

Lucas Ferraz Furlan

Análise de Séries Temporais com Dados Reais
e Desenvolvimento de Modelos de Previsão

Este exemplar corresponde à redação final do trabalho de conclusão de curso devidamente corrigido e defendido por Lucas Ferraz Furlan e aprovado pela banca examinadora.

Aprovado em 11 de fevereiro de 2025

Banca Examinadora:

- Maria Sílvia de Assis Moura (Orientadora)
- Márcio Luis Lanfredi Viola
- Francisco Antonio Rojas Rojas

Resumo

Este Trabalho de Conclusão de Curso (TCC) aborda o desenvolvimento de modelos de previsão de séries temporais, especificamente aplicados a cinco variáveis de mercado: Pneus, Chapas de Aço, Borracha, Energia Elétrica no Brasil e Embalagens de Polietileno. O estudo emprega uma combinação de alisamento exponencial e modelos ARIMA, reconhecidos por sua robustez na análise de dados temporais com tendências e padrões sazonais. O objetivo é realizar previsões de 18 meses adiante, equilibrando as nuances de comportamento a médio e longo prazo das séries. A pesquisa foca na otimização dos parâmetros de previsão, buscando um compromisso entre a sensibilidade às condições atuais do mercado e a incorporação de tendências históricas. A dualidade de métodos permite abordar séries temporais com diferentes graus de volatilidade e periodicidade, proporcionando uma compreensão mais aprofundada e uma aplicabilidade mais ampla. As implicações práticas deste estudo são particularmente relevantes para a tomada de decisões estratégicas no âmbito comercial e industrial, diante do papel crítico que tais produtos desempenham na economia.

Palavras-chave: *modelos ARIMA, previsão, séries temporais, alisamento exponencial..*

Abstract

This Undergraduate Thesis (TCC) addresses the development of time series forecasting models, specifically applied to five market variables: Tires, Steel Sheets, Rubber, Electric Energy in Brazil, and Polyethylene Packaging. The study employs a combination of exponential smoothing and ARIMA models, recognized for their robustness in analyzing temporal data with trends and seasonal patterns. The goal is to provide forecasts up to 18 months ahead, balancing medium- and long-term behavioral nuances of the series.

The research focuses on optimizing forecasting parameters, aiming for a compromise between sensitivity to current market conditions and the incorporation of historical trends. The duality of methods allows addressing time series with different degrees of volatility and periodicity, providing a deeper understanding and broader applicability. The practical implications of this study are particularly relevant for strategic decision-making in the commercial and industrial sectors, given the critical role these products play in the economy.

Keywords: *ARIMA models, forecasting, time series, exponential smoothing.*

Lista de Figuras

4.1	Série Histórica do Custo do Produto Pneu	33
4.2	Previsão de 18 Meses para o Produto Pneu	36
5.1	Série Histórica do Custo do Produto Embalagem de Polietileno	38
5.2	Previsão de 18 Meses para o Produto Embalagem de Polietileno	42
6.1	Série Histórica do Custo do Produto Borracha.	44
6.2	Previsão de 18 Meses para o Produto Borracha.	47
7.1	Série Histórica do Custo da Energia Elétrica no Brasil	49
7.2	Previsão de 18 Meses para a Energia Elétrica no Brasil.	51
8.1	Série Histórica do Custo do Produto Chapas de Aço	53
8.2	Previsão de 18 Meses para o Produto Chapas de Aço.	56
A.1	Previsão do Custo de Pneu (Metodologia ARIMA)	61
A.2	Previsão do Custo de Pneu (Metodologia Alisamento Exponencial)	61

Lista de Tabelas

4.1	Resultados do Teste de Friedman para a Série de Preços do Produto PNEU. . .	34
4.2	Melhores Modelos Selecionados com Base no RMSE.	34
4.3	Modelo Final Selecionado Após Refinamento.	35
5.1	Resultados do Teste de Friedman para a Série de Preços da Embalagem de Polietileno.	40
5.2	Melhores Modelos Selecionados com Base no RMSE.	40
5.3	Modelos Refinados Selecionados com Base no RMSE.	41
6.1	Resultados do Teste de Friedman para a Série de Preços da Borracha.	45
6.2	Melhores Modelos Selecionados com Base no RMSE.	45
6.3	Resultados Refinados com os Melhores Parâmetros.	46
7.1	Resultados do Teste de Friedman para a Série de Preços de Energia Elétrica. . .	50
7.2	Melhores Combinações de Parâmetros para o Modelo de Energia Elétrica.	50
8.1	Resultado do Teste de Friedman para Chapa de Aço.	54
8.2	Melhores Modelos - Refinamento Inicial.	54
8.3	Melhores Modelos - Refinamento Adicional.	55
A.1	Comparação de RMSE entre as Metodologias ARIMA e Alisamento Exponencial.	60

Sumário

Lista de Figuras	7
Lista de Tabelas	9
1 Introdução	14
1.1 Objetivo	16
2 Dados e Características das Séries Temporais	17
2.1 Origem dos Dados	17
2.2 Características das Séries Temporais	18
3 Análise Estatística	19
3.1 Fundamentação Teórica da Metodologia ARIMA	19
3.1.1 Etapas do modelo	21
3.1.2 Estimação do Modelo	24
3.1.3 Método de Máxima Verossimilhança	24
3.1.4 Considerações sobre a Convergência	24
3.1.5 Diagnóstico de Modelos ARIMA	25
3.1.6 Teste de Hipótese para Resíduos	25
3.1.7 Teste de Box-Pierce e Ljung-Box	26
3.1.8 Modificação do Modelo com Base nos Resíduos	27
3.2 Fundamentação teórica do Alisamento Exponencial	28
3.2.1 Fundamentos do Método	28
3.2.2 Extensões do Método	29
3.2.3 Modelo Holt-Winters	30
3.3 Métrica de Erro(RMSE)	31

4	Previsão de Custo do Produto PNEU	32
4.1	Análise Descritiva da Série Histórica	32
4.2	Metodologia	33
4.2.1	Escolha dos Parâmetros	34
4.2.2	Refinamento dos Parâmetros	35
4.3	Resultados	35
5	Previsão de Custo do Produto Embalagem de Polietileno	37
5.1	Análise Descritiva da Série Histórica	38
5.2	Metodologia	39
5.2.1	Escolha dos Parâmetros	40
5.2.2	Refinamento dos Parâmetros	41
5.3	Resultados	41
6	Previsão de Custo do Produto Borracha	43
6.1	Análise Descritiva da Série Histórica	44
6.2	Metodologia	45
6.2.1	Escolha dos Parâmetros	45
6.2.2	Refinamento dos Parâmetros	46
6.3	Resultados	46
7	Previsão de Custo de Energia Elétrica	48
7.1	Análise Descritiva da Série de Dados	49
7.2	Metodologia	49
7.2.1	Escolha dos Parâmetros	50
7.3	Resultados e Discussão	50
8	Previsão de Custo do Produto Chapa de Aço	52
8.1	Análise Descritiva da Série Histórica	53
8.2	Metodologia	54
8.2.1	Escolha dos Parâmetros	54
8.2.2	Refinamento dos Parâmetros	55
8.3	Resultados	55

9	Considerações Finais	57
	Referências Bibliográficas	59
A	Comparação dos Modelos	60

Capítulo 1

Introdução

A análise de séries temporais é um pilar central na Estatística, oferecendo ferramentas essenciais para a compreensão e previsão de fenômenos econômicos, sociais e naturais que se desdobram ao longo do tempo, como citou [Chatfield \(2003\)](#). Em um mundo no qual a quantidade de dados cresce exponencialmente, métodos estatísticos que permitem a extração de padrões, a identificação de tendências e a projeção de futuros cenários são de valor inestimável. Neste contexto, o presente Trabalho de Conclusão de Curso explora a aplicação de dois métodos de previsão de séries temporais: o alisamento exponencial e o modelo ARIMA (Autoregressive Integrated Moving Average), amplamente discutidos por [Hyndman & Athanasopoulos \(2018\)](#).

