)$$

Além disso, esta métrica de *performance* é considerada a mais comum utilizada na medição da precisão e eficácia de um modelo de previsão de séries temporais (Ajitesh Kumar, 2022), servindo assim de meio de comparação entre os diversos modelos.

O resultado do RMSE também é dado de acordo com as unidades do nosso conjunto de dados, pelo que quanto menor for o resultado melhor será o modelo.



## RESULTADOS E DISCUSSÃO

Esta secção é composta pela análise de todos os resultados obtidos nos diversos modelos testados assim como a sua consolidação e comparação. Todos os modelos foram avaliados pelas 4 métricas de *performance* descritas na secção anterior e que irão servir de meio de comparação, tendo como finalidade avaliar qual o modelo que apresentou um melhor ajuste ao conjunto de dados.

### 3.1. RESULTADOS OBTIDOS POR CADA MODELO

Primeiramente, através do modelo ARIMA realizou-se a previsão conforme referido anteriormente através da parametrização do AutoArima do qual se verificou que o melhor modelo sugerido foi ARIMA(0,1,1)(0,0,0)[0].

Posto isto, com o melhor modelo extraiu-se as métricas, que constam na tabela abaixo, dos seguintes cenários:

- **Modelo A1:** aplicação do modelo ARIMA onde se obteve o melhor modelo com base no critério AIC, métricas aplicadas ao conjunto de teste;
- **Modelo A2:** aplicação do modelo ARIMA onde se obteve o melhor modelo com base no critério AIC, métricas de acordo com o conjunto de treino;
- **Modelo A3:** previsão com o melhor modelo *step-by-step*, métricas aplicadas ao conjunto de teste;
- **Modelo A4:** previsão com o melhor modelo *step-by-step*, métricas de acordo com o conjunto de treino.

Conforme se pode observar pelos resultados obtidos na Tabela 5, os modelos A1 e A2 apresentam uma grande discrepância nos resultados entre eles das diversas métricas, devido à função `auto_arima`.

Devido a resultados como um MAPE de 43,5988%, que nos indica que os valores da nossa previsão estão cerca de 43% desfasados do valor real e um RMSE de 35.7034, que nos informa que a nossa estimativa está com um desfasamento de em média cerca de 35 dólares, procedeu-se à execução do AutoArima *step-by-step* onde se notou que o facto de se estar a estimar ponto a ponto influencia imenso a previsão.

Tabela 5: Resultados obtidos com o modelo ARIMA sobre o conjunto de teste e treino

	MAPE	MAE	RMSE	MSE
<b>MODELO A1</b>	43.5988%	29.1962	35.7034	1274.7326
<b>MODELO A2</b>	1.5890%	0.9235	1.3489	1.8195
<b>MODELO A3</b>	2.5301%	1.2755	2.0316	4.1273
<b>MODELO A4</b>	1.5841%	0.9227	1.3313	1.7723

Ainda assim, obteve-se um MAPE de aproximadamente 2,5% aplicado ao conjunto de teste, um MAE que apresenta um desfasamento de cerca de 1.27 dólares, um RMSE de 2.03 dólares e um MSE de 4.12 dólares de desfasamento que demonstram que o modelo teve um bom ajuste face aos valores reais. Esse ajuste é visível na Figura 10.

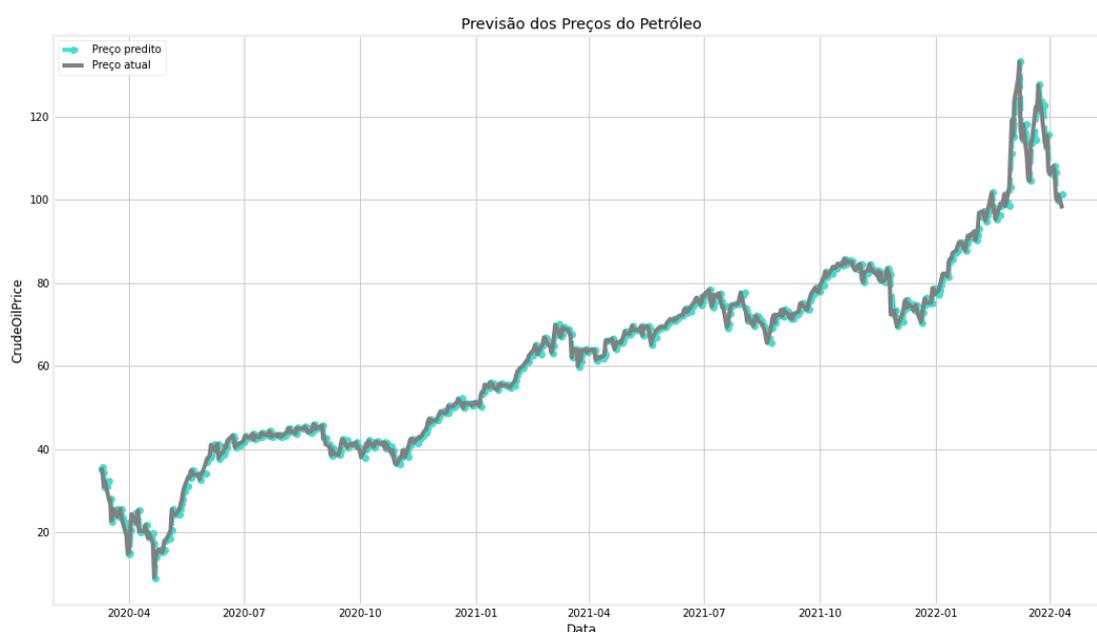


Figura 10: Série Temporal dos Preços Atuais e Preditos

Comparando os resultados do modelo A1 com os do A2 parece existir *overfitting*, visto que os resultados ótimos no conjunto de treino e bastante discrepantes no conjunto de teste, o que quer dizer que o modelo “decorou” os valores e não aprendeu a previsão. Além disso, o *overfitting* é uma prática associada a este modelo mesmo com uma análise aprofundada dos parâmetros utilizados. Já no modelo A3 e A4 não se verifica a existência de *overfitting*.

A *Random Walk* também foi aplicada ao conjunto de treino e de teste, ficando com os seguintes cenários:

- **Modelo B1:** *Random Walk* gerada com o tamanho do conjunto de teste;
- **Modelo B2:** *Random Walk* gerada com o tamanho do conjunto de treino com o intuito de se aplicar as métricas nos dados de treino.

Antes de proceder à análise dos resultados propriamente ditos, é importante referenciar que o Modelo B2 realizou-se para verificar qual o impacto que teria se aumentássemos o tamanho do conjunto de previsão. Assim sendo, na Tabela 6 verificou-se uma pequena deterioração dos resultados obtidos. O MAPE sofreu um aumento de aproximadamente 1%, enquanto o RMSE aumento cerca de 7 dólares.

Com um MAPE de 43%, um desfasamento de aproximadamente 5 e 7 dólares no MAE e RMSE respetivamente, conclui-se que este modelo não obteve bons resultados.

Tabela 6: Resultados obtidos com o modelo *Random Walk* sobre o conjunto de teste e treino

	MAPE	MAE	RMSE	MSE
<b>MODELO B1</b>	43.3151%	28.9749	35.5083	1260.8383
<b>MODELO B2</b>	44.4510%	33.2604	42.2233	1782.8074

Adicionalmente, também se utilizou o modelo *Prophet* porque é uma biblioteca de código aberto projetada para fazer previsões para conjuntos de dados de séries temporais univariadas (Jason Brownlee, 2020), tal como o conjunto de dados que está a ser trabalhado. Através do *Prophet* obteve-se as métricas dos seguintes cenários:

- **Modelo C1:** *Prophet* aplicado ao conjunto de teste;
- **Modelo C2:** *Prophet* aplicado ao conjunto de treino.

