

INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE
MINAS GERAIS - *CAMPUS* BETIM
BACHARELADO EM ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Allanderson Barros de Oliveira

**DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE PREÇO DO
MINÉRIO DE FERRO**

Betim
2025

ALLANDERSON BARROS DE OLIVEIRA

DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE PREÇO DO MINÉRIO DE FERRO

Trabalho de Conclusão de Curso apresentado à banca examinadora do curso de Engenharia de Controle e Automação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais *Campus* Betim, como parte dos requisitos para obtenção do título de Bacharel em Engenharia de Controle e Automação.

Orientador: Prof. Dr. Daniel Almeida Godinho

Betim
2025

FICHA CATALOGRÁFICA

O48d Oliveira, Allanderson Barros de

Desenvolvimento de modelos de previsão de preço do minério de ferro /
Allanderson Barros de Oliveira. – 2025.

47 f. : il.

Trabalho de conclusão de curso (Bacharelado em Engenharia de Controle
e Automação) - Instituto Federal de Educação, Ciência e Tecnologia de
Minas Gerais, Câmpus Betim, 2025.

Orientação: Prof. Dr. Daniel Almeida Godinho

1. Mineração de dados. 2. Aprendizado de máquina. 3. Economia -
Mercado. 4. Engenharia de Controle e Automação. I. Oliveira, Allanderson
Barros de. II. Título.


CDU: 004.8

Allanderson Barros de Oliveira


DESENVOLVIMENTO DE MODELOS DE PREVISÃO DE PREÇO DO MINÉRIO DE FERRO

Trabalho de Conclusão de Curso apresentado à banca examinadora do curso de Engenharia de Controle e Automação do Instituto Federal de Educação, Ciência e Tecnologia de Minas Gerais *Campus* Betim, como parte dos requisitos para obtenção do título de Bacharel em Engenharia de Controle e Automação.


Aprovado em: 05/08/2025 pela banca examinadora:

Documento assinado digitalmente
 DANIEL ALMEIDA GODINHO
Data: 18/09/2025 13:26:36-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Daniel Almeida Godinho (Orientador) - IFMG

Documento assinado digitalmente
 GUSTAVO LOBATO CAMPOS
Data: 17/09/2025 16:52:52-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Gustavo Lobato Campos - IFMG

Documento assinado digitalmente
 LEANDRO FREITAS DE ABREU
Data: 18/09/2025 14:21:30-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Leandro Freitas de Abreu - UFMG

AGRADECIMENTOS

Agradeço, primeiramente, aos meus pais, por todo o apoio e incentivo que me foram dedicados não apenas durante a elaboração deste trabalho, mas ao longo de toda a minha trajetória acadêmica. Essa parceria foi a base para que eu pudesse chegar até aqui. Sem esse suporte, esta conquista não seria possível.

Ao meu orientador, Professor Daniel Godinho, muito obrigado. Sou especialmente grato por sua disponibilidade para sanar dúvidas e, principalmente, por ter topado o desafio de orientar este trabalho.

Ao meu amigo e grande parceiro, Vitor, expresso minha sincera gratidão. Seu incentivo constante e apoio foram um suporte fundamental em toda a jornada acadêmica.

"Nós só podemos ver um pouco do futuro, mas o suficiente para perceber que há muito a fazer."(Alan Turing)

RESUMO

Este trabalho teve como objetivo principal desenvolver e avaliar comparativamente modelos de previsão para o preço do minério de ferro, matéria-prima principal de diversas indústrias como construção civil e automobilística. Previsões nesse cenário podem trazer estabilidade econômica e saúde para empresas do ramo. Para tal, foram implementadas abordagens estatísticas tradicionais (ARIMA), de aprendizado de máquina (XGBoost) e estratégias híbridas (*Ensemble* e Método de Resíduos). A análise também investigou o impacto da incorporação de variáveis exógenas no desempenho dos modelos. Os resultados demonstraram a superioridade do modelo *Ensemble*, sem variáveis exógenas, que combinou as previsões do ARIMA e do XGBoost, alcançando o menor erro quadrático médio (RMSE de 6.97) e o maior coeficiente de determinação R^2 de 0.67. Este desempenho se destaca por ter sido o único a superar o resultado do modelo trivial (RMSE de 7.05 e R^2 de 0.65), que por sua vez superou as demais abordagens complexas, evidenciando a dificuldade intrínseca da previsão. Verificou-se que a adição de variáveis exógenas foi, em geral, prejudicial à performance, especialmente em modelos lineares. Conclui-se que a combinação de modelos com diferentes naturezas é uma estratégia robusta para a previsão de séries temporais complexas, e que o tratamento adequado das variáveis externas é um fator crítico para o sucesso da previsão.

Palavras-chave: previsão; mineração; dados; modelos; exógenas.

ABSTRACT

The main objective of this work was to develop and comparatively evaluate forecasting models for the price of iron ore, a key raw material for various industries such as civil construction and automotive. Accurate forecasts in this scenario can bring economic stability and health to companies in the sector. To this end, traditional statistical approaches (ARIMA), machine learning models (XGBoost), and hybrid strategies (Ensemble and Residuals Method) were implemented. The analysis also investigated the impact of incorporating exogenous variables on the models' performance. The results demonstrated the superiority of the Ensemble model without exogenous variables, which combined the predictions of ARIMA and XGBoost, achieving the lowest Root Mean Square Error (RMSE of 6.97) and the highest coefficient of determination (R^2 of 0.67). This performance is notable as it was the only one to outperform the baseline model (RMSE of 7.05 and R^2 of 0.65), which in turn surpassed the other complex approaches, highlighting the intrinsic difficulty of the forecast. It was found that the addition of exogenous variables was, in general, detrimental to performance, especially in linear models. It is concluded that combining models of different natures is a robust strategy for forecasting complex time series, and that the proper handling of external variables is a critical factor for successful forecasting.

Keywords: forecasting; mining; data; models; exogenous.

LISTA DE ILUSTRAÇÕES

Figura 1 – Produção de aço no mundo	17
Figura 2 – Árvore de decisão	20
Figura 3 – Metodologia	25
Figura 4 – Método de janelas	29
Figura 5 – Modelos utilizados	30
Figura 6 – Decomposição da serie	34
Figura 7 – Estágios da serie	35
Figura 8 – Correlações	37
Figura 9 – Diagramas ACF e PACF para a série principal	38
Figura 10 – Comparação dos modelos sem exógenas	39
Figura 11 – Comparação dos modelos com exógenas	40
Figura 12 – Comparação dos modelos híbridos sem exógenas	41
Figura 13 – Comparação dos modelos híbridos com exógenas	42

LISTA DE TABELAS

Tabela 1 – Conjunto de dados, fontes e detalhamento das variáveis.	26
Tabela 2 – Métodos, bibliotecas e parâmetros configuráveis	31
Tabela 3 – Métricas de avaliação de desempenho dos modelos.	32
Tabela 4 – Correlações	36
Tabela 5 – Hiperparâmetros utilizados no modelo XGBoost	39
Tabela 6 – Tabela resumo dos resultados	42

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Justificativa	14
1.2	Objetivos	15
1.3	Organização do Texto	15
2	REVISÃO BIBLIOGRÁFICA	17
2.1	Minério de Ferro e a Influência Global	17
2.2	Series Temporais	18
2.3	ARIMA	19
2.4	Gradient Boosting	20
2.5	Métricas de comparação de modelos	21
2.6	Correlação e colinearidade	22
2.7	Trabalhos relacionados	23
3	METODOLOGIA	25
3.1	Coleta e características dos dados	25
3.2	Pré-Processamento	27
3.3	Definição da Estrutura do Modelo	28
3.4	Validação e Análise de Resultados	32
4	RESULTADOS	34
4.1	Características da variável dependente	34
4.2	Correlações	36
4.3	Modelos	38
5	CONCLUSÃO E TRABALHOS FUTUROS	44
5.1	Trabalhos Futuros	44
	REFERÊNCIAS	46

1 INTRODUÇÃO

O mercado de commodities, particularmente o minério de ferro, desempenha um papel importante na economia global, sendo um dos principais insumos para a produção de aço, essencial em diversas indústrias, como construção civil e automotiva. Com a crescente demanda por infraestrutura e desenvolvimento industrial, os preços do minério de ferro são influenciados por fatores como a oferta e a demanda, políticas comerciais, e a saúde econômica de países consumidores, especialmente a China, que é o maior importador mundial.

Essa volatilidade afeta diretamente a economia de países exportadores, como o Brasil, onde o setor mineral é um dos pilares da balança comercial. As oscilações podem impactar desde a arrecadação de impostos até a geração de empregos no setor, além disso indústrias dependentes do aço, como a construção civil, automotiva e de bens de consumo, são impactadas nos custos de produção, o que pode refletir no preço final dos produtos e, consequentemente, no poder de compra dos consumidores.

A previsão de preços pode ser realizada utilizando uma variedade de técnicas, desde métodos estatísticos tradicionais, como médias móveis e suavização exponencial, até abordagens mais avançadas, como modelos baseados em séries temporais e algoritmos de aprendizado de máquina (HYNDMAN; ATHANASOPOULOS, 2008). Cada técnica possui suas vantagens, dependendo da complexidade e dos padrões dos dados analisados. Neste contexto, o presente trabalho abordará o modelo ARIMA e suas variações, além do algoritmo XGBoost, avaliando seu desempenho na previsão de preços.

1.1 Justificativa

A previsão dos preços do minério de ferro apresenta um desafio significativo devido ao seu caráter intrinsecamente volátil. Essa volatilidade é impulsionada por diversos fatores complexos, que incluem desde as condições macroeconômicas globais até políticas governamentais específicas, a dinâmica de oferta e demanda, eventos geopolíticos e variações climáticas. A interação desses fatores resulta em uma elevada instabilidade nos preços, gerando um cenário de incerteza para investidores, empresas e governos envolvidos na indústria de mineração (RADETZKI, 2008). Relatórios periódicos de instituições como o Banco Mundial frequentemente destacam como o crescimento econômico, especialmente de grandes consumidores como a China, influencia diretamente essa dinâmica (World Bank, 2025).

Prever os preços do minério de ferro é uma estratégia eficaz de negócios e de gestão de riscos. A capacidade de antecipar tendências permite que as empresas planejem suas operações de produção e seus investimentos de capital de forma mais eficiente, buscando a otimização de custos e a maximização dos lucros (BREALEY; MYERS; ALLEN, 2020). A gestão da volatilidade de preços é, de fato, reconhecida como um dos principais desafios operacionais para o setor de mineração e metais (Ernst & Young, 2024).

Para os governos, especialmente de nações exportadoras, entender as tendências de preços é igualmente interessante. Essa compreensão auxilia na formulação de políticas econômicas e na regulação do mercado, visando a estabilidade econômica e o fomento ao crescimento sustentável. Análises detalhadas do mercado, como as fornecidas pela Conferência das Nações Unidas sobre Comércio e Desenvolvimento, oferecem dados valiosos para esse planejamento estratégico em nível nacional (UNCTAD, 2016).