A necessidade de realizar previsões é de interesse em diversas áreas, desde a meteorologia até o mercado financeiro. Para produtos como Pneus, Chapas de Aço, Borracha, Energia Elétrica e Embalagens de Polietileno, a capacidade de prever sua demanda e preço não é apenas uma questão de lucratividade, mas também de sustentabilidade operacional. No ambiente econômico atual, marcado por rápidas mudanças e incertezas, a previsão acurada de séries temporais é fundamental para a adaptação e o sucesso empresarial.

Os modelos ARIMA são amplamente utilizados para modelar séries temporais estacionárias e não estacionárias, proporcionando uma estrutura flexível que pode ser utilizada em diversas situações. Por outro lado, o alisamento exponencial é particularmente útil para séries que exibem um nível de incerteza mais significativo, reagindo de forma adaptativa às mudanças mais recentes nos dados. A utilização dessas duas metodologias oferece um enfoque poderoso e versátil, trazendo uma boa capacidade de modelar previsões dos produtos analisados nesse trabalho.

Este trabalho se propõe a investigar a aplicabilidade desses modelos para prever 18 meses à frente nas séries temporais de cinco produtos distintos, cada qual com suas características

e dinâmicas próprias. A integração dos modelos de alisamento exponencial e ARIMA tem o potencial de fornecer percepções detalhadas e previsões mais precisas. Serão considerados os aspectos de sazonalidade, tendência e ruído, que são inerentes às séries temporais econômicas, buscando entender não só como esses produtos têm se comportado historicamente, mas também como poderão se comportar no futuro sob diferentes condições de mercado.

Além de sua aplicação prática, este estudo contribui para a literatura acadêmica ao examinar a sinergia entre os modelos ARIMA e de alisamento exponencial. Enquanto o ARIMA se concentra na descrição dos dados através de um processo estocástico, o alisamento exponencial enfatiza a importância de ponderar as observações mais recentes diferentemente, refletindo a crença de que as condições mais atuais têm maior influência sobre o futuro imediato.

A escolha dos cinco produtos para este estudo não é aleatória, cada um representa um setor vital da economia, com diferentes padrões de demanda e oferta. A previsão precisa de sua evolução é crucial para os processos de planejamento e gestão das empresas que operam nesses mercados. Com o avanço tecnológico e o aumento da disponibilidade de dados, as organizações demandam cada vez mais modelos de previsão sofisticados e customizados às suas necessidades.

Dessa forma, esse trabalho está estruturado da seguinte maneira, primeiro apresentamos um pouco sobre os dados e características das séries temporais abordadas, em diante, descrevemos a fundamentação teórica de ambos os modelos citados, e, finalmente, partimos para a parte da previsão, que é o principal interesse do nosso estudo.

1.1 Objetivo

O objetivo deste Trabalho de Conclusão de Curso é a análise de séries temporais econômicas, concentrando-se na previsão de indicadores de mercado para cinco produtos distintos: Pneus, Chapas de Aço, Borracha, Energia Elétrica no Brasil e Embalagens de Polietileno. A pesquisa busca aprimorar as técnicas de modelagem e previsão, visando otimizar a tomada de decisões estratégicas nas áreas comercial e industrial. A finalidade é fornecer estimativas confiáveis para um horizonte de 18 meses, facilitando o planejamento operacional e a alocação eficiente de recursos.

Capítulo 2

Dados e Características das Séries Temporais

2.1 Origem dos Dados

Os dados utilizados neste trabalho foram extraídos de uma plataforma interna da empresa na qual trabalho, chamada Yeb. Esta plataforma consolida informações provenientes do *site* do COMEX Stat, uma ferramenta oficial do Ministério da Economia, Indústria, Comércio Exterior e Serviços do Brasil ([Ministério da Economia \(2022\)](#)). O COMEX Stat é uma base de dados abrangente que fornece estatísticas de comércio exterior do Brasil, e é amplamente utilizada para a análise de indicadores econômicos.

Os dados originais obtidos do COMEX foram processados pela Yeb, a qual aplicou algumas metodologias e cálculos específicos para ajustar e preparar as séries temporais que foram analisadas. Devido à confidencialidade das operações internas da empresa, os detalhes desses cálculos não puderam ser explicitados neste trabalho. No entanto, é importante ressaltar que os procedimentos realizados visam refinar os dados brutos, garantindo maior acurácia nas previsões e nas análises estatísticas subsequentes.

Também é importante destacar que, para a série de Energia Elétrica, por se tratar de uma série que não é especificamente um "produto", os dados são extraídos de uma fonte distinta: o Painel de Preços da CCEE, uma base oficial do governo brasileiro.

2.2 Características das Séries Temporais

As séries temporais analisadas apresentam variações e comportamentos distintos, o que reflete a natureza diversa dos mercados e produtos avaliados. As séries temporais de produtos como Pneus, Chapas de Aço, Borracha, Energia Elétrica no Brasil e Embalagens de Polietileno são sensíveis a diferentes fatores econômicos, sazonais e estruturais.

Em suma, cada uma das séries temporais analisadas possui características únicas que exigem abordagens específicas de modelagem. A consideração de aspectos como tendência, sazonalidade, volatilidade e estacionariedade é essencial para a construção de modelos de previsão robustos e confiáveis, que possam capturar as dinâmicas subjacentes dos dados e oferecer insights valiosos para a tomada de decisões estratégicas.

- **Tendência:** Algumas das séries mostram uma tendência clara ao longo do tempo, que pode ser decorrente de mudanças estruturais no mercado, avanços tecnológicos ou modificações na demanda e oferta. A tendência pode ser linear ou não linear, e é fundamental identificá-la para ajustar corretamente os modelos de previsão;
- **Sazonalidade:** Certas séries temporais podem exibir sazonalidade, que é a repetição regular de padrões ao longo de intervalos específicos, como meses ou trimestres. A presença de sazonalidade requer o uso de modelos que possam capturar essas flutuações periódicas;
- **Volatilidade:** Algumas séries podem apresentar alta volatilidade, o que significa que os valores podem flutuar significativamente em curtos períodos de tempo. A volatilidade pode ser causada por fatores como variações nos preços das matérias-primas, mudanças na política comercial, ou eventos econômicos inesperados;
- **Estacionariedade:** A análise inicial das séries também envolve verificar se as séries são estacionárias, ou seja, se suas propriedades estatísticas, como a média e a variância, permanecem constantes ao longo do tempo. Muitas das séries temporais econômicas necessitam de diferenciação ou transformação para alcançar estacionariedade, um pré-requisito para a aplicação de certos modelos como o ARIMA;
- **Interferências Externas:** Algumas séries podem ser influenciadas por fatores externos, como políticas governamentais, mudanças no câmbio, ou crises econômicas. Essas interferências podem introduzir ruídos ou choques nas séries temporais, tornando o processo de modelagem e previsão mais desafiador. A identificação de tais interferências é crucial para ajustar os modelos corretamente.

