



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CAMPUS AGRESTE
NÚCLEO DE TECNOLOGIA
ENGENHARIA DE PRODUÇÃO

MARCOS ANTONIO SALES GUIMARÃES

**MODELAGEM PREDITIVA COM SÉRIES TEMPORAIS SARIMA PARA O
MERCADO DE CHUMBO**

Caruaru
2025

MARCOS ANTONIO SALES GUIMARAES

**MODELAGEM PREDITIVA COM SÉRIES TEMPORAIS SARIMA PARA O
MERCADO DE CHUMBO**

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia de Produção do Campus Agreste da Universidade Federal de Pernambuco – UFPE, na modalidade de monografia, como requisito parcial para a obtenção do grau de bacharel em Engenharia de Produção.

Área de concentração: Pesquisa Operacional.

Orientador: Prof. Dr. Lucimario Gois De Oliveira Silva.

Caruaru

2025

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Guimarães, Marcos Antonio Sáles.

MODELAGEM PREDITIVA COM SÉRIES TEMPORAIS SARIMA PARA
O MERCADO DE CHUMBO / Marcos Antonio Sáles Guimarães. - Caruaru,
2025.

63 : il., tab.

Orientador(a): Lucimario Gois De Oliveira Silva

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro Acadêmico do Agreste, Engenharia de Produção, 2025.

9.

Inclui referências.

1. Previsão de Séries Temporais. 2. SARIMA. 3. Preço do Chumbo. 4.
Mercado de Metais. 5. Baterias Chumbo-Ácido. 6. Planejamento de
Suprimentos. I. Silva, Lucimario Gois De Oliveira. (Orientação). II. Título.

620 CDD (22.ed.)

MARCOS ANTONIO SALES GUIMARÃES

**MODELAGEM PREDITIVA COM SÉRIES TEMPORAIS SARIMA PARA O
MERCADO DE CHUMBO**

Trabalho de Conclusão de Curso
apresentado ao Curso de Graduação
em Engenharia de Produção do
Centro Acadêmico do Agreste da
Universidade Federal de
Pernambuco, como requisito parcial
para a obtenção do título de Bacharel
em Engenharia de Produção.

Aprovada em: 08 de agosto de 2025.

BANCA EXAMINADORA

Prof. Dr. Lucimario Gois De Oliveira Silva (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. José Leão e Silva (Examinador Interno)
Universidade Federal de Pernambuco

Prof. Dr. Isaac Pergher (Examinador Interno)
Universidade Federal de Pernambuco

Dedico este trabalho a Deus, por me conceder força e sabedoria, e à minha família, por ser o alicerce firme e a fonte constante de amor, apoio e inspiração em cada passo da minha jornada.

AGRADECIMENTOS

Gostaria de agradecer primeiramente a Deus pela oportunidade de realizar o sonho de cursar o ensino superior e por ter sido minha força em todos os momentos difíceis.

Agradeço também à minha família. Ao meu pai Marcos e à minha mãe Edna, por todo o apoio e carinho durante essa jornada. À minha irmã Érika, que sempre acreditou em mim, muitas vezes mais do que eu mesmo, e nunca permitiu que eu desistisse, sempre me incentivando a sonhar mais alto.

Sou profundamente grato aos professores que contribuíram para minha formação e me mostraram o valor da educação. Em especial, agradeço ao professor Lucimaro, por sua paciência e apoio na construção deste trabalho de conclusão de curso. À professora Marcele, por ter me apresentado ao mundo da pesquisa acadêmica. Ao professor Luciano, por ter expandido minha visão sobre as aplicações da pesquisa operacional, e por ter se tornado, além de professor, um amigo. Ao professor Anderson, por todo o suporte, pelas conversas dentro e fora da universidade, e pela amizade construída ao longo do tempo.

Não poderia deixar de agradecer aos amigos que estiveram ao meu lado durante essa caminhada. Ruhama, minha amiga mais antiga, que é uma inspiração em muitos aspectos e sempre esteve disponível para me escutar e apoiar. Bruno, que me acolheu como família e hoje considero um irmão. Eva, minha dupla da faculdade, com quem enfrentei muitos desafios, dentro da nossa “bolha”. Anne, que me ajudou a enfrentar os momentos difíceis e esteve sempre tentando me levantar. Maria Eduarda, a Duda, minha grande amiga do Sul, que trouxe leveza para os dias na faculdade e me salvou em muitos momentos. Helena, que sempre foi impecável em tudo o que faz e me ensinou muito sobre amizade e profissionalismo. Layla, que me apoiou desde o início e se tornou uma irmã para mim em Caruaru.

Por fim, agradeço a todos os outros amigos que fizeram parte dessa jornada. Cada um contribuiu de forma única, e mesmo que não estejam mencionados aqui, levo todos no coração.

Os amigos são a família que escolhemos.

RESUMO

Este trabalho tem como objetivo propor um modelo de previsão para o preço do chumbo com base em séries temporais, utilizando a metodologia SARIMA. A pesquisa concentra-se no mercado internacional do chumbo, com ênfase na London Metal Exchange (LME), buscando oferecer uma ferramenta de apoio à tomada de decisão para empresas que atuam no setor de baterias chumbo-ácido. Para isso, foram coletados dados históricos mensais de preços do chumbo entre 1990 e 2025, com recorte analítico de 2010 a 2025. Após o tratamento da série, diversos modelos SARIMA foram ajustados e avaliados com base em métricas como o Critério de Informação de Akaike (AIC), erro de previsão (MAE, RMSE e MAPE) e análise dos resíduos. Os melhores modelos foram comparados com abordagens alternativas, como média móvel simples, regressão linear e as previsões disponibilizadas por uma consultoria especializada contratada pela empresa. Os resultados indicam que o modelo SARIMA apresentou desempenho superior na previsão de curto prazo, contribuindo com maior acurácia e confiabilidade para o planejamento da área de suprimentos de chumbo.

Palavras-chave: Previsão de Séries Temporais; SARIMA; Preço do Chumbo; Mercado de Metais; Baterias Chumbo-Ácido; Planejamento de Suprimentos.

ABSTRACT

This study aims to propose a forecasting model for lead prices based on time series analysis using the SARIMA methodology. The research focuses on the international lead market, particularly the London Metal Exchange (LME), seeking to provide a decision-support tool for companies operating in the lead-acid battery sector. Historical monthly lead price data from 1990 to 2025 were collected, with a detailed analysis conducted on the period from 2010 to 2025. After preprocessing the series, several SARIMA models were fitted and evaluated using metrics such as the Akaike Information Criterion (AIC), forecast error (MAE, RMSE, and MAPE), and residual analysis. The best-performing models were compared with alternative approaches, including simple moving averages, linear regression, and forecasts from a specialized consulting firm currently used by the company. The results show that the SARIMA model delivered superior short-term forecast performance, offering greater accuracy and reliability for lead supply planning.

Keywords: Time Series Forecasting; SARIMA; Lead Price; Metal Market; Lead-Acid Batteries; Supply Planning.

LISTA DE FIGURAS

Figura 1 –	DataFrame com os preços dos metais Cobre, Zinco, Alumínio, Chumbo, Estanho e Níquel (1990–2025)	36
Figura 2 –	DataFrame com os preços mensais do Chumbo (Pb)	37
Figura 3 –	Análise Exploratória dos Preços do Chumbo	38
Figura 4 –	Análise Exploratória dos Preços do Chumbo (2010 - 2025)	40
Figura 5 –	Decomposição da série temporal em tendência, sazonalidade e ruído	41
Figura 6 –	Resultado do teste de Dickey-fuller aumentado	43
Figura 7 –	Gráfico de autocorrelação (ACF)	44
Figura 8 –	Gráfico de autocorrelação (PACF)	44
Figura 9 –	Resultado do teste de Dickey-fuller Aumentado da parte sazonal	45
Figura 10 –	Gráfico de autocorrelação (ACF) - sazonal	46
Figura 11 –	Gráfico de autocorrelação (PACF) - sazonal	46
Figura 12 –	Gráfico de autocorrelação (PACF) - sazonal	48
Figura 13 –	Comparação das previsões SARIMA vs. Preço real LME	52
Figura 14 –	Comparação das previsões Média Móvel vs. Preço real LME	53
Figura 15 –	Comparação das previsões Regressão Linear Simples vs. Preço real LME	53
Figura 16 –	Comparação das previsões Empresa externa vs. Preço real LME	54

LISTA DE TABELAS

Tabela 1 –	Resumo estatístico dos preços do chumbo (1990-2025)	38
Tabela 2 –	Resumo estatístico dos preços do chumbo (2010–2025)	40
Tabela 3 –	Top 10 modelos com o Menor MAE	49
Tabela 4 –	Top 10 modelos com o Menor RMSE	49
Tabela 5 –	Top 10 modelos com o Menor MAE	50
Tabela 6 –	AIC de cada modelo do Top 10 modelos com menores erros	50
Tabela 7 –	Tabela comparativo dos erros dos métodos de previsão	54

LISTA DE FÓRMULAS

Fórmula 1 – Média Histórica	27
Fórmula 2 – Regressão Linear	27
Fórmula 3 – ARIMA	28
Fórmula 4 – SARIMA	29
Fórmula 5 – AIC.	30
Fórmula 6 – MAE	30
Fórmula 7 – RMSE	30
Fórmula 8 – MAPE	31
Fórmula 9 – Modelo SARIMA	49
Fórmula 10 – VARIAÇÃO ENTRE OS MODELO 1 E 6 SARIMA	53

LISTA DE ABREVIATURAS E SIGLAS

LME	London Metal Exchange
SARIMA	Seasonal Autoregressive Integrated Moving Average
CONAMA	Conselho Nacional do Meio Ambiente
RMSE	Root Mean Squared Error – Raiz do Erro Quadrático Médio
MAE	Mean Absolute Error – Erro Absoluto Médio
MAPE	Mean Absolute Percentage Error – Erro Percentual Absoluto Médio
UPS	Uninterruptible Power Supply – Fonte de Alimentação Ininterrupta
SLI	Starting, Lighting and Ignition – Partida, Iluminação e Ignição
CAGR	Taxa de crescimento anual composta
PbS	Sulfeto de Chumbo – Galena
BIN	Baterias inservíveis.
SHFE	Shanghai Futures Exchange
ARIMA	AutoRegressive Integrated Moving Average
SLT	Seasonal and Trend decomposition using Loess
ADF	Augmented Dickey-Fuller
AR	AutoRegressive
I	Integrated
MA	Moving Average
AIC	O Critério de Informação de Akaike
ACF	Autocorrelation Function – Função de Autocorrelação
PACF	Partial Autocorrelation Function – Função de Autocorrelação Parcial
LSTM	Short-Term Memory – Memória de Longo e Curto Prazo
BIC	Bayesian Information Criterion – Critério de Informação Bayesiano
Pb	Chumbo
OMC	Organização Mundial do comércio
RNN	Redes Neurais recorrentes
M1	Previsão mês seguinte

M2	Previsão 2 meses na frente
M3	Previsão 3 meses na frente
M4	Previsão 4 meses na frente