Além disso, previsões acuradas auxiliam na estabilidade dos mercados globais de commodities, reduzindo o impacto de choques súbitos de preços que podem afetar economias inteiras, especialmente aquelas dependentes da exportação de minério de ferro. A capacidade de antecipar mudanças nos preços pode também beneficiar a pesquisa acadêmica e o desenvolvimento de novas tecnologias no setor. Promovendo inovações que podem levar a práticas de mineração mais eficientes e sustentáveis, um tema cada vez mais relevante nos debates sobre a disponibilidade de recursos a longo prazo (MUDD, 2010).

1.2 Objetivos

O objetivo principal deste trabalho é desenvolver e aperfeiçoar modelos para prever os preços do minério de ferro utilizando métodos de modelagem de séries temporais. Para alcançar este objetivo, os seguintes objetivos específicos foram delimitados:

- Coletar e preparar os dados necessários para a análise.
- Formular e testar hipóteses baseadas nos dados coletados para identificar padrões e tendências relevantes.
- Construir modelos de previsão utilizando diferentes técnicas, como ARIMA e *extreme gradient boosting*, para comparar suas performances.
- Medir e avaliar a acurácia dos modelos desenvolvidos, utilizando métricas apropriadas para determinar a precisão das previsões.

1.3 Organização do Texto

O trabalho está estruturado da seguinte forma:

No capítulo 2, são abordadas as teorias e metodologias relacionadas à previsão de séries temporais, com ênfase no modelo ARIMA. São explorados conceitos-chave, análises iniciais e a relevância das variáveis correlacionadas, além de uma revisão de trabalhos anteriores na área. No capítulo 3, descreve-se a sequência de passos para o desenvolvimento da pesquisa. Começa com a explicação dos dados utilizados, seguida pelos métodos de coleta e preparação, formulação de hipóteses e construção dos modelos de previsão, concluindo com a modelagem usando ARIMA. No capítulo 4 são apresentados os resultados obtidos, incluindo a avaliação

das previsões realizadas pelo modelo ARIMA e a comparação com XGBoost. As discussões focam na interpretação dos resultados, limitações do estudo e sugestões para pesquisas futuras. No capítulo 5, são destacados os principais pontos e conclusões do modelo proposto, discutindo as implicações práticas dos resultados e sua aplicabilidade em diferentes contextos. A conclusão também aborda as contribuições do estudo para a área e oferece reflexões sobre o impacto do trabalho e sua relevância para estudos futuros.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo, é introduzida a dinâmica do mercado de minério de ferro, os principais conceitos de séries temporais, técnicas de previsão e métricas de avaliação de modelos. Em (2.1) explora o mercado global do minério de ferro, no (2.2) detalha as propriedades das séries temporais, no (2.3) discute o modelo ARIMA, no (2.4) apresenta o método de *Extreme Gradient Boosting*. Além disso, aborda as métricas para comparação de modelos (2.5) e revisa trabalhos anteriores (2.6) que contextualizam e enriquecem a abordagem do trabalho.

2.1 Minério de Ferro e a Influência Global

O minério de ferro é uma *commodity* essencial que sustenta a indústria siderúrgica global, sendo fundamental para a produção de aço que é usado para uma vasta gama de setores econômicos, desde a construção civil e infraestrutura até a fabricação de automóveis e maquinários. O seu preço é sensível a um conjunto de fatores globais, a demanda é liderada pelo ritmo da economia chinesa conforme podemos ver na figura 1, sendo diretamente influenciada pelo crescimento do produto interno do país e, mais especificamente, pelo volume de aço que produz (LEMOS, 2012).




Figura 1 – Produção de aço no mundo

Fonte: Adaptado de World steel 2023

Detendo a hegemonia da siderurgia global, a China responde por mais da metade da produção de aço, posicionando-se assim como a principal demandante de minério de ferro, matéria-prima indispensável para essa indústria.

Indicadores que medem a atividade do setor industrial e a confiança dos gestores de compras atuam como um termômetro antecedente da procura futura pela *commodity*. No campo financeiro, a cotação do dólar frente a outras moedas globais exerce uma influência inversa, pois um dólar valorizado pode encarecer o minério para os países compradores, essa dinâmica cambial é frequentemente afetada pelas decisões sobre a taxa de juros americana (KOSSMANN, 2023). Outra influência são os custos logísticos, determinante que pode ser medido com os indicadores de frete marítimo que impactam diretamente o preço final do insumo para as siderúrgicas (OLIVEIRA, 2017). Em uma perspectiva mais ampla, o nível de industrialização das economias representa uma variável para a demanda de longo prazo, sustentando o consumo de aço para o desenvolvimento de infraestrutura e da indústria.

2.2 Series Temporais

As séries temporais são sequências de dados ordenadas no tempo, onde cada ponto representa uma observação registrada em intervalos temporais consistentes. O conceito central de séries temporais envolve a análise de como os valores observados evoluem ao longo do tempo, considerando as suas características dinâmicas (BOX; JENKINS, 1970). Diferentemente de outros conjuntos de dados, essas séries têm uma dimensão temporal, o que implica que a ordem dos dados é fundamental para a análise e a modelagem.

Uma das características fundamentais das séries temporais é a autocorrelação, que refere-se à correlação dos valores atuais com valores passados. Essa característica permite a exploração de padrões que podem ser usados para previsões futuras. Tendência é outra característica comum, representando um movimento geral ascendente ou descendente nos dados ao longo do tempo, refletindo mudanças estruturais no processo subjacente (HYNDMAN; ATHANASOPOULOS, 2018).

Sazonalidade refere-se a padrões que se repetem em intervalos regulares de tempo, influenciados por ciclos naturais ou eventos recorrentes, como mudanças sazonais ou horários de pico em séries de vendas. Além disso, as séries temporais podem exibir ciclicidade, onde flutuações ocorrem de maneira não fixa, geralmente devido a condições econômicas ou de mercado.

Desenvolver modelos eficazes para séries temporais apresenta vários desafios. Um desafio central é a estacionariedade, que implica que as propriedades estatísticas da série, como a média e a variância, sejam constantes ao longo do tempo. Muitas séries temporais reais não são estacionárias, exigindo transformações, como diferenciação ou transformação logarítmica, para estabilizar antes da modelagem (HYNDMAN; ATHANASOPOULOS, 2018).

Interpretar os resultados dos modelos pode ser uma tarefa difícil, especialmente em séries de alta dimensionalidade ou com estruturas subjacentes complexas. Ferramentas de visualização e análise de componentes podem ajudar a enxergar melhor os padrões capturados pelos modelos

(SHMUELI; LICHTENDAHL, 2017).

2.3 ARIMA

O modelo ARIMA (Autoregressive Integrated Moving Average) é composto por três componentes principais:

1. Autorregressão (AR): Assume que os valores passados influenciam linearmente os valores futuros. A ordem p indica quantos valores passados são considerados. A fórmula geral é:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \varepsilon_t, \quad (2.1)$$

onde $\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes de autorregressão e ε_t é um termo de erro aleatório (BOX; JENKINS, 1970).

2. Integração (I): Refere-se ao número de diferenciações necessárias para tornar a série estacionária, indicada pela ordem d . A diferenciação é calculada como:

$$Y_t = X_t - X_{t-1}. \quad (2.2)$$

3. Média Móvel (MA): Modela a dependência entre um valor observado e termos de erro passados, com a ordem q indicando quantos termos de erro são considerados:

$$X_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}, \quad (2.3)$$

onde $\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes de média móvel (BOX; JENKINS, 1970).

A equação final do modelo ARIMA combina esses componentes e é expressa como:

$$\Phi(B)(1-B)^d X_t = \Theta(B)\varepsilon_t, \quad (2.4)$$

onde $\Phi(B)$ é o polinômio de autorregressão de ordem p , $(1-B)^d$ representa o operador de diferenciação de ordem d , e $\Theta(B)$ é o polinômio de média móvel de ordem q . Aqui, B é o operador de defasagem.

A escolha dos parâmetros p , d , e q é crucial e pode ser feita através da análise da função de autocorrelação (ACF), da função de autocorrelação parcial (PACF), e de testes de raiz unitária como o ADF (Augmented Dickey-Fuller). Esses métodos ajudam a determinar as características da série e a estruturar o modelo de forma eficaz (DICKEY; FULLER, 1979).

A principal vantagem do ARIMA é sua capacidade de transformar séries não estacionárias em estacionárias, permitindo modelar flutuações de média e variância ao longo do tempo. Isso é especialmente útil para previsões de curto prazo, onde a continuidade dos padrões temporais é predominante.

Existem variações do método que abordam diferentes aspectos das séries temporais. O modelo SARIMA (sazonal ARIMA) incorpora um componente sazonal, capturando padrões

que se repetem em intervalos regulares. Este modelo adiciona parâmetros P , D , Q e s (período sazonal) para modelar especificamente a sazonalidade (HYNDMAN; ATHANASOPOULOS, 2018). Por outro lado, o ARIMAX inclui variáveis exógenas para considerar fatores externos que podem influenciar a série temporal, o que é particularmente útil quando eventos ou variáveis externas têm um impacto direto nas observações da série (TSAY, 2005).

2.4 Gradient Boosting

O *Extreme Gradient Boosting* (XGBoost) é um método de classificação, não sendo comum seu uso em previsão de série temporal, mas este trabalho irá avaliar o desempenho do modelo nesse cenário. O XGBoost é uma implementação avançada do método de *Gradient Boosting*, que utiliza árvores de decisão como modelos fracos para formar um modelo preditivo forte. Na figura 2, podemos observar o princípio de seu funcionamento, que pode ser entendido como um fluxo de decisões.

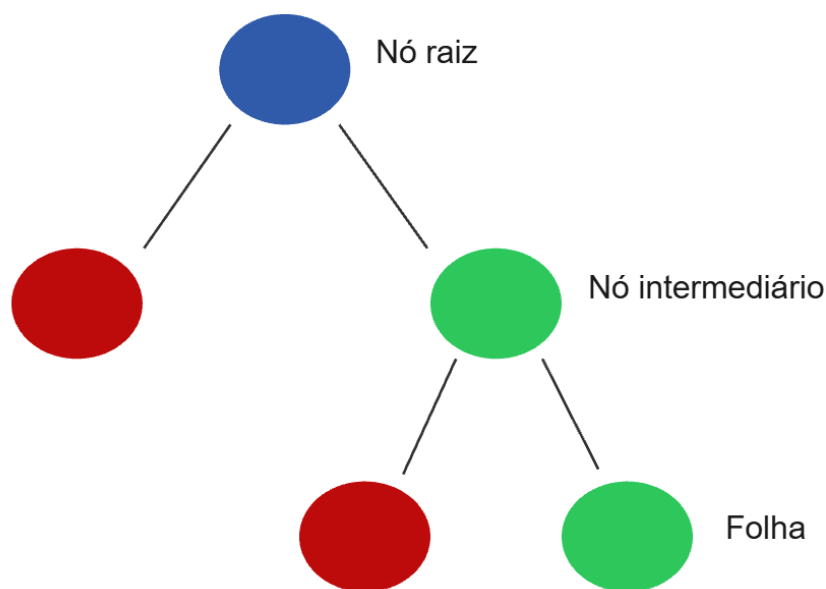


Figura 2 – Árvore de decisão

Fonte: do Autor

Tudo começa no nó raiz (azul), que representa o conjunto de dados completo e onde a primeira regra de decisão é aplicada para dividir os dados. Dependendo do resultado, os dados seguem por um ramo até um nó intermediário (verde), que aplica uma nova regra para afunilar ainda mais a separação daquele subgrupo. Este processo de divisão continua até que os dados cheguem a um nó final, a folha (verde), que não faz mais perguntas e representa a previsão ou classificação final para todos os dados que alcançaram aquele ponto.