Capítulo 3

Análise Estatística

3.1 Fundamentação Teórica da Metodologia ARIMA

A metodologia ARIMA foi proposta, inicialmente, por Box e Jenkins na década de 1970 e se tornou a espinha dorsal da análise de séries temporais, a qual é descrita detalhadamente por [Morettin & Toloï \(2006\)](#). É uma metodologia baseada na premissa de que informações sobre o futuro de uma série temporal estão contidas nos próprios dados passados.

A metodologia permite modelar dados com tendências e sazonalidades, ajustando-se a diversos padrões de séries temporais e é composta por três elementos: termos autorregressivos (AR), integração (I) para alcançar a estacionariedade, e termos de médias móveis (MA), formando assim o modelo ARIMA.

Além disso, esse modelo é parametrizado por três valores principais: p , d , e q . O parâmetro p refere-se ao número de termos autorregressivos usados no modelo, capturando a dependência entre intervalos consecutivos, d indica a ordem de integração necessária para tornar a série estacionária, e q corresponde ao número de termos de médias móveis, que ajudam a modelar o ruído aleatório na série. Essa configuração tridimensional permite ao ARIMA modelar características diversas em séries temporais, adaptando-se tanto a tendências como a ciclos sazonais.

Componente Autorregressivo (AR)

Segundo [Morettin & Toloï \(2006\)](#), este componente modela a correlação entre uma observação e seus valores anteriores, assumindo que valores passados têm influência nos valores futuros. A equação do modelo AR(p) é:

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + \epsilon_t,$$

em que:

- X_t é a série temporal no tempo t ,
- $\phi_1, \phi_2, \dots, \phi_p$ são os coeficientes do modelo,
- ϵ_t é o termo de erro (ruído branco).

Expandindo o conceito autorregressivo para incluir componentes adicionais, a equação do modelo ARIMA, posteriormente, evoluiu para abranger também as médias móveis.

Componente de Médias Móveis (MA)

O componente MA(q) modela o erro da previsão como uma combinação linear dos erros passados:

$$X_t = \mu + \epsilon_t - \theta_1\epsilon_{t-1} - \theta_2\epsilon_{t-2} - \dots - \theta_q\epsilon_{t-q},$$

em que:

- μ é a média da série,
- $\theta_1, \theta_2, \dots, \theta_q$ são os coeficientes para os erros de previsões passadas,
- ϵ_t é o termo de erro (ruído branco).

Componentes Autorregressivo e de Médias Móveis (ARMA)

Posteriormente, [Morettin & Tolo \(2006\)](#) relataram que, em determinadas situações, o ideal seria um modelo que incluísse características tanto do modelo autorregressivo (AR) quanto do de médias móveis (MA), para capturar a dependência de curto prazo nos erros (ruído branco) da série temporal, deduzindo a partir disso o modelo ARMA.

Os modelos ARMA combinam características dos modelos autorregressivos (AR) e de médias móveis (MA) e são populares em diversas áreas, incluindo economia e ciências geofísicas. Esses modelos são particularmente úteis quando se deseja capturar tanto a autocorrelação de uma série temporal quanto os efeitos de choques aleatórios anteriores.

A fórmula para um modelo ARMA(p, q) é dada por:

$$X_t = \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q},$$

em que:

- X_t representa o valor ajustado no tempo t ,
- ϕ_i são os parâmetros do modelo auto-regressivo, $i = 1, \dots, p$,
- θ_j são os parâmetros do modelo de médias móveis, $j = 1, \dots, q$,
- ϵ_t representa o termo de erro no tempo t .

3.1.1 Etapas do modelo

Como detalhado por [Morettin & Toloi \(2006\)](#), a metodologia é composta por um ciclo definido por três etapas principais: identificação, estimação e verificação(diagnóstico).

Identificação do Modelo

Segundo [Morettin & Toloi \(2006\)](#), a identificação pode ser descrita em 3 etapas:

- Verificar se existe necessidade de uma transformação na série original, com o objetivo de estabilizar a variância(estacionariedade). Tal identificação pode ser realizada utilizando o auxílio de gráficos;
- Diferenciar a série quantas vezes for necessário para tornar a série estacionária, de modo que o processo modelado seja reduzido a um ARMA(p, q);
- Identificar as ordens do processo ARMA(p, q) resultante através da análise das autocorrelações e autocorrelações parciais estimadas.

Nesta subseção, abordamos uma das partes mais críticas do método, que é a identificação das ordens da metodologia ARIMA. Essa escolha é realizada, principalmente, com base nas autocorrelações e autocorrelações parciais estimadas, as quais esperamos que representem adequadamente as respectivas quantidades teóricas desconhecidas.

Detalhados também por [Morettin & Toloi \(2006\)](#), a função de autocorrelação (ACF) e a função de autocorrelação parcial (PACF) são descritas matematicamente da seguinte forma:

A função de autocorrelação (ACF), que mede a correlação entre uma série temporal e seus próprios valores defasados, ajudando a identificar padrões repetitivos ao longo do tempo, para um *lag* k é dada por:

$$\rho_k = \frac{\gamma_k}{\gamma_0},$$

para $k = 0, 1, \dots$, em que:

- $\gamma_k = E[(X_t - \mu)(X_{t-k} - \mu)]$ representa a autocovariância entre os pontos X_t e X_{t-k} ;
- γ_0 é a variância da série, que é a autocovariância no *lag* zero ($k = 0$);
- μ é a média da série temporal.

Isto é usado para identificar a força e a duração das relações lineares ao longo dos *lags* da série. Esta medida ajuda a compreender como os valores passados da série influenciam os valores futuros, permitindo modelar adequadamente a dependência temporal.

A função de autocorrelação parcial (PACF), em que o coeficiente ϕ_{kk} ajusta a correlação no *lag* k removendo os efeitos das correlações em todos os lags menores, é definida por:

$$\phi_{kk} = \rho_k - \sum_{j=1}^{k-1} \phi_{k-1,j} \rho_{k-j},$$

em que:

- ϕ_{kk} é o coeficiente de autocorrelação parcial no *lag* k ;
- ρ_k é a autocorrelação no *lag* k ;
- $\phi_{k-1,j}$ são os coeficientes da PACF para lags menores que k .

Na função de autocorrelação parcial (PACF), o coeficiente ϕ_{kk} ajusta a correlação no *lag* k removendo os efeitos das correlações em todos os lags menores. Essa função é importante para determinar o número de termos autorregressivos (p) em um modelo AR(p), porque permite identificar quais defasagens (*lags*) têm influência direta sobre a variável dependente, eliminando os efeitos indiretos das defasagens intermediárias, isolando os efeitos diretos dos *lags* sobre a variável dependente, sem a confusão introduzida pelos *lags* intermediários.

Segundo [Morettin & Tolo \(2006\)](#), no processo de identificação, as autocorrelações e autocorrelações parciais estimadas são fundamentais, pois descrevem como os valores de uma série temporal estão correlacionados com seus valores em atrasos sucessivos, ajudando a determinar a ordem dos termos autorregressivos (AR) e de médias móveis (MA) do modelo. Autocorrelações revelam correlações globais entre *lags* (intervalos de tempo), enquanto autocorrelações parciais isolam a correlação de cada *lag* ajustando os efeitos dos outros *lags*. A análise dessas funções permite modelar a dependência linear na série, essencial para capturar a dinâmica temporal nos dados.