Ao observar os resultados obtidos da Tabela 7, verificamos que a grande maioria apresenta uma diferença superior ao dobro comparando os resultados do modelo C1 com o modelo C2. A percentagem da métrica MAPE diminuiu aproximadamente 26% quando aplicada ao conjunto de treino, embora continue um pouco alta (cerca de 14%) uma vez que o modelo foi treinado com esses mesmo dados e nem assim os consegue prever com exatidão.

Tabela 7: Resultados obtidos no modelo Prophet sobre o conjunto de teste e treino

	MAPE	MAE	RMSE	MSE
<b>MODELO C1</b>	39.9274%	17.9639	21.9048	479.8231
<b>MODELO C2</b>	14.1566%	8.5685	11.5481	133.3578

Para além do MAPE, também se nota essa diferença nos restantes especialmente no MSE que o valor médio dos erros cerca de 346 dólares, continuando sem apresentar um bom ajuste. Embora existam estas discrepâncias entre estes modelos considera-se que existiu *overfitting* visto que a diferença entre os erros percentuais sobre treino e teste são significativas.

Conforme podemos ver na Figura 11 através da região a azul (intervalo de previsão), o intervalo de valores que podem ser registados ainda é elevado. Ainda assim, também é observável que os grandes picos são difíceis de prever, visto que não estão contemplados na região com os possíveis valores.

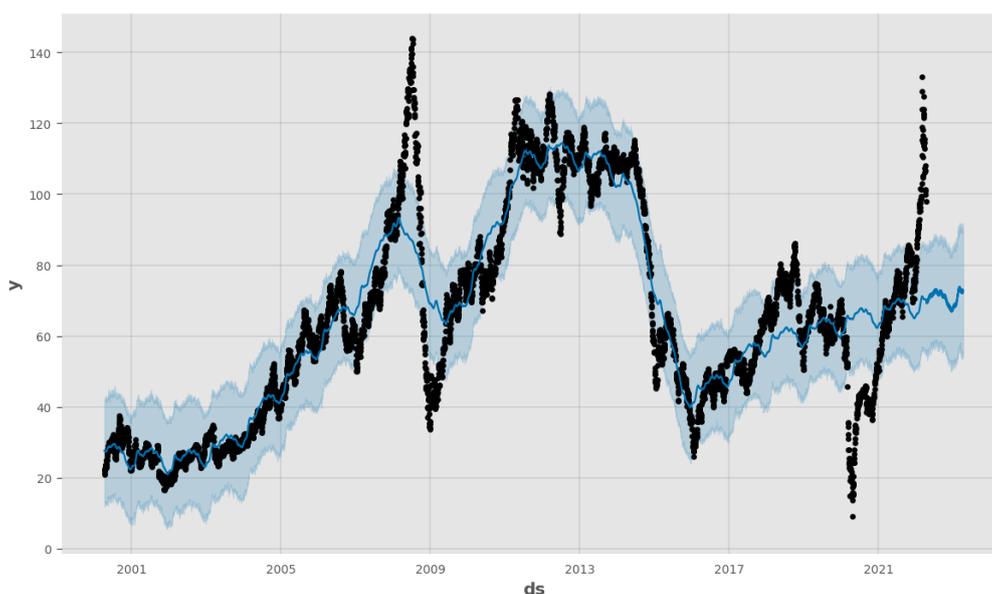


Figura 11: Série Temporal dos Valores Preditos e Atuais

Com o *package* DARTS, testou-se os seguintes modelos:

- **Modelo D1:** *Naive Drift* aplicado ao conjunto de teste;
- **Modelo D2:** *Exponential Smoothing* aplicado ao conjunto de teste;
- **Modelo D3:** *Theta method* aplicado ao conjunto de teste;
- **Modelo D4:** *AutoArima* aplicado ao conjunto de teste;
- **Modelo D5:** *N-beats* aplicado ao conjunto de teste.

Nestes modelos não se calculou através do código o valor do MSE, no entanto tendo o RMSE é algo bastante fácil de se fazer manualmente. Como o RMSE nos indica informações mais relevantes não se deu importância em calcular a métrica MSE. Além disso, estes modelos foram aplicados a dois conjuntos de previsão: A – previsão de 545 dias; B – previsão de 205 dias.

Inicialmente, aplicou-se os modelos para prever 545 dias conforme se tinha realizado a previsão nos modelos anteriores.

Observando os resultados da Tabela 8, podemos verificar que todos os modelos apresentaram um MAPE superior a 30%, pelo que se considera um desfasamento face ao preço real elevado. No entanto, verificou-se que os modelos que melhor se adaptaram foram o modelo D3-A e D5-A, com valores a rondar os 14 e os 18 dólares por barril nas métricas MAE e RMSE, respetivamente.

Os restantes três modelos apresentaram resultados relativamente piores, apresentando um MAE por volta dos 20 dólares por barril e um RMSE a rondar os 24 dólares por barril.

*Tabela 8: Resultados obtidos com o pacote Darts sobre o conjunto de teste de 545 dias*

	<b>MAPE</b>	<b>MAE</b>	<b>RMSE</b>	<b>MSE</b>
<b>MODELO D1 - A</b>	37.3302%	19.8176	24.2223	-
<b>MODELO D2 - A</b>	37.3127%	19.8307	24.2446	-
<b>MODELO D3 - A</b>	32.2814%	14.5659	18.1661	-
<b>MODELO D4 - A</b>	38.4395%	20.9094	25.6404	-
<b>MODELO D5 - A</b>	34.1904%	14.1173	18.8885	-

Derivado dos resultados obtidos nos modelos acima, decidiu-se verificar o comportamento dos modelos com um conjunto de previsão menor, pelo que se passou de 545 dias preditos para 205 dias.

Posto isto, os resultados obtidos pelos modelos aquando da previsão de um número de dias menor foram mais promissores encontra-se na Tabela 9. Os modelos D1-B, D2-B e D4-B apresentaram resultados bastante semelhantes em todas as métricas. O MAPE ronda os 11% de desfasamento, assim como o MAE e o RMSE apresentam uma variação de aproximadamente 11 e 16 dólares, respetivamente. Estes resultados não são ótimos, mas podem servir de comparação.

Os modelos mais simples, como o *Naive Drift*, muitas vezes são o ponto de partida de modelos mais complexos, pelo que servem de base de comparação (Rob e George, 2018) para garantir que os novos modelos são bons modelos de previsão e que apresentam resultados mais promissores.

O modelo D2-B utilizou-se devido a este não ser um excelente modelo a lidar com a tendência (Natalie Regoli, 2016) e como esta série não apresenta sazonalidade poderia ser uma boa opção. No entanto, o facto dos resultados terem sido medíocres pode estar relacionado com o facto deste modelo trabalhar melhor no curto-prazo tal se comprova com a melhoria dos resultados quando se diminuiu de uma previsão de 545 dias para 205 dias. No entanto, ainda se considera uma previsão de médio/longo-prazo.