A partir desse princípio, o método consiste em utilizar diversas árvores, onde ele otimiza iterativamente uma função de perda ao adicionar novas árvores que corrigem os erros das árvores anteriores (CHEN; GUESTRIN, 2016).

A equação geral para a predição em XGBoost em uma determinada iteração m é:

$$F_m(x) = F_{m-1}(x) + v \cdot h_m(x), \quad (2.5)$$

onde $F_m(x)$ é o modelo acumulado até a m -ésima iteração, v é a taxa de aprendizado, e $h_m(x)$ é o modelo de árvore treinado na m -ésima iteração.

A função de perda a ser minimizada no XGBoost é expressa como:

$$L(\theta) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_k \Omega(h_k), \quad (2.6)$$

onde $l(y_i, \hat{y}_i)$ é a função de perda entre o valor real y_i e a predição \hat{y}_i , e $\Omega(h_k)$ é o termo de regularização definido como:

$$\Omega(h_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2. \quad (2.7)$$

Neste termo, T é o número de folhas da árvore, γ é o parâmetro de regularização de complexidade da árvore, λ é o coeficiente de regularização L2, e w_j são os pesos das folhas.

O objetivo do XGBoost é encontrar a árvore $h_m(x)$ que minimiza a função de perda regularizada em cada iteração, ajustando os resíduos dos modelos anteriores. Esse ajuste é realizado utilizando o gradiente da função de perda, que permite melhorar iterativamente a precisão do modelo ao longo do tempo.

O modelo também utiliza técnicas como divisão baseada em histograma para dados contínuos e compressão de recursos para lidar eficientemente com grandes volumes de dados e melhorar a escalabilidade (CHEN; GUESTRIN, 2016).

2.5 Métricas de comparação de modelos

A avaliação de modelos de previsão é uma etapa crítica ao desenvolver qualquer modelo de previsão. Para determinar a eficácia, várias métricas de desempenho podem ser utilizadas, ajudando a comparar diferentes modelos e selecionar o mais adequado para a tarefa em questão (HYNDMAN; ATHANASOPOULOS, 2018). O Erro Absoluto Médio (MAE - Mean Absolute Error) mede a média das diferenças absolutas entre as predições do modelo e os valores reais, calculado como:

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (2.8)$$

onde y_i são os valores reais, \hat{y}_i são as predições, e n é o número de observações. O MAE fornece uma medida clara de erro em termos da unidade de medida original (WILLMOTT; MATSUURA, 2005). O Erro Quadrático Médio (MSE - Mean Squared Error) calcula a média dos quadrados das diferenças entre as predições e os valores reais. A fórmula é:

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2. \quad (2.9)$$

O MSE penaliza erros maiores mais severamente do que o MAE, devido à sua natureza quadrática, tornando-o útil quando se deseja penalizar grandes erros (HYNDMAN; ATHANASOPOULOS, 2018). A Raiz do Erro Quadrático Médio (RMSE - Root Mean Squared Error) é a raiz quadrada do MSE, fornecendo uma medida de erro na mesma unidade dos dados originais:

$$\text{RMSE} = \sqrt{\text{MSE}}. \quad (2.10)$$

O RMSE é comumente usado para dar uma interpretação mais direta do erro médio (HYNDMAN; ATHANASOPOULOS, 2018). O Erro Percentual Absoluto Médio (MAPE - Mean Absolute Percentage Error) expressa o erro médio em termos percentuais, sendo calculado como:

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|. \quad (2.11)$$

O MAPE é útil para entender o erro relativo ao tamanho dos valores observados, mas pode ser problemático se houver valores reais próximos de zero (KIM; WILLMOTT, 1999). O Coeficiente de Determinação (R^2) mede a proporção da variância nos dados que é explicada pelo modelo. Ele varia de 0 a 1, onde valores próximos de 1 indicam um bom ajuste do modelo:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}, \quad (2.12)$$

onde \bar{y} é a média dos valores reais (JONES, 1975).

Ao escolher métricas para avaliar modelos de previsão, é importante considerar o contexto do problema e as características dos dados. Por exemplo, se os dados contêm muitos *outliers*, o MAE pode ser preferido ao MSE ou RMSE. Da mesma forma, o MAPE é útil para comparações entre séries de diferentes magnitudes, mas pode não ser adequado se os dados contêm zeros ou valores muito próximos de zero.

2.6 Correlação e colinearidade

A análise de correlação constitui uma das ferramentas estatísticas mais fundamentais para a investigação da relação entre duas ou mais variáveis. O princípio da correlação é quantificar a força e a direção de uma associação linear entre variáveis contínuas. O coeficiente de correlação de Pearson (r), cujo valor varia no intervalo de $[-1, 1]$, é a medida mais comum para essa finalidade. Um valor de r próximo a 1 indica uma forte correlação positiva, sugerindo que as variáveis tendem a aumentar ou diminuir conjuntamente. Por outro lado, um valor próximo a -1 indica uma forte correlação negativa, em que o aumento de uma variável está associado à diminuição da outra. Um coeficiente próximo a zero sugere a ausência de uma relação linear, embora não descarte a possibilidade de outras formas de associação, como as não lineares (HAIR *et al.*, 2019).

Quando a análise envolve dados coletados ao longo do tempo, ou seja, séries temporais, a análise de correlação convencional pode se mostrar insuficiente. A correlação cruzada surge como

uma extensão da correlação de *Pearson*, projetada especificamente para medir a similaridade entre duas séries temporais em função de um deslocamento temporal, ou *lag*, aplicado a uma delas. Em vez de calcular um único coeficiente, a função de correlação cruzada (CCF) gera uma série de coeficientes para diferentes *lags* positivos e negativos. Isso permite não apenas determinar a existência de uma relação entre as séries, mas também identificar se uma série lidera a outra e qual o tempo de defasagem dessa liderança (BOX; JENKINS, 1970).

A colinearidade, ou multicolinearidade, descreve a alta correlação entre duas ou mais variáveis independentes em um modelo de regressão. O seu efeito prático é o aumento da variância dos coeficientes de regressão estimados, tornando as estimativas individuais instáveis e imprecisas. Como resultado, os erros padrão associados a esses coeficientes aumentam, o que diminui o poder estatístico dos testes de hipótese individuais (MONTGOMERY; PECK; VINING, 2021). Isso pode levar à falha em identificar preditores estatisticamente significantes, mascarando relações verdadeiras entre as variáveis e a resposta.

Para diagnosticar a presença e a severidade da multicolinearidade em um modelo de regressão, o fator de inflação da variância (VIF) é a métrica mais utilizada. O VIF mede o quanto a variância de um coeficiente de regressão estimado é aumentada devido à sua correlação com as outras variáveis independentes no modelo. Para cada variável preditora X_i , o VIF é calculado da seguinte forma:

$$VIF_i = \frac{1}{1 - R_i^2}, \quad (2.13)$$

onde R_i^2 é o coeficiente de determinação obtido de uma regressão auxiliar de X_i em todas as outras variáveis predictoras do modelo. Esse R_i^2 indica a proporção da variância de X_i que é explicada pelas outras predictoras. Um valor de VIF igual a 1 indica a ausência de correlação entre a variável em questão e as demais. Valores de VIF entre 1 e 5 sugerem uma correlação moderada, enquanto valores superiores a 5, são comumente utilizados como limiares para indicar a presença de multicolinearidade problemática (GUJARATI; PORTER, 2009; HAIR *et al.*, 2019). Existem alguns caminhos para solucionar esse problema, como a remoção de uma das variáveis correlacionadas ou o uso de técnicas de regressão mais robustas à colinearidade.

2.7 Trabalhos relacionados

Dado o objetivo desse trabalho, é válido ressaltar trabalhos disponíveis na literatura que compartilham objetivo similares.

No estudo de (HAMILTON, 2022), modelos nebulosos como o PWFTS (Probabilistic Weighted Fuzzy Time Series) e o FDT-FTS (Fuzzy Decision Trees) foram comparados a métodos tradicionais, incluindo ARIMA, MLP e XGBoost, na previsão dos preços do minério de ferro. Apesar dos modelos nebulosos apresentarem desempenho superior em métricas como RMSE e MAPE, é crucial reconhecer a complexidade intrínseca dessas técnicas. A implementação de modelos fuzzy envolve desafios significativos na seleção e calibração de variáveis, além de

exigir maior esforço para a interpretação dos resultados. Esta complexidade pode limitar sua aplicabilidade prática, fazendo com que, em alguns contextos, métodos mais simples sejam preferíveis pela facilidade de uso e compreensão.

Em (LIMA *et al.*, 2010) explora o uso de modelos ARIMA-GARCH combinados com redes neurais e *wavelet* para a previsão de preços de commodities, especificamente a soja. Os autores realizam previsões dentro das subséries decompostas por uma ondaleta, reconstruindo a série temporal e gerando estimativas futuras para os preços. A aplicação prática e a validação dos modelos foram feitas por meio da análise dos preços da saca de 60 quilos de soja, onde as técnicas propostas demonstraram ser eficazes na redução de ruído e melhoria da qualidade das previsões. A pesquisa também contribui para a discussão sobre técnicas avançadas de previsão, provando que a integração de métodos clássicos com novas tecnologias pode oferecer ganhos valiosos.

Em (MEDEIROS, 2021), foi utilizada a técnica de XGBoost para prever o comportamento de preços em operações de day-trade com minicontratos futuros de Dólar Comercial e Ibovespa. Os resultados mostraram que o modelo atingiu uma acurácia de 50,1% para o Dólar Comercial, e uma acurácia de 51,8% para o Ibovespa, apesar do resultado parecer limitado, para o mercado de especulações a curto prazo é uma acurácia relevante, demonstrando que o modelo pode servir de apoio para tomadas de decisão no mercado financeiro.

3 METODOLOGIA

A metodologia deste estudo seguiu uma sequência organizada conforme apresentado pela figura 3.