SUMÁRIO

1	INTRODUÇÃO	16
1.1	JUSTIFICATIVA	17
1.2	OBJETIVOS	18
1.2.1	OBJETIVO GERAL	18
1.2.2	OBJETIVOS ESPECÍFICOS	18
1.3	ESTRUTURA DO TRABALHO	18
2	REFERÊNCIAL TÓRICO	20
2.1	O SETOR DE BATERIAS CHUMBO-ÁCIDO	20
2.1.1	PANORAMA TECNOLÓGICO E INDUSTRIAL.....	21
2.1.2	O PAPEL DO CHUMBO E SUPRIMENTO GLOBAL.....	21
2.1.3	CADEIA DE SUPRIMENTOS E LOGÍSTICA REVERSA NO BRASIL.....	22
2.1.4	VOLATILIDADE DE PREÇOS E IMPACTO NO PLANEJAMENTO ESTRATÉGICO.....	23
2.2	SÉRIES TEMPORAIS E PREVISÃO.....	23
2.2.1	CONCEITOS BÁSICOS DE SÉRIES TEMPORAIS.....	24
2.2.2	TENDÊNCIA, SAZONALIDADE E RUÍDO.....	24
2.2.3	ESTACIONALIDADE E TESTE DE DICKY-FULLER.....	25
2.2.4	ANÁLISE DE OUTLIERS.....	25
2.3	MODELOS PREDITIVOS PARA SÉRIES TEMPORAIS.....	26
2.3.1	MODELOS SIMPLES: MÉDIA HISTÓRICA E REGRESSÃO LINEAR.....	26
2.3.2	ARIMA.....	27
2.3.3	SARIMA.....	27
2.4	AVALIAÇÃO DE MODELOS PREDITIVOS	28

2.4.1	CRITÉRIO DE INFORMAÇÃO DE AKAIKE (AIC).....	29
2.4.2	ERROS QUADRÁTICOS, MAE, RMSE, MAPE.....	29
2.4.3	GRÁFICOS ACF E PACF.....	30
2.5	REVISÃO DE PREÇOS E TOMADA DE DECISÃO INDUSTRIAL.	30
2.5.1	APLICAÇÕES DA PREVISÃO NO PLANEJAMENTO DE COMPRAS.....	31
2.5.2	ESTRATÉGIAS DE HEDGE E GESTÃO DE RISCO.....	31
2.5.3	IMPACTOS SOBRE A PRECIFICAÇÃO E COMPETITIVIDADE INDUSTRIAL.....	32
2.6	REVISÃO DE LITERATURA.....	32
2.6.1	APLICAÇÕES NA PREVISÃO DE COMMODITIES AGRÍCOLAS E INDUSTRIAIS.....	33
2.6.2	APLICAÇÕES EM METAIS E PRODUTOS INDUSTRIAIS.....	33
2.6.3	REVISÃO E COMPARATIVOS METODOLÓGICOS.....	33
3	METODOLOGIA.....	35
3.1	CLASSIFICAÇÃO DA PESQUISA.....	35
3.2	ETAPAS METODOLÓGICAS DA PESQUISA.....	36
3.2.1	COLETA E CARACTERIZAÇÃO DOS DADOS.....	36
3.2.2	PLATAFORMA COMPUTACIONAL E FERRAMENTAS.....	36
3.2.3	TRATAMENTO DOS DADOS.....	37
3.2.4	ANÁLISE ESTATÍSTICA.....	38
3.2.5	DECOMPONDO A SÉRIE TEMPORAL.....	42
3.2.6	ESTACIONALIDADE.....	44
3.2.7	ACF E PACF.....	45
3.2.8	ANALISANDO A SAZONALIDADE.....	46
3.2.9	CONSTRUINDO O MODELO SARIMA.....	48
4	RESULTADOS E DISCUSSÕES.....	53
5.	CONSIDERAÇÕES FINAIS.....	57
	REFERÊNCIAS.....	58

1 INTRODUÇÃO

A indústria de acumuladores elétricos representa um pilar estratégico da economia moderna, sendo as baterias do tipo chumbo-ácido responsáveis por cerca de 70% do mercado global de armazenamento energético entre 1990 e 2018 (YANAMANDRA; PINISETTY; GUPTA, 2023). Este estudo, desenvolvido em uma fabricante de baterias localizada no Agreste Pernambucano, aborda um desafio crítico enfrentado pelo setor: a previsão dos preços do chumbo cotado na *London Metal Exchange* (LME), insumo que representa aproximadamente 60% do peso de uma bateria automotiva (MALECHA et al., 2023).

O chumbo possui propriedades únicas que o tornam insubstituível na tecnologia chumbo-ácido, como alta eficiência energética, durabilidade e uma taxa de reciclagem que pode alcançar até 99% em países com logística reversa avançada (MA et al., 2022; YANAMANDRA; PINISETTY; GUPTA, 2023). No entanto, o contexto brasileiro impõe desafios adicionais à autossuficiência na obtenção deste metal, principalmente devido a três fatores:

- (i) a impossibilidade de reciclar as baterias novas utilizadas por montadoras na fabricação de veículos zero-quilômetro;
- (ii) a Resolução CONAMA nº 452/2012, que proíbe a importação de baterias inservíveis, classificadas como resíduos perigosos; e
- (iii) a eficiência limitada da logística reversa, que mesmo com altos índices de recuperação, não consegue reter 100% do chumbo necessário à produção de novas baterias.

Diante desse cenário, prever com precisão os preços futuros do chumbo torna-se essencial não apenas para o planejamento de compras, mas também para a projeção de custos industriais, definição de preços de venda e estratégias de hedge cambial. Contudo, os métodos atualmente utilizados para essa previsão na empresa estudada, mostram-se limitados, muitas vezes incapazes de capturar as complexas dinâmicas do mercado, o que pode comprometer a confiabilidade das projeções e, consequentemente, a tomada de decisão estratégica. Em contratos internacionais, por exemplo, é comum que os preços dos insumos metálicos sejam definidos com base nas cotações futuras da LME, o que torna ainda mais crítico o acesso a estimativas

confiáveis para os meses seguintes.

Neste contexto, este trabalho propõe a aplicação da metodologia SARIMA (*Seasonal Autoregressive Integrated Moving Average*) para modelar a série temporal de preços do chumbo cotado na LME, com o objetivo de aumentar a acurácia das previsões e, assim, subsidiar decisões estratégicas da empresa. O modelo foi escolhido por sua capacidade em capturar padrões de tendência, sazonalidade conforme demonstrado nos estudos de Giri e Giri (2024). Espera-se que, com a aplicação adequada dessa metodologia, seja possível obter previsões mais robustas e alinhadas com a complexidade do mercado global de metais.

1.1 JUSTIFICATIVA

A volatilidade nos preços de commodities metálicas, como o chumbo, impõe riscos consideráveis a empresas que dependem fortemente desses insumos para sua produção. No contexto de uma indústria nacional que opera com elevada dependência da importação, a imprecisão nas projeções de preços pode resultar em decisões equivocadas de compra, desequilíbrios no orçamento operacional e perdas financeiras significativas.

Atualmente, a empresa estudada utiliza métodos empíricos ou simplificados para prever a variação do preço do chumbo, os quais, embora práticos, não oferecem confiabilidade suficiente para cenários de alta instabilidade como explicado por Hyndman e Athanasopoulos (2018), a empresa conta também com uma previsão externa enviada por uma consultoria externa baseada em análises de informações referentes ao mercado de Chumbo. Esses métodos frequentemente desconsideram padrões sazonais e impactos de eventos externos, como crises sanitárias ou conflitos internacionais, gerando lacunas críticas para uma gestão estratégica eficaz.

A adoção de um modelo estatístico robusto, como o SARIMA, justifica-se por sua ampla aplicação em contextos de séries temporais sazonais, com resultados positivos na previsão de variáveis econômicas voláteis conforme nos estudos de Giri e Giri (2024) e De Araújo, Lima e Mesquita (1997). Ao oferecer maior precisão e estabilidade nas projeções, esse tipo de abordagem pode melhorar a qualidade das decisões gerenciais, otimizar o uso de recursos financeiros e contribuir para a competitividade e sustentabilidade da empresa no médio e longo prazo.

Dessa forma, este trabalho se justifica tanto pelo seu potencial de impacto prático, ao apoiar a tomada de decisão em uma organização real, quanto por sua relevância científica, ao aplicar uma metodologia reconhecida no tratamento de séries temporais em um contexto ainda pouco explorado na literatura nacional.

1.2 OBJETIVOS

1.2.1 OBJETIVO GERAL

Desenvolver e avaliar um modelo preditivo baseado na metodologia SARIMA para a previsão dos preços do chumbo cotado na London Metal Exchange (LME), comparando os erros dessa previsão com a dos métodos atualmente utilizados por uma empresa do setor de acumuladores elétricos (média móvel e regressão), com o objetivo de dar apoio a tomada de decisões.

1.2.2 OBJETIVOS ESPECÍFICOS

- Diagnosticar as limitações dos métodos tradicionais atualmente utilizados para a previsão de preços do chumbo em uma empresa do setor de acumuladores elétricos.
- Implementar o modelo SARIMA na análise de séries temporais do preço do chumbo, considerando padrões de tendência e sazonalidade.
- Avaliar erros e a eficácia do modelo SARIMA em comparação com os métodos tradicionais, utilizando métricas estatísticas como RMSE, MAE, MAPE e AIC.
- Demonstrar eficiência entre os modelos adotados pela empresa e o modelo proposto.
- Determinar qual o modelo de previsão é o melhor frente aos citados no estudo.

1.3 ESTRUTURA DO TRABALHO

A presente monografia está estruturada em cinco capítulos, conforme descrito a seguir:

- O Capítulo 1 apresenta a introdução ao tema, expondo a problemática da pesquisa, a motivação do estudo, os objetivos — geral e específicos —, além da justificativa da escolha do tema.
- O Capítulo 2 é dedicado ao referencial teórico, no qual são discutidos os principais conceitos teóricos e estudos anteriores relacionados à previsão de séries temporais, modelagem SARIMA, volatilidade de commodities e aplicações no setor de acumuladores elétricos.
- O Capítulo 3 descreve a metodologia adotada para o desenvolvimento do trabalho. São apresentados os dados utilizados, a caracterização da série temporal, o processo de modelagem com SARIMA (incluindo ajuste, validação e avaliação), bem como a análise dos métodos tradicionais de previsão utilizados pela empresa e os critérios estatísticos empregados na comparação de desempenho.
- O Capítulo 4 apresenta os resultados obtidos com a aplicação dos modelos, incluindo as previsões geradas, a comparação entre SARIMA e os métodos tradicionais com base em métricas estatísticas de desempenho, os erros gerados em cada modelo e as possíveis implicações práticas para o planejamento e a gestão de compras da indústria de baterias chumbo-ácido.
- Por fim, o Capítulo 5 reúne as considerações finais do trabalho, sintetizando os principais achados, discutindo as limitações da pesquisa, propondo sugestões de continuidade e recomendando possíveis aplicações práticas dos resultados no contexto industrial.

