



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

Previsão do preço do petróleo bruto: uma revisão sistemática de literatura

Camila Matos

Programa de Pós Graduação em Engenharia de Produção - UTFPR

Fernando Henrique Lermen

Engenharia de Produção - UNESPAR

Valderice Herth Junkes

Programa de Pós Graduação em Engenharia de Produção - UTFPR

Gustavo de Souza Matias

Engenharia de Produção - UNESPAR

Hugo Valadares Siqueira

Programa de Pós Graduação em Engenharia de Produção - UTFPR

Resumo: O petróleo bruto é o principal material de fornecimento de combustíveis e produtos químicos e é considerado um mineral vital para a economia e permanecerá dominante pelo menos durante a próxima década. A forma de prever o preço do petróleo é considerada complexa por vários autores, e por isso, vários estudos utilizaram modelos de previsão. Com isso, este estudo tem como objetivo identificar como a literatura tem previsto o preço do petróleo bruto. Para isso, foi realizada uma revisão sistemática da literatura, composta por coleta de dados, análise bibliométrica e análise de conteúdo. A busca foi realizada nas bases de dados Web of Science e Scopus, resultando em uma amostra final de 173 documentos. Como principais resultados da análise bibliométrica, foi apresentado um panorama sobre a evolução temática, a produção dos autores por país e a compreensão dos temas impulsionadores, emergentes e decrescentes da área investigada. Com base na análise de conteúdo, foram identificados os modelos de previsão mais utilizados para previsão do preço. Por fim, este estudo contribui para novos pesquisadores na busca por realizar uma previsão robusta e precisa do preço do petróleo e sugestões para estudos futuros.

Palavras-chave: Petróleo; Preço do Petróleo; Previsão; Previsão de Preço; Preço.

Crude Oil Price Forecasting: A Systematic Literature Review

Abstract: Crude oil is the main supply material for fuels and chemicals and is considered a vital mineral for the economy and will remain dominant for at least the next decade. The way to predict the price of oil is considered complex by several authors, and therefore, several studies use forecasting models. Therefore, this study aims to identify how the literature has predicted the price of crude oil. To this end, a systematic review of the literature was carried out, consisting of data collection, bibliometric analysis and content analysis. The search was carried out in the Web of Science and Scopus databases, resulting in a final sample of 173 documents. As the main results of the bibliometric analysis, an overview of thematic evolution, the production of authors by country and the understanding of the driving, emerging and decreasing themes of the investigated area was presented. Based on content analysis, the most used forecasting models for price forecasting were

identified. Finally, this study contributes to new researchers in the search for robust and accurate oil price forecasting and suggestions for future studies.

Keywords: Petroleum; Oil Price; Forecast; Price Forecast; Price.

1. Introdução

O petróleo bruto é o principal material de abastecimento de combustíveis e produtos químicos, além de ser um mineral vital para a economia e permanecerá dominante pelo menos na próxima década (Borodin *et al.*, 2023). O petróleo bruto e seus derivados, apresentam qualidade diferenciada, cujos preços são fundamentais para gerir a estabilidade e mapear as perspectivas de crescimento da economia mundial (Zhang *et al.*, 2019; Norouzi & Fani, 2022). Consecutivamente, as oscilações nos preços do petróleo bruto acabam por abalar as economias de muitos países, dependendo de vários fatores.

Usualmente, é impulsionado pela oferta dos países exportadores e pela demanda dos países industrializados (Al-Maamary *et al.*, 2017). Além disso, outros fatores como produto interno bruto (Saari *et al.*, 2016; Srivasstav *et al.*, 2018), taxas de câmbio (Turhan *et al.*, 2013) e preço de ativos financeiros (Antonakakis *et al.*, 2023) influenciam na flutuação do preço do petróleo bruto, que também é afetado por crises econômicas (Chatziantoniou *et al.*, 2021) e eventos políticos (King *et al.*, 2012). Não obstante, as flutuações nos preços podem afetar a saúde da economia, especialmente nos países produtores de petróleo bruto, porque os países importadores são mais suscetíveis a variações de preços com transações realizadas em dólares norte-americanos (USD) (Ramadani & Devianto, 2020).

Em uma perspectiva global, o impacto do petróleo bruto no PIB oscila entre 0,5% e 4,5% e o componente mais crítico que afeta essa relação, entre o petróleo bruto e o PIB, é a evolução do preço, o qual reflete o resultado da mistura de muitos fatores nas mudanças políticas globais, mudanças militares, mudanças econômicas, disputas e conflitos (Shehabi 2022; Oppong *et al.*, 2023). Com isso, nota-se que mercado de petróleo assumiu novas características que afetam significativamente o desenvolvimento da economia global, a segurança estratégica nacional e o sentimento do investidor (Yu *et al.*, 2017).

Como os preços do petróleo são afetados por diversos fatores econômicos e políticos, é crucial determinar como esses preços serão eventualmente alterados. Nesse sentido, a principal justificativa para desenvolver essa pesquisa é falta de um levantamento de métodos de previsão de petróleo que considera flutuações e volatilidade quanto a série de preços disponíveis. Para isso, o objetivo foi realizar uma análise bibliográfica e identificar na literatura os modelos de previsão mais utilizados para prever o preço do petróleo bruto.