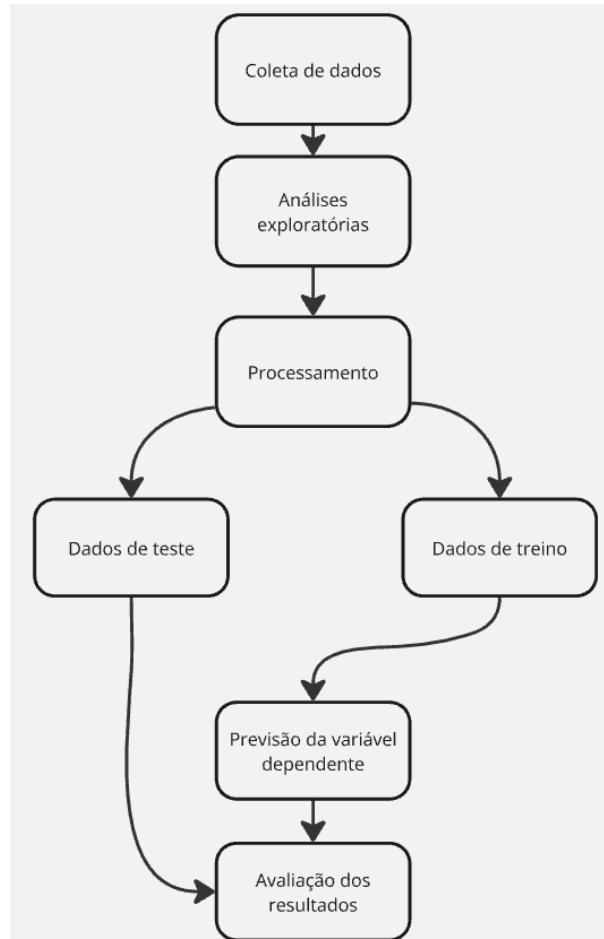


Figura 3 – Metodologia

Fonte: do Autor

Partindo da coleta de dados e passando pela análise exploratória e o devido processamento, prosseguindo com a divisão em conjuntos de treino e teste, até a aplicação dos modelos de previsão e a avaliação dos resultados.

3.1 Coleta e características dos dados

A coleta de dados foi realizada a partir de diversas fontes utilizadas para análise de mercado, conforme apresentado na Tabela 1. As variáveis selecionadas incluem o preço do minério de ferro, indicadores econômicos, financeiros e de produção, buscando uma base sólida para as análises e um potencial de previsão. A definição do conjunto de variáveis para este estudo seguiu uma abordagem fundamentada em hipóteses e em evidências empíricas da literatura, como o trabalho de (HAMILTON, 2022) que utiliza uma variável de frete marítimo como o *Baltic Dry*

Index (BDI). Os dados abrangem o período de janeiro de 2015 até junho de 2025, fornecendo dados suficientes para identificar tendências de curto prazo. Cada fonte foi escolhida com base na relevância e no volume dos dados disponíveis, assegurando a adequação ao objetivo do trabalho.

Tabela 1 – Conjunto de dados, fontes e detalhamento das variáveis.

Variável	Amostra	Unidade	Fonte de Dados	Detalhamento
Minério de Ferro 62%	Mensal	USD/t	IndexMundi < https://www.indexmundi.com/commodities/?commodity=iron-ore&months=360 >	Preço de referência internacional para o minério de ferro com 62% de pureza.
Índice do Dólar (DXY)	Mensal	Índice	Investing.com < https://br.investing.com/indices/usdollar-historical-data >	Mede o valor do dólar americano em relação a moedas estrangeiras.
PIB China	Trimestral	Trilhão de CNY	National Bureau of Statistics of China < https://data.stats.gov.cn/english/easyquery.htm?cn=B01 >	Principal indicador da atividade econômica e do crescimento da economia chinesa.
Taxa de Juros Americana	Mensal	%	MacroTrends < https://www.macrotrends.net/2015/fed-funds-rate-historical-chart >	Taxa básica de juros definida pelo <i>Federal Reserve</i> , influenciando o crédito global.
Índice de Produção Industrial	Trimestral	Índice	World Bank < https://prosperitydata360.worldbank.org/en/indicator/IMF+IFS+AIP_IX >	Índice que reflete o volume da produção do setor industrial no mundo.
Produção de Aço na China	Mensal	Milhões de Toneladas	TradingEconomics < https://pt.tradingeconomics.com/china/steel-production >	Volume total de aço bruto produzido na China, principal consumidor de minério de ferro.
<i>Purchasing Managers' Index</i> (PMI)	Mensal	Índice	TradingView < https://www.tradingview.com/symbols/ECONOMICS-PMI/ >	Indicador antecedente que mede o nível de atividade dos gestores de compras no setor manufatureiro.
<i>Baltic Dry Index</i> (BDI)	Mensal	Índice	TradingView < https://www.tradingview.com/chart/7H64lcHi/ >	Índice do custo de transporte marítimo de matérias-primas sólidas a granel.

Fonte: do Autor

Essas variáveis capturam diferentes dimensões do cenário econômico global que podem afetar o preço do minério de ferro. Enquanto o PIB da China, a Produção de Aço e o Índice de Industrialização refletem o crescimento econômico e a atividade industrial, o *Purchasing Managers' Index* indica a confiança e o ritmo do setor manufatureiro. Por outro lado, o índice do dólar e a taxa de juros americana trazem a influência de fatores monetários e financeiros sobre os mercados internacionais de commodities. Além disso, o *Baltic Dry Index* avalia as condições do transporte marítimo de cargas, fornecendo indícios da demanda global por matérias-primas.

3.2 Pré-Processamento

O pré-processamento dos dados é uma etapa fundamental para garantir a integridade e consistência das séries temporais, além de preparar os dados para a modelagem subsequente. A linguagem de programação *Python* foi a ferramenta escolhida para este trabalho devido ao seu rico ecossistema de bibliotecas e simplicidade de aplicação. Para as etapas de tratamento e processamento dos dados, serão utilizadas as bibliotecas *Pandas* e *NumPy*, enquanto a implementação e análise dos modelos estatísticos serão realizadas com o pacote *Statsmodels*.

Inicialmente, as séries temporais de todas as variáveis serão organizadas e alinhadas cronologicamente, garantindo que não haja discrepâncias temporais entre os diferentes conjuntos de dados. Qualquer dado ausente será tratado utilizando técnicas adequadas, como interpolação linear, que preserva a continuidade da série, ou imputação baseada em algoritmos, como *k-nearest neighbors* (TROYANSKAYA *et al.*, 2001).

A normalização ou padronização das variáveis será aplicada quando necessário, utilizando métodos como a padronização z-score, que transforma os dados para uma distribuição com média zero e desvio-padrão igual a um (HASTIE; TIBSHIRANI; FRIEDMAN, 2009). Essa técnica garante que todas as variáveis estejam na mesma escala, prevenindo que uma variável com valores maiores domine a análise. Para prevenir o vazamento de dados, a normalização será realizada de forma independente após a divisão da série. O procedimento correto consiste em ajustar o normalizador utilizando apenas os dados do conjunto de treino e, em seguida, essa mesma transformação, com os parâmetros já definidos, é aplicada ao conjunto de teste. Isso garante que nenhuma informação do conjunto de teste influencie a etapa de treinamento, o que poderia levar a uma superestimação irreal do desempenho do modelo.

A diferenciação das séries temporais será aplicada para remover tendências e tornar os dados estacionários, condição necessária para modelos de séries temporais. A estacionariedade será avaliada utilizando testes estatísticos, como o teste de Dickey-Fuller Aumentado (ADF) (DICKEY; FULLER, 1979). Para verificar a existência de defasagens temporais entre as variáveis independentes e a variável dependente, será utilizada a função de correlação cruzada (*cross-correlation function*, CCF), que mede a correlação entre duas séries em diferentes defasagens (BOX; JENKINS, 1970). Isso permitirá identificar atrasos no impacto de uma variável sobre a outra. A defasagem ótima será determinada com base nos picos de correlação da CCF, e as variáveis serão ajustadas no tempo de acordo com essas defasagens identificadas.

Adicionalmente, será avaliada a utilização da transformação *Box-Cox*, a fim de verificar se a estabilização de variância promovida por essa transformação pode melhorar o desempenho do método. A transformação de Box-Cox é um procedimento estatístico utilizado para estabilizar a variância e aproximar a distribuição dos dados à normalidade, condições que beneficiam a performance de muitos modelos de previsão (BOX; COX, 1964). A técnica é definida pela

seguinte função de potência, onde y_i é o dado original:

$$y_i^{(\lambda)} = \begin{cases} \frac{y_i^\lambda - 1}{\lambda} & \text{se } \lambda \neq 0 \\ \ln(y_i) & \text{se } \lambda = 0 \end{cases} \quad (3.1)$$

O parâmetro λ é otimizado a partir dos próprios dados tipicamente por meio da maximização da função de log-verossimilhança para encontrar a transformação que melhor ajusta a série às premissas do modelo. Casos específicos de λ correspondem a transformações conhecidas: se $\lambda=1$, os dados não são alterados; se $\lambda=0$, aplica-se a transformação logarítmica; e se $\lambda=0.5$, utiliza-se a raiz quadrada. O objetivo é, portanto, mitigar a variância não constante para que o modelo de previsão possa capturar os padrões da série de forma mais precisa.

Por fim, será conduzida uma análise de multicolinearidade entre as variáveis independentes por meio do cálculo do fator de inflação da variância (VIF), garantindo que variáveis com alta correlação não comprometam a estabilidade do modelo. Variáveis com VIF elevado serão transformadas ou removidas para garantir a performance na previsão (MONTGOMERY; PECK; VINING, 2021).

3.3 Definição da Estrutura do Modelo

Após o pré-processamento dos dados, o próximo passo é a estruturação dos modelos e a preparação adequada para a análise preditiva. A divisão dos dados em conjuntos de treino e teste será realizada preservando a ordem temporal, fundamental para séries temporais. Neste trabalho, será adotada uma divisão de 80% dos dados mais antigos para o conjunto de treino e 20% dos mais recentes para o conjunto de teste. A escolha por uma proporção maior para o conjunto de teste fundamenta-se na busca por uma avaliação mais robusta da capacidade de generalização do modelo, essa prática é importante para se obter uma estimativa confiável do erro em dados futuros (JAMES *et al.*, 2023). Embora outras abordagens existam, como a divisão 90/10 utilizada em (HAMILTON, 2022), a presente metodologia prioriza um rigor maior na validação dos modelos.

Adicionalmente, será empregada a técnica de *rolling window*, na qual o conjunto de treinamento é atualizado à medida em que a variável dependente é prevista, alinhando-se ao objetivo de previsões de curto prazo, o funcionamento da técnica é apresentado na figura 4.