2 REFERÊNCIAL TEÓRICO

Nesta seção, serão abordados os principais conceitos e ferramentas que fundamentam a metodologia deste trabalho. Inicialmente, será apresentada uma visão geral do mercado de baterias chumbo-ácido, destacando o papel do chumbo na sua fabricação. Em seguida, será discutido o funcionamento dos mercados nacional e internacional desse metal, com ênfase nas dinâmicas de precificação, nas principais bolsas de valores responsáveis pela cotação da commodity e nos fatores que influenciam suas oscilações.

Além disso, serão explicadas as ferramentas estatísticas utilizadas na construção do modelo preditivo, detalhando seu funcionamento e sua relevância para o contexto estudado. Por fim, será realizada uma revisão bibliográfica sobre a aplicação da metodologia SARIMA na previsão de preços de commodities, com foco em sua eficácia e em estudos já publicados sobre o tema.

2.1 O Setor de Baterias Chumbo-Ácido

O mercado global de baterias tem desempenhado papel fundamental na transição energética e na eletrificação de vários setores da economia, como telecomunicações, sistemas de energia ininterrupta (UPS), indústria automotiva, mineração e sistemas de defesa. Dentro desse contexto, as baterias chumbo-ácido, desenvolvidas há mais de um século, continuam a ocupar posição de destaque por suas características técnicas, econômicas e ambientais. De acordo com Wang e Zhu (2020), essa tecnologia permanece altamente relevante devido ao seu baixo custo, elevada robustez operacional e facilidade de reciclagem.

Com a crescente demanda por fontes de armazenamento de energia eficientes e sustentáveis, compreender a dinâmica técnica e econômica das baterias chumbo-ácido, em especial, do mercado do chumbo torna-se essencial. Este capítulo tem como objetivo apresentar uma análise estruturada do setor, abordando aspectos tecnológicos, logísticos, ambientais e de mercado que justificam a necessidade de modelos preditivos para o preço do chumbo no contexto industrial brasileiro.

2.1.1 Panorama Tecnológico e Industrial

As baterias chumbo-ácido são amplamente utilizadas em sistemas de partida, iluminação e ignição (SLI) de veículos automotivos, além de aplicações industriais como data centers, subestações elétricas e UPS. Tan et al. (2019) ressaltam que essa tecnologia possui uma das maiores taxas de reaproveitamento do setor, com mais de 90% do chumbo sendo reciclado, o que reforça sua competitividade frente a soluções mais modernas, como as baterias de íon-lítio.

Entre suas principais vantagens, destacam-se a durabilidade eletroquímica, a baixa resistividade elétrica e a maleabilidade dos componentes, que facilitam a produção e manutenção dos sistemas. Apesar da antiguidade da tecnologia, melhorias contínuas nos processos de fabricação e reciclagem permitiram sua manutenção no mercado com desempenho técnico satisfatório.

O mercado global de baterias chumbo-ácido movimentou cerca de US\$ 48 bilhões em 2024, com projeções que apontam para uma expansão superior a US\$ 73 bilhões até 2032, com uma taxa média de crescimento anual (CAGR) entre 4% e 6% (FORTUNE BUSINESS INSIGHTS, 2025). A Ásia-Pacífico lidera tanto em produção quanto em consumo, impulsionada pela demanda crescente de veículos e pela expansão de infraestrutura energética. No entanto, países como o Brasil também seguem fortemente dependentes dessa tecnologia, especialmente em aplicações onde confiabilidade e custo-benefício são decisivos.

2.1.2 O Papel do Chumbo e Suprimento Global

O chumbo é o insumo mais crítico para a produção das baterias chumbo-ácido, representando em média 60% de seu peso total (MALECHA et al., 2023). Ele é empregado principalmente na confecção das placas eletroquímicas (ânodo e cátodo) responsáveis pelos processos de carga e descarga da bateria.

A cadeia de suprimento global do chumbo é dividida em duas frentes principais: chumbo primário, obtido diretamente da mineração de minérios como a galena (PbS), e chumbo secundário, resultante da reciclagem de baterias usadas e outros resíduos industriais. Estima-se que mais da metade do chumbo utilizado globalmente seja de origem secundária (MA et al., 2022), refletindo os avanços na economia circular e na

logística reversa.

Apesar disso, o processo de recuperação do chumbo secundário apresenta gargalos técnicos e estruturais. A Logística Reversa nem sempre alcança a recuperação total do chumbo contido nas baterias inservíveis (BIN), sendo comum a adição de chumbo de alta pureza importado para garantir a qualidade do produto final. Além disso, fatores como a restrição legal à importação de sucata, a baixa eficiência de coleta em algumas regiões e a demanda contínua da indústria automotiva acentuam a dependência de suprimento internacional — sobretudo em países com menor autonomia mineral, como o Brasil.

2.1.3 Cadeia de Suprimentos e Logística Reversa no Brasil

A cadeia de suprimentos do chumbo no Brasil apresenta particularidades que aumentam sua vulnerabilidade às oscilações do mercado internacional. Embora o país possua capacidade instalada para reciclagem de baterias, ainda depende significativamente da importação de chumbo refinado, o que expõe as empresas a variações cambiais, custos logísticos e incertezas geopolíticas.

Um dos principais entraves é a Resolução CONAMA nº 452/2012, que classifica baterias inservíveis como resíduos perigosos, impedindo sua importação para reciclagem. Com isso, a matéria-prima reciclável de baixo custo disponível internacionalmente não pode ser aproveitada, obrigando a indústria brasileira a adquirir chumbo já refinado, geralmente a preços mais elevados.

Adicionalmente, a logística reversa no setor automotivo ainda é parcial. As baterias de veículos novos (0 km) geralmente permanecem em uso por anos antes de retornarem ao sistema de reciclagem. Esse descompasso entre consumo e retorno de insumos gera períodos de escassez e obriga a aquisição de chumbo de outras fontes (YANAMANDRA; PINISETTY; GUPTA, 2023).

Mesmo com avanços tecnológicos e investimentos em eficiência de recuperação, as perdas no processo ainda limitam a autossuficiência (MA et al., 2022). Isso obriga muitas empresas a desenvolverem estratégias robustas de abastecimento, gestão de estoques e controle de custos, aumentando a necessidade de previsibilidade de preços como ferramenta estratégica.

2.1.4 Volatilidade de Preços e Impacto no Planejamento Estratégico

A precificação internacional do chumbo é majoritariamente definida por duas bolsas de commodities: a London Metal Exchange (LME) e a Shanghai Futures Exchange (SHFE). A LME, sediada em Londres, é considerada a principal referência global para metais não ferrosos, enquanto a SHFE, com sede na China, desempenha papel central no mercado asiático, o maior consumidor e produtor mundial de chumbo (CHEN; TONGURAI, 2022).

A interdependência entre esses mercados faz com que o preço do chumbo seja altamente volátil, influenciado por fatores como:

- Ritmo da produção industrial chinesa;
- Políticas ambientais e sanitárias que afetam a mineração e a reciclagem;
- Oscilações cambiais e custos logísticos internacionais;
- Eventos geopolíticos como pandemias, sanções ou conflitos armados.

Essa volatilidade afeta diretamente a formação de preços das baterias, os custos de produção, a definição de contratos de compra e a gestão de estoques industriais. Empresas com grande dependência do insumo, como fabricantes de acumuladores, enfrentam riscos operacionais e financeiros significativos.

Nesse cenário, torna-se imperativo o uso de modelos quantitativos de previsão de preços, como os baseados em séries temporais. Eles permitem maior acurácia na estimativa de custos futuros, facilitando o planejamento produtivo, o controle orçamentário e a competitividade global.

2.2 SÉRIES TEMPORAIS E PREVISÃO

O estudo de séries temporais é um dos pilares da modelagem estatística aplicada à previsão de variáveis econômicas, industriais e financeiras. Uma série temporal é definida como um conjunto de observações ordenadas no tempo, geralmente coletadas em intervalos regulares, como dias, meses ou anos (HYNDMAN; ATHANASOPOULOS, 2018). Essa abordagem permite a análise de padrões e comportamentos recorrentes, viabilizando a construção de modelos preditivos que auxiliam na tomada de decisões estratégicas em ambientes marcados por incertezas e sazonalidade, como é o caso do mercado de metais.

No contexto deste estudo, séries temporais referem-se ao comportamento mensal dos preços do chumbo negociado internacionalmente.

2.2.1 Conceitos básicos de séries temporais

As séries temporais são classificadas de acordo com suas propriedades estatísticas e estruturais. Uma série pode ser estacionária, quando suas características como média, variância e autocovariância não variam ao longo do tempo, ou não estacionária, quando apresenta tendências ou padrões sazonais (HYNDMAN; ATHANASOPOULOS, 2018). O conceito de estacionariedade é crucial, pois muitos modelos preditivos, como ARIMA e SARIMA, requerem que os dados sejam estacionários para produzir estimativas confiáveis.

Além disso, as séries podem ser aditivas ou multiplicativas, dependendo da forma como seus componentes (tendência, sazonalidade e ruído) se combinam. Em um modelo aditivo, os componentes se somam; já no modelo multiplicativo, são combinados por multiplicação, sendo mais adequado quando a variabilidade sazonal cresce proporcionalmente ao nível da série.

2.2.2 Tendência, sazonalidade e ruído

Uma das primeiras etapas na análise de séries temporais é a decomposição da série em três elementos principais:

- **Tendência (*Trend*):** Refere-se ao movimento de longo prazo da série, podendo indicar crescimento ou declínio consistente ao longo do tempo;
- **Sazonalidade (*Seasonality*):** Refere-se a padrões que se repetem em intervalos regulares, como ciclos anuais ou mensais;
- **Ruído (*Noise*):** Representa a variação aleatória ou imprevisível da série, não explicada por tendência ou sazonalidade.

A identificação desses componentes auxilia na escolha do modelo preditivo adequado e na interpretação dos resultados. Métodos como a decomposição clássica e o STL (*Seasonal and Trend decomposition using Loess*) são frequentemente utilizados para isolar esses efeitos e preparar os dados para modelagem (HYNDMAN; ATHANASOPOULOS, 2018).

2.2.3 Estacionalidade e teste de Dickey-Fuller

Como mencionado, muitos modelos de séries temporais, como o ARIMA (*AutoRegressive Integrated Moving Average*), pressupõem que a série seja estacionária. Quando não é, aplica-se uma técnica chamada diferenciação, que transforma a série por meio da subtração de valores passados para remover tendências.

Uma das principais ferramentas para verificar a estacionariedade é o teste de Dickey-Fuller aumentado (ADF – *Augmented* Dickey-Fuller). Esse teste estatístico verifica a presença de raiz unitária na série, que indica não estacionariedade. Um valor de p menor que 0,05 geralmente indica que a série é estacionária e, portanto, adequada para aplicação de modelos como o ARIMA/SARIMA (HYNDMAN; ATHANASOPOULOS, 2018; DE ARAÚJO et al., 1997).