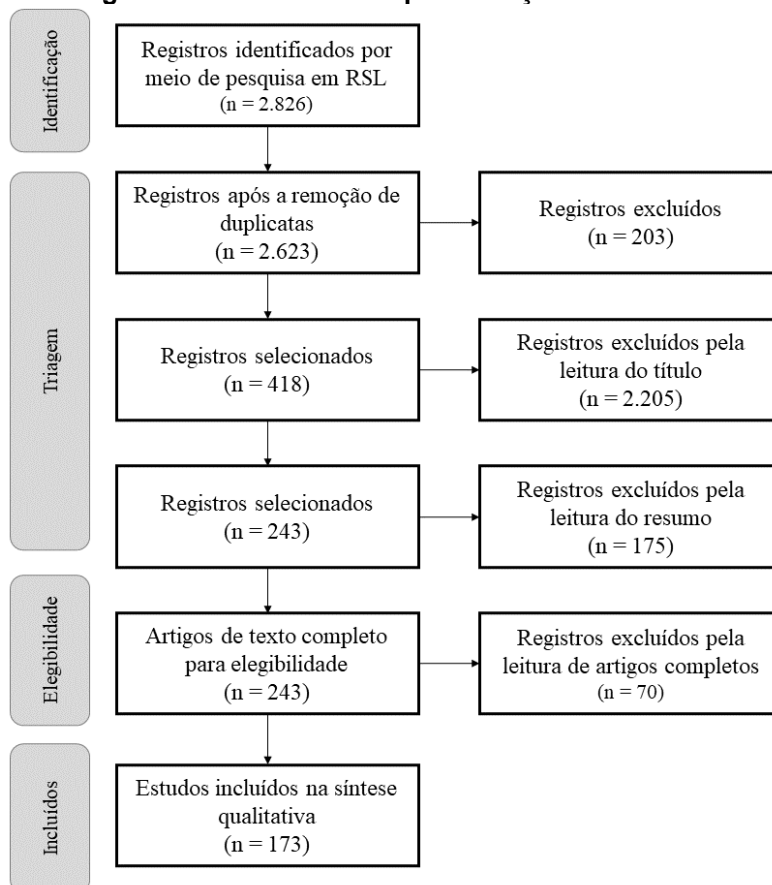
2. Metodologia

O método utilizado nesse estudo é Revisão Sistemática da Literatura (RSL), que segue as etapas propostas por Denyer e Tranfield *et al.* (2009) que delimitam princípios específicos a serem aplicados na busca, classificação e interpretação dos achados. A RSL aumenta a legitimidade dos resultados, oferecendo uma base confiável para formular opiniões e considerações para estudos futuros (Roberts & Priest, 2006). As avaliações são conduzidas usando um ciclo iterativo estruturado em três etapas: i) coleta de dados, ii) análise bibliométrica e iii) análise de conteúdo (Denyer & Tranfield *et al.*, 2009).

Na etapa de coleta de dados (i), a string de busca foi definida: ("demand forecast" OR "time series" OR forecasting) AND (price OR "oil prices") AND (petroleum OR "Crude oil" OR "Fossil Fuel"). Utilizando uma amostra temporal de treze anos (2011-2023), a busca foi realizada nas bases de dados Web of Science e Scopus, que abrangem um número representativo de periódicos de diferentes áreas, com impacto relevante, em fevereiro de 2023. A string apresentou 1.764 estudos identificados na base Web of Science e 1.062 na Scopus. Para fins de análise, os 2.826 estudos identificados foram inseridos no software

gerenciador de referência Mendeley©. Para o processo de seleção da amostra de estudos, foram realizadas quatro reduções seguindo o Preferred reporting items for systematic review and meta-analysis protocols (PRISMA) proposto por Moher *et al.* (2009). Esse processo pode ser visto na Figura 1 do protocolo PRISMA utilizado para seleção da amostra de estudos analisada.

Figura 1 - Método Prisma para seleção da amostra



Fonte: elaborado pelos autores

A primeira redução excluiu 203 estudos por duplicidade. Na segunda, 2.205 estudos foram excluídos por estarem fora do escopo da leitura de títulos. A terceira redução se deu na leitura de resumos, excluindo 175 estudos. A quarta redução tratou da leitura completa dos 243 artigos, sendo excluídos 70 estudos, restando 173 que compõem o portfólio final.


Na estatística de dados (ii), foi utilizado o pacote bibliometrix, juntamente com o software R, que é uma linguagem em código aberto. O pacote R bibliometrix é um algoritmo escrito na linguagem R que fornece um conjunto de ferramentas para pesquisa quantitativa em bibliometria e scientometria. A coleta de dados pelo pacote bibliometrix pode ser realizada com dados das principais bases científicas, como Scopus e Web of Science. Em seguida, os registros foram convertidos em dataframes, para que pudessem ser lidos nos padrões Bibliometrix. Nesta etapa, foi empregada a abordagem de extração de dados sugerida por Tranfield *et al.* (2003) na amostra de 173 documentos.

A análise de conteúdo seguiu a sequência de Elo e Kyngäs (2008): codificação aberta, categorização e abstração. Por meio dessas etapas, buscou-se identificar informações relevantes por meio de um processo dedutivo por meio da codificação da amostra estudada.