A identificação adequada dos parâmetros da metodologia ARIMA depende crucialmente da análise das autocorrelações (ACF) e autocorrelações parciais (PACF). Estas funções desempenham papéis distintos conforme o componente do modelo:

- **AR (Autorregressivo):** A autocorrelação parcial (PACF) é usada para identificar o número de defasagens (*lags*) no componente AR. Em um modelo puramente $AR(p)$, a PACF exibe defasagens significativas para os primeiros p *lags* e passa a ser zero em *lags* maiores.
- **MA (Médias Móveis):** A autocorrelação (ACF) identifica o número de *lags* no componente MA. Para um modelo puramente $MA(q)$, a ACF mostra defasagens significativas para os primeiros q *lags* e decresce rapidamente em *lags* subsequentes.
- **ARMA (Misto):** Em modelos combinados, a análise conjunta de ACF e PACF ajuda a discernir a interação entre os componentes AR e MA, sendo muitas vezes necessário um ajuste iterativo baseado em ambas as funções para estabelecer os valores de p e q precisos.

Dessa forma, interpretando os ACF e PACF teremos uma noção mais aprimorada sobre o número de parâmetros do modelo. No entanto, não temos apenas essa alternativa para lidar com essa questão.

Segundo [Morettin & Tolo \(2006\)](#), para aprimorar a descrição sobre a identificação das ordens p , d , e q no modelo ARIMA, é importante enfatizar também o processo de seleção baseado na análise de critérios informativos como o Critério de Informação de Akaike (AIC) ou o Critério de Informação Bayesiano (BIC), que tem por objetivo indicar o modelo mais parcimonioso, isto é, com menor número de parâmetros, uma vez que são construídos com base na variância estimada e no tamanho da amostra. A princípio, o modelo que apresentar o menor valor de AIC e BIC será o que melhor se ajustará aos dados.

Os valores para os critérios AIC e BIC são obtidos através das seguintes fórmulas:

$$AIC = \ln \hat{\sigma}_{p,q}^2 + \frac{2(p+q)}{n},$$

$$BIC = \ln \hat{\sigma}_{p,q}^2 + \frac{(p+q) \ln n}{n},$$

em que:

- \ln representa o logaritmo natural;

- $\hat{\sigma}_{p,q}^2$ é a estimativa da variância da metodologia ARMA(p,q);
- p é a ordem do componente autorregressivo da metodologia ARMA;
- q é a ordem do componente de média móvel da metodologia ARMA;
- n é o número de observações.

Esses critérios ajudam a equilibrar a complexidade do modelo contra a sua adequação aos dados, escolhendo o modelo que minimiza a perda de informação.

3.1.2 Estimação do Modelo

Identificando inicialmente um modelo provisório ARIMA (p, d, q) , o próximo passo é a estimação de seus parâmetros. Este processo é geralmente realizado utilizando o método de máxima verossimilhança, adequado para séries que foram diferenciadas d vezes para alcançar a estacionariedade.

3.1.3 Método de Máxima Verossimilhança

Consideramos a função de verossimilhança para a série diferenciada W_t , que é expressa pela seguinte equação:

$$L(W_1, \dots, W_n | \boldsymbol{\theta}) = \prod_{t=1}^n f(W_t | W_{t-1}, \dots, W_1; \boldsymbol{\theta}),$$

em que:

- f representa a densidade condicional de W_t dado os valores passados;
- $\boldsymbol{\theta}$ é o vetor de parâmetros do modelo, incluindo coeficientes AR e MA.

A maximização de L em relação a $\boldsymbol{\theta}$ fornece estimativas que aproximam a série modelada aos dados observados, respeitando a estrutura da metodologia ARIMA especificada.

$$\hat{\boldsymbol{\theta}} = \arg \max_{\boldsymbol{\theta}} L(W_1, \dots, W_n | \boldsymbol{\theta}).$$

3.1.4 Considerações sobre a Convergência

A convergência do processo de estimação é essencial, sendo influenciada pela escolha de valores iniciais adequados e pela robustez do algoritmo de otimização usado. Detalhes adicionais incluem:

- A necessidade de avaliar a sensibilidade das estimativas aos valores iniciais;
- A importância de utilizar métodos de otimização que evitem dependências excessivas desses valores iniciais;
- O exame dos resíduos do modelo ajustado para verificar a adequação do modelo e identificar padrões residuais não capturados.

Estas etapas asseguram que a estimação dos parâmetros seja realizada de maneira eficaz, permitindo o uso da metodologia ARIMA para previsões confiáveis e análises subsequentes.

3.1.5 Diagnóstico de Modelos ARIMA

Após estimar o modelo ARIMA, é crucial verificar se ele representa adequadamente os dados observados. Essa verificação é feita através dos resíduos do modelo, em que verificamos se os resíduos se comportam como ruído branco, indicando que o modelo captura adequadamente a estrutura de dependência dos dados.

3.1.6 Teste de Hipótese para Resíduos

Para avaliar a adequação do modelo ajustado, analisamos os resíduos $\hat{\varepsilon}_t$ através da Função de Autocorrelação (ACF) e da Função de Autocorrelação Parcial (PACF). O objetivo é verificar se os resíduos seguem um comportamento de ruído branco, ou seja, se não apresentam autocorrelação significativa.

As hipóteses testadas são:

- H_0 : O modelo é adequado (os resíduos são ruído branco).
- H_1 : O modelo não é adequado (os resíduos não são ruído branco).

Se H_0 for verdadeiro, então os resíduos $\hat{\varepsilon}_t \sim N(0, \sigma^2)$, sendo independentes e identicamente distribuídos. Assim, suas autocorrelações devem ser aproximadamente nulas, ou seja, $\hat{r}_k \approx 0$. A autocorrelação estimada é dada por:

$$\hat{r}_k = \frac{\sum_{t=k+1}^n \hat{\varepsilon}_t \hat{\varepsilon}_{t-k}}{\sum_{t=1}^n \hat{\varepsilon}_t^2} \quad (3.1)$$

Além disso, sob a hipótese nula, espera-se que:

$$\hat{r}_k \sim N\left(0, \frac{1}{n}\right) \quad (3.2)$$

Para verificar se os resíduos realmente apresentam esse comportamento, aplicamos testes formais de autocorrelação, como os testes de Box-Pierce e Ljung-Box.

3.1.7 Teste de Box-Pierce e Ljung-Box

Os testes de Box-Pierce e Ljung-Box são utilizados para detectar autocorrelação nos resíduos e verificar se podem ser considerados ruído branco. Conforme [Morettin & Tolo \(2006\)](#), a estatística utilizada nesses testes é dada por:

- Box-Pierce:

$$Q(k) = n \sum_{j=1}^k \hat{r}_j^2; \quad (3.3)$$

- Ljung-Box:

$$Q(k) = n(n+2) \sum_{j=1}^k \frac{\hat{r}_j^2}{n-j}, \quad (3.4)$$

nas quais k representa o número de defasagens (lags) consideradas na estatística do teste.

A hipótese nula desses testes assume que os resíduos seguem um comportamento de ruído branco. Se a estatística $Q(k)$ for muito grande, rejeita-se H_0 , indicando a presença de autocorrelação significativa nos resíduos.