Esse teste é amplamente utilizado em aplicações reais para verificar a adequação de transformações pré-modelagem e garantir que os resíduos dos modelos não carreguem estrutura temporal.

2.2.4 Análise de outliers

Outliers são valores extremos ou anômalos que não seguem o padrão geral da série. Sua presença pode distorcer a média, aumentar a variância e comprometer a acurácia dos modelos preditivos. Em séries temporais econômicas, como o preço do chumbo, outliers podem refletir eventos extraordinários, como guerras, pandemias ou mudanças regulatórias repentinas.

A identificação de outliers pode ser realizada visualmente por meio de gráficos de linha, boxplots ou tecnicamente por meio de testes estatísticos, como o teste de Grubbs ou métodos de detecção baseados em resíduos de modelos ajustados. Após identificados, os outliers podem ser corrigidos, excluídos ou tratados com técnicas robustas que limitam seu impacto nos parâmetros do modelo (HYNDMAN; ATHANASOPOULOS, 2018).

2.2.5 MODELOS PREDITIVOS PARA SÉRIES TEMPORAIS

Modelos de previsão são ferramentas fundamentais para antecipar o comportamento futuro de séries temporais com base em padrões históricos. Em contextos industriais e financeiros, como o mercado de metais, a escolha do modelo adequado pode significar maior eficiência na alocação de recursos, gestão de estoques e mitigação de riscos. Esta seção apresenta os principais modelos utilizados neste trabalho, partindo de abordagens mais simples até modelos autorregressivos com componentes sazonais.

2.2.6 Modelos simples: média histórica e regressão linear

Os modelos simples de previsão são frequentemente utilizados como benchmarks. A média histórica consiste em projetar o valor futuro com base na média aritmética dos valores passados. Apesar de sua simplicidade, é útil em contextos onde os dados não apresentam variações significativas, ou como ponto de comparação para modelos mais sofisticados (HYNDMAN; ATHANASOPOULOS, 2018).

A regressão linear, por sua vez, busca ajustar uma equação linear que relacione o tempo com os valores da série, capturando possíveis tendências ao longo do tempo. Seu uso é apropriado quando há indícios de crescimento ou declínio constante, mas não consegue incorporar sazonalidade ou dependência serial entre os dados — limitações importantes quando se trabalha com séries econômicas e de commodities.

A média histórica é dada por:

$$\hat{y}_t = \frac{1}{n} \sum_{i=1}^n y_{t-i} \quad (1)$$

Já a regressão linear com tempo assume a forma:

$$y_t = \beta_0 + \beta_1 t + \varepsilon_t \quad (2)$$

Onde:

- y_t é o valor da série no tempo t ;
- β_0 é o intercepto;
- β_1 é o coeficiente de tendência;
- ε_t é o termo de erro aleatório.

2.2.7 ARIMA

O modelo ARIMA (*AutoRegressive Integrated Moving Average*) é um dos mais utilizados para previsão de séries temporais univariadas. Ele combina três componentes:

- AR (*AutoRegressive*): incorpora o efeito de valores passados da própria série;
- I (*Integrated*): representa o número de diferenciações aplicadas à série para torná-la estacionária;
- MA (*Moving Average*): modela o erro da previsão como uma combinação linear de erros passados.

Conforme a equação:

$$\Phi(B)(1 - B)^d y_t = \theta(B)\varepsilon_t \quad (3)$$

Onde:

- y_t : valor da série no tempo t
- B : operador de defasagem, tal que $B^k y_t = y_{t-k}$
- d : ordem da diferenciação (integração)
- ε_t : erro aleatório (ruído branco)
- $\Phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$: parte autorregressiva (AR)
- $\theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$: parte de médias móveis (MA)

A notação padrão ARIMA(p, d, q) especifica a ordem de cada componente. A aplicação do ARIMA requer que a série seja estacionária; por isso, testes como o *Augmented* Dickey-Fuller (ADF) são utilizados previamente para avaliar a necessidade de diferenciação (DE ARAÚJO et al., 1997; HYNDMAN; ATHANASOPOULOS, 2018).

Neste trabalho, foram testadas várias combinações de parâmetros com base em critérios estatísticos como o AIC (*Akaike Information Criterion*), visando identificar o modelo com melhor desempenho preditivo.

2.2.8 SARIMA

O modelo SARIMA (*Seasonal ARIMA*) é uma extensão do ARIMA que incorpora sazonalidade explícita, sendo especialmente útil para séries que apresentam padrões periódicos recorrentes, como os preços de commodities em mercados globais. Ele é representado pela notação SARIMA(p, d, q)(P, D, Q, s), onde

os termos entre parênteses adicionais se referem à parte sazonal:

- P, D, Q: ordens do componente autorregressivo, de diferenciação e de média móvel sazonais;
- s: período da sazonalidade (por exemplo, 12 para dados mensais com sazonalidade anual).

Conforme a equação:

$$\Phi(B)\Phi_s(B^s)(1-B)^d(1-B^s)^D y_t = \theta(B)\theta_s(B^s)\varepsilon_t \quad (4)$$

Onde:

- $\Phi(B)$, $\theta(B)$: componentes não sazonais AR e MA
- $\Phi_s(B^s)$, $\theta_s(B^s)$: componentes sazonais AR e MA
- d : ordem da diferenciação regular
- D : ordem da diferenciação sazonal
- s: período da sazonalidade (por exemplo, 12 para dados mensais com padrão anual)

A modelagem SARIMA permite capturar não apenas tendências e ruído, mas também padrões sazonais complexos, melhorando a acurácia preditiva em muitos contextos (HYNDMAN; ATHANASOPOULOS, 2018).

No presente estudo, foram ajustados diversos modelos SARIMA com diferentes configurações de parâmetros sazonais e não sazonais. Os modelos foram avaliados por meio de métricas como o MAE e o RMSE, e o melhor desempenho foi utilizado para gerar previsões do preço do chumbo para o período de 2024.

2.3 AVALIAÇÃO DE MODELOS PREDITIVOS

A avaliação de modelos preditivos em séries temporais é uma etapa essencial para garantir que as previsões sejam confiáveis e úteis para a tomada de decisão. A escolha do melhor modelo não se baseia apenas no ajuste aos dados históricos, mas também na sua capacidade de generalização e na robustez frente a diferentes condições da série. Para isso, utilizam-se métricas quantitativas e ferramentas gráficas que ajudam a mensurar o desempenho e diagnosticar possíveis falhas.

2.3.1 Critério de Informação de Akaike (AIC)

O Critério de Informação de Akaike (AIC) é amplamente utilizado na comparação entre modelos estatísticos. Ele busca equilibrar a qualidade do ajuste com a complexidade do modelo, penalizando aqueles com muitos parâmetros para evitar *overfitting*.

A fórmula do AIC é dada por:

$$AIC = 2k - 2\ln(\hat{L}) \quad (5)$$

Onde:

- k é o número de parâmetros estimados no modelo;
- $\hat{L}$ é o valor da função de verossimilhança do modelo ajustado.

Um modelo com menor valor de AIC é preferível, pois representa melhor ajuste com menor complexidade. Vale destacar que o AIC permite comparar apenas modelos estimados sobre o mesmo conjunto de dados. Na prática, ele é utilizado em conjunto com outras métricas de erro para uma avaliação mais robusta (HYNDMAN; ATHANASOPOULOS, 2018).

2.3.2 Erros quadráticos, MAE, RMSE, MAPE

Os erros de previsão permitem quantificar a diferença entre os valores previstos e os observados. As métricas mais utilizadas incluem:

- MAE (*Mean Absolute Error* – Erro Absoluto Médio):

$$MAE = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t| \quad (6)$$

Indica o erro médio absoluto, sendo de fácil interpretação e robusto a outliers.

- RMSE (*Root Mean Squared Error* – Raiz do Erro Quadrático Médio):

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (7)$$

Dá maior peso a erros grandes, sendo útil quando grandes desvios são penalizados.

- MAPE (*Mean Absolute Percentage Error* – Erro Percentual Absoluto Médio):

$$MAPE = \frac{n}{100\%} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (8)$$

Expressa o erro em termos percentuais, facilitando comparações entre séries com escalas diferentes.

Cada métrica possui suas vantagens e limitações. O ideal é analisá-las em

conjunto, pois um modelo com bom RMSE pode apresentar MAPE alto se os valores reais forem muito baixos, por exemplo (KEMALBAY; KORKMAZOGLU, 2021).

2.3.3 Gráficos ACF e PACF

Além das métricas numéricas, a análise gráfica desempenha papel importante no diagnóstico de modelos de séries temporais. Dois dos principais gráficos utilizados são:

- **ACF** (*Autocorrelation Function* – Função de Autocorrelação): Mede a correlação entre os valores da série com suas próprias defasagens. É útil para identificar padrões de repetição, sazonalidade e dependência temporal (HASAN, 2023).

- Se os resíduos do modelo mostrarem autocorrelação significativa, isso indica que o modelo não capturou toda a estrutura da série.

- **PACF** (*Partial Autocorrelation Function* – Função de Autocorrelação Parcial):

Mede a correlação entre um valor e suas defasagens, removendo o efeito das intermediárias. Auxilia na identificação da ordem do termo AR no modelo ARIMA/SARIMA (HASAN, 2023).

Ambos os gráficos são essenciais para:

- Diagnosticar se os resíduos são de fato ruído branco;
- Avaliar a necessidade de inclusão de mais termos AR ou MA;
- Verificar a presença de estrutura sazonal residual.

Gráficos ACF e PACF bem comportados (com poucas autocorrelações significativas após o lag 0) indicam que o modelo ajustado é adequado.

2.4 REVISÃO DE PREÇOS E TOMADA DE DECISÃO INDUSTRIAL

Em mercados altamente voláteis, como o de metais não ferrosos, a previsão de preços exerce papel estratégico fundamental para a sustentabilidade e a competitividade das empresas. Modelos quantitativos de previsão, como os baseados em séries temporais, possibilitam às indústrias anteciparem movimentos do mercado, planejar compras com maior eficiência, mitigar riscos financeiros e aprimorar decisões

de precificação.

2.4.1 Aplicações da previsão no planejamento de compras

A previsão de preços é especialmente útil para setores que trabalham com insumos com forte volatilidade e impacto relevante na composição de custos – como o chumbo nas indústrias de baterias. Como dito por Kwas e Rubaszek (2021), uso de modelos preditivos permite que a área de suprimentos:

- Antecipe movimentos de alta nos preços para antecipar compras;
- Evite estoques excessivos em períodos de queda de preços;
- Alinhe a reposição de insumos com as janelas de melhor custo-benefício.

Além disso, a previsão reduz a dependência exclusiva da intuição ou da análise subjetiva de tendências, incorporando variáveis estatísticas e ciclos históricos do mercado. Isso permite que empresas operem com estoques mais enxutos, evitem rupturas no abastecimento e otimizem o capital de giro.

Em empresas que consomem milhares de toneladas de chumbo por ano, mesmo pequenas variações de centavos por quilo podem representar impactos significativos no resultado financeiro, o que justifica a importância da previsão para o setor.