3. Resultados e Discussão

Os resultados e a discussão refletem os principais periódicos identificados e suas características e semelhanças, assim a Figura 2 apresenta informações referentes à Produtividade de artigos por ano que ilustra a tendência de publicação relacionada ao tema.

Figura 2 - Produtividade de artigos por ano




Fonte: Método aplicado adaptado de Aria e Cuccurullo (2017)

Os resultados mostram que o número de publicações anuais aumentou gradativamente a partir de 2019. Ainda assim, em 2014 foi apresentado um pico, porém, o período de 2015 a 2018 registrou uma estagnação nas publicações. Vale ressaltar que 2021 (por exemplo, He *et al.*; e Zhang *et al.*) e 2022 (por exemplo, Devianto *et al.*; e Wang e Fang) apresentaram pico de publicações, com 35 e 31 documentos respectivamente.

Quanto as informações bibliométricas referentes a quantidade de artigos publicados em cada jornal, identificou a Energy Economics (22 documentos), como líder de publicações, sendo considerado o principal journal de campo para economia de energia e finanças. Quanto a produtividade dos autores da amostra, o autor que mais publicou na amostra foi Wang S com 14 documentos, seguido por Yu L com 10 documentos. Nesse mesmo sentido, levantado informações bibliométricas referentes à quantidade de citações da amostra, sendo Karasu *et al.* (2020) com 248 citações, ou seja, o líder. Seguidos por Zhao *et al.* (2017) com 171 citações e Jammazi e Aloui (2012) com 170 citações.

Quanto a localização das afiliações desses autores, notou-se a China o país com maior quantidade de autores (344), a maior consumidora e produtora de energia do mundo em 2020 e a quinta maior produtora de petróleo e outros líquidos do mundo em 2021. Essa frequência de autores é seguida pelo Irã com 28 autores, país que possui alguns dos maiores depósitos mundiais de reservas de petróleo e gás natural, classificando-se como o terceiro maior produtor mundial de petróleo e maior reserva de petróleo em 2021. A Malasya apresenta 17 autores e os Estados Unidos, maior produtor de petróleo do mundo, com 16. A análise bibliométrica apresenta a evolução temática do tema (Figura 3).

Figura 3 - Evolução temática

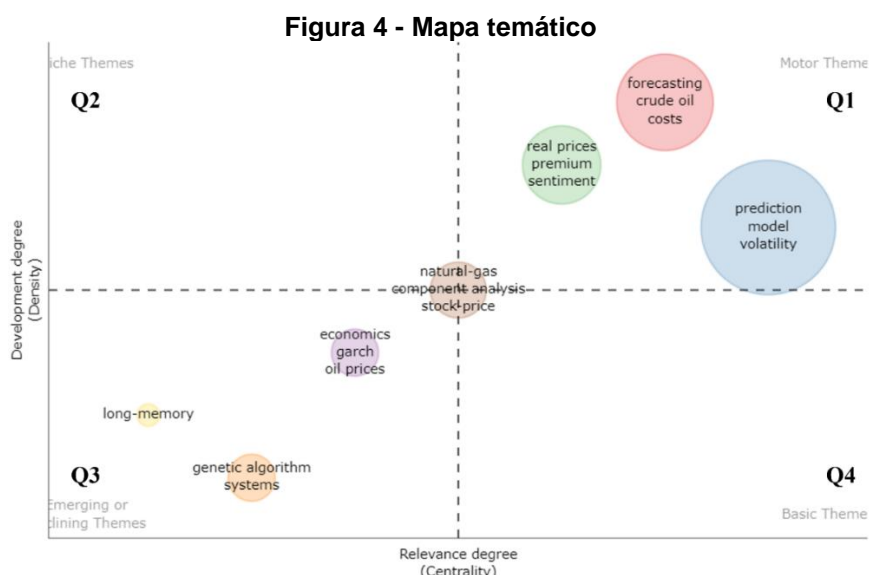


Fonte: Método aplicado adaptado de Aria e Cuccurullo (2017)

O lado esquerdo da imagem apresenta como os temas surgiram e foram nomeados, enquanto o lado direito apresenta a situação atual para onde migraram. É possível notar que a produção de trabalhos de previsão de petróleo nos anos de 2011 a 2016 giravam em torno de temas como predição e movimento. O tema movimento passou apenas a ser combinado ou substituído por predição, tema que por sua vez, a partir dos anos 2017 à 2020 continuou tendo forte presença nas produções bem como passou a ser combinado também com os seguintes temas: modelo; dinâmico; sentimento; mercado de ações e choque. Essa evolução se dá pois os estudos passaram a considerar nos modelos de previsão de preço do petróleo, os impactos do mercado de ação que influenciam diretamente no preço, bem como a combinação de modelos dinâmicos (Zhang *et al.*, 2018).

Além da mudança de temas utilizados a partir dos anos de 2017 a 2020, também surgiram temas como: sentimento; mercado e redes neurais. Isso ocorreu pelo alto volume de estudos que passaram a utilizar os modelos de redes neurais para previsão do preço, concluindo a eficácia desses modelos, além de considerar as notícias sobre o preço do petróleo como variáveis dos modelos, pois os estudos afirmam a influência dessas notícias no preço do petróleo que podem ser mensuradas com técnicas de análise de sentimento (LU *et al.*, 2020). A partir de 2021 até o ano de 2023 os temas evoluíram ainda mais, passando, todos eles, exceto redes neurais, a serem combinados com a volatilidade, ou seja, a medição da variação do preço do petróleo, muitos estudos passaram a prever essa volatilidade do preço do petróleo (EL HOKAYEM *et al.*, 2022; ALTAN e KARASU, 2022).