Para além disso, os outros modelos, D3-B e D5-B, também apresentaram resultados semelhantes entre eles no que toca ao RMSE, rondando os 12 dólares por barril, pois nas outras métricas o modelo D3-B apresentou um MAPE de aproximadamente 9,5%, cerca de 3% mais baixo do que o modelo D5-B. No MAE o valor do modelo D3-B rondou os 8 dólares de desfasamento do valor real enquanto no modelo D5-B registou um desfasamento de cerca de 10 dólares por barril. Com isto, podemos concluir que o modelo que apresentou melhores resultados na grande maioria das métricas foi o modelo D3-B.

Tabela 9: Resultados obtidos com o pacote Darts sobre o conjunto de teste de 205 dias

	MAPE	MAE	RMSE	MSE
<b>MODELO D1 - B</b>	11.1578%	10.8011	16.0985	-
<b>MODELO D2 - B</b>	11.1644%	10.8122	16.1228	-
<b>MODELO D3 - B</b>	9.4832%	8.7696	12.5948	-
<b>MODELO D4 - B</b>	11.2748%	10.8514	16.0978	-
<b>MODELO D5 - B</b>	12.4407%	10.1472	12.1827	-

Ainda assim, é possível verificarmos como se comportaram os modelos na Figura 12 e como foi o ajuste. Conforme se pode observar, o *N-beats*, modelo D5-B, foi o modelo que apresentou um melhor ajuste já sendo expectável devido a apresentar erros menores face aos outros modelos, com exceção do modelo *Theta* (D3-B). O modelo D3-B que também apresentava dos melhores resultados conseguimos ver que acompanha o padrão crescente da séries, mas não se ajusta muito bem aos picos.

Os restantes modelos, apresentam uma previsão quase em linha reta o que se comprova com as discrepâncias registadas na tabela na ordem dos 11 e 16 dólares nas métricas MAE e RMSE, respetivamente.

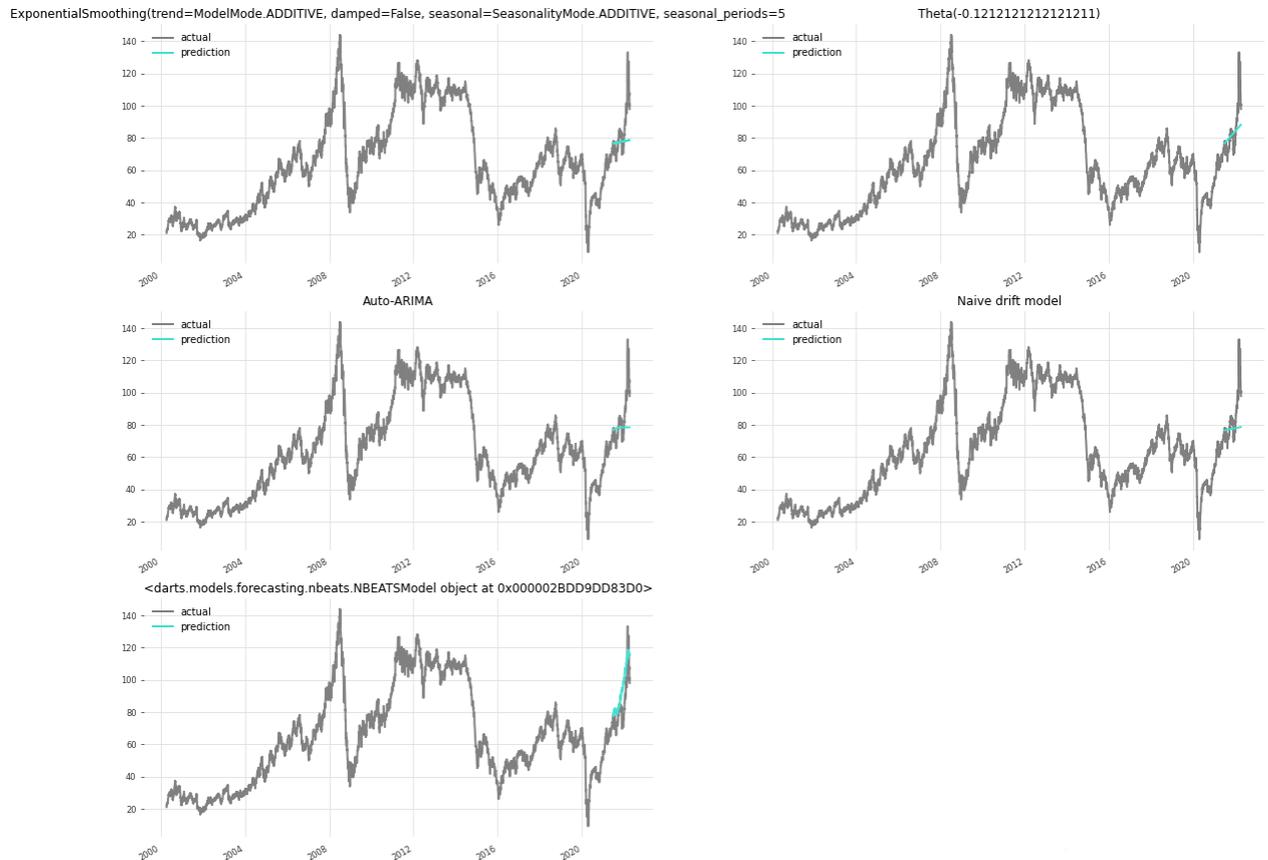


Figura 12: Séries Temporais com a previsão dos modelos utilizados com o package DARTS para um conjunto de 205 dias

Por fim, como último modelo testou-se a rede neuronal LSTM, onde se extraiu as métricas nos seguintes cenários:

- **Modelo E1:** LSTM aplicado ao conjunto de validação;
- **Modelo E2:** LSTM aplicado ao conjunto de teste.

Neste modelo, aplicou-se *tunning* através da otimização bayesiana e escolheu-se 12 lags, ou seja, prevê-se o 13º dia com base nos 12 dias anteriores com uma probabilidade de *dropout* de 0,5. Considerou-se 100 unidades do espaço de saída e 50 épocas. Assim, obteve-se uma rede neuronal com 12 *inputs*, 2 camadas intermédias cada uma com 100 nós para se obter o *output* final. Na Figura 13 é visível a arquitetura idêntica à que foi gerada pelo modelo LSTM nesta dissertação, ou seja, na *input layer* existem 12 inputs, na *layer 1* e *layer 2* constam 100 nós e por fim é gerado o *output*.