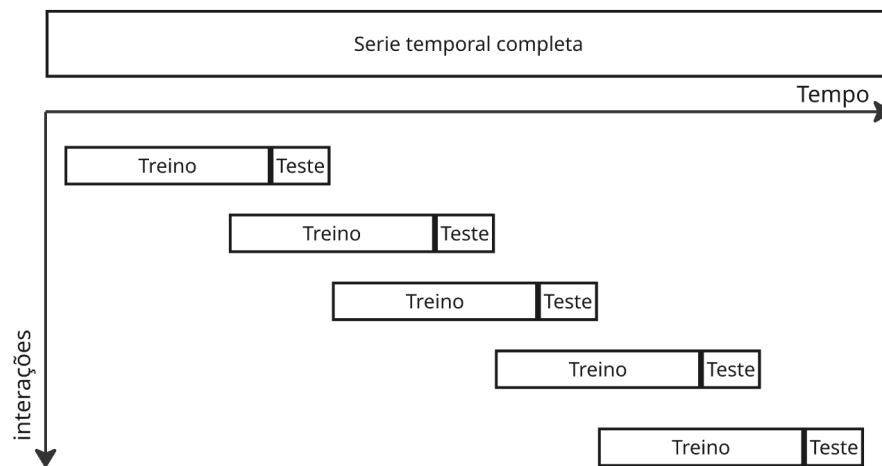


Figura 4 – Método de janelas

Fonte: do Autor

A cada iteração, o modelo é treinado com os dados contidos nessa janela para prever o período imediatamente seguinte, como o próximo mês. Após a previsão ser feita, a janela desliza para a frente no tempo, o dado mais antigo do conjunto de treinamento é descartado e o valor real do período que acabamos de prever é incorporado. O modelo é então completamente retreinado com esta nova janela de dados atualizada para fazer a próxima previsão. Este ciclo de retreinamento contínuo garante que o modelo se adapte dinamicamente aos padrões mais recentes da série, tornando a avaliação de sua performance mais realista.

A estratégia de modelagem adotada neste trabalho emprega uma abordagem híbrida para a previsão de preços. Foram selecionados dois modelos primários com naturezas distintas, o ARIMA e o algoritmo de aprendizado de máquina XGBoost. Visando potencializar a acurácia das previsões, as saídas de ambos os modelos serão combinadas através de duas técnicas de ensemble distintas, que exploram diferentes formas de sinergia entre os modelos. O fluxograma metodológico na Figura 5 ilustra visualmente a arquitetura proposta.

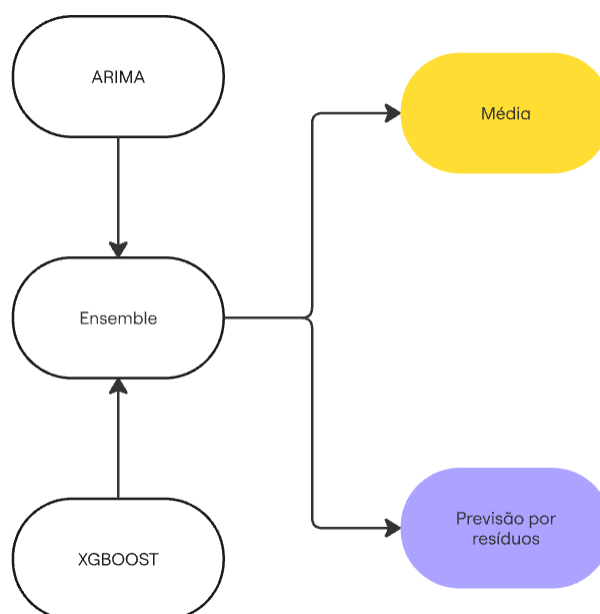


Figura 5 – Modelos utilizados

Fonte: do Autor

A metodologia se desenvolve a partir das previsões individuais dos modelos ARIMA e XGBoost, que servem como base para duas estratégias de ensemble: a média simples e a previsão por resíduos. A primeira técnica é a mais direta, consistindo no cálculo da média aritmética das previsões geradas por ambos os modelos para cada ponto no horizonte de tempo. A premissa desta abordagem é que os erros individuais de cada modelo, por serem de naturezas distintas, podem se anular mutuamente, o que tende a resultar em uma previsão final mais estável e precisa do que a de qualquer um dos modelos operando isoladamente.

A segunda abordagem, a previsão por resíduos, implementa um método híbrido de forma sequencial. Primeiramente, o modelo ARIMA é ajustado à série temporal para gerar uma previsão inicial. Na sequência, calculam-se os seus resíduos (a diferença entre os valores reais e os previstos), que contêm os padrões de erro e as não linearidades que o ARIMA não conseguiu capturar. Estes resíduos tornam-se a variável-alvo para o modelo XGBoost, que é treinado especificamente para prevê-los. A previsão final deste ensemble é então construída pela soma da previsão original do ARIMA com a previsão dos resíduos gerada pelo XGBoost, criando um mecanismo de correção.

Por fim, ambas as estratégias de ensemble, bem como os modelos base individuais, serão testados de forma univariada e de forma multivariada, para avaliarmos o desempenho das variáveis exógenas como preditoras.

O desempenho de cada modelo é intrinsecamente dependente da especificação de seus parâmetros e hiperparâmetros. Portanto, uma etapa fundamental do processo metodológico consiste na seleção e ajuste desses valores para otimizar a performance de previsão. A tabela

2 resume os métodos de modelagem adotados, as respectivas bibliotecas utilizadas para sua implementação e os principais parâmetros que foram configurados e analisados neste estudo.

Tabela 2 – Métodos, bibliotecas e parâmetros configuráveis

Método	Bibliotecas	Parâmetros Configuráveis
ARIMA	statsmodels	p (ordem autorregressiva) d (número de diferenciações) q (ordem da média móvel) AIC (critério de informação de Akaike)
ARIMAX	statsmodels	p (ordem autorregressiva) d (número de diferenciações) q (ordem da média móvel) exog (variáveis exógenas) AIC (critério de informação de Akaike)
XGBoost	xgboost	n_estimators (número de árvores) max_depth (profundidade máxima) learning_rate (taxa de aprendizado) subsample (fração de amostras para treino) colsample_bytree (fração de variáveis por árvore)
Métodos híbridos(Por resíduo e por média)	-	Não se aplica

Fonte: do Autor

O modelo ARIMA será estruturado com os parâmetros p (ordem autorregressiva), d (número de diferenciações) e q (ordem de média móvel), definidos com base na análise das funções de autocorrelação (ACF) e autocorrelação parcial (PACF), além do critério de informação de Akaike (AIC) para a seleção da melhor combinação de parâmetros.

No ARIMAX, além dos parâmetros p , d e q , também será considerada a inclusão de variáveis exógenas defasadas, cuja defasagem será ajustada de acordo com a análise de correlação cruzada (CCF) realizada previamente para garantir que seus efeitos temporais sejam capturados corretamente.

Para o XGBoost, a estruturação dos dados será feita com janelas deslizantes (*sliding windows*), transformando as séries temporais em um formato supervisionado, onde os valores passados são usados para prever valores futuros. Os principais parâmetros que serão ajustados incluem o número de árvores ($n_estimators$), a profundidade máxima das árvores (max_depth), a taxa de aprendizado ($learning_rate$) e o subsampling ($subsample$) das amostras de treino. Esses parâmetros serão otimizados utilizando técnicas de busca, como o *Grid Search*, para garantir que o modelo capture da melhor maneira possível as dinâmicas temporais e as interações entre variáveis.

3.4 Validação e Análise de Resultados

A etapa de validação e análise de resultados consiste na avaliação da qualidade e da efetividade dos modelos de previsão desenvolvidos. Após a implementação dos algoritmos propostos e a divisão dos dados em conjuntos de treino e teste, é preciso verificar o quão bem as previsões se ajustam aos valores reais observados. Para isso, serão utilizadas métricas como o RMSE, o MAE e o R^2 , presentes na Tabela 3, a seguir, com um resumo de como devem ser interpretadas.

Tabela 3 – Métricas de avaliação de desempenho dos modelos.

Métrica	Interpretação Resumida
MAE	Mede a média da magnitude dos erros. Está na mesma unidade da variável original e indica o quão longe, em média, as previsões estão dos valores reais. Quanto menor, melhor.
RMSE	Similar ao MAE, mas penaliza erros grandes de forma mais significativa por elevá-los ao quadrado. Também está na mesma unidade da variável. Quanto menor, melhor.
R^2	Indica a proporção da variância dos dados que é explicada pelo modelo. Varia de 0 a 1, representando a porcentagem do acerto do modelo. Quanto mais próximo de 1, melhor o ajuste.

Fonte: do Autor

Dessa forma, é possível identificar eventuais discrepâncias e verificar se os modelos estão subajustados ou superajustados, além de avaliar a capacidade de previsão nesse cenário complexo.

Nesse processo, a consistência dos resultados é verificada ao longo do período de teste, examinando se o desempenho do modelo permanece consistente diante de variações no comportamento dos dados. Em situações em que o conjunto de dados apresenta estruturas sazonais ou não estacionárias, é comum que o desempenho do modelo oscile conforme determinadas janelas temporais. Por isso, a análise gráfica das séries de previsão em comparação às séries observadas pode ser relevante, a visualização do comportamento temporal facilita a identificação de padrões e sugestões de hipóteses além de eventuais falhas do modelo em capturar picos ou vales abruptos.

O modelo de previsão trivial, também conhecido como modelo de persistência, possui a lógica mais fundamental em previsão de séries temporais, ele assume que as condições do futuro imediato serão idênticas às do presente. Portanto, a melhor estimativa para o valor do próximo período é simplesmente o último valor que foi efetivamente observado. Este método não aprende padrões complexos, mas é extremamente útil como um ponto de referência para avaliar se modelos mais sofisticados realmente oferecem um desempenho superior (HYNDMAN;

ATHANASOPOULOS, 2018).

A fórmula matemática para essa previsão é:

$$\hat{y}_{t+1} = y_t \quad (3.2)$$

Onde:

- \hat{y}_{t+1} é o valor previsto para o próximo período.
- y_t é o valor real observado no período atual.

Por fim, a análise comparativa dos resultados tem como ponto de partida a validação dos modelos propostos frente ao desempenho do modelo trivial. Esta etapa inicial é importante para estabelecer uma régua de referência e garantir que as abordagens mais complexas, de fato, agregam valor de previsão que justifique sua aplicação. Superada essa validação fundamental, a comparação se aprofunda na escolha do modelo que melhor atende aos objetivos propostos. Em algumas situações, o modelo que apresenta melhor desempenho em métricas gerais pode não ser o mais adequado para aplicações específicas que exijam menor subestimação ou maior sensibilidade aos picos. Além disso, a discussão dos resultados também se estende à análise crítica dos limites de cada abordagem, destacando possíveis ajustes futuros como a inclusão de novas variáveis exógenas, refinamento de hiperparâmetros ou adoção de metodologias mais avançadas para aprimorar a performance das previsões.