O tema predição passou a ser combinado também com risco e OPEC que é a Organização dos Países Exportadores de Petróleo. Por sua vez, modelo passou a ser combinado com predição, demanda e gás natural, pois estudos utilizaram modelos de previsão de preço tanto para o petróleo quanto para o gás, (BOUTESKA *et al.*, 2023; DING *et al.*, 2022), além de considerar como variável nos modelos a demanda de petróleo bruto. (EL HOKAYEM *et al.*, 2022; LU *et al.*, 2021). Mercado, mercado de ações e choques, foram combinados com o tema predição. E por fim, redes neurais combinada com Long Short Term Memory (LSTM) que é um modelo de rede neural recorrente. Este modelo como tema emergente nos últimos anos é comprovado pela sua alta aparição nos estudos desta amostra, observado na Figura 4 que ilustra o mapa temático em torno das palavras mais relevantes citadas na amostra.



O mapa temático é intuitivo e elaborado com a análise de co-palavras que desenha grupos de palavras-chave consideradas como temas. O eixo vertical, representado pela densidade, mede a força dos elos internos dentro de um tema, enquanto o eixo horizontal, representado pela centralidade, mede a força dos elos entre o tema e outros temas no mapa. As palavras

podem ser analisadas com base no quadrante em que estão localizadas. O quadrante superior esquerdo (Q1) exibe palavras com alto grau de desenvolvimento, mas sem grande relevância, como previsão, custo, volatilidade. O quadrante inferior esquerdo (Q2) compreende palavras com baixo grau de desenvolvimento e aplicabilidade, como gás natural, análise de componentes e preço de estoque, este está correlato com os outros quadrantes. O quadrante inferior direito (Q3) exibe termos que, embora relevantes, ainda têm um pequeno impacto na pesquisa, tais como economia, memória longa, algoritmos genéticos e sistemas. Por fim, o quadrante superior direito (Q4) apresenta palavras com alto grau de desenvolvimento e relevância, ou seja, predição, modelo e volatilidade.

Como este estudo visa levantar os principais modelos de previsão de preço de petróleo, buscou-se identificar na literatura os mesmos. Assim, foram levantados 108 modelos e um software utilizados em 251 trabalhos de previsão do preço. Destes, 40% são modelos estatísticos, 23% são modelos de aprendizado de máquina e 21% são modelos de redes neurais. Os outros 11% estão distribuídos entre os modelos de otimização, matemáticos, de séries temporais, modelo Graybox, inteligência artificial, híbrido, modelo macroeconômico e modelo de técnica de análise.

Os três modelos mais utilizados na amostra possuem abordagens diferentes para cada modelagem. Os modelos estatísticos geralmente lidam com dados paramétricos, podem ser interpretáveis e explicáveis, no entanto também podem demonstrar sensibilidade em suposições inadequadas e outliers, além de apresentar dificuldade ao lidar com dados de alta dimensionalidade e não lineares. Já modelos de aprendizado de máquina podem lidar com dados não paramétricos, é capaz de ajustar o modelo com base em padrões dos dados e lidar com dados não lineares, no entanto, podem ser difíceis de interpretar, explicar e lidar com dados escassos. Os modelos de redes neurais também são capazes de lidar com dados não paramétricos, de alta dimensionalidade e não lineares, no entanto, também possuem as mesmas limitações que os modelos de aprendizado de máquina, bem como podem ser computacionalmente intensivos (JORDAN e MITCHELL, 2015).

Nota-se que alguns modelos foram mais utilizados que outros, como é o caso do modelo Long Short Term Memory (LSTM) utilizado em 19 estudos, o modelo Support Vector Machine (SVM) em 13 estudos e o modelo Autoregressive Integrated Moving Average (ARIMA), utilizado em 11 estudos.

O modelo LSTM é um modelo de rede neural recorrente utilizado para modelar e prever séries com dependências de longo prazo, captura correlações complexas entre os dados, e evita o problema do desvanecimento do gradiente, que pode ocorrer em outros modelos de redes neurais recorrentes (HOCHREITER E SCHMIDHUBER, 1997). Wu, Wu e Zhu (2019) utilizou o LSTM para previsão, após decompor a série de dados com o EEMD, mostrando ótimo desempenho, o que indica que o modelo pode ser muito promissor para previsão do preço do petróleo bruto. Yao e Wang (2021) combinaram o modelo LSTM com o modelo GM, mostrando alta acurácia na previsão, principalmente em termos de séries de longo prazo com menor frequência. Jovanovic *et al.* (2022) combinou o LSTM com o algoritmo SSA modificado, em que o SSA ajusta os hiperparâmetros do LSTM.

Na amostra estudada, em grande parte, o LSTM é utilizado em combinação com outros modelos, exceto no estudo de Deng, Ma e Zeng (2021) que utilizaram para prever o preço do petróleo bruto em Xangai em que afirmam uma forte capacidade de generalização e alta precisão de previsão do modelo. Guo *et al.* (2022) afirmam que o modelo tem capacidade de aprendizado não linear mais forte do que os modelos gerais de aprendizado de máquina e, em comparação com o modelo BPNN, o LSTM tem melhor capacidade de previsão, principalmente pelo recurso de memória histórica que o LSTM apresenta. Cen e Wang (2019) verificaram que o modelo pode captar as principais características de flutuação dos preços do petróleo bruto para diferentes níveis de frequência de flutuação.