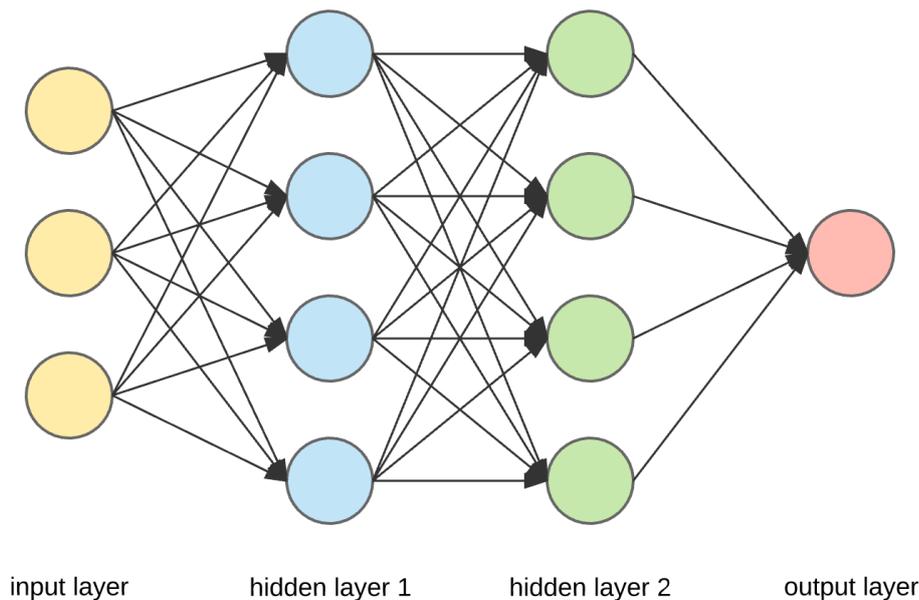


Figura 13: Exemplo de arquitetura de Rede Neural LSTM - Arden Dertat, 2017

No modelo LSTM, o conjunto de treino foi dividido em duas partes com tamanhos diferentes de forma a gerar-se um conjunto de validação. Assim, ficámos com um conjunto de treino composto por 4621 registo e um conjunto de validação composto por 574 registos. Posto isto, observou-se que quando se aplicou o modelo ao conjunto de validação os resultados foram bastante bons, uma vez que se obteve um MAPE de aproximadamente 2.7% assim como um MAE e um RMSE com um desfasamento de 1.7 e 2.2 dólares, respetivamente. Para além disso, também o MSE apresenta um valor médio ótimo de aproximadamente 5.0 dólares, que corresponde à média da soma de todos os erros.

Em relação ao modelo E2, onde se aplicou o modelo ao conjunto de teste, verificou-se métricas com valores bastante promissores. O modelo apresentou um MAPE com cerca de 3.8% de discrepância entre o valor real e o valor predito, cerca de 2.0 dólares de desfasamento de acordo com a métrica MAE e 2.8 dólares de acordo com o RMSE. Relativamente à métrica MSE, apresenta uma média da soma dos erros dos 545 registos de aproximadamente 7.9 dólares.

Entre os dois cenários apresentados na Tabela 10, podemos concluir que a previsão no conjunto de validação obteve melhores resultados, embora o conjunto apresente mais 29 registos. Contudo, estes resultados podem justificar-se pelo facto de no conjunto de validação não existirem picos acentuados que é o que acontece no conjunto de teste.

Tabela 10: Resultados obtidos com o modelo LSTM sobre o conjunto de validação e teste

	MAPE	MAE	RMSE	MSE
<b>MODELO E1</b>	2.6778%	1.7174	2.2495	5.0600
<b>MODELO E2</b>	3.8639%	2.0492	2.8183	7.9431

De acordo com a Figura 14, podemos verificar que a previsão do modelo E1 conseguiu ter um excelente ajuste ao conjunto de validação, pelo que se espera ter bons resultados também no conjunto de teste. Os valores previstos apresentaram um excelente ajuste, o que já era de esperar tendo em conta as métricas apresentadas na Tabela 10.



Figura 14: Série Temporal com a previsão sobre o conjunto de validação com o modelo LSTM

Na Figura 15, à semelhança do que se verificou na Figura 14, também é visível um bom ajuste dos valores de previsão face ao conjunto de teste. Assim, é possível concluir que este é um modelo muito interessante para a previsão de preços do petróleo conseguindo adaptar-se com um erro relativamente baixo às variações apresentadas pela série temporal.



Figura 15: Série Temporal com a previsão sobre o conjunto de teste com o modelo LSTM

De forma a realçar a discrepância entre os valores reais e os valores preditos, retirou-se este plano aproximado de uma parte do conjunto de teste (Ver Figura 16), para que se perceba que estamos perante erros mínimos.

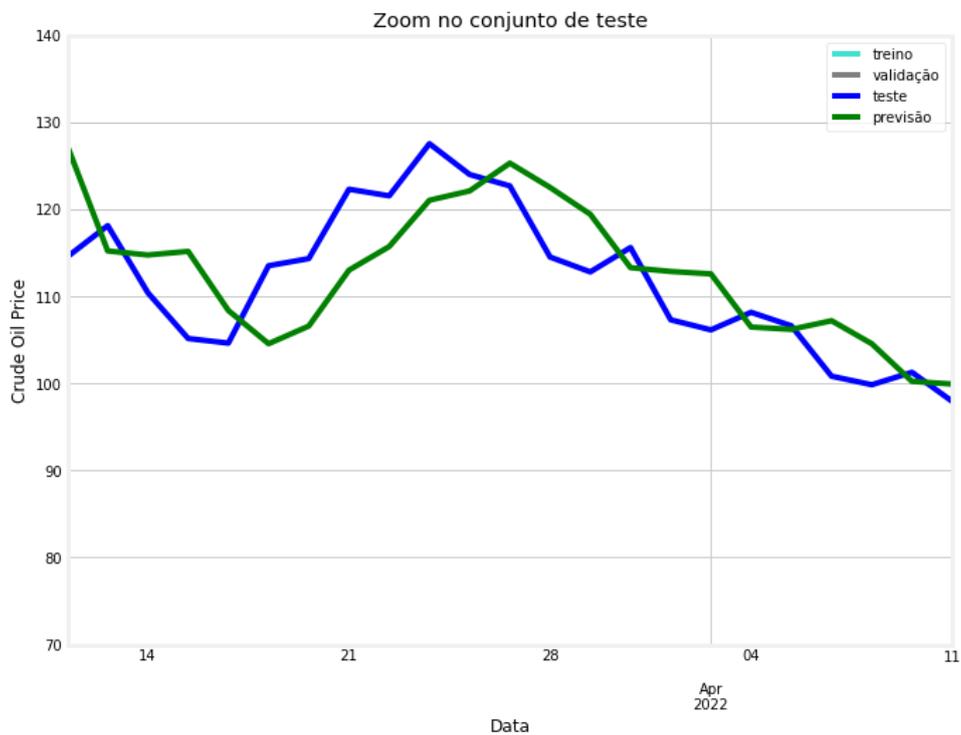


Figura 16: Aproximação da previsão sobre o conjunto de teste com o modelo LSTM

### 3.2. CONSOLIDAÇÃO DOS RESULTADOS OBTIDOS

De uma forma geral, podemos concluir que se obteve um grande leque de valores nos diferentes modelos, dos quais alguns apresentaram um bom comportamento e outros um comportamento menos bom.

Os modelos B e C registaram métricas com valores muito altos face aos restantes pelo que não faz qualquer sentido os utilizar neste tipo de previsão. O modelo A1 também é automaticamente excluído, pois como dissemos anteriormente a função `auto_arima` encontra-se quase sempre em *overfitting*, pelo que também não seria uma boa opção.

Os modelos D que foram tidos em conta na Tabela 11 são os modelos que foram previstos para o intervalo de 545 dias, visto ser a forma mais justa de comparar modelos de previsão entre si. Contudo, os erros registados para estes modelos são elevados tornando a previsão pouco precisa. No entanto, através do *AutoArima step-by-step* (Modelo A3 e A4) e dos modelos E obteve-se excelentes resultados pelo que a previsão de séries temporais do preço do petróleo pode passar pelo uso destes modelos.

Para as economias estes valores são muito importantes pois influenciam muitos preços de outros produtos, atingindo assim a vida da população.