4 RESULTADOS

Neste capítulo, são apresentados os resultados obtidos a partir da aplicação da metodologia detalhada no capítulo anterior. Inicialmente, serão discutidas as características da variável dependente, seguidas pela análise das correlações entre as variáveis do estudo. Por fim, será realizada a comparação entre os modelos testados, destacando as diferenças, semelhanças e a performance de cada um.

4.1 Características da variável dependente

Os dados da variável dependente estão dispostos em uma série temporal que abrange o período de janeiro de 2015 a junho de 2025. Essa variável reflete as flutuações do mercado ao longo de uma década, capturando ciclos econômicos, variações sazonais e impactos de eventos globais significativos. Foi realizada uma decomposição da série, para capturar informações relevantes como tendência e sazonalidade, conforme pode ser observado na figura 6.




Figura 6 – Decomposição da serie

Fonte: do Autor

O componente observado reflete os valores reais da série de preços entre 2015 e 2025. Observa-se um crescimento moderado até 2020, seguido por uma aceleração acentuada, que termina em um pico próximo a 2021. Após esse ponto, o preço apresenta queda e uma posterior estabilização, esse comportamento sugere a influência de fatores contextuais, possivelmente associado ao evento da pandemia de COVID-19, que gerou muitas mudanças econômicas interna-

cionais que afetaram na oferta e demanda de commodities. A tendência evidencia de forma mais clara esse movimento estrutural, com uma trajetória de alta acentuada entre 2019 e 2021, atingindo o ponto máximo nesse último ano. Posteriormente, observa-se uma reversão da tendência, com perda de força no crescimento e certa estabilização ao redor de 2023, essa componente capta o movimento de longo prazo do mercado e ajuda a isolar flutuações permanentes. A sazonalidade revela flutuações periódicas regulares ao longo dos anos, com padrão recorrente anual. Essa oscilação indica que o preço possui comportamento sazonal consistente, provavelmente influenciado por ciclos de produção, exportação, demanda internacional ou outros fatores recorrentes do setor. O componente de resíduo, que representa a parte da série não explicada pela tendência ou sazonalidade, mostra dispersões mais intensas entre 2020 e 2022. Isso pode ser interpretado como impactos de choques pontuais, que não seguem padrões históricos, fora esses períodos, os resíduos se mantêm próximos de zero.

O teste de estacionariedade ADF foi aplicado e o valor obtido foi $-2,79$, enquanto o p-valor associado foi $6,2\%$, superior ao nível de significância de 5% . Além disso, o ADF não excedeu os valores críticos para os níveis de 1% , 5% e 10% . Dessa forma, como já era esperado, isso indica que a série não é estacionária.

Para preparar a série para a modelagem, foram aplicadas transformações visando a estacionariedade. A diferenciação de primeira ordem foi utilizada para remover a tendência, enquanto a transformação de *Box-Cox* foi avaliada como um método para estabilizar a variância. A Figura 7 ilustra o impacto visual de cada abordagem, permitindo comparar o resultado da aplicação individual e combinada dessas técnicas.

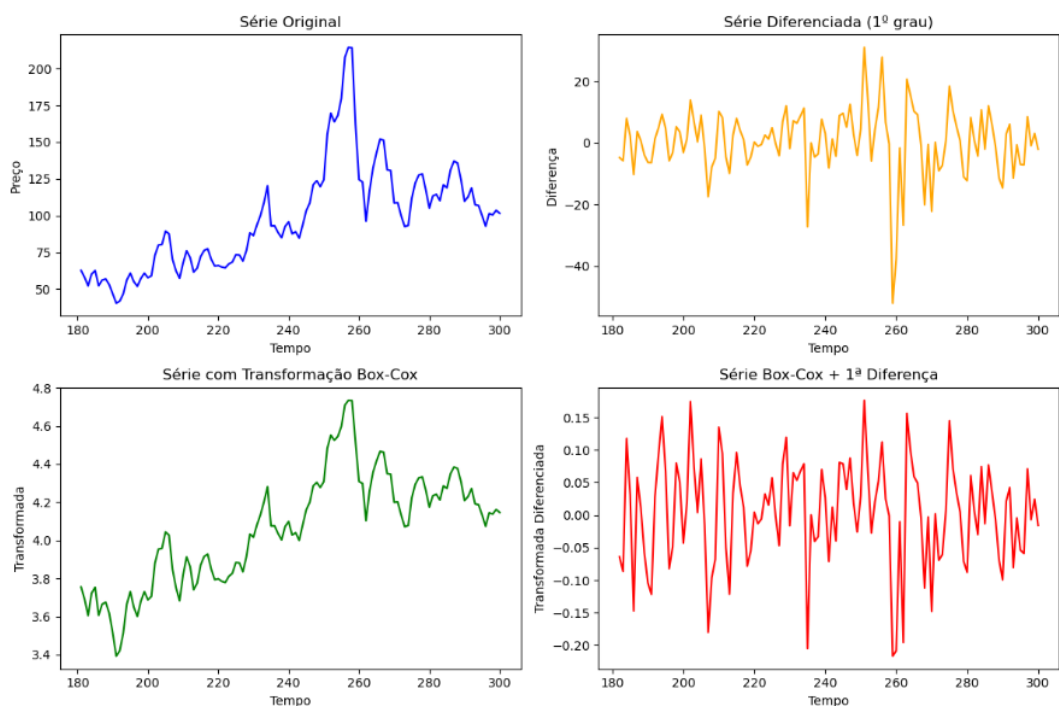


Figura 7 – Estágios da serie

Fonte: do Autor

A figura ilustra o tratamento da série original, que exibe não estacionariedade tanto na média, devido à sua clara tendência, quanto na variância. Para corrigir esses pontos, a diferenciação de primeira ordem remove a tendência, fazendo a série oscilar em torno de um nível constante, enquanto a transformação de *Box-Cox* estabiliza a variância, tornando as flutuações mais uniformes ao longo do tempo. A aplicação conjunta de ambas as técnicas resulta em uma série visualmente estacionária, com média e variância constantes, estabelecendo assim a condição adequada para a modelagem preditiva.

4.2 Correlações

Para investigar as relações entre o preço do minério de ferro e as variáveis explicativas ao longo do tempo, foi aplicada a análise de correlação cruzada. Esse método permitiu identificar as correlações em diferentes defasagens temporais, fornecendo uma base para compreender como as variáveis se relacionam em diferentes períodos, conforme podemos verificar na tabela 3.

Tabela 4 – Correlações

Defasagem (meses)	BDI	Produção de aço	Índice industrialização	Juros americanos	PMI	Índice do dólar	PIB chines
0.0	0.659	0.694	0.224	0.184	-0.012	-0.107	0.616
1.0	0.584	0.7	0.241	0.173	0.009	-0.114	0.621
2.0	0.51	0.69	0.257	0.162	0.024	-0.114	0.629
3.0	0.464	0.664	0.278	0.142	0.015	-0.121	0.621
4.0	0.424	0.642	0.263	0.104	0.001	-0.127	0.606
5.0	0.398	0.629	0.236	0.097	-0.014	-0.128	0.598
6.0	0.398	0.649	0.238	0.088	-0.034	-0.135	0.589
7.0	0.385	0.679	0.237	0.077	-0.034	-0.163	0.597
8.0	0.376	0.722	0.238	0.065	-0.023	-0.151	0.592
9.0	0.369	0.752	0.255	0.054	-0.017	-0.141	0.564
10.0	0.333	0.736	0.247	0.046	-0.084	-0.141	0.517
11.0	0.28	0.699	0.228	0.039	-0.14	-0.148	0.474
12.0	0.228	0.659	0.229	0.033	-0.152	-0.152	0.462

1 ↑

0

↓ -1

Correlação Positiva

Sem Correlação

Correlação Inversa

Fonte: do Autor

O *Baltic Dry Index* (BDI) apresentou seu pico de correlação na defasagem 0, com um valor de 0,65, indicando que as variações nesse índice impactam o preço do minério de ferro de forma imediata, esse resultado é consistente com a relação entre os custos de transporte marítimo e a dinâmica de exportação de commodities. A produção de aço na China, por sua vez, apresentou o maior valor de correlação na defasagem 9, com 0,75, evidenciando um impacto com atraso de nove meses no preço do minério de ferro, o que reflete a influência da oferta no mercado. O Índice de industrialização alcançou sua maior correlação na defasagem 3, com um valor de 0,27, sugerindo que tendências econômicas globais influenciam o preço do minério de ferro após três meses. Já a variável Juros americanos apresentou a maior correlação na defasagem 0, com um valor de 0,18, indicando que aumentos nas taxas de juros têm um efeito imediato no

preço do minério. A análise do Índice de compras (PMI) não demonstrou nenhuma correlação significativa. Dado esse resultado, podemos dizer que o volume de negociações no mercado não afeta o preço. O Índice do dólar (DXY) apresentou a maior correlação negativa em módulo na defasagem 7, com um valor de $-0,16$, evidenciando que a valorização do dólar impacta o preço do minério, tornando-o mais caro em mercados globais. Por fim, o PIB chinês alcançou sua maior correlação na defasagem 2, com um valor de $0,62$, refletindo a relação entre o nível de atividade econômica e a demanda por minério de ferro com um atraso de dois meses.

Foi realizada uma análise visual através dos gráficos de dispersão com o objetivo específico de verificar a existência de padrões que justifiquem a exploração de correlações não lineares. Conforme ilustrado na Figura 8.

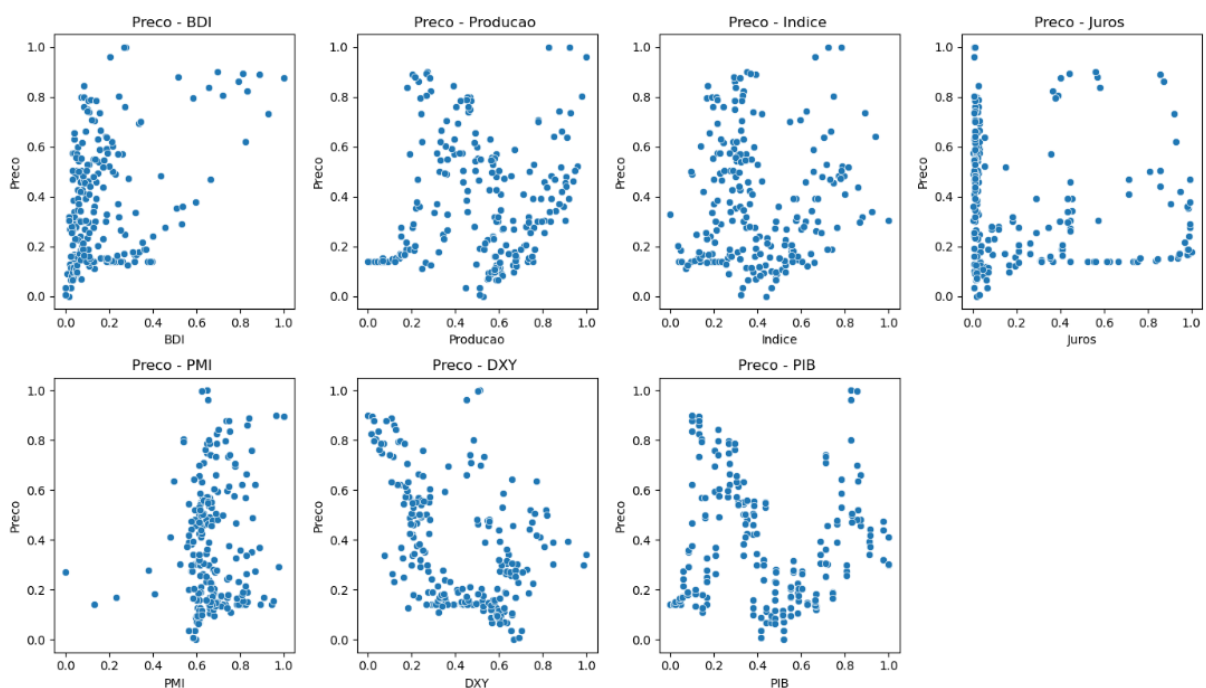


Figura 8 – Correlações

Fonte: do Autor

Contudo, os gráficos apresentados não apresentaram nenhum padrão claro de figura curva ou de outra complexidade, sendo assim não houve motivo para aplicar um método de correlação mais complexo.