A estatística $Q(k)$ segue aproximadamente uma distribuição qui-quadrado χ^2 com $k - p - q$ graus de liberdade, onde p e q representam os parâmetros do modelo ajustado. Para valores elevados de $Q(k)$, rejeita-se a hipótese de ruído branco nos resíduos, sugerindo que o modelo ajustado pode não ser adequado.

É importante ressaltar que, conforme indicado por [Morettin & Tolo \(2006\)](#), há críticas ao uso do teste de Box-Pierce devido à sua tendência de não detectar algumas estruturas presentes nos resíduos. Uma modificação dessa estatística foi proposta por Ljung, resultando no teste de Ljung-Box, que ajusta os graus de liberdade para obter uma estatística mais precisa.

Os testes de autocorrelação residual desempenham um papel fundamental na validação do modelo, garantindo que as previsões baseadas nele sejam confiáveis e que não haja padrões não capturados pelo modelo ajustado.

3.1.8 Modificação do Modelo com Base nos Resíduos

Suponha que os resíduos do modelo ajustado não se comportem como ruído branco. Podemos, então, ajustar o modelo conforme o método descrito no Capítulo 8.3 de [Morettin & Tolo](#) (2006):

- Modelo ajustado: $\phi(B)\Delta^d Z_t = \theta(B)\hat{\varepsilon}_t$
- Novo modelo proposto: $\phi(B)\theta(B)\Delta^d Z_t = \theta(B)\phi(B)\hat{\varepsilon}_t$

Este novo modelo é ajustado para tornar os resíduos comportarem-se como ruído branco. O ciclo de identificação, estimação e verificação deve continuar até que um modelo satisfatório seja encontrado.

A verificação final da metodologia ARIMA é uma etapa crítica para confirmar que o modelo é adequado para as análises subsequentes, garantindo que os resíduos do modelo se comportem como ruído branco, e que o modelo seja capaz de capturar adequadamente a estrutura dos dados.

3.2 Fundamentação teórica do Alisamento Exponencial

Desenvolvido na década de 1950 por Charles C. Holt, o método de Alisamento Exponencial representa um marco na análise de séries temporais. Documentado extensivamente por [Morettin & Toloí \(2006\)](#) e [Hyndman & Athanasopoulos \(2018\)](#), este método se destaca pela sua capacidade de modelar eficientemente as flutuações em séries temporais utilizando uma abordagem que prioriza as informações mais recentes. Esta técnica é usada tanto para a previsão quanto para a suavização de dados, ajustando-se dinamicamente às mudanças observadas sem a necessidade de modelos complexos de previsão. Sua aplicabilidade estende-se desde análises econômicas até o planejamento industrial, demonstrando sua versatilidade e importância no campo da Estatística Aplicada.

3.2.1 Fundamentos do Método

Em primeiro momento, foi proposto o chamado Alisamento Exponencial Simples, que se trata de uma técnica importante em análise de séries temporais que prioriza as observações mais recentes. Este método utiliza um parâmetro de suavização, denotado por λ , que modula a importância relativa entre o valor mais recente observado e a previsão anterior. Esse parâmetro pode variar entre 0 e 1, em que valores mais próximos de 1 dão maior peso às observações anteriores, enquanto valores próximos a 0 enfatizam a observação mais recente.

A formulação do Alisamento Exponencial Simples é dada por:

$$\bar{X}_t = \alpha X_t + (1 - \alpha)\bar{X}_{t-1}, \quad (3.5)$$

em que:

- \bar{X}_{t+1} é a previsão para o próximo período;
- X_t é o valor observado na série temporal no período t ;
- \bar{X}_t é a previsão anterior para o período t (ou o valor inicial para $t = 1$);
- α é o fator de suavização exponencial, um valor entre 0 e 1 que controla a contribuição relativa do valor observado Y_t e da previsão anterior X_t .

Para previsões de k passos à frente, a fórmula é dada por:

$$\hat{X}_t(k) = \bar{X}_t, \quad \forall k > 0,$$

onde $\hat{X}_t(k)$ é a previsão para o período $t + k$ feita no período t .

Além disso, a equação de atualização da previsão pode ser expressa como:

$$\hat{X}_t(k) = \alpha X_t + (1 - \alpha)\hat{X}_{t-1}(k + 1).$$

Para $k = 1$, a equação se reduz a:

$$\hat{X}_t(1) = \alpha e_t + \hat{X}_{t-1}(1),$$

onde $e_t = X_t - \hat{X}_{t-1}(1)$ é o erro de previsão a um passo. Isso indica que a nova previsão pode ser obtida da anterior, adicionando-se um múltiplo do erro de previsão, o que permite que a previsão se ajuste a mudanças no nível da série.

Como já citado, este método é eficaz para séries temporais sem tendências claras ou componentes sazonais, proporcionando uma forma flexível e rápida de responder a mudanças recentes nos dados (Box et al. (2015)).

3.2.2 Extensões do Método

Posteriormente, em 1957, esse método foi aprimorado por Holt, ampliando o Alisamento Exponencial Simples para capturar tanto o nível quanto a tendência das séries temporais. Esta abordagem é essencial para séries com comportamentos tendenciais evidentes. As fórmulas chave são apresentadas a seguir (Hyndman & Athanasopoulos (2018)).

A fórmula para a **tendência** \hat{T}_t é dada por:

$$\hat{T}_t = \beta(\bar{X}_t - \bar{X}_{t-1}) + (1 - \beta)\hat{T}_{t-1}, \quad (3.6)$$

A fórmula para o **nível** \bar{X}_t , ajustado, incorpora tanto a observação atual quanto a tendência estimada:

$$\bar{X}_t = \alpha X_t + (1 - \alpha)(\bar{X}_{t-1} + \hat{T}_{t-1}), \quad (3.7)$$

em que:

- \hat{T}_t é a taxa de crescimento estimada no tempo t ;
- β é o fator de suavização para a tendência, em que $0 \leq \beta \leq 1$;

- X_t é o nível estimado no tempo t ;
- X_{t-1} é o nível estimado no tempo $t - 1$;
- \hat{T}_{t-1} é a taxa de crescimento estimada no tempo $t - 1$.

Estas extensões do método de Holt permitem uma modelagem mais precisa de séries temporais que exibem tendências claras, facilitando ajustes adaptativos tanto nos níveis quanto nas tendências ao longo do tempo. Este método é particularmente útil em aplicações de previsão onde ajustes rápidos aos dados são cruciais para a tomada de decisão eficiente. No entanto, a sazonalidade, componente fundamental quando tratamos de previsão estatística, ainda foi implementada em nenhum dos métodos apresentados até então.

3.2.3 Modelo Holt-Winters

Por fim, em 1960, Peter Winters em conjunto com Holt, expandiram o método para incorporar sazonalidade, resultando no modelo Holt-Winters. Este modelo leva em consideração tanto tendência quanto sazonalidade, adaptando o método de Holt para incluir um componente sazonal de forma que:

$$\hat{S}_t = \gamma \cdot (X_t - \bar{X}) + (1 - \gamma)\hat{S}_{t-s}, \quad (3.8)$$

em que:

- \hat{S}_t é o componente de sazonalidade no tempo t ;
- γ é o fator de suavização para a sazonalidade, onde $0 \leq \gamma \leq 1$;
- s é o comprimento do ciclo sazonal.