Tabela 11: Consolidação dos resultados obtidos em todos os modelos

	MAPE	MAE	RMSE	MSE
MODELO A1	43.5988%	29.1962	35.7034	1274.7326
MODELO A3	2.5301%	1.2755	2.0316	4.1273
MODELO B1	43.3151%	28.9749	35.5083	1260.8383
MODELO C1	39.9274%	17.9639	21.9048	479.8231
MODELO D1 - A	37.3302%	19.8176	24.2223	-
MODELO D2 - A	37.3127%	19.8307	24.2446	-
MODELO D3 - A	32.2814%	14.5659	18.1661	-
MODELO D4 - A	38.4395%	20.9094	25.6404	-
MODELO D5 - A	34.1904%	14.1173	18.8885	-
MODELO E2	3.8639%	2.0492	2.8183	7.9431

Contrariamente ao estudo dos autores Bin e Jun, em 2019, em que o modelo SARIMA mostra um desempenho mais baixo do que os outros modelos e o LSTM geralmente pode formar uma boa previsão. Além disso, é importante ter em conta que os autores anteriores não utilizaram a previsão ponto a ponto no modelo SARIMA daí os resultados serem menos promissores que os outros modelos. Isto mostra que embora esta dissertação e o estudo dos autores prevejam ambos os mesmos dados, como o intervalo de tempo não foi o mesmo e o modelo ARIMA não foi aplicado de igual forma, obteve-se resultados opostos face aos modelos LSTM e ARIMA.

Conforme se pode verificar na Tabela 11, o modelo *Random Walk* apresentou dos piores resultados, sendo normalmente utilizado como referência a ser superada na previsão de preços (Sabri, Zhenya e Yifan, 2022).

Complementarmente, conciliou-se todos os valores preditos por todos os modelos na Figura 17 para visualizar o comportamento dos mesmos. Na Figura 17, incluiu-se o conjunto de teste visto este representar as previsões reais para se conseguir comparar e identificar quais os modelos que conseguiram o melhor ajuste e a melhor performance.

Assim sendo, é possível concluir que os modelos ARIMA *step by step* e a rede neuronal LSTM foram os únicos que conseguiram acompanhar o conjunto de teste. A *Random Walk* e o modelo ARIMA ficaram muito longínquos dos valores reais. Estes resultados já eram de esperar visto que a Figura 17 vai ao encontro dos erros registados na Tabela 11.

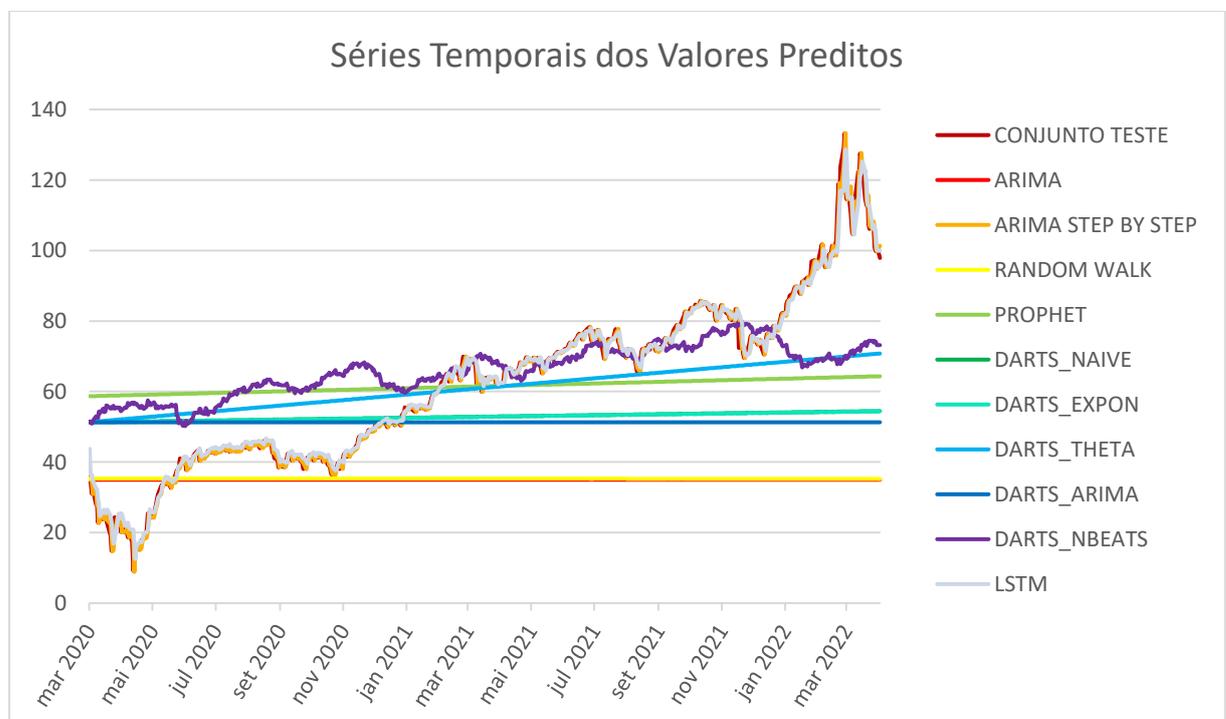


Figura 17: Valores Reais e Valores Preditos pelos diferentes modelos

## CONCLUSÕES

Conforme já foi referido anteriormente, esta dissertação aborda um tópico muito interessante para a economia de um país, dando maior ênfase à economia portuguesa por ser o país onde resido, visto que o preço do petróleo tem um grande impacto na economia.

Adicionalmente, o preço do petróleo tem um efeito extraordinário nos mercados financeiros internacionais (Seçkin *et al.*, 2021). O facto de que as volatilidades nos preços do petróleo têm um impacto notável no crescimento económico, nos mercados de títulos, nas taxas de relatórios de ações e na segurança nacional torna necessário prever o preço do petróleo com alta precisão (Seçkin *et al.*, 2021, como citado em Francesco *et al.*, 2017; Hooman *et al.*, 2020).

Posto isto, conclui-se que esta dissertação à semelhança dos estudos realizados por diversos autores analisados na literatura poderá servir de base para ser utilizada no estudo da economia, uma vez que ao prever as flutuações é possível tomar decisões antecipadas que consigam melhorar as condições de vida da população.

Atualmente, estes estudos são imprescindíveis pois estamos perante uma situação económica instável que começou com a guerra da Ucrânia e o primeiro impacto que se sentiu foi precisamente nos preços do petróleo que depois deu azo à subida de preços em diversos produtos e serviços. Devido a todos estes fatores o nível de vida em Portugal subiu e estamos prestes a entrar numa recessão económica que se espera que seja contornada com algumas decisões derivadas de estudos de previsão, como o da série temporal do petróleo utilizada nesta tese. Para os países importadores de petróleo, a persistência dos preços do petróleo é importante para determinar as políticas de metas de inflação (Melike *et al.*, 2020).

Para lidar com o facto dos preços do petróleo serem difíceis de prever, as previsões podem ser feitas usando métodos clássicos, mas esses métodos de estimativa só podem fornecer resultados benéficos por curtos períodos (Didem, 2020), como o modelo ARIMA. Por outro lado, para observar a tendência de preços de longo prazo, são desenvolvidas as redes neurais artificiais, adequadas e úteis para tendências de longo prazo (Didem, 2020), tendo-se aplicado modelos como LSTM e *Prophet*.