O modelo SVM é um modelo de aprendizado de máquina supervisionado capaz de lidar com dados não lineares, que é o caso do preço do petróleo, e pode ser usado para previsões precisas mesmo quando há pouco dados de treinamento disponíveis. Entretanto ele pode ser computacionalmente intensivo, principalmente se usado com grandes conjuntos de dados, bem como pode ser sensível à escolha dos parâmetros (CHANG e LIN, 2011). Zhao *et al.* (2015) utilizou o SVM em combinação com o Algoritmo Genético (GA), em que foi empregado para selecionar os parâmetros do modelo SVM. Li *et al.* (2016) afirma que o SVM pode superar os modelos LSSVM, ANN e ARIMA em muitos casos, enquanto Yu, Zhang e Wang (2017) cita mais modelos em que ele é melhor, como o FNN, ARIMA, ARFIMA, MS-ARFIMA e RW. Li *et al.* (2021) utilizou o modelo SVM após decompor os dados da série com o modelo VMD, descrevendo potencial do modelo em prever preços. O modelo SVM foi muito utilizado para fins de comparação com novos modelos híbridos propostos, como nos trabalhos de: Liu e Huang (2021); e, Wang e Wang (2020). É importante mencionar que embora os autores tenham citado o uso do modelo SVM, na verdade utilizaram a variação desse modelo, no caso o Support Vector Regression (SVR), ambos modelos são variações do mesmo conceito fundamental, mas cada um é aplicado de forma adequada a tarefa de classificação e regressão (PARRELA, 2007).

O modelo ARIMA é um modelo estatístico paramétrico, geralmente utilizado em previsão de séries temporais de comportamento linear, que se baseia em três componentes principais, sendo a autoregressão (AR), diferenciação integrada (I) e média móvel (MA) (Box, Jenkins E Reinsel, 2015). Mesmo sendo muito utilizado nos estudos da amostra, o modelo ARIMA, assim como os modelos estatísticos, não seria recomendado para a previsão dos preços de petróleo bruto, uma vez que os preços possuem um comportamento muito complexo para um modelo deste tipo, é o que se confirma nos estudos de Yu, Dai e Tang (2016) e Li *et al.* (2015). Os autores afirmam ainda que os modelos de Inteligência Artificial produzem resultados de previsão muito melhores do que ARIMA em todos os casos, em termos de MAPE e RMSE, por serem mais apropriados para capturar padrões.

A alta quantidade do uso do ARIMA, é justificada pois os autores utilizaram o modelo para comparar com os novos propostos por eles. Nesse sentido, o ARIMA foi utilizado como modelo de comparação por 20% dos estudos da amostra, sendo superado em todas as comparações (DEVIANTO *et al.*, 2022; KHOOJINE *et al.*, 2022). Entretanto, nos estudos em que foi utilizado para previsão como modelo proposto, foi em casos combinatórios para construção de modelos híbridos. Liu e Huang, (2021) utilizaram o ARIMA para previsão do preço médio, combinando com o modelo GARCH para previsão de volatilidade e o LSTM, já Amir, Shabri e Ishaq (2018) aplicou o modelo para cada função de modo intrínseco extraída com o objetivo de estimar os parâmetros para um novo modelo.

Li *et al.* (2016) relata que devido à não linearidade e não estacionariedade dos dados, é difícil para modelos únicos prever com precisão o preço do petróleo. Segundo Baumeister, Kilian e Lee (2014) um modelo híbrido supera os modelos individuais na previsão. Esse fato justifica 251 autores utilizarem esses 108 modelos em uma amostra de 173 estudos, comprovando a combinação de dois ou mais modelos em suas previsões, propondo, em sua maioria, modelos híbridos. Apenas 9% dos estudos utilizaram um único modelo para a previsão. Liu e Huang (2021), por exemplo, combinaram os modelos ARIMA, para previsão do preço médio, o GARCH, para previsão de volatilidade, e o LSTM para extração de eventos e análise de sentimentos. Zhao e Xue (2022) combinaram os modelos TN, LP, LSTM e SVM. Lu *et al.* (2021) selecionaram os principais fatores de influência com o modelo linear generalizado regularizado elástico, GLMNET, o método do laço e a média do modelo bayesiano e utilizaram o LSTM para prever. Apesar dos vários modelos de previsão, vale lembrar que a escolha do modelo depende de cada situação.

Por fim, dentre os estudos analisados, foi possível identificar algumas oportunidades de estudos futuros, conforme apresenta o Quadro 1.