2.4.2 Estratégias de hedge e gestão de risco

Outra aplicação direta das previsões de preço é no suporte às estratégias de hedge e à gestão de risco cambial e de commodities. O mercado de chumbo, por ser cotado em dólar e negociado internacionalmente, está sujeito a flutuações tanto da cotação internacional quanto da taxa de câmbio. Modelos como ARIMA e SARIMA fornecem projeções que ajudam as empresas a:

- Tomar decisões sobre a fixação antecipada de contratos com fornecedores;
- Determinar o timing ideal para fechamento de câmbio;
- Avaliar se é o caso de utilizar instrumentos financeiros de proteção, como contratos futuros ou opções em bolsas de metais (como a LME).

A previsibilidade reduz a exposição da empresa à volatilidade dos mercados

internacionais e contribui para a estabilidade das margens operacionais. Especialmente em negócios com margens apertadas, essa proteção é crucial para garantir viabilidade econômica em períodos de forte oscilação (UŽÍK et al, 2023).

2.4.3 Impactos sobre a precificação e competitividade industrial

Além de compras e hedge, as previsões de preço do chumbo afetam diretamente a formação de preços dos produtos finais. Em mercados competitivos, a capacidade de estimar com precisão os custos futuros permite que a empresa:

- Estabeleça políticas de precificação mais realistas e sustentáveis;
- Evite subcotação (preços abaixo do custo real) ou superavaliação (perda de mercado);
- Ganhe agilidade para reajustar preços conforme tendências futuras, e não apenas após os fatos consumados.

Isso é especialmente relevante para setores em que os clientes realizam contratos com cláusulas de reajuste indexadas a commodities. Ter previsões confiáveis permite à empresa justificar repasses de custo de forma transparente e técnica, fortalecendo relações comerciais.

Empresas que adotam modelos preditivos ganham vantagem competitiva também no planejamento estratégico de médio e longo prazo, pois conseguem simular cenários e alinhar decisões operacionais com previsões robustas e justificadas quantitativamente (KWAS; RUBASZEK, 2021).

2.5 Revisão de Literatura

O modelo SARIMA se destaca em algumas pesquisas aplicadas à previsão de preços de materiais e commodities, especialmente aqueles com comportamento sazonal e variabilidade econômica, como metais industriais e agrícolas.

2.5.1 Aplicações na Previsão de Commodities Agrícolas e Industriais

Wanjuki et al. (2021) implementaram o modelo SARIMA para prever o índice de preços de alimentos e bebidas no Quênia, demonstrando que o uso do componente sazonal melhora significativamente a precisão da previsão comparado a modelos não

sazonais. As previsões foram validadas usando MAPE, MAE e RMSE, sendo consideradas satisfatórias em termos de desempenho estatístico.

Diop e Kamdem (2022) combinaram transformação em wavelet com SARIMA para capturar padrões multiescala em preços futuros agrícolas. Essas técnicas aumentaram a acurácia ao decompor a série em ciclos sazonais detalhados, justificando metodologias híbridas em contexto de sazonalidade complexa

Em estudo recente, Ojha e Karki (2024) aplicaram SARIMA à série mensal de preços mundiais do trigo, ajustando log-transformação e diferenciação sazonal e validando o modelo com AIC e erros estatísticos, gerando previsões de longo prazo precisas e interpretáveis

2.5.2 Aplicações em Metais e Produtos Industriais

O trabalho de Huang et al. (2023) propôs um modelo híbrido SARIMA-LSSVM (um modelo que combina o SARIMA a um aprendizado de máquinas) para prever demanda no mercado spot de produtos de aço, destacando a eficiência da combinação entre modelagem linear (SARIMA) para tendências e sazonalidade, e métodos não lineares (LSSVM) para capturar padrões complexos

Essa abordagem demonstra como o SARIMA pode servir como base sólida em modelos preditivos industriais.

2.5.3 Revisão e Comparativos Metodológicos

Uma revisão de métodos de previsão de commodities indica que SARIMA segue sendo amplamente utilizado como benchmark, embora modelos híbridos e redes neurais estejam em crescente destaque. Modelos como Prophet (é um modelo de séries temporais desenvolvido pela empresa Meta), LSTM (é um tipo avançado de rede neural recorrente, muito usado para prever séries temporais com padrões complexos e de longo prazo) e regressão com componentes sazonais têm sido comparados ao SARIMA em diversos contextos (ZHANG; TANG, 2024).

3 METODOLOGIA

3.1 CLASSIFICAÇÃO DA PESQUISA

Este trabalho se configura como uma pesquisa quantitativa e aplicada, voltada ao desenvolvimento de um modelo de previsão para preços de commodities, especificamente o chumbo negociado na *London Metal Exchange* (LME), com foco em subsidiar decisões de compras industriais e estratégias de gestão de risco.

Segundo Creswell e Creswell (2017), a pesquisa quantitativa é caracterizada pelo uso sistemático de métodos estatísticos ou computacionais para descrever, testar hipóteses e estabelecer relações causais entre variáveis. Quando aplicada, essa abordagem visa resolver problemas práticos, promovendo inovação ou melhoria em contextos organizacionais reais.

A abordagem metodológica adotada é empírica, baseada em modelagem matemática e estatística, o que se alinha às diretrizes apresentadas por Fávero et al. (2020), que destacam a importância da aplicação de modelos quantitativos em contextos empresariais como ferramenta para apoiar decisões sob incerteza. Para isso algumas etapas devem ser realizadas.:

- Identificação do problema e definição do objetivo da previsão;
- Estruturação da base de dados histórica;
- Construção e calibração de modelos preditivos (SARIMA);
- Avaliação do desempenho preditivo por critérios quantitativos (AIC, RMSE, MAE, MAPE);
- Análise da adequação do modelo e de seus resultados à realidade operacional da organização.

A estrutura geral também se alinha à proposta de modelagem matemática descrita por Arenales et al. (2011), que compreende as seguintes etapas:

- i. Definição do problema;
- ii. Construção do modelo matemático;
- iii. Solução do modelo;
- iv. Validação da solução;
- v. Implementação e análise dos resultados obtidos.

Dessa forma, o presente estudo posiciona-se metodologicamente como uma

pesquisa empírica quantitativa aplicada com base em modelagem matemática, combinando fundamentos estatísticos com aplicabilidade direta ao contexto decisório industrial.

3.2 Etapas metodológicas da Pesquisa

3.2.1 Coleta e Caracterização dos Dados

Os dados utilizados para a realização das previsões neste trabalho referem-se aos preços do chumbo na *London Metal Exchange* (LME), abrangendo o período de 02 de janeiro de 1990 até 20 de janeiro de 2025. Essas informações foram coletadas a partir de bases de dados fornecidas diariamente por empresas especializadas, com a principal fonte sendo a Shock Metais, que disponibiliza os dados relativos ao fechamento diário da bolsa de Londres.

A escolha da base de dados da LME foi motivada pelo fato de que esta representa o maior mercado de chumbo do mundo, além de ser amplamente utilizada pelas principais *traders* internacionais para a precificação do metal nas suas negociações. A base de dados utilizada neste estudo foi fornecida pela empresa, no entanto, ela também pode ser obtida através da compilação dos dados diários fornecidos pela plataforma da Shock Metais, caso necessário.

3.2.2 Plataforma Computacional e Ferramentas

Para o desenvolvimento da modelagem preditiva, análise estatística e visualização dos dados, foi utilizada a linguagem de programação Python, amplamente adotada na área de ciência de dados e estatística aplicada, devido à sua versatilidade e ampla biblioteca de recursos.

O ambiente de desenvolvimento escolhido foi o Jupyter Notebook, por sua interface interativa que facilita tanto a execução passo a passo dos códigos quanto a documentação do raciocínio analítico. As principais bibliotecas utilizadas foram:

- Pandas: para manipulação, tratamento e estruturação dos dados em formato tabular (DataFrames);
- NumPy: para operações vetoriais e manipulação de arrays numéricos de forma eficiente;

- Matplotlib e Seaborn: para construção de gráficos e visualizações exploratórias dos dados e dos resultados da modelagem;
- Statsmodels: biblioteca principal para implementação dos modelos de séries temporais, especialmente o SARIMA, com suporte a critérios como AIC, análise de resíduos e diagnóstico de modelos;
- SciPy: utilizada para realização de testes estatísticos, como o teste de Dickey-Fuller aumentado (ADF) e manipulações matemáticas complementares;
- Scikit-learn: empregada na avaliação de desempenho dos modelos por meio de métricas como RMSE (*Root Mean Squared Error*), MAE (*Mean Absolute Error*) e MAPE (*Mean Absolute Percentage Error*);
- Pmdarima: auxiliar na automação da busca pelos melhores hiperparâmetros dos modelos ARIMA e SARIMA com base em critérios de seleção como AIC (*Akaike Information Criterion*) e BIC (*Bayesian Information Criterion*).

Toda a análise foi executada em ambiente local, com sistema operacional Windows 10, processador AMD Ryzen 5 5600G e 16 GB de memória RAM, recursos considerados plenamente adequados para a realização dos experimentos propostos com séries temporais mensais, incluindo modelagem, avaliação e visualizações estatísticas.

3.2.3 Tratamento dos dados

Na primeira etapa, a base de dados foi lida e armazenada em um DataFrame (estrutura de dados bidimensional que organiza dados em linhas e colunas).

A Figura 1 apresenta um resumo dos dados brutos utilizados no estudo, contendo os preços dos metais Cobre (Cu), Zinco (Zn), Alumínio (Al), Chumbo (Pb), Estanho (Sn) e Níquel (Ni), no período compreendido entre 2 de janeiro de 1990 e 10 de janeiro de 2025.

Figura 1 – DataFrame com os preços dos metais Cobre, Zinco, Alumínio, Chumbo, Estanho e Níquel (1990–2025)

```

0          Data  Cobre Zinco Alumínio  Chumbo Estanho Níquel
0  1990-01-02 00:00:00    NaN    NaN    NaN  726.3355    NaN    NaN
1  1990-01-03 00:00:00    NaN    NaN    NaN  716.1784    NaN    NaN
2  1990-01-04 00:00:00    NaN    NaN    NaN   733.5    NaN    NaN
3  1990-01-05 00:00:00    NaN    NaN    NaN  714.816    NaN    NaN
4  1990-01-08 00:00:00    NaN    NaN    NaN  718.707    NaN    NaN
...
8846 2025-01-14 00:00:00  9016  2831  2554.5  1914.5  29550  15600
8847 2025-01-15 00:00:00  9020  2792   2562   1907  29125  15630
8848 2025-01-16 00:00:00  9135  2824   2628   1930  29550  15665
8849 2025-01-17 00:00:00  9132  2884  2658.5   1936  29400  15840
8850 2025-01-20 00:00:00  9043.5 2891   2675  1948.5  29350  15680

```

[8851 rows x 7 columns]

Fonte: Autor.