A previsão realizada englobou 545 dias, praticamente 1 ano e meio, com o intuito de avaliar o comportamento dos modelos numa previsão a médio/longo-prazo visto ser onde a rede neuronal LSTM tem grande destaque. Anteriormente, apenas era possível realizar previsões a curto-prazo pelo que a previsão era realizada para poucos dias. Embora se pudesse prever a longo-prazo os resultados eram muito maus e não tinham precisão alguma, o que não favorecia nada a aplicabilidade dos modelos assim como a tomada de decisões.

Em contrapartida, caso se diminuísse o número de dias preditos nesta dissertação possivelmente iríamos obter resultados mais promissores, uma vez que com menos dados para prever os modelos normalmente apresentam um ajuste melhor, ou seja, os erros obtidos iriam apresentar resultados mais baixos. Este ponto foi possível verificar nos modelos D quando se diminuiu o número de dias predito, mas é de realçar que carece de um estudo mais aprofundado para se conseguir aferir qual deverá ser a dimensão da previsão a ser realizada.

Com este trabalho concluiu-se também que os modelos que obtiveram melhores resultados foram os modelos mais analisados na literatura, ou seja, o modelo ARIMA e a rede neuronal LSTM. O modelo ARIMA apresentou um MAPE de aproximadamente 2,5% e a rede LSTM de 3,8%, já o RMSE rondou os 2 dólares por barril em ambos os modelos. Embora estes resultados sejam bastante promissores, é comum analisar-se modelos complementares que venham melhorar os pontos em que estes modelos não são tão fortes. Assim sendo, este considera-se ser um ponto a ser abordado em trabalhos futuros ou de forma a complementar esta análise. Nota-se ainda, que o LSTM se destaca na previsão a médio/ longo prazo, pois apesar do ARIMA *step by step* ter um erro menor, continua a empregar uma previsão ao curto prazo, mas construída de forma iterativa.

Ainda assim, também se pode concluir que existem alguns modelos que embora tenham sido muito pouco ou nada estudados também apresentaram bons resultados, como por exemplo o *Prophet* e o *Theta*. Embora os valores do MAPE, quando previstos para um intervalo menor, tenham sido entre os 9%-11% são valores bastante promissores que carecem de uma análise mais aprofundada futuramente.

Por conseguinte, todos os modelos foram avaliados com as métricas mais utilizadas em séries temporais, conforme se comprovou através da análise da literatura realizada anteriormente. Estas métricas, permitiram que fossem realizadas comparações entre os modelos.

Durante a realização deste trabalho, existiram algumas limitações como por exemplo a comparação entre modelos completamente diferentes nem sempre ser justa ainda assim resultou em resultados muito promissores e relativamente semelhantes. Em adição, é necessário referir que alguns dos modelos utilizados apresentam melhores resultados quando se prevê num curto-prazo enquanto outros se revelam melhor quando estão perante uma previsão a longo-prazo.

Ainda assim, existe também o fator intervalo de tempo que é necessário ter em conta, pois embora não tenha sido propriamente uma limitação, foi notável através da literatura que os resultados foram diversos para a previsão dos preços do petróleo Brent pois os períodos de tempo em análise eram diferentes, e, em períodos diferentes ocorrem eventos diferentes.

É importante ter em conta estas limitações para os próximos passos, uma vez que podem ser pontos fulcrais na comparação de modelos de previsão nesta série temporal. Não obstante, é igualmente importante verificar se as métricas também apresentam diferentes adaptações a certos intervalos de previsão.

Como trabalho futuro, será importante aprofundar a análise de alguns modelos também bastante utilizados pelos artigos analisados e perceber quais as melhores métricas para medir a *performance* dos mesmos, assim como conjugar alguns modelos que possam ser complementares como já foi referido.

Para além disso, embora este estudo se baseie numa análise univariada dos preços do petróleo *Brent* poderia ser bastante relevante adicionar variáveis exógenas, como por exemplo o valor do dólar ou variáveis macroeconómicas, com o intuito de melhorar os resultados obtidos e verificar qual seria o impacto dessas mesmas variáveis na previsão dos preços do petróleo.

Posteriormente, esta análise também poderia ser aplicada em outros conjuntos de dados de preços de petróleo, como por exemplo o *West Texas Intermediate (WTI) Crude*, para servir como meio de comparação e conseguir-se identificar se as séries teriam o mesmo comportamento ou não.

Embora o tema abordado nesta dissertação esteja a ser cada vez mais estudado, ainda carece de um estudo mais aprofundado visto ser um tema bastante complexo e com diversas influências externas. No entanto, torna-se bastante interessante para quem gosta de analisar possíveis aplicabilidades úteis no mundo económico.



## REFERÊNCIAS BIBLIOGRÁFICAS

6. Tips to using auto\_arima — pmdarima 2.0.1 documentation. (2022). Acedido a 30 de Abril, 2022, em: [https://alkaline-ml.com/pmdarima/tips\\_and\\_tricks.html](https://alkaline-ml.com/pmdarima/tips_and_tricks.html)
- Abdollahi, H., & Ebrahimi, S. B. (2020). A new hybrid model for forecasting Brent crude oil price. *Energy*, 200, 117520.
- Ahmed, N. K., Atiya, A. F., Gayar, N. E., & El-Shishiny, H. (2010). An Empirical Comparison of Machine Learning Models for Time Series Forecasting. *Econometric Reviews*, 29(5–6), 594–621.
- Ali, R. (2022, March 18). Predictive Modeling: Types, Benefits, and Algorithms. Acedido a 25 de Outubro, 2022, em: <https://www.netsuite.com/portal/resource/articles/financial-management/predictive-modeling.shtml>
- Amadeo, K. (2022, June 6). What Is Crude Oil? Acedido a 29 de Outubro, 2022, em: <https://www.thebalancemoney.com/crude-oil-prices-trends-and-impact-on-the-economy-and-you-3305738>
- Asiah, M., Nik Zulkarnaen, K., Safaai, D., Nik Nurul Hafzan, M. Y., Mohd Saberi, M., & Siti Syuhaida, S. (2019). A Review on Predictive Modeling Technique for Student Academic Performance Monitoring. *MATEC Web of Conferences*, 255, 03004.
- Assimakopoulos, V., & Nikolopoulos, K. (2000). The theta model: a decomposition approach to forecasting. *International Journal of Forecasting*, 16(4), 521–530.
- Athanasopoulos, g, & Hyndman, R. J. (2022). 3.1 Some simple forecasting methods | Forecasting: Principles and Practice (2nd ed). Acedido a 20 de Setembro, 2022, em: <https://otexts.com/fpp2/simple-methods.html>
- Bademosi, L. (2021, December 14). What Do We See With AIC/BIC - The Startup. Acedido a 10 de Outubro, 2022, em: <https://medium.com/swlh/what-do-we-see-with-aic-bic-57b3e12685d>
- Baumeister, C., & Peersman, G. (2013). Time-Varying Effects of Oil Supply Shocks on the US Economy. *American Economic Journal: Macroeconomics*, 5(4), 1–28.
- Benedetto, F., Mastroeni, L., & Vellucci, P. (2020). Extraction of information content exchange in financial markets by an entropy analysis. *ACM Transactions on Management Information Systems (TMIS)*, 12(1), 1–16.
- Bildirici, M., Guler Bayazit, N., & Ucan, Y. (2020). Analyzing Crude Oil Prices under the Impact of COVID-19 by Using LSTARGARCHLSTM. *Energies*, 13(11), 2980.
- Boubaker, S., Liu, Z., & Zhang, Y. (2022). Forecasting oil commodity spot price in a data-rich environment. *Annals of Operations Research*, 1–18.
- Breul, H. (2016, January 6). Crude oil prices started 2015 relatively low, ended the year lower. Acedido a 25 de Setembro, 2022, em: <https://www.eia.gov/todayinenergy/detail.php?id=24432>
- Brownlee, J. (2016, 23 de Dezembro). How to Identify and Remove Seasonality from Time Series Data with Python. Acedido a 29 de Outubro, 2022, em: <https://machinelearningmastery.com/time-series-seasonality-with-python/>