Ao aplicar o cálculo do fator de inflação da variância, foi encontrado grau de multilinearidade de 6,3 entre a produção de aço na china e o PIB, como essas duas variáveis tem uma alta relação entre si, nesse trabalho usaremos apenas a produção de aço na china por ter um coeficiente de correlação maior com a variável que sera prevista.

4.3 Modelos

Para a construção de todos os modelos apresentados, foi realizada a normalização de todas as variáveis. Para a identificação dos parâmetros do modelo ARIMA, foram gerados os gráficos da ACF e da PACF, tanto para a série original quanto para a série diferenciada, conforme apresentado na Figura 9.

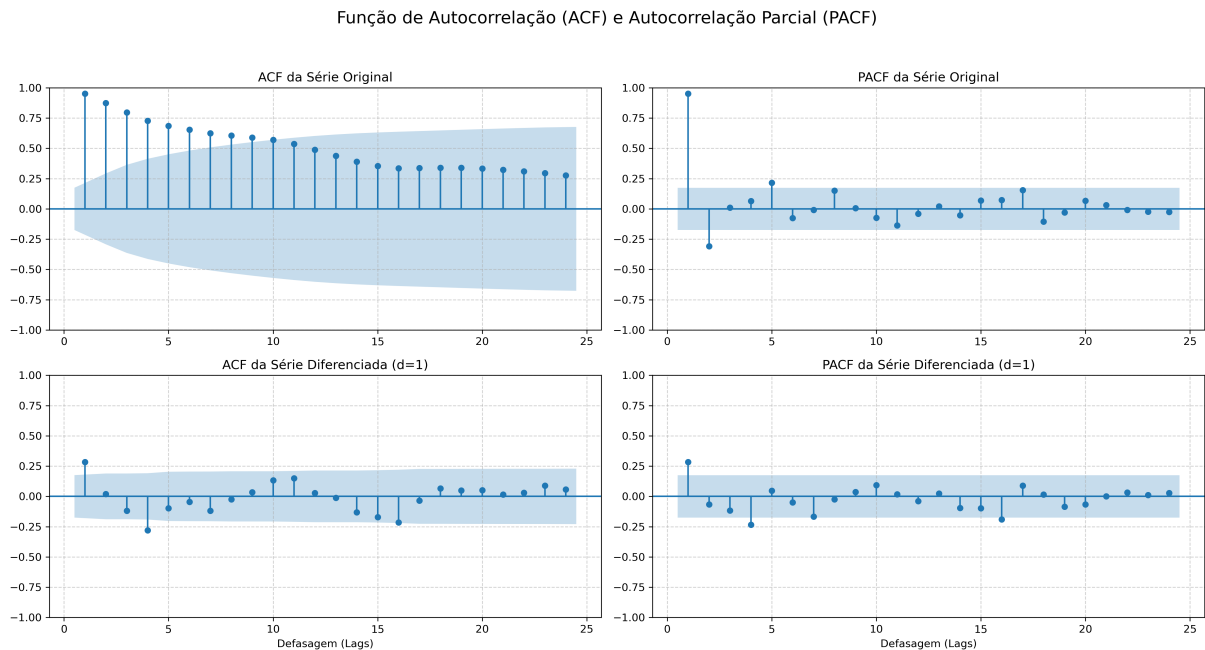


Figura 9 – Diagramas ACF e PACF para a série principal

Fonte: do Autor

A análise inicial, realizada sobre a série original, revela um decaimento muito lento das autocorrelações no gráfico ACF. Este padrão é uma evidência de não estacionariedade, indicando a presença de uma tendência na série. Diante disso, aplicou-se uma ordem de diferenciação para estabilizar a média, estabelecendo o parâmetro $d=1$.

Com a série já estacionária, a análise para determinar as ordens p e q se concentra nos gráficos inferiores. O gráfico ACF exibe um padrão de corte brusco após a primeira defasagem lag , há um pico estatisticamente significativo em $lag=1$, e os valores subsequentes caem imediatamente para dentro do intervalo de confiança. Este comportamento é um indicativo de um processo de média móvel de ordem 1, o que sugere a escolha do parâmetro $q=1$. O gráfico PACF, por sua vez, não apresenta um padrão de decaimento que sugira um componente autorregressivo dominante. Portanto, com base na análise do ACF e PACF, o modelo mais adequado para a série em estudo é o ARIMA(0, 1, 1). Para o modelo XGBoost, após aplicar o *grid research* os parâmetros são apresentados na tabela 5.

Tabela 5 – Hiperparâmetros utilizados no modelo XGBoost

Parâmetro	Descrição	Valor
n_estimators	Número de árvores	200
max_depth	Profundidade máxima das árvores	5
learning_rate	Taxa de aprendizado	0.15
subsample	Fração de amostras por árvore	0.8
colsample_bytree	Fração de colunas por árvore	0.9

Fonte: Do Autor

A primeira etapa na avaliação dos resultados consiste em uma análise visual da performance dos modelos, confrontando as previsões geradas com os valores reais no conjunto de teste. A Figura 10 ilustra essa comparação, mostrando a trajetória prevista pelos modelos ARIMA e XGBoost em relação à série observada. A partir do gráfico, é possível notar que ambos os modelos capturam a dinâmica geral do período, incluindo a subida acentuada e a queda subsequente, embora com comportamentos distintos, o XGBoost aparenta ser mais reativo aos picos e vales, enquanto o ARIMA segue uma trajetória mais suavizada.




Figura 10 – Comparação dos modelos sem exógenas

Fonte: do Autor

Embora a inspeção visual ofereça informações relevantes sobre o comportamento de cada modelo, uma avaliação conclusiva requer uma análise quantitativa e objetiva. Para determinar formalmente qual modelo possui a maior acurácia de previsão, as métricas discutidas no capítulo anterior foram aplicadas. O modelo ARIMA apresentou um desempenho notavelmente superior ao modelo XGBoost. Com um RSME de 7.36 e um MAE de 6.29, demonstrou ter erros de previsão menores em comparação com o XGBoost, que obteve 7.94 e 6.76, respectivamente. Além disso, o coeficiente R^2 do ARIMA (0.63) foi mais elevado que o do XGBoost (0.57), indicando que o modelo conseguiu explicar uma maior proporção da variabilidade dos dados do que o modelo de aprendizado de máquina sem variáveis adicionais.

Após a análise dos modelos univariados, o estudo avança para verificar se a inclusão de variáveis exógenas pode aprimorar a acurácia das previsões. Para este fim, foram desenvolvidos os modelos ARIMAX e XGBoost com exógenas, incorporando as variáveis BDI, produção de aço, índice de industrialização e juros americanos, com suas respectivas defasagens temporais discutidas no tópico 4.2. A Figura 11 compara o desempenho preditivo desses modelos multivariados com os valores reais no conjunto de teste, permitindo uma avaliação visual sobre se a informação adicional resultou em previsões mais aderentes à realidade, especialmente nos pontos de inflexão da série.




Figura 11 – Comparação dos modelos com exógenas

Fonte: do Autor

Ambos os modelos registraram uma queda significativa de performance em comparação com suas versões originais. O ARIMAX, embora tenha piorado em relação ao ARIMA, ainda se mostrou consideravelmente mais eficaz que o XGBoost, com um RSME de 9.05 contra 10.90 e um R^2 de 0.44 contra um valor muito baixo de 0.20. Isso sugere que as variáveis exógenas escolhidas prejudicaram a capacidade preditiva de ambos os modelos, mas o impacto negativo foi consideravelmente maior no XGBoost.

Após a avaliação dos modelos de forma individual, a análise avança para as estratégias de ensemble, que combinam as previsões de ambas as abordagens. A Figura 12 compara visualmente o desempenho do ensemble por média e do método de resíduos contra os valores reais. A análise inicial sugere que ambos os métodos híbridos acompanham a série de perto, com o modelo de média apresentando uma trajetória visualmente mais estável e aderente aos dados.




Figura 12 – Comparação dos modelos híbridos sem exógenas

Fonte: do Autor

Ao analisar as métricas do modelo *ensemble* por média, destacou-se como o de melhor performance geral. Ele obteve o menor RSME (6.97), um dos menores MAE (5.82) e o maior R^2 (0.67) entre todos os modelos analisados, superando com folga o modelo baseado em resíduos, que apresentou um desempenho menos satisfatório (RSME 9.46) e baixo poder de explicação R^2 (0.39). A principal hipótese para o desempenho inferior do modelo que utiliza os resíduos reside na natureza dos próprios resíduos. Um modelo ARIMA, por definição, deve capturar toda a estrutura de autocorrelação linear da série, deixando para trás resíduos que se assemelham a um ruído branco, ou seja, flutuações aleatórias sem padrão. Ao tentar modelar esses resíduos com um algoritmo, provavelmente o modelo não encontrou nenhum padrão real para aprender, em vez disso, ele pode ter se sobreajustado ao ruído aleatório presente no conjunto de treinamento. Consequentemente, ao ser aplicado a dados novos, o XGBoost adiciona previsões de erro instáveis e incorretas à previsão do ARIMA, resultando na amplificação do erro total em vez de sua redução, o que explica as métricas de desempenho significativamente piores.

A Figura 13 compara visualmente as previsões dos dois modelos com exógenas contra os valores reais. O resultado se mantém parecido com o anterior univariado, sendo a abordagem por média mais estável, enquanto o método de resíduos exhibe maior volatilidade.