No entanto, para a precificação do chumbo (Pb), foi necessário adaptar a base de dados à frequência mensal dos preços, para isso a primeira etapa do tratamento dos dados consistiu na conversão da frequência dos dados de diária para uma frequência mensal. Esse tratamento foi realizado calculando a média dos preços diários de cada mês, consolidando-os em um único valor mensal, que já é uma prática utilizada para o cálculo do preço no mês.

Após a conversão da frequência dos dados, foi realizado um filtro nas colunas existentes no DataFrame para isolar apenas a coluna relevante ao estudo.

A figura 2 apresenta o resultado do filtro realizado nas colunas, contendo apenas os dados mensais do chumbo (Pb).

Figura 2 – DataFrame com os preços mensais do Chumbo (Pb)

```

0          Chumbo
1990-01-01  707.663127
1990-02-01  779.930935
1990-03-01 1060.666795
1990-04-01  836.169705
1990-05-01  825.467424
...
2024-10-01 2035.818182
2024-11-01 1988.428571
2024-12-01 2010.066667
2025-01-01 1921.230769
2025-12-01 1946.000000

```

[422 rows x 1 columns]

Fonte: Autor.

3.2.4 Análise Estatística

A segunda etapa realizada foi uma análise estatística exploratória, cujo objetivo foi compreender a organização e a natureza da série temporal que está sendo estudada, bem como identificar padrões e tendências no comportamento dos preços do chumbo ao longo do período estudado. Para isso, foram calculadas métricas estatísticas descritivas e gerados gráficos que auxiliam na interpretação dos resultados.

Tabela 1 - Resumo estatístico dos preços do chumbo (1990-2025)


Tamanho da Amostra	Média	Desvio Padrão	Mínimo	Máximo	Quartis		
					25%	50%	75%
422	1.397	788	376	3.720	571	1.617	290

Fonte: Autor.

- Tamanho da amostra: A amostra contém 422 meses de dados, representando a série temporal completa do período estudado;
- Média: O valor médio do preço do chumbo foi de US\$ 1.397,00, indicando o valor central em torno do qual os dados se distribuem;
- Desvio Padrão: O desvio padrão de US\$ 788,00 revela uma alta variabilidade nos preços, sugerindo flutuações significativas ao longo do tempo;
- Mínimo e máximo: Ao longo do período estudado os preços do Chumbo variam entre US\$ 376,00 (mínimo) e US\$ 3.720,00 (máximo), mostrando que há uma grande amplitude nos preços;
- Quartis: Representa os valores que dividem a amostra em quatro partes iguais. O primeiro quartil (Q1) foi de US\$ 571,00, o segundo quartil (Q2 ou mediana) US\$1.617,00, e o terceiro quartil (Q3) de US\$ \$2.090,00.

Para complementar a análise estatística, foram gerados gráficos que permitiram visualizar a distribuição e o comportamento dos preços do chumbo ao longo do tempo. Segue os resultados obtidos após a análise exploratória.

Figura 3 - Análise Exploratória dos Preços do Chumbo



- Série temporal dos preços do chumbo ao longo do tempo (em USD);
- Distribuição de frequência dos preços do chumbo com curvas de densidade;
- Boxplot dos preços do chumbo, evidenciando a mediana, quartis e valores externos.

Fonte: Autor, 2025.

O primeiro gráfico apresenta a evolução dos preços ao longo do período estudado. A partir dele foi possível identificar três fases distintas no comportamento dos preços:

- Primeira fase (1990–2004): Caracterizada por preços relativamente baixos e estáveis, com pouca volatilidade.
- Segunda fase (2004–2010): Marcada por um crescimento acelerado dos preços, seguido de uma forte volatilidade, especialmente durante a crise econômica de 2008.
- Terceira fase (2010–2025): Período de estabilização dos preços em um novo patamar, com a presença de sazonalidades e menor volatilidade em comparação à fase anterior.

O segundo gráfico, que apresenta a distribuição dos preços do chumbo, revela que os dados não seguem uma distribuição normal. Essa característica sugere a presença de múltiplas distribuições ou a influência de eventos externos que impactam os preços ao longo do tempo.

O terceiro gráfico, um boxplot, mostra que não há outliers na série temporal. No entanto, a grande amplitude dos dados, decorrente da alta variabilidade, podem mascarar a presença de valores atípicos.

Por meio das análises realizadas, é possível perceber uma provável mudança no comportamento do preço do chumbo, essas mudanças podem ter ocorrido devido a eventos externos sendo alguns desses prováveis eventos: Entrada da China na

Organização Mundial do Comércio (OMC) em 2001 e a Crise financeira de 2008.

A entrada da China na (OMC) em 2001 fez com que marcasse um ponto de inflexão na economia global marcado pela variação do valor de várias commodities e para o chumbo não foi diferente, passando a ter um novo patamar de preços após esse evento (OMC, 2025).

A crise econômica de 2008 causou um grande impacto nos preços das commodities, interrompendo a trajetória de alta nos preços que estava sendo impulsionada pelos países emergentes e principalmente pela China que havia entrado na OMC (ABE, 2011). Esta crise fez com que houvesse vários outliers na série temporal que não estão sendo apontados no gráfico do box-plot devido à grande amplitude presente na série.

Diante da alta variabilidade dos distúrbios observados na segunda fase e pelos dados da primeira fase não condizem com a realidade atual onde a China participa da OMC, optou-se por realizar um corte temporal nos dados, utilizando apenas os dados da terceira fase (2010-2025) para as análises subsequentes. Essa decisão foi tomada para garantir maior estabilidade e confiabilidade nos resultados.

A nova série temporal, compreendendo o período de 2010 a 2025, apresenta as seguintes características conforme mostrado na Tabela 2:

Tabela 2 – Resumo estatístico dos preços do chumbo (2010–2025)


Tamanho da Amostra	Média	Desvio Padrão	Mínimo	Máximo	Quartis		
					25%	50%	75%
182	2.095	225	1.616	2.741	1.952	2.088	2.228

Fonte: Autor, 2025.

Amplitude reduzida: A diferença entre os valores mínimos e máximos é menor em comparação com a série completa.

Para complementar a análise estatística, foram gerados novos gráficos que permitiram visualizar a distribuição e o comportamento dos preços do chumbo ao longo do tempo na nossa nova série temporal. A Figura 4 apresenta 3 gráficos: (1) a série temporal dos preços do chumbo, (2) a distribuição dos preços e (3) o boxplot dos preços.

Figura 4 - Análise Exploratória dos Preços do Chumbo (2010 - 2025).



- Série temporal dos preços do chumbo ao longo do tempo (em USD);
- Distribuição de frequência dos preços do chumbo com curvas de densidade;
- Boxplot dos preços do chumbo, evidenciando a mediana, quartis e valores externos.


Fonte: Autor, 2025.

- Sazonalidade evidente: A análise gráfica revela a presença de sazonalidade nos preços do chumbo um padrão que será explorado em maior detalhe nas etapas seguintes do trabalho.
- Distribuição mais próxima da normal: A distribuição dos dados na terceira fase se assemelha mais a uma distribuição normal.
- Outliers: A série apresenta um outlier.

3.2.5 Decompondo a série temporal

Uma série temporal contém alguns elementos: Tendência, sazonalidade e ruídos ou erros. Nesse tópico iremos estudar a série mais profundamente vendo cada um desses elementos para o preço do chumbo.

Figura 5 - Decomposição da série temporal em tendência, sazonalidade e ruído.



Fonte: Autor, 2025.

Para análise exploratória da série temporal, foi utilizada a metodologia de decomposição aditiva clássica, que permite separar a série em três componentes principais: tendência, sazonalidade e resíduos. A tendência foi estimada por meio de uma média móvel centrada de 12 períodos, suavizando flutuações de curto prazo e evidenciando o comportamento de longo prazo dos preços. A decomposição foi realizada adotando o modelo aditivo com periodicidade de 12 meses, o que reflete ciclos sazonais anuais. A componente de sazonalidade capta os padrões repetitivos e sistemáticos ao longo do tempo, enquanto os resíduos representam as variações aleatórias não explicadas pelos demais componentes.

Com o gráfico acima, podemos fazer a seguinte análise:

- **Tendência:** No primeiro gráfico podemos observar que o preço do chumbo apresenta uma tendência de queda suave durante os últimos anos. Analisando a série como um todo, podemos ver que no período estudado (15 anos) apesar das variações o preço tem uma tendência de estabilização, pois de 2022 para frente os picos e vales passaram a ser bem menores em comparação aos anos anteriores.

- Sazonalidade: O segundo gráfico revela a presença de 15 picos e 15 vales ao longo do período estudados, o que corresponde a quantidade de anos que contém a nossa série temporal. Esse padrão sugere a existência de uma possível sazonalidade anual no preço do chumbo, indicando que existe a possibilidade de haver uma sazonalidade anual.
- Ruídos: No terceiro e último gráfico, observamos que os ruídos não apresentam pontos de concentração ao longo do tempo, também não apresentam possuir tendência e sazonalidade. Essa ausência de padrões nos ruídos indica que não há mudanças significativas no comportamento da série que possam ser atribuídas por fatores externos.

Falando um pouco mais sobre a sazonalidade, podemos observar que a sazonalidade anual presente no preço do chumbo está intimamente ligada às condições climáticas (especialmente em países desenvolvidos) e ao comportamento da demanda por baterias, uma vez que cerca de 70% do chumbo comercializado tem como destino a produção de baterias de chumbo-ácido (PAOLIELLO, CHASIN, 2001). Durante períodos de baixas temperaturas, como o inverno, a eficiência e a capacidade dessas baterias podem ser afetadas negativamente, levando a uma maior necessidade de substituições e, conseqüentemente, a um aumento nas vendas.

3.2.6 Estacionalidade

Nesse tópico, iremos avaliar a série temporal quanto ao primeiro parâmetro do nosso modelo SARIMA, que corresponde ao “I” (integração), indicando se a série é estacionária ou não. Para isso, iremos utilizar o teste de Dickey-fuller Aumentado (ADF).

Através do teste, foram obtidos os seguintes resultados:

Figura 6 - Resultado do teste de Dickey-fuller Aumentado.

```
Estatística do teste ADF: -3.3394600953344957
Valor-p: 0.013204149632407661
Valores críticos:
  1%: -3.467004502498507
  5%: -2.8776444997243558
 10%: -2.575355189707274
Conclusão: Rejeitamos a hipótese nula. A série é ESTACIONÁRIA.
```

Fonte: Autor.


Pelo teste, observamos que o valor p é menor que 0,05, o que nos leva a rejeitar a hipótese nula (H_0 : A série não é estacionária). Sendo assim, podemos prosseguir com o estudo sem a necessidade de realizar uma diferenciação na série temporal.

3.2.7 ACF e PACF

Nesse tópico iremos realizar a análise de Autocorrelação (ACF) e Autocorrelação Parcial (PACF). Essas análises serão utilizadas para determinar qual serão os parâmetros utilizados das partes AR (Auto-Regressiva) e MA (Média Móveis) do nosso modelo SARIMA.