- Brownlee, J. (2019, 20 de Agosto). A Gentle Introduction to Exponential Smoothing for Time Series Forecasting in Python. Acedido a 12 de Outubro, 2022, em: <https://machinelearningmastery.com/exponential-smoothing-for-time-series-forecasting-in-python/>
- Carvalho, T. P., Soares, F. A. A. M. N., Vita, R., Francisco, R. D. P., Basto, J. P., & Alcalá, S. G. S. (2019). A systematic literature review of machine learning methods applied to predictive maintenance. *Computers & Industrial Engineering*, 137, 106024.
- Cen, Z., & Wang, J. (2019). Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer. *Energy*, 169, 160–171.
- Chen, P., Niu, A., Liu, D., Jiang, W., & Ma, B. (2018). Time Series Forecasting of Temperatures using SARIMA: An Example from Nanjing. *IOP Conference Series: Materials Science and Engineering*, 394, 052024.
- Choudhary, A., Kumar, S., Sharma, M., & Sharma, K. P. (2022). A Framework for Data Prediction and Forecasting in WSN with Auto ARIMA. *Wireless Personal Communications*, 123(3), 2245–2259.
- Cirillo, A. (2017, Novembro). R Data Mining. Acedido a 20 de Maio, 2022, em: <https://www.oreilly.com/library/view/r-data-mining/9781787124462/>
- de A. Araujo, R., Vasconcelos, G. C., & Ferreira, T. A. E. (2007). Hybrid differential evolutionary system for financial time series forecasting. *2007 IEEE Congress on Evolutionary Computation*.
- Dertat, A. (2017, 8 de Agosto). Applied Deep Learning - Part 1: Artificial Neural Networks. Acedido a 29 de Outubro, 2022, em: <https://towardsdatascience.com/applied-deep-learning-part-1-artificial-neural-networks-d7834f67a4f6>
- Dierckx, T. (2022, 30 de Março). ARIMA-GARCH forecasting with Python - Analytics Vidhya. Acedido a 28 de Setembro, 2022, em: <https://medium.com/analytics-vidhya/arima-garch-forecasting-with-python-7a3f797de3ff>
- Dudek, G. (2019). Short-term load forecasting using Theta method. *E3S Web of Conferences*, 84, 01004.
- ELDER, J., & SERLETIS, A. (2010). Oil Price Uncertainty. *Journal of Money, Credit and Banking*, 42(6), 1137–1159.
- FRED Economic Data. (2022, 26 de Outubro). Acedido a 11 de Abril, 2022, em <https://fred.stlouisfed.org/series/DCOILBRETEU>
- GeeksforGeeks. (2020, 24 de Outubro). Intuition of Adam Optimizer. Acedido a 16 de Setembro, 2022, em: <https://www.geeksforgeeks.org/intuition-of-adam-optimizer/>
- Ghazali, R., Hussain, A. J., & Salleh, M. N. M. (2008). Application of Polynomial Neural Networks to Exchange Rate Forecasting. *2008 Eighth International Conference on Intelligent Systems Design and Applications*.
- Güteryüz, D., & Özden, E. (2020). The Prediction of Brent Crude Oil Trend Using LSTM and Facebook Prophet. *Avrupa Bilim Ve Teknoloji Dergisi*, (20), 1–9.
- H. Vo, A., Nguyen, T., & Le, T. (2020). Brent Oil Price Prediction Using Bi-LSTM Network. *Intelligent Automation & Soft Computing*, 26(4), 1307–1317.
- He, Y., Wang, S., & Lai, K. K. (2010). Global economic activity and crude oil prices: A cointegration analysis. *Energy Economics*, 32(4), 868–876.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

- Hossain, A., Zaman, F., Nasser, M., & Islam, M. M. (2009). Comparison of GARCH, Neural Network and Support Vector Machine in Financial Time Series Prediction. *Lecture Notes in Computer Science*, 597–602.
- Huang, Y., Dai, X., Wang, Q., & Zhou, D. (2021). A hybrid model for carbon price forecasting using GARCH and long short-term memory network. *Applied Energy*, 285, 116485.
- J, J. (2021, 3 de Janeiro). MAE and RMSE — Which Metric is Better? - Human in a Machine World. Acedido a 26 de Setembro, 2022, em: <https://medium.com/human-in-a-machine-world/mae-and-rmse-which-metric-is-better-e60ac3bde13d>
- Jenkins, G. M., Box, G. E. P., Reinsel, G. C., & Ljung, G. M. (1976). Time series analysis: forecasting and control rev. ed. *Holden-Day*, 37(2), 238–242.
- Karasu, S., & Altan, A. (2022). Crude oil time series prediction model based on LSTM network with chaotic Henry gas solubility optimization. *Energy*, 242, 122964.
- Kilian, L. (2008). A Comparison of the Effects of Exogenous Oil Supply Shocks on Output and Inflation in the G7 Countries. *Journal of the European Economic Association*, 6(1), 78–121.
- Kilimci, Z. H., Akyuz, A. O., Uysal, M., Akyokus, S., Uysal, M. O., Atak Bulbul, B., & Ekmis, M. A. (2019). An Improved Demand Forecasting Model Using Deep Learning Approach and Proposed Decision Integration Strategy for Supply Chain. *Complexity*, 2019, 1–15.
- Kumar, A. (2022, 22 de Agosto). Performance metrics for Time-series Forecasting models. Acedido a 26 de Setembro, 2022, em: <https://vitalflux.com/performance-metrics-for-time-series-forecasting-models/>
- Kumar G, V. (2021, 16 de Junho). Statistical tests to check stationarity in Time Series – Part 1. Acedido a 14 de Agosto, 2022, em: <https://www.analyticsvidhya.com/blog/2021/06/statistical-tests-to-check-stationarity-in-time-series-part-1/>
- Li, R., Hu, Y., Heng, J., & Chen, X. (2021). A novel multiscale forecasting model for crude oil price time series. *Technological Forecasting and Social Change*, 173, 121181.
- Lu, C. J., Chang, C. H., Chen, C. Y., Chiu, C. C., & Lee, T. S. (2009). Stock index prediction: A comparison of MARS, BPN and SVR in an emerging market. *2009 IEEE International Conference on Industrial Engineering and Engineering Management*.
- Lu, J., Valois, F., Dohler, M., & Wu, M. Y. (2010). Optimized Data Aggregation in WSNs Using Adaptive ARMA. *2010 Fourth International Conference on Sensor Technologies and Applications*. <https://doi.org/10.1109/sensorcomm.2010.25>
- Lu, Y., Luo, J., Cui, Y., He, Z., & Xia, F. (2022). Improved CEEMDAN, GA, and SVR Model for Oil Price Forecasting. *Journal of Environmental and Public Health*, 2022, 1–11.
- Mandal, S. K. (2020). Impact of crude oil on global economy. *International Journal of Creative Research Thoughts (IJCRT)*, 8(4), 2320–2882.
- MAPE (Mean Absolute Percentage Error). (2022, 5 de Outubro). Acedido a 10 de Outubro, 2022, em: [https://docs.oracle.com/en/cloud/saas/planning-budgeting-cloud/pfusu/insights\\_metrics\\_MAPE.html](https://docs.oracle.com/en/cloud/saas/planning-budgeting-cloud/pfusu/insights_metrics_MAPE.html)
- Md Saleh, N. I., Ab Ghani, H., & Jilani, Z. (2022). Defining factors in hospital admissions during COVID-19 using LSTM-FCA explainable model. *Artificial Intelligence in Medicine*, 132, 102394.