Quadro 1 - Oportunidades para estudos futuros identificadas na amostra estudada

Autor(es)	Descrição
Abdollahi (2020)	Combinar o modelo SVM com outros modelos, como algoritmo de otimização
Altan e Karasu (2022)	Incluir indicadores de risco macroeconômicos ou geopolíticos no modelo
Cheng, Chu e Hsu (2021)	Utilizar uma abordagem multivariada, pois muitos fatores afetam o preço do petróleo bruto
de Medeiros <i>et al.</i> (2022)	Utilizar modelos de aprendizado de máquina para seleção de variáveis explicativas para o modelo
Li <i>et al.</i> (2021)	Considerar previsões híbridas multiescala
Lu <i>et al.</i> (2021)	Introduzir mais variáveis independentes, no modelo, com a ajuda de dados de pesquisa na Internet
Wang <i>et al.</i> (2020)	Os desenvolvimentos futuros deste estudo incluirão alguns fatores da Internet que afetam os mercados de petróleo bruto, como notícias da Internet e dados do Blog, com objetivo de aprimorar a capacidade preditiva e a pontualidade
Wu, Wang e Hao (2022)	Realizar previsão a longo prazo
Yang <i>et al.</i> (2021)	Utilizar um método apropriado e que economize tempo para selecionar parâmetros ótimos para o modelo
Yao e Wang (2021)	Selecionar diferentes modelos para diferentes componentes após a decomposição, de forma adaptativa de acordo com suas propriedades para melhorar os resultados da previsão
Zhang <i>et al.</i> (2021)	Considerar outros fatores de influência que afetam as mudanças no preço do petróleo bruto para melhorar ainda mais o efeito geral da previsão

Muitas outras opções foram sugeridas por outros autores, no entanto, com o passar do tempo, essas lacunas já foram preenchidas ou eram ainda sugestões que se tratava do próprio modelo proposto, tal como aplicá-lo em outra série de dados.

4. Considerações Finais

Este estudo teve como objetivo identificar como a literatura tem previsto o preço do petróleo bruto. Para isso, foi realizada uma revisão sistemática da literatura, composta por coleta de dados, análise bibliométrica e análise de conteúdo. Por meio, da análise bibliométrica mostrou que o número de publicações anuais sobre o tema aumentou gradualmente a partir de 2019; a revista líder em publicação é Energy Economics e o autor que mais publicou artigos na amostra foi Wang S e o líder de citação foi KARASU *et al.*, (2020). Na análise bibliométrica também foi possível analisar que a produção de trabalhos de previsão de petróleo nos anos de 2011 a 2016 girou em torno de temas como previsão e movimento, passando, anos depois, a considerar temas como: modelo; dinâmico; sentimento; mercado de ações; choque; sentimento; redes neurais; demanda e gás natural.

Os principais resultados da análise de conteúdo trouxeram os métodos de decomposição mais utilizados, EEMD e VMD; bem como métodos de previsão do preço do petróleo, LSTM, SVR e ARIMA. Contudo, o modelo ARIMA não seria uma boa escolha para previsão do preço do petróleo devido às suas limitações. O uso de modelos de aprendizado de máquina e redes neurais tem um bom desempenho.

Como limitação, este estudo enfatiza o limite de busca de 13 anos, além de buscar modelos que foram utilizados para prever apenas o preço do petróleo bruto, não considerando outros tipos de commodities. Por fim, como sugestões para pesquisas futuras são propostas a utilização de modelos, separadamente, para cada componente, tendência, sazonalidade e componentes aleatórios e cíclicos, e posteriormente combinar estes modelos, podendo criar um modelo caixa cinza. De acordo com os modelos combinados de previsão de curto e longo prazo, também pode tornar-se um modelo híbrido multiescala. Outras sugestões retiradas dos estudos avaliados são propostas.

Referências

AAMIR, M.; SHABRI, A.; ISHAQ, M. Crude Oil Price Forecasting By Ceemdan Based Hybrid

- Model Of Arima And Kalman Filter. **Journal Teknologi**, V. 80, N. 4, P. 67–79, Jul. 2018.
- ABDOLLAHI, H. A novel hybrid model for forecasting crude oil price based on time series decomposition. **APPLIED ENERGY**, v. 267, jun. 2020.
- AL-MAAMARY, H. M. S.; KAZEM, H. A.; CHAICHAN, M. T. The impact of oil price fluctuations on common renewable energies in GCC countries. **Renewable and Sustainable Energy Reviews**, v. 75, p. 989–1007, 2017.
- ANTONAKAKIS, N. et al. Dynamic connectedness among the implied volatilities of oil prices and financial assets: New evidence of the COVID-19 pandemic. **International Review of Economics and Finance**, v. 83, p. 114–123, 2023.
- ARIA, M.; CUCCURULLO, C. Bibliometrix: An R-tool for comprehensive science mapping analysis. **Journal of Informetrics**, 11(4), pp 959-975, Elsevier, 2017.
- BAUMEISTER, C.; KILIAN, L.; LEE, T. K. Are there gains from pooling real-time oil price forecasts? **Energy Economics**, v. 46, n. S1, p. S33–S43, 2014.
- BORODIN, A. et al. Overview of the Russian Oil and Petroleum Products Market in Crisis Conditions: Economic Aspects, Technology and Problems. **Energies**, v. 16, n. 4, 2023.
- BOUTESKA, A. et al. Nonlinearity in forecasting energy commodity prices: Evidence from a focused time-delayed neural network. **RES. IN INT. BUS. AND FINANCE**, v. 64, jan. 2023.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. (2015). **Time series analysis: forecasting and control**. 5th Edition. John Wiley & Sons, 2015.
- BREIMAN, L. **Random forests**. *Machine Learning*, 45(1), 5-32, 2001.
- CEN, Z.; WANG, J. Crude oil price prediction model with long short term memory deep learning based on prior knowledge data transfer. **ENERGY**, v. 169, p. 160–171, 2019.
- CHATZIANTONIOU, I. et al. A closer look into the global determinants of oil price volatility. **Energy Economics**, v. 95, 2021.
- CHANG, C.-C.; LIN, C.-J. LIBSVM: A Library for support vector machines. **ACM Transactions on Intelligent Systems and Technology**, v. 2, n. 3, 2011.
- CHENG, M.-L.; CHU, C.-W.; HSU, H.-L. A study of univariate forecasting methods for crude oil price. **Maritime Business Review**, 2021.
- DENG, C.; MA, L.; ZENG, T. Crude Oil Price Forecast Based on Deep Transfer Learning: Shanghai Crude Oil as an Example. **SUSTAINABILITY**, v. 13, n. 24, 2021.
- DENYER, D.; TRANFIELD, D. **Producing a systematic review**, In Buchanan, D.; Bryman, A. (Eds). *The Sage Handbook of Organizational Research Methods*, Sage Publications, London, p. 671-689, 2009.
- DEVIANTO, D. et al. The hybrid model of autoregressive integrated moving average and fuzzy time series Markov chain on long-memory data. **Front. in Applied Mathematics and Statistics**, v. 8, 2022.