A Seguir serão apresentados os gráficos e as análises feitas:


Figura 7 - Gráfico de autocorrelação (ACF).



Fonte: Autor, 2025.

Pelo gráfico de ACF, observamos um decaimento lento, indicando que os lags com maior correlação são os de 0 a 5, sendo o lag 0 o que apresenta a maior correlação. Logo o parâmetro AR está entre 0 e 5.

Figura 8 - Gráfico de autocorrelação (PACF).



Fonte: Autor, 2025.

No gráfico de PACF, verificamos que os dois primeiros lags apresentam maior significância. Sendo assim, os parâmetros da parte AR do modelo que podem ser utilizados são 0 e 1.

3.2.8 Analisando a Sazonalidade

Para a análise da componente sazonal, iremos primeiro avaliar a estacionariedade da série após a diferenciação sazonal. Para isso, realizaremos o teste de Dickey-Fuller Aumentado (ADF) novamente, mas desta vez aplicando uma diferenciação de 12 períodos para verificar se os dados se tornam estacionários em uma base anual.

Segue os resultados:

Figura 9 - Resultado do teste de Dickey-Fuller Aumentado da parte sazonal.

Estatística do teste ADF: -3.053502421094151

Valor-p: 0.030191113400510894

Valores críticos:

1%: -3.472703119504854

5%: -2.880131672353732

10%: -2.5766826861130268

Conclusão: Rejeitamos a hipótese nula. A série é ESTACIONÁRIA.

Fonte: Autor, 2025.


Como podemos observar, para a componente sazonal, o p-valor também ficou abaixo de 0,05. Isso indica que a diferenciação sazonal foi eficaz para tornar a série

estacionária, permitindo que prossigamos com a análise sem a necessidade de mais uma diferenciação.

O próximo passo foi analisar os gráficos ACF e PACF da parte sazonal para determinar os parâmetros dos componentes AR e MA do modelo.

Segue os resultados:


Figura 10 - Gráfico de autocorrelação (ACF) - sazonal.



Fonte: Autor, 2025.

Podemos observar que o gráfico ACF da Figura 10 (referente a sazonalidade) apresenta o mesmo comportamento do gráfico ACF da Figura 7 da série temporal. Nota-se que os cinco primeiros lags possuem maior significância, indicando que, para a componente MA do modelo, o parâmetro deve estar entre 0 e 5.

Figura 11 - Gráfico de autocorrelação (PACF) - sazonal.



Fonte: Autor, 2025.

Para o Gráfico PACF, já temos uma leitura um pouco diferente podemos ver que os 3 primeiros lags apresentam alguma significância sendo os dois primeiros com uma correlação positiva e o terceiro sendo uma correlação negativa, sendo assim os parâmetros para a Parte AR ficam sendo entre 0 e 3.

3.2.9 Construindo o modelo SARIMA

A partir das análises realizadas anteriormente, iremos agora iniciar a construção do nosso modelo SARIMA. sendo representado da seguinte forma:

$$\text{SARIMA}(p,d,q)(PDQ)s \text{ (9)}$$

p: Ordem do termo autoregressivo (AR).

d: Número de diferenciações necessárias para tornar a série estacionária.

q: Ordem do termo de média móvel (MA).

P: Ordem do termo autoregressivo sazonal (SAR).

D: Número de diferenciações sazonais.

Q: Ordem do termo de média móvel sazonal (SMA).

s: Período sazonal.

Com base nas análises realizadas anteriormente os parâmetros do nosso modelo podem assumir os seguintes números:

p: 2 opções (0, 1).

d: 1 opção (0).

q: 6 opções (0, 1, 2, 3, 4, 5).

P: 4 opções (0, 1, 2, 3).

D: 1 opção (0).

Q: 6 opções (0, 1, 2, 3, 4, 5).

s: 1 opção (12).

Logo, temos um total de 288 possibilidades de combinação entre os parâmetros que estão representadas na figura a seguir:

Figura 12 - Gráfico de autocorrelação (PACF) - sazacional.

	p	d	q	P	D	Q	s
0	0	0	0	0	0	0	12
1	0	0	0	0	0	1	12
2	0	0	0	0	0	2	12
3	0	0	0	0	0	3	12
4	0	0	0	0	0	4	12
...	...	...	...	...	...	...	...
283	1	0	5	3	0	1	12
284	1	0	5	3	0	2	12
285	1	0	5	3	0	3	12
286	1	0	5	3	0	4	12
287	1	0	5	3	0	5	12

[288 rows x 7 columns]

Fonte: Autor, 2025.

O próximo passo consistiu na seleção do modelo com melhor desempenho para previsões de curto prazo. Inicialmente, foi realizada uma análise comparativa considerando os quatro primeiros passos de previsão à frente do mês corrente, denominados M1, M2, M3 e M4 (sendo M o mês base da previsão, M1 a estimativa para o mês seguinte, M2 para dois meses à frente, e assim sucessivamente até M4). Essa avaliação permitiu observar a capacidade preditiva dos modelos em diferentes horizontes temporais. As métricas utilizadas foram MAE (Erro Absoluto Médio), RMSE (Raiz do Erro Quadrático Médio) e MAPE (Erro Percentual Absoluto Médio), aplicadas em uma estratégia *rolling* no período de janeiro a dezembro de 2023.

No entanto, para o objeto de estudo deste trabalho, a comparação final concentrou-se no desempenho em M1, por ser o horizonte de previsão mais relevante para a tomada de decisão imediata e também por garantir comparabilidade com outros

métodos de previsão que não possuem a mesma capacidade de estender estimativas até M4. Essa escolha não invalida o potencial do modelo adotado, que se destaca justamente por permitir projeções além do M1, oferecendo uma visão mais ampla do comportamento futuro dos preços do chumbo.

A escolha por avaliar o desempenho nas quatro primeiras previsões se justifica pela relevância prática desse horizonte no contexto do mercado de chumbo. Esse intervalo abrange a maioria dos cenários de precificação adotados comercialmente, como cotações com base no mês seguinte à chegada do material no porto ou na fábrica, ou ainda o mês seguinte ao embarque. Assim, a análise busca refletir com maior fidelidade a dinâmica real das operações de compra e venda do insumo.

Inicialmente, os modelos foram ranqueados de acordo com o menor valor de erro em cada métrica. A seguir, apresentamos o top 10 dos modelos SARIMA para cada uma das métricas:

- Top 10 modelos SARIMA com o menor MAE acumulado

Tabela 3 – Top 10 modelos com o Menor MAE.

Ranking	p	d	q	P	D	Q	s	MAE
1	1	0	5	0	0	4	12	3.137
2	1	0	4	0	0	4	12	3.164
3	1	0	5	2	0	0	12	3.242
4	1	0	5	2	0	1	12	3.251
5	1	0	4	2	0	0	12	3.255
6	1	0	5	3	0	1	12	3.255
7	1	0	5	0	0	2	12	3.255
8	1	0	5	3	0	0	12	3.260
9	1	0	4	0	0	2	12	3.262
10	1	0	4	3	0	0	12	3.269

Fonte: Autor, 2025.

- Top 10 modelos SARIMA com o menor RMSE acumulado

Tabela 4 – Top 10 modelos com o Menor RMSE

Ranking	p	d	q	P	D	Q	s	RMSE
1	1	0	5	0	0	4	12	3.137
2	1	0	4	0	0	4	12	3.164
3	1	0	5	2	0	0	12	3.242
4	1	0	5	2	0	1	12	3.251
5	1	0	4	2	0	0	12	3.255
6	1	0	5	3	0	1	12	3.255
7	1	0	5	0	0	2	12	3.255
8	1	0	5	3	0	0	12	3.260
9	1	0	4	0	0	2	12	3.262
10	1	0	4	3	0	0	12	3.269

Fonte: Autor, 2025.

- Top 10 modelos SARIMA com o menor MAPE acumulado

Tabela 5 – Top 10 modelos com o Menor MAE

Ranking	p	d	q	P	D	Q	s	MAPE
1	1	0	5	0	0	4	12	11,36
2	1	0	4	0	0	4	12	11,46
3	1	0	5	2	0	0	12	11,74
4	1	0	4	2	0	0	12	11,78
5	1	0	5	0	0	2	12	11,78
6	1	0	5	2	0	1	12	11,80
7	1	0	5	3	0	0	12	11,80
8	1	0	4	0	0	2	12	11,81
9	1	0	5	3	0	1	12	11,82
10	1	0	4	3	0	0	12	11,84

Fonte: Autor, 2025.

Após a análise das métricas de erro, foi realizada uma nova avaliação considerando o critério de informação de Akaike (AIC). O AIC é utilizado para balancear a qualidade do ajuste do modelo e sua complexidade, sendo preferível o modelo com menor valor de AIC.

Tabela 6 – AIC de cada modelo do Top 10 modelos com menores erros.

Modelo	p	d	q	P	D	Q	s	AIC
1	1	0	5	0	0	4	12	4.022
2	1	0	4	0	0	4	12	4.585
3	1	0	5	2	0	0	12	1.871
4	1	0	4	2	0	0	12	1.870
5	1	0	5	0	0	2	12	1.814
6	1	0	5	3	0	0	12	1.727
7	1	0	4	0	0	2	12	1.825
8	1	0	5	3	0	1	12	1.730
9	1	0	4	3	0	0	12	1.729
10	1	0	5	2	0	1	12	1.873

Fonte: Autor, 2025.

Dentre os modelos do TOP 10 em desempenho de erro, o modelo SARIMA(1,0,5)(3,0,0)[12], denominado modelo 6, apresentou o menor AIC. No entanto, o modelo 1 havia sido o que apresentou o menor erro RMSE.

Para determinar se a escolha do modelo com o menor AIC é justificada, comparamos diretamente os desempenhos de erros dos dois:

$$\text{Desempenho Relativo (RMSE)} = \frac{RMSE_{\text{modelo 6}}}{RMSE_{\text{modelo 1}}} = \frac{3.255}{3.137} \approx 104\% (10)$$

Isso indica que o modelo 6 apresenta um RMSE apenas 4% superior ao modelo 1, mas com uma vantagem significativa em termos de AIC. Assim apesar do erro ligeiramente superior, a escolha recaiu sobre o modelo 3 por apresentar:

- Um valor de AIC Substancialmente menor (indicando melhor equilíbrio entre ajuste e parcimônia),
- Maior potencial de generalização (menor risco de overfitting).


Portanto o modelo selecionado para gerar as previsões de preços do chumbo para o ano de 2024 foi o SARIMA (1,0,5)(3,0,0)[12].

4 RESULTADOS E DISCUSSÕES

A partir dos estudos do capítulo anterior, o modelo escolhido foi o SARIMA(1,0,5)(3,0,0)[12], pois foi o que apresentou o menor erro para a previsão dos próximos 4 meses (M1 a M4), considerando as métricas MAPE, RMSE e MAE, além de apresentar o menor valor de AIC, o que indica maior potencial de generalização. Embora tenham sido avaliadas previsões dos próximos meses (M1 a M4), optou-se por utilizar exclusivamente o horizonte de um mês (M1) na comparação entre modelos, visto que outros métodos considerados na pesquisa não permitiam a obtenção de previsões multietapas com a mesma estrutura. Essa escolha garante uma base comparativa equitativa entre todos os modelos testados.