Esta extensão permite uma adaptação mais flexível às variações sazonais da série temporal, melhorando significativamente a precisão das previsões em dados que exibem padrões sazonais claros e consistentes. A inclusão do componente de sazonalidade, junto ao ajuste de tendências, facilita a modelagem de séries complexas, adaptando-se dinamicamente às mudanças ao longo do tempo.

3.3 Métrica de Erro(RMSE)

O Raiz do Erro Quadrático Médio (RMSE, do inglês *Root Mean Square Error*) é uma medida amplamente utilizada para avaliar a precisão de previsões em modelos de séries temporais. Ele quantifica a diferença entre os valores observados e os valores previstos, fornecendo uma ideia da magnitude do erro de previsão. O RMSE é particularmente útil porque penaliza erros maiores de forma mais significativa, devido ao uso do quadrado dos erros. Dessa forma, foi a métrica escolhida nesse trabalho para tomada de decisão em relação a escolha dos parâmetros e comparação dos modelos.

O RMSE é calculado como a raiz quadrada da média dos erros quadráticos. Matematicamente, para uma série de previsões \hat{X}_t e valores observados X_t , o RMSE é definido por:

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (X_t - \hat{X}_t)^2},$$

em que:

- N é o número de observações;
- X_t é o valor observado no período t ;
- \hat{X}_t é o valor previsto para o período t .

O RMSE fornece uma medida do desvio médio entre os valores observados e os valores previstos. Quanto menor o valor do RMSE, mais próximas estão as previsões dos valores reais, indicando um modelo mais preciso. Por outro lado, um RMSE alto sugere que o modelo pode não estar capturando adequadamente a dinâmica da série temporal.

Capítulo 4

Previsão de Custo do Produto PNEU

Neste capítulo, apresentamos a análise e previsão do custo do produto PNEU, utilizando o método de alisamento exponencial. O objetivo principal é estimar os preços futuros com base nos dados históricos, avaliando diferentes combinações de parâmetros para identificar o modelo mais adequado e confiável.

Inicialmente, abordamos também a modelagem pela metodologia ARIMA (AutoRegressive Integrated Moving Average), no entanto, os resultados indicaram que a metodologia do Alisamento Exponencial teve um melhor desempenho, como evidenciado na Apêndice A. Sendo assim, a partir de então, iremos considerar apenas a metodologia do Alisamento Exponencial para ajustar as previsões dos produtos deste trabalho.

A flexibilidade do método em ajustar os pesos das observações passadas, controlados pelos parâmetros α (nível) e β (tendência), foi determinante para alcançar um desempenho superior. Posteriormente, caso tenhamos a presença de sazonalidade nas séries, mais um parâmetro será introduzido no modelo, o γ (sazonalidade), como detalhado na subseção 3.2.3.

Neste capítulo, detalhamos o processo de análise da série histórica, a escolha dos melhores parâmetros do modelo, e apresentamos os resultados da previsão dos próximos 18 meses, ressaltando a aplicabilidade e os benefícios do método escolhido.

4.1 Análise Descritiva da Série Histórica

A análise descritiva da série histórica é essencial para compreender o comportamento dos preços ao longo do tempo.

A Figura 4.1 apresenta a evolução do preço do produto PNEU de janeiro de 2017 a julho de 2024, destacando as tendências e flutuações nos custos ao longo do período.

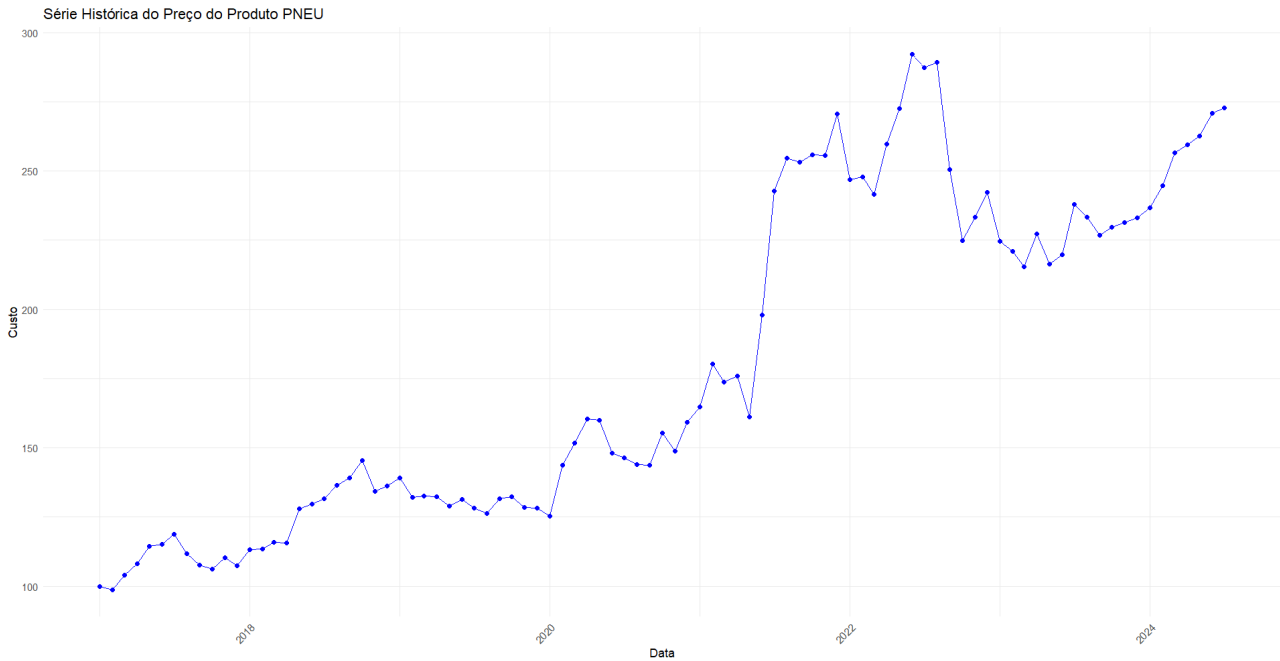


Figura 4.1: Série Histórica do Custo do Produto Pneu

Pela Figura 4.1 observa-se uma tendência geral de aumento nos custos. Até 2021, os preços apresentaram variações relativamente modestas, com leves aumentos seguidos de pequenas quedas.

O período de 2021 a 2022 mostra flutuações mais relevantes, com grandes aumentos mensais, possivelmente associadas a fatores externos, como os impactos da pandemia do COVID-19 na cadeia de suprimentos. Finalmente, em 2023 e 2024, os valores se mantêm em um patamar mais elevado.

Essas características reforçam a importância de utilizar modelos eficientes para previsão, considerando a presença de tendências e flutuações que podem impactar os preços futuros do produto. Nesse caso, para o produto PNEU, observamos uma clara tendência de alta durante o decorrer da série, que deverá ser capturado pelo nosso modelo de previsão.

4.2 Metodologia

Antes de começarmos a aplicarmos nosso modelo de previsão do alisamento exponencial, é necessário decidir se optaremos pelo que inclui o parâmetro de sazonalidade, detalhado na Equação 3.2.3, ou se escolheremos o modelo que não inclui, detalhado na Equação 3.2.2.

Para auxiliar nessa decisão, utilizamos o teste de Friedman, um método não paramétrico desenvolvido por Friedman (1937), que avalia diferenças entre medições repetidas em grupos. Este teste é particularmente útil para verificar a presença de sazonalidade em séries temporais.

Os resultados do teste de Friedman para a série de preços do produto PNEU, apresentados na Tabela 4.1, indicam um valor de $p = 0.3498$, superior ao nível de significância $\alpha = 10\%$. Dessa forma, não rejeitamos a hipótese nula de ausência de sazonalidade, o que justifica o ajuste de um modelo sem o componente sazonal para a previsão dessa série.

Tabela 4.1: Resultados do Teste de Friedman para a Série de Preços do Produto PNEU.

Estatística Qui-quadrado	Graus de Liberdade	p-valor	Conclusão
12.187	11	0.3498	Não Rejeitar H_0

Com base no resultado do teste, optou-se por aplicar o modelo de Holt-Winters sem o componente sazonal, focando nos parâmetros α e β . O parâmetro α controla a suavização dos níveis da série, refletindo como as mudanças recentes influenciam a estimativa atual. Já o parâmetro β ajusta a suavização da tendência, garantindo maior flexibilidade na captura de mudanças no padrão de crescimento, como já explicado anteriormente.

4.2.1 Escolha dos Parâmetros

Para garantir a avaliação adequada do desempenho do modelo de previsão, os dados históricos foram divididos em conjuntos de treino e teste. Foram utilizados os últimos 18 meses como conjunto de teste, enquanto o restante dos dados foi destinado ao treino do modelo.

A separação dos dados em treino e teste tem como objetivo avaliar a capacidade preditiva do modelo. O conjunto de treino é utilizado para ajustar os parâmetros do modelo, enquanto o conjunto de teste permite verificar a precisão das previsões em dados não utilizados durante o ajuste, através do erro quadrático médio. Esta abordagem torna a análise mais eficiente e alinhada às melhores práticas em modelagem preditiva.

Para selecionar os melhores parâmetros, foi realizada uma busca refinada considerando todas as combinações possíveis entre α e β , variando de 0.1 a 1.0, com incrementos de 0.1. Os modelos foram avaliados com base no RMSE (Root Mean Square Error), resultando nos dois melhores modelos apresentados na Tabela 4.2.

Tabela 4.2: Melhores Modelos Selecionados com Base no RMSE.

Alpha (α)	Beta (β)	RMSE
0.6	1.0	0.051
0.6	0.9	0.062

4.2.2 Refinamento dos Parâmetros

Com base nos dois melhores modelos, foi realizado um refinamento dos valores de α e β , adicionando uma casa decimal à análise, com objetivo de aprimorar ainda mais a nossa busca pelos parâmetros ideais. Sendo realizado novamente uma busca pelos melhores parâmetros, mas, dessa vez, apenas com o intervalo estabelecido entre os parâmetros dos dois melhores modelos da busca anterior.

Nesse caso, pela tabela 4.2, como o α foi o mesmo nos dois melhores modelos, fixamos em 0.6 e variamos apenas o β entre 0.90 e 1.00, com incrementos de 0.01. Dessa forma, após realizar todos cálculos referentes as novas combinações de α e β aos RMSE (Root Mean Square Error), o modelo final selecionado utilizou os parâmetros apresentados na Tabela 4.3.

Tabela 4.3: Modelo Final Selecionado Após Refinamento.

Alpha (α)	Beta (β)	RMSE
0.6	0.97	0.050

4.3 Resultados

Com os parâmetros selecionados, o modelo foi aplicado à série histórica completa para realizar a previsão dos próximos 18 meses (agosto de 2024 a janeiro de 2026).

A Figura 4.2 apresenta a previsão do custo do produto PNEU para o período futuro. O gráfico diferencia os dados históricos observados (linha azul) e os valores previstos (linha tracejada vermelha).




Figura 4.2: Previsão de 18 Meses para o Produto Pneu

Como esperado, a partir da Figura 4.2, observa-se uma tendência de crescimento nos custos projetados, o que está alinhado com os padrões históricos da série, que também indicam períodos de aumento constante.

Notavelmente, a curva de previsão apresenta uma inclinação ascendente uniforme, o que reflete a natureza suave e progressiva do modelo de Holt-Winters. Esse padrão é esperado, já que os parâmetros $\alpha = 0.6$ e $\beta = 0.97$ foram ajustados para capturar as variações de nível e tendência da série, enfatizando com maior ponderação as observações dos últimos meses observados.

Pela previsão, espera-se que o preço de custo do produto aumente mais de 20% nos próximos 18 meses, o que pode ser útil para decisões estratégicas relacionadas ao planejamento de estoque, precificação e análise de mercado, já que temos um valor esperado de crescimento bem significativo.

Capítulo 5

Previsão de Custo do Produto Embalagem de Polietileno

Neste capítulo, apresentamos a análise e previsão do custo do produto Embalagem de Polietileno, utilizando o método de alisamento exponencial. O objetivo principal continua sendo estimar os preços futuros com base nos dados históricos, avaliando diferentes combinações de parâmetros para identificar o modelo mais adequado e confiável.

Inicialmente, é necessário destacar que as embalagens de polietileno são produtos que estão em um movimento de mercado um pouco complicado para seus vendedores, que envolve fatores como regulamentações ambientais, inovações tecnológicas e tendências de consumo.

O crescente apelo por soluções sustentáveis e o impacto de movimentos ambientalistas têm influenciado significativamente a demanda por este tipo de produto. A busca por alternativas biodegradáveis e recicláveis, aliada à pressão regulatória para a redução de plásticos descartáveis, reforça a necessidade de uma abordagem eficiente para prever custos e monitorar variações no mercado.

Portanto, é importante destacar que, neste estudo, estamos considerando apenas fatores matemáticos em questão, não estamos vinculando nenhuma premissa externa de tendência de mercado para o cálculo das previsões. Dessa forma, caso seja usado para algum tipo de tomada de decisão em ramos empresariais, deve ser analisado, além da própria previsão, as premissas de movimento de mercado desse produto específico, que como já falado, tem suas peculiaridades.

5.1 Análise Descritiva da Série Histórica

A análise descritiva da série histórica é essencial para compreender o comportamento dos preços ao longo do tempo. A Figura 5.1 apresenta a evolução do preço do produto Embalagem de Polietileno de janeiro de 2017 a setembro de 2024, destacando as tendências e flutuações nos custos ao longo do período.




Figura 5.1: Série Histórica do Custo do Produto Embalagem de Polietileno

Pela Figura 5.1, observa-se que, a partir de 2020, houve um movimento de alta bastante intenso nos preços, associado principalmente ao aumento da demanda por embalagens plásticas durante a pandemia de COVID-19. Esse crescimento reflete o impacto das medidas emergenciais adotadas globalmente, como o aumento do consumo de equipamentos de proteção individual (EPIs), como máscaras e luvas descartáveis, e a intensificação das compras online, que ampliaram significativamente o uso de embalagens plásticas.

Além disso, esse aumento nos preços também foi influenciado pela alta do petróleo no período da pandemia de COVID-19, que atingiu valores próximos a 120 dólares por barril. O petróleo é uma das principais matérias-primas utilizadas na produção de plásticos, e sua valorização durante esse período impactou diretamente os custos de produção de embalagens de polietileno. Essa combinação de fatores levou a um aumento expressivo nos preços observados até o ano de 2022.

No entanto, após meados de 2022, especificamente em junho, os preços começaram a apresentar uma tendência de queda, puxando o mercado novamente para um patamar mais baixo. Essa

mudança pode ser atribuída ao arrefecimento da demanda provocada pelo fim das restrições mais severas da pandemia, pela normalização do preço do Petróleo, e pelas regulamentações voltadas para a redução do consumo de plásticos convencionais.

Esses movimentos no mercado de embalagens plásticas evidenciam tanto os desafios quanto as oportunidades para a adoção de soluções mais sustentáveis, como o uso de materiais biodegradáveis e recicláveis. A conscientização ambiental tem desempenhado um papel crucial nesse cenário, incentivando práticas de consumo responsável.

Além disso, a partir dos fatores macroeconômicos citados acima, é importante ressaltar que, para esse produto, além de termos um olhar estatístico, que veremos no decorrer deste capítulo, é necessário acompanhar as premissas que o mercado proporciona, pois, a partir delas, teremos uma boa ideia de como o preço de custo do produto deve reagir nos próximos meses.

No entanto, como o objetivo desse trabalho é ajustar previsões estatísticas, daremos continuidade, sem adotar outras medidas que insiram conceitos macroeconômicos nas análises.

5.2 Metodologia

A metodologia adotada baseia-se no modelo de alisamento exponencial de Holt-Winters, ajustado com diferentes combinações de parâmetros α (alpha) e β (beta). O mesmo procedimento que foi utilizado para o produto Pneu, conforme mostrado em 4.1.

Antes de ajustar o modelo, foi realizado o teste de sazonalidade de Friedman para avaliar a presença de efeitos sazonais significativos na série histórica. Como já comentado em 4.2, o teste de Friedman é um método não paramétrico utilizado para verificar diferenças em medições repetidas em grupos. Ele avalia se há variações sistemáticas entre períodos, indicando a presença de sazonalidade.

No caso do produto Pneu, por ser uma série histórica que não aparentou ter movimentos sazonais presentes, era esperado que o teste de Friedman não apontasse para a presença de sazonalidade significativa, que, depois, foi confirmado pelo resultado do teste. Sendo assim, para as Embalagens de Polietileno, foi realizado o teste também, para confirmar se as flutuações sazonais realmente não são relevantes.

Caso sejam relevantes, iríamos considerar outro parâmetro no nosso modelo de previsão, especificamente o γ (gamma), que controla a suavização do componente sazonal no modelo de alisamento exponencial, como detalhado em 3.2.3. Esse parâmetro é utilizado para ajustar variações sazonais sistemáticas ao longo do tempo, permitindo que o modelo capture ciclos

repetitivos presentes na série histórica. Assim, ao incorporar o γ , é possível prever oscilações sazonais de forma mais precisa, garantindo maior aderência às características da série.

No entanto, os resultados do teste de Friedman para a série de preços da Embalagem de Polietileno, apresentados na Tabela 5.1, indicam um valor de $p = 0.622$, acima do nível de significância $\alpha = 10\%$. Dessa forma, não rejeitamos a hipótese nula de ausência de sazonalidade, o que nos levou a ajustar um modelo sem o componente sazonal.

Tabela 5.1: Resultados do Teste de Friedman para a Série de Preços da Embalagem de Polietileno.

Estatística Qui-quadrado	Graus de Liberdade	p-valor
8.999	11	0.622

Com base no resultado do teste, o modelo de Holt-Winters foi ajustado para capturar as tendências de nível e tendência da série histórica, desconsiderando qualquer componente sazonal. O parâmetro α controla a suavização dos níveis da série, determinando quão rápido as mudanças recentes impactam na estimativa do nível atual. Já o parâmetro β ajusta a suavização da tendência.

Ambos passaram pelo mesmo processo de refinamento de parâmetros para minimizar o RMSE (Root Mean Square Error) do modelo e, assim, espera-se tornar a nossa previsão mais assertiva, mesmo processo de refinamento realizado nos capítulos anteriores.

5.2.1 Escolha dos Parâmetros

Como já explicado em 4.2.1, os dados foram divididos em treino e teste, de modo que os respectivos erros quadráticos médios fossem calculados com diferentes parâmetros, para que, dessa forma, a busca pelos melhores parâmetros fosse eficiente.

Para selecionar os melhores parâmetros do modelo de alisamento exponencial, foi realizada uma busca considerando todas as combinações possíveis entre α e β , variando de 0.1 a 1.0, com incrementos de 0.1. Os modelos foram avaliados com base no RMSE (Root Mean Square Error), e os dois melhores modelos foram selecionados, conforme apresentado na Tabela 5.2.

Tabela 5.2: Melhores Modelos Selecionados com Base no RMSE.

Alpha (α)	Beta (β)	RMSE
0.8	1.0	0.0918
0.9	0.9	0.0944

5.2.2 Refinamento dos Parâmetros

Com base nos dois melhores modelos selecionados, foi realizado um refinamento dos valores de α e β , adicionando uma casa decimal à análise. Nessa etapa, foram testadas combinações mais precisas de valores, considerando todos os valores contidos no intervalo de $\alpha = 0.80$ e $\alpha = 0.90$ e $\beta = 0,90$ e $\beta = 1.00$, conforme apresentado na Tabela 5.3.

Tabela 5.3: Modelos Refinados Selecionados com Base no RMSE.

Alpha (α)	Beta (β)	RMSE
0.80	1.00	0.0918
0.80	0.99	0.0918
0.81	0.99	0.0919
0.82	0.98	0.0920
0.84	0.96	0.0923

O modelo final selecionado utilizou os parâmetros $\alpha = 0.80$ e $\beta = 1.00$, que apresentou o menor RMSE (Root Mean Square Error) no refinamento. Esse modelo foi aplicado à série histórica completa para a previsão de custos futuros.

5.3 Resultados

Com os parâmetros selecionados, o modelo foi aplicado à série histórica completa para realizar a previsão dos próximos 18 meses (outubro de 2024 a março de 2026).

A Figura 5.2 apresenta a previsão do custo do produto Embalagem de Polietileno para o período futuro. O gráfico diferencia os dados históricos observados (linha azul) e os valores previstos (linha tracejada vermelha).




Figura 5.2: Previsão de 18 Meses para o Produto Embalagem de Polietileno

Como observado na Figura 5.2, a previsão reflete uma tendência de leve redução nos custos projetados ao longo do período analisado. Essa redução está alinhada aos padrões históricos mais recentes da série, que demonstram uma queda acentuada a partir de meados de 2022, possivelmente associada à desaceleração da demanda após os picos gerados pela pandemia de COVID-19.

Durante a pandemia, a necessidade de materiais plásticos, como embalagens, máscaras e luvas, resultou em um aumento significativo da demanda e, conseqüentemente, dos preços. No entanto, com o avanço da recuperação econômica global e a implementação de regulamentações mais rígidas em relação ao uso de plásticos, o mercado de polietileno retornou a uma trajetória de queda moderada, refletindo um movimento de ajuste e maior preocupação com práticas sustentáveis.

Por fim, essa previsão de leve queda para os próximos 18 meses pode ser relevante para estratégias empresariais, como planejamento de estoques, definição de preços e análise de mercado.

Capítulo 6

Previsão de Custo do Produto

Borracha

Neste capítulo, abordamos a análise e previsão do custo do produto Borracha Natural, um material amplamente utilizado em indústrias como a