EIA. US Energy Information Administration. **Oil and petroleum products explained**. Disponível em: https://www.eia.gov/energyexplained/index.php?page=oil_homem. Acesso em: 19 mai. 2023.

EL HOKAYEM, J. et al. Forecasting Oil Prices: A Comparative Analysis between Neural Network and Regression Models. **Rev. of Ec. and Finance**, v. 20, n. 1, p. 133–143, 2022.

ELO, S; KYNGÄS, H. The qualitative content analysis process. **Journal of advanced nursing**, v. 62, n. 1, p. 107-115, 2008.

GUO, J. et al. Multi-perspective crude oil price forecasting with a new decomposition-ensemble framework. **RESOURCES POLICY**, v. 77, 2022.

HAQUE, M. I.; SHAIK, A. R. Predicting Crude Oil Prices During a Pandemic: A Comparison of Arima and Garch Models. **Montenegrin J. Of Economics**, v. 17, n. 1, p. 197–207, 2021.

HENDRAWATY, E. et al. Modelling and forecasting crude oil prices during covid-19 pandemic. **Int. Journal of Energy Economics and Policy**, v. 11, n. 2, p. 149–154, 2021.

HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, 9(8), 1735-1780, 1997.

JAMMAZI, R.; ALOUI, C. Crude oil price forecasting: Experimental evidence from wavelet decomposition and neural network modeling. **Energy Economics**, v. 34, n. 3, p. 828–841, 2012.

JORDAN, M. I.; MITCHELL, T. M. Machine learning: Trends, perspectives, and prospects. **Science**, v. 349, n. 6245, p. 255–260, 2015.

JOVANOVIC, L. et al. Multi-Step Crude Oil Price Prediction Based on LSTM Approach Tuned by Salp Swarm Algorithm with Disputation Operator. **Sustainability**, v. 14, n. 21, 2022.

KARASU, S. et al. A new forecasting model with wrapper-based feature selection approach using multi-objective optimization technique for chaotic crude oil time series. **ENERGY**, v. 212, 2020.

KHOOJINE, A. S.; SHADABFAR, M.; TABRIZ, Y. E. A Mutual Information-Based Network Autoregressive Model for Crude Oil Price Forecasting Using Open-High-Low-Close Prices. **MATHEMATICS**, v. 10, n. 17, 2022.

KING, K.; DENG, A.; METZ, D. An econometric analysis of oil price movements: the role of political events and economic news, financial trading, and market fundamentals. **Bates White Economic Consulting**, v. 1, p. 53, 2012.

LI, T. et al. Forecasting Crude Oil Price Using EEMD and RVM with Adaptive PSO-Based Kernels. **ENERGIES**, v. 9, n. 12, 2016.

LI, T. et al. Forecasting crude oil prices based on variational mode decomposition and random sparse Bayesian learning. **APPLIED SOFT COMPUTING**, v. 113, n. B, 2021.

LIU, J.; HUANG, X. Forecasting Crude Oil Price Using Event Extraction. **IEEE ACCESS**, v. 9, p. 149067–149076, 2021.

LIU, Y. et al. Forecasting Oil Price by Hierarchical Shrinkage in Dynamic Parameter Models. **DISCRETE DYNAMICS IN NATURE AND SOCIETY**, v. 2020, 2020.

LU, Y. et al. Improved CEEMDAN, GA, and SVR Model for Oil Price Forecasting. **JOURNAL OF ENVIRONMENTAL AND PUBLIC HEALTH**, v. 2022, jun. 2022.

MOHER, D.; LIBERATI, A.; TETZLAFF, J.; ALTMAN, D. G.; PRISMA, G. Preferred reporting items for systematic reviews and meta-analyses: the PRISMA statement. **International Journal of Surgery**, v. 8, n. 5, p. 336-341, 2009.

NOROUZI, N.; FANI, M. Globalization and the oil market: An overview on considering petroleum as a trade commodity. **Journal of Energy Management and Technology**, v. 6, n. 1, p. 54-62, 2022.