- Md-Khair, N. Q. N., Samsudin, R., & Shabri, A. (2017). Forecasting Crude Oil Prices using Discrete Wavelet Transform with Autoregressive Integrated Moving Average and Least Square Support Vector Machine Combination Approach. *International Journal on Advanced Science, Engineering and Information Technology*, 7(4–2), 1553.
- Mean Absolute Percentage Error (MAPE). (2022, 27 de Maio). Acedido a 12 de Outubro, 2022, em: <https://www.statisticshowto.com/mean-absolute-percentage-error-mape/>
- Mengist, W., Soromessa, T., & Legese, G. (2020). Method for conducting systematic literature review and meta-analysis for environmental science research. *MethodsX*, 7, 100777.
- Mohammadi, H., & Su, L. (2010). International evidence on crude oil price dynamics: Applications of ArimaGarch models. *Energy Economics*, 32(5), 1001–1008.
- MSE vs. RMSE: Which Metric Should You Use? (2021, 30 de Setembro). Acedido a 13 de Outubro, 2022, em: <https://www.statology.org/mse-vs-rmse/>
- N-BEATS — darts documentation. (2022). Acedido a 20 de Setembro, 2022, em: [https://unit8co.github.io/darts/generated\\_api/darts.models.forecasting.nbeats.html](https://unit8co.github.io/darts/generated_api/darts.models.forecasting.nbeats.html)
- Onnen, H. (2022). N-BEATS Unleashed: Deep Forecasting Using Neural Basis Expansion Analysis in Python. Acedido a 20 de Setembro, 2022, em: <https://towardsdatascience.com/n-beats-unleashed-deep-forecasting-using-neural-basis-expansion-analysis-in-python-343dd6307010>
- Perevochtchikova, M., De la Mora-De la Mora, G., Hernández Flores, J. L., Marín, W., Langle Flores, A., Ramos Bueno, A., & Rojo Negrete, I. A. (2019). Systematic review of integrated studies on functional and thematic ecosystem services in Latin America, 1992–2017. *Ecosystem Services*, 36, 100900.
- Piatetsky, G. (2014, 28 de Outubro). CRISP-DM, still the top methodology for analytics, data mining, or data science projects. Acedido a 25 de Setembro, 2022, em: <https://www.kdnuggets.com/2014/10/crisp-dm-top-methodology-analytics-data-mining-data-science-projects.html>
- Picciolo, F., Papandreou, A., Hubacek, K., & Ruzzenenti, F. (2017). How crude oil prices shape the global division of labor. *Applied Energy*, 189, 753–761.
- Prabhakaran, S. (2022, 3 de Setembro). ARIMA Model – Complete Guide to Time Series Forecasting in Python. Acedido a 26 de Setembro, 2022, em: <https://www.machinelearningplus.com/time-series/arima-model-time-series-forecasting-python/>
- Prasad, E. (2022, 6 de Janeiro). What is Auto-ARIMA? - featurepreneur. Acedido a 28 de Setembro, 2022, em: <https://medium.com/featurepreneur/what-is-auto-arima-b8025c6d732d>
- Pulagam. (2020, 26 de Junho). Time Series forecasting using Auto ARIMA in python. Acedido a 26 de Setembro, 2022, em: <https://towardsdatascience.com/time-series-forecasting-using-auto-arima-in-python-bb83e49210cd>
- Safiullin, M. R., Elshin, L. A., & Gilmanov, A. M. (2019). Prospects of LSTM Neural Networks Use in Supply Chain Management When Developing a Crypto Currency Rate Forecast. *International Journal of Supply Chain Management*, 8(6), 815–819.
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181, 526–534.

- Sehgal, N., & Pandey, K. K. (2015). Aftermath of 2008 Financial Crisis on Oil Prices. *Proceedings of the 7th International Joint Conference on Knowledge Discovery, Knowledge Engineering and Knowledge Management*.
- Smith, T. (2020, 19 de Novembro). Random Walk Theory: Definition, How It's Used, and Example. Acedido a 28 de Setembro, 2022, em: <https://www.investopedia.com/terms/r/randomwalktheory.asp>
- Table Definitions, Sources, and Explanatory Notes. (2022). Acedido a 24 de Setembro, 2022, em: [https://www.eia.gov/dnav/pet/TblDefs/pet\\_pri\\_spt\\_tbldef2.asp](https://www.eia.gov/dnav/pet/TblDefs/pet_pri_spt_tbldef2.asp)
- Tang, L., Dai, W., Yu, L., & Wang, S. (2015). A Novel CEEMD-Based EELM Ensemble Learning Paradigm for Crude Oil Price Forecasting. *International Journal of Information Technology & Decision Making*, 14(01), 141–169.
- Taylor, S. J. (2020, 5 de Setembro). fbprophet. Acedido a 28 de Setembro, 2022, em: <https://pypi.org/project/fbprophet/>
- Taylor, S. J., & Letham, B. (2018). Forecasting at Scale. *The American Statistician*, 72(1), 37–45.
- Verma, Y. (2021, 6 de Setembro). Complete Guide To Dickey-Fuller Test In Time-Series Analysis. Acedido a 12 Maio, 2022, em: <https://analyticsindiamag.com/complete-guide-to-dickey-fuller-test-in-time-series-analysis/>
- Wang, B., & Wang, J. (2019). Energy futures prices forecasting by novel DPFWR neural network and DS-CID evaluation. *Neurocomputing*, 338, 1–15.
- Wang, Y., & Wu, C. (2012). Forecasting energy market volatility using GARCH models: Can multivariate models beat univariate models? *Energy Economics*, 34(6), 2167–2181.
- Weng, Y., Wang, Z., & Zhou, L. (2021). LSTM Framework Design and Volatility Research on Intelligent Forecasting Model for Solving the Parallel Dislocation Problem. *Journal of Physics: Conference Series*, 1982(1), 012028.
- Women in Data Science La Paz (@WiDS\_LaPaz) /. (2022, July 17). Acedido a 25 de Setembro, 2022, em: [https://twitter.com/WiDS\\_LaPaz](https://twitter.com/WiDS_LaPaz)
- Xue, J., Zhou, S., Liu, Q., Liu, X., & Yin, J. (2018). Financial time series prediction using  $\ell_{2,1}$ RF-ELM. *Neurocomputing*, 277, 176–186.
- Ye, M., Zyren, J., & Shore, J. (2006). Forecasting short-run crude oil price using high- and low-inventory variables. *Energy Policy*, 34(17), 2736–2743.