Na figura 13, podemos ver o desempenho do modelo de previsão frente o realizado de 2024:

Figura 13 – Comparação das previsões SARIMA vs. Preço real LME.




Fonte: Autor, 2025.

A partir do gráfico da figura 13, percebe-se que o modelo apresenta uma boa aderência frente realizado ao longo de todo período de 2024, realizando a previsão do M1 do preço do Pb.

Em seguida foi feita uma comparação frente a média móvel levando em consideração a média dos últimos 2 meses, a escolha desse período para realização da previsão utilizando a média móvel foi que durante um teste para o ano de 2023 esse foi o período que apresentou o menor erro considerando a média móvel.

Na figura 14 a seguir são apresentadas as previsões geradas por esse modelo frente o realizado:

Figura 14 – Comparação das previsões Média Móvel vs. Preço real LME.




Fonte: Autor, 2025.

Podemos ver que também apresenta uma boa aderência ao realizado, porém há momentos em que as duas curvas acabam se descolando isso ocorre devido ao fato deste método não acompanhar bem as sazonalidades presentes na série temporal não conseguindo identificar as subidas e quedas do preço do chumbo.

Outro método utilizado pela empresa é a previsão por meio da regressão Linear simples o período encontrado para realizar as previsões foi de um período de 4 meses, pois esse assim como a média foi o período que apresentou o menor erro durante as previsões em 2023.

Segue a previsão dos preços utilizando a regressão frente o realizado:

Figura 15 – Comparação das previsões Regressão Linear Simples vs. Preço real LME.



Fonte: Autor, 2025.


As previsões geradas pela regressão também apresentaram uma boa aderência a curva de realizado, porém há pontos onde a curva consegue captar a tendência do preço, porém mesmo assim as curvas acabam se descolando.

Outro modelo de previsão utilizado pela empresa em questão é o modelo fornecido por uma consultoria externa que leva como base acontecimentos no mercado que impactam negativamente ou positivamente no preço do chumbo, esse

seria um modelo mais especulativo, pois a empresa do estudo em questão paga para uma empresa externa que realiza as previsões e também oferece relatórios a respeito do mercado de Chumbo no mundo.

Segue a previsão realizada pela empresa frente o realizado:

Figura 16 – Comparação das previsões Empresa externa vs. Preço real LME.



Fonte: Autor, 2025.

Podemos ver que a previsão apresenta uma constância o que leva a gerar alguns erros, isso ocorre ela é limitada, pois oferece uma previsão para o trimestre do ano e não mensal como é visto nas previsões anteriores, e como para a empresa é importante o dado mensal iremos contar com o valor do trimestre para os três meses a que ele se refere.

Após a geração das previsões referentes aos três modelos em uso na empresa, foi realizada uma comparação entre os erros dos modelos apresentados e do modelo proposto, que pode ser visto na tabela a seguir:

Tabela 7 – Tabela comparativo dos erros dos métodos de previsão

Modelo	MAE	RMSE	MAPE
Consultoria	1081	1081	53%
Média (M1)	621	621	30%
Regressão	819	819	39%
SARIMA	522	522	25%

Fonte: Autor, 2025.

A partir da tabela, temos que a previsão do modelo SARIMA foi o que apresentou o melhor desempenho geral frente as outras previsões, tendo o menor erro frente as outras formas de previsão ao longo de 2024. Outra conclusão que temos

é que a previsão proposta pela consultoria foi a que apresentou maior erro.

Apesar de haver uma pequena variação entre o modelo SARIMA e a Média móvel (18% a menos), isso se trata de um valor significativo, pois pode representar uma variação de 360 dólares por tonelada de chumbo levando em consideração um preço médio de U\$ 2.000/ton.

Então pela visão dos erros, temos que a previsão gerada pelo SARIMA é a melhor opção para a previsão do preço do Chumbo para a LME dentre os métodos informados.

5 CONSIDERAÇÕES FINAIS

O modelo de previsão desenvolvido neste trabalho apresentou desempenho superior em relação aos métodos tradicionalmente utilizados pela empresa, demonstrando um menor erro nas previsões no M1 sem gerar custos adicionais para a empresa além de trazer a possibilidade de enxergar uma previsão no horizonte de 4 meses algo que não era visto em alguns dos modelos utilizados anteriormente pela empresa. Dessa forma, o estudo alcança êxito ao entregar uma solução preditiva mais precisa e eficiente do que as abordagens atualmente empregadas, abrindo novas possibilidades para aplicações práticas e futuras investigações não só do Pb mas também para outros insumos que tem um impacto nos suprimentos da empresa.

Além de atender à previsão de curto prazo (M1), estudos futuros podem explorar técnicas mais avançadas, como redes neurais recorrentes (RNNs) ou modelos baseados em aprendizado profundo, capazes de capturar padrões mais complexos ao longo do tempo.

Outro ponto com potencial de melhoria é a incorporação de variáveis exógenas (ex.: taxa de câmbio, preço de energia, dados macroeconômicos), que podem contribuir significativamente para aumentar a capacidade explicativa do modelo e sua sensibilidade às dinâmicas do mercado global de metais. Essa evolução possibilitaria à empresa contar com previsões ainda mais sólidas para dar suporte à decisão, simulação de custos e elaboração de estratégias de proteção comercial.

REFERÊNCIAS

ABE, Mirian Mayumi. A crise de 2008 e seu impacto em países economicamente dependentes de commodities. 2011

Analysis Report, até 2032. Fortune Business Insights™, 2025. Disponível em: <https://www.fortunebusinessinsights.com/pt/industry-reports/lead-acid-battery-market-100237>. Acesso em: 29 jun. 2025, às 21h30.

ARENALES, M. et al. Pesquisa Operacional. 1. ed. Rio de Janeiro: Elsevier: ABEPRO, 2011.

CHEN, Xiangyu; TONGURAI, Jittima. Spillovers and interdependency across base metals: evidence from China's futures and spot markets. *Resources Policy*, v. 75, p. 102479, 2022.

CONAMA. Resolução nº 452, de 2 de julho de 2012. Diário Oficial da União, Brasília, 3 jul. 2012.

CRESWELL, John W.; CRESWELL, J. David. Research design: Qualitative, quantitative, and mixed methods approaches. Sage publications, 2017.

DE ARAÚJO, Antônio Carlos; LIMA, Ricardo Chaves; MESQUITA, Teobaldo Campos. Um modelo de previsão de preços internacionais do cacau. *Revista Econômica do Nordeste*, v. 28, n. 3, p. 311-325, 1997.

DIOP, Mamadou-Diéne; SADEFO KAMDEM, Jules. Multiscale agricultural commodities forecasting using wavelet-SARIMA process. *Journal of Quantitative Economics*, v. 21, n. 1, p. 1-40, 2023.

FÁVERO, L. P.; BELFIORE, P.; SILVA, F. L.; CHAN, B. L. Análise de dados: modelagem multivariada para tomada de decisões. 3. ed. Rio de Janeiro: Elsevier, 2020.

FORTUNE BUSINESS INSIGHTS. Lead Acid Battery Market Size, Share & Industry Analysis Report, até 2032. Fortune Business Insights™, 2025. Disponível em: <https://www.fortunebusinessinsights.com/pt/industry-reports/lead-acid-battery-market-100237>. Acesso em: 29 jun. 2025, às 21h30.

GIRI, Anisha; GIRI, Vijay Raj. Forecasting cauliflower prices in Nepal: a comparative analysis using seasonal time series and nonlinear models. *Cogent Food & Agriculture*, v. 10, n. 1, p. 2340155, 2024.

HASAN, Mahmud; WATHODKAR, Gauree; MUIA, Mathias. ARMA model development and analysis for global temperature uncertainty. *Frontiers in Astronomy and Space Sciences*, v. 10, p. 1098345, 2023.

HUANG, Junting et al. Potential Demand Forecasting for Steel Products in Spot

Markets Using a Hybrid SARIMA-LSSVM Approach. *Journal of Forecasting*, 2025.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. *Forecasting: principles and practice*. OTexts, 2018.

KEMALBAY, Gulder; KORKMAZOGLU, Ozlem Berak. Sarima-arch versus genetic programming in stock price prediction. *Sigma Journal of Engineering and Natural Sciences*, v. 39, n. 2, p. 110-122, 2021.

KWAS, Marek; RUBASZEK, Michał. Forecasting commodity prices: Looking for a benchmark. *Forecasting*, v. 3, n. 2, p. 447-459, 2021.

LONDON METAL EXCHANGE (LME). About the London Metal Exchange. Disponível em: <https://www.lme.com/en/about>. Acesso em: 13 jun. 2025.

MA, Yang et al. Analysis of a more sustainable method for recycling waste lead batteries: Surface renewal promotes desulfurization agent regeneration. *Waste Management*, v. 137, p. 319-328, 2022.

MALECHA, Daniel et al. Recovery of Pure Lead-Tin Alloy from Recycling Spent Lead-Acid Batteries. *Materials*, v. 16, n. 17, p. 5882, 2023.

OJHA, Sahil; KARKI, Lila B. Forecasting Global Wheat Price in the Context of Changing Climate and Market Dynamics: An Application of SARIMA Modeling Technique. *American Journal of applied Statistics and Economics*, 2025.

OMC. China and the World Trade Organization. Disponível em: https://www.wto.org/english/thewto_e/acc_e/a1_chine_e.htm. Acesso em: 11 mar 2025

PAOLIELLO, M. M. B., CHASIN, A. A. M. *Ecotoxicologia do chumbo e seus compostos*. Salvador, CRA, 2001. 144p. (Cadernos de Referência Ambiental, 3).

UŽÍK, Martin et al. Portfolio hedging strategy-metals and commodities. *Acta Montanistica Slovaca*, 2023.

YANAMANDRA, K.; PINISETTY, D.; GUPTA, N. Impact of carbon additives on lead-acid battery electrodes: A review. *Renewable and Sustainable Energy Reviews*, v. 173, p. 113078, 2023. Disponível em: <https://doi.org/10.1016/j.rser.2022.113078>. Acesso em: 10 jul. 2024.

WANG, Pengcheng; ZHU, Changqing. Summary of lead-acid battery management system. In: *IOP Conference Series: Earth and Environmental Science*. IOP Publishing, 2020. p. 022014.

WANJUKI, Teddy Mutugi; WAGALA, Adolphus; MURIITHI, Dennis K. Forecasting commodity price index of food and beverages in Kenya using seasonal autoregressive integrated moving average (SARIMA) models. *European Journal of Mathematics and Statistics*, v. 2, n. 6, p. 50-63, 2021.

ZHANG, Tingting; TANG, Zhenpeng. Agricultural commodity futures prices prediction based on a new hybrid forecasting model combining quadratic decomposition technology and LSTM model. *Frontiers in Sustainable Food Systems*, v. 8, p. 1334098, 2024.