OECD. Organisation for Economic Co-operation and Development. **The impact of Coronavirus(COVID-19)and the global oil price shock on the fiscal position of oil-exporting developing countries**. Tackling coronavirus (COVID-10) contributing to a global effort. 2020.

RAMADANI, K.; DEVIANTO, D. **The forecasting model of bitcoin price with fuzzy time series Markov chain and Chen logical method**. (A. F. Purnama B. Nugraha D.A., Ed.)AIP Conference Proceedings. **Anais...American Institute of Physics Inc.**, 2020.

SAARI, M. Y.; DIETZENBACHER, E.; LOS, B. The impacts of petroleum price fluctuations on income distribution across ethnic groups in Malaysia. **Ecological Economics**, v. 130, p. 25–36, 2016.

SHEHABI, M. Modeling long-term impacts of the COVID-19 pandemic and oil price declines on Gulf oil economies. **Economic Modelling**, v. 112, 2022.

SRIVASSTAV, A. et al. **The dynamics of petroleum pricing and the impact of petroleum product prices on key sectors of the economy**. Proceedings of 2017 IEEE International Conference on Technological Advancements in Power and Energy: Exploring Energy Solutions for an Intelligent Power Grid, TAP Energy 2017. **Anais...Institute of Electrical and Electronics Engineers Inc.**, 2018.

TURHAN, I.; HACIHASANOGLU, E.; SOYTAS, U. Oil prices and emerging market exchange rates. **Emerging Markets Fin. and Trade**, v. 49, n. SUPPL.1, p. 21–36, 2013.

WANG, B.; WANG, J. Deep multi-hybrid forecasting system with random EWT extraction and variational learning rate algorithm for crude oil futures. **Expert Systems With Applications**, V. 161, 2020.

WANG, D.; FANG, T. Forecasting Crude Oil Prices with a WT-FNN Model. **ENERGIES**, v. 15, n. 6, mar. 2022.

WANG, J.; WANG, J. A New Hybrid Forecasting Model Based on SW-LSTM and Wavelet Packet Decomposition: A Case Study of Oil Futures Prices. **Computational Intelligence and Neuroscience**, v. 2021, jul. 2021.

WANG, Y.; WU, C.; YANG, L. Oil price shocks and stock market activities: Evidence from oil-importing and oil-exporting countries. **J. of Comp. Econ.**, v. 41, n. 4, p. 1220–39, 2013.

WU, C.; WANG, J.; HAO, Y. Deterministic and uncertainty crude oil price forecasting based on outlier detection and modified multi-objective optimization algorithm. **Resources Policy**, V. 77, 2022.

WU, Y.-X.; WU, Q.-B.; ZHU, J.-Q. Improved EEMD-based crude oil price forecasting using LSTM networks. **Physica A-Statistical Mec. And Its Appl.**, v. 516, P. 114–124, 2019.

YANG, Y. et al. Forecasting crude oil price with a new hybrid approach and multi-source data. **ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE**, v. 101, 2021.

YAO, T.; WANG, Z. Crude oil price prediction based on LSTM network and GM (1,1) model. **GREY SYSTEMS-THEORY AND APPLICATION**, v. 11, n. 1, p. 80–94, jan. 2021.

YU, L. et al. Investigation of diversity strategies in RVFL network ensemble learning for crude oil price forecasting. **SOFT COMPUTING**, v. 25, n. 5, p. 3609–3622, mar. 2021.

YU, L.; DAI, W.; TANG, L. A novel decomposition ensemble model with extended extreme learning machine for crude oil price forecasting. **ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE**, v. 47, n. SI, p. 110–121, jan. 2016.

YU, L.; ZHANG, X.; WANG, S. Assessing Potentiality of Support Vector Machine Method in Crude Oil Price Forecasting. **EURASIA JOURNAL OF MATHEMATICS SCIENCE AND TECHNOLOGY EDUCATION**, v. 13, n. 12, p. 7893–7904, 2017.

ZHANG, J.-L.; ZHANG, Y.-J.; ZHANG, L. A novel hybrid method for crude oil price forecasting. **ENERGY ECONOMICS**, v. 49, p. 649–659, 2015.

ZHANG, T. et al. Multi-step-ahead crude oil price forecasting based on two-layer decomposition technique and extreme learning machine optimized by the particle swarm optimization algorithm. **ENERGY**, v. 229, 2021.

ZHANG, Y. et al. Forecasting the prices of crude oil: An iterated combination approach. **ENERGY ECONOMICS**, v. 70, p. 472–483, 2018.

ZHANG, Z. et al. Geopolitical risk trends and crude oil price predictability. **ENERGY**, v. 258, nov. 2022.

ZHAO, L. et al. A VAR-SVM model for crude oil price forecasting. **International Journal of Global Energy Issues**, v. 38, n. 1–3, p. 126–144, 2015.

ZHAO, Y.; LI, J.; YU, L. A deep learning ensemble approach for crude oil price forecasting. **ENERGY ECONOMICS**, v. 66, p. 9–16, 2017.

ZOU, Y.; YU, L.; HE, K. Wavelet Entropy Based Analysis and Forecasting of Crude Oil Price Dynamics. **ENTROPY**, v. 17, n. 10, p. 7167–7184, 2015.