Figura 13 – Comparação dos modelos híbridos com exógenas

Fonte: do Autor

Analisando as métricas, o modelo ensemble teve uma leve queda no seu poder de explicação R^2 de 0.67 para 0.61, mas alcançou o menor valor de MAE de todos os modelos (5.51), indicando que, em média, seus erros de previsão foram os menores em magnitude. Em contrapartida, o modelo de resíduos melhorou em todas as métricas ao incorporar as variáveis externas, sugerindo que essas variáveis ajudaram a explicar a variância que o modelo original de resíduos não capturava.

A Tabela 6, a seguir, consolida os resultados para todos os modelos testados neste trabalho, desde os modelos base e suas variações com variáveis exógenas, até as estratégias de ensemble e o modelo trivial de referência. A análise comparativa destes indicadores permitirá identificar, de forma conclusiva, o modelo com o desempenho superior para a previsão da série em estudo.

Tabela 6 – Tabela resumo dos resultados

Modelo	RMSE	MAE	R^2
ARIMA	7.36	6.29	0.63
ARIMAX	9.05	6.43	0.44
XGBoost	7.94	6.76	0.57
XGBoost Exo.	10.90	8.15	0.20
Ensemble	6.97	5.82	0.67
Ensemble Exo.	7.61	5.51	0.61
Resíduos	9.46	7.54	0.39
Resíduos Exo.	8.55	6.19	0.50
Modelo trivial	7.05	5.65	0.65

Fonte: Do autor.

O modelo *Ensemble* se destacou como a estratégia de maior acurácia geral, alcançando o menor RMSE (6.97) e o maior R^2 (0.67), indicando o melhor equilíbrio entre a magnitude do erro e o ajuste aos dados.

Contudo, uma observação notável é o desempenho do modelo trivial, que superou todos os modelos individuais sofisticados. O modelo trivial obteve o menor MAE de todos (5.65), superando até mesmo o modelo *Ensemble* nesta métrica específica. Este resultado mostra a alta dificuldade em prever a série em estudo e demonstra que apenas a combinação de modelos via *ensemble* foi capaz de agregar um valor de previsão marginalmente superior a um baseline tão robusto.

Na comparação entre os modelos base, o ARIMA se mostrou uma alternativa superior ao XGBoost para esta série temporal. De forma geral, a introdução de variáveis exógenas, ao contrário da expectativa inicial, degradou a performance dos modelos mais acurados. Isso levanta a hipótese de que as variáveis escolhidas, apesar de correlacionadas, podem ter introduzido mais ruído do que sinal preditivo no período de teste. A única exceção foi o Método de Resíduos, que melhorou com as variáveis exógenas, sugerindo que elas podem ter alguma utilidade para modelar os erros remanescentes do modelo principal.

5 CONCLUSÃO E TRABALHOS FUTUROS

O presente trabalho propôs-se a desenvolver e aperfeiçoar modelos para a previsão dos preços do minério de ferro, um grande desafio devido à volatilidade e complexidade deste mercado. Ao final da análise comparativa, conclui-se que o objetivo foi alcançado, sendo possível não apenas gerar previsões, mas também extrair conclusões valiosas sobre as metodologias avaliadas neste estudo.

As conclusões-chave deste trabalho podem ser resumidas em alguns pontos centrais. Primeiramente, o desempenho do modelo trivial, que estabeleceu uma referência de performance competitiva e superou quase todas as abordagens de forma individual. Neste cenário desafiador, confirmou-se a superioridade das abordagens híbridas, o modelo *ensemble* por média foi o único que conseguiu superar o modelo trivial, de forma relativamente considerável. Essa combinação resultou em um modelo que mitigou as fraquezas individuais de cada um, como a suavização excessiva do ARIMA e a instabilidade do XGBoost, gerando o resultado mais promissor do estudo.

A segunda conclusão refere-se ao impacto das variáveis exógenas. A introdução de variáveis externas demonstraram ser uma faca de dois gumes, cuja eficácia depende criticamente da capacidade do modelo em compreender sua relação com a variável alvo, para modelos que assumem linearidade, as variáveis adicionaram mais ruído do que sinal, degradando a performance. Contudo, o mesmo conjunto de variáveis melhorou o desempenho do modelo de resíduos, esse resultado comprova que a seleção de uma variável externa é tão importante quanto a escolha do algoritmo correto para interpretar sua contribuição.

Apesar dos resultados, é fundamental reconhecer as limitações do estudo. O mercado é um sistema dinâmico e os modelos aqui propostos, embora capturem padrões históricos, representam uma simplificação inerente dessa realidade. A própria eficácia do modelo trivial serve como uma prova quantitativa dessa complexidade, ilustrando que, em mercados voláteis, modelos baseados no passado recente são difíceis de superar. Os modelos não são imunes a choques estruturais ou eventos súbitos, como novas políticas comerciais, que não possuem precedentes nos dados de treinamento. A dificuldade em incorporar variáveis exógenas de forma produtiva ilustra esse problema, a simples adição de dados não garante a captura das complexas relações de causa e efeito que governam o mercado. Ainda assim, os resultados dos modelos podem ser aplicados como um norteador que aponta a tendência de preços com base no cenário mais recente.

5.1 Trabalhos Futuros

Como continuação deste estudo, diversos caminhos de pesquisa futura podem ser explorados. Uma primeira sugestão é testar os modelos apresentados em horizontes de previsão mais longos, para avaliar sua performance em contextos de médio e longo prazo.

Adicionalmente, para validar a metodologia, recomenda-se sua aplicação em cenários

com padrões mais determinísticos e menos aleatórios, como séries de demanda de energia elétrica ou dados de processos industriais.

REFERÊNCIAS

- BOX, G. E.; JENKINS, G. M. **Time series analysis: forecasting and control**. [S.l.]: Holden-Day, 1970. Citado 4 vezes nas páginas 18, 19, 23 e 27.
- BOX, G. E. P.; COX, D. R. An analysis of transformations. **Journal of the Royal Statistical Society. Series B (Methodological)**, Wiley for the Royal Statistical Society, v. 26, n. 2, p. 211–252, 1964. Citado na página 27.
- BREALEY, R. A.; MYERS, S. C.; ALLEN, F. **Principles of Corporate Finance**. [S.l.]: McGraw-Hill Education, 2020. Citado na página 14.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. p. 785–794, 2016. Citado 2 vezes nas páginas 20 e 21.
- DICKEY, D. A.; FULLER, W. A. Distribution of the estimators for autoregressive time series with a unit root. **Journal of the American statistical association**, Taylor & Francis, v. 74, n. 366a, p. 427–431, 1979. Citado 2 vezes nas páginas 19 e 27.
- Ernst & Young. **Risks and opportunities for mining and metals**. [S.l.], 2024. A numeração do ano pode variar, pois o relatório é publicado anualmente. Citado na página 14.
- GUJARATI, D. N.; PORTER, D. C. **Basic Econometrics**. 5. ed. Boston: McGraw-Hill Irwin, 2009. Citado na página 23.
- HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E. **Multivariate Data Analysis**. 8. ed. Andover: Cengage Learning, 2019. Citado 2 vezes nas páginas 22 e 23.
- HAMILTON, J. T. **Previsão de Preços de Minério de Ferro Utilizando Modelos de Inteligência Computacional**. Dissertação (Mestrado) — UFOP, 2022. Citado 3 vezes nas páginas 23, 25 e 28.
- HASTIE, T.; TIBSHIRANI, R.; FRIEDMAN, J. **The Elements of Statistical Learning: Data Mining, Inference, and Prediction**. [S.l.]: Springer, 2009. Citado na página 27.
- HYNDMAN, R.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. [S.l.]: OTexts, 2008. Citado na página 14.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. [S.l.]: OTexts, 2018. Citado 5 vezes nas páginas 18, 20, 21, 22 e 33.
- JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An Introduction to Statistical Learning: with Applications in R**. Second. New York, NY: Springer, 2023. Citado na página 28.
- JONES, E. B. Rethinking the coefficient of determination. **American Statistician**, Taylor & Francis, v. 29, n. 4, p. 245–251, 1975. Citado na página 22.
- KIM, Y.; WILLMOTT, C. J. A modified index of agreement for evaluating model performance. **International Journal of Climatology: A Journal of the Royal Meteorological Society**, Wiley Online Library, v. 19, n. 11, p. 1291–1300, 1999. Citado na página 22.
- KOSSMANN, C. H. **Mercado do Minério de Ferro**. Cariacica, ES, 2023. Citado na página 18.

- LEMOS, P. R. d. A influência chinesa no mercado de minério de ferro e os impactos para a companhia vale s.a. Monografia (Graduação em Ciências Econômicas). 2012. Citado na página 17.
- LIMA, F. G.; KIMURA, H.; NETO, A. A.; PERERA, L. C. J. Previsão de preços de commodities com modelos arima-garch e redes neurais com ondaletas: velhas tecnologias – novos resultados. **R. Adm., São Paulo**, Universidade de São Paulo, São Paulo, SP, Brasil, v. 45, n. 2, p. 188–202, abr./maio/jun. 2010. Citado na página 24.
- MEDEIROS, A. S. V. d. **Estudo sobre o Uso de Análise Técnica e XGBoost em Operações de Day-Trade**. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte, 2021. Citado na página 24.
- MONTGOMERY, D. C.; PECK, E. A.; VINING, G. G. **Introduction to Linear Regression Analysis**. 6. ed. Hoboken, NJ: Wiley, 2021. Citado 2 vezes nas páginas 23 e 28.
- MUDD, G. M. The ‘peak minerals’ debate: a review of the literature. **Energy Policy**, v. 38, n. 11, p. 6965–6974, 2010. Citado na página 15.
- OLIVEIRA, P. C. M. d. **Análise Operacional e de Custo Logístico do Processo de Transbordo de Navio para Navio – Transshipment – no Brasil: Uma Aplicação ao Minério de Ferro no Porto**. Tese (Tese (Doutorado em Engenharia de Transportes)) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2017. Citado na página 18.
- RADETZKI, M. **A Handbook of Primary Commodities in the Global Economy**. [S.l.]: Cambridge University Press, 2008. Citado na página 14.
- SHMUELI, G.; LICHTENDAHL, K. C. **Practical Time Series Forecasting: A Hands-On Guide**. 3rd. ed. [S.l.]: Axcel-BLX, LLC, 2017. Citado na página 19.
- TROYANSKAYA, O. *et al.* Missing value estimation methods for dna microarrays. **Bioinformatics**, Oxford University Press, v. 17, n. 6, p. 520–525, 2001. Citado na página 27.
- TSAY, R. S. **Analysis of Financial Time Series**. Hoboken, NJ: John Wiley & Sons, 2005. Citado na página 20.
- UNCTAD. **Iron Ore Market Report**. [S.l.], 2016. A UNCTAD publica relatórios sobre o mercado de minério de ferro periodicamente. Citado na página 15.
- WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (mae) over the root mean square error (rmse) in assessing average model performance. **Climate Research**, Inter-Research, v. 30, n. 1, p. 79–82, 2005. Citado na página 21.
- World Bank. **Commodity Markets Outlook**. [S.l.], 2025. Citado na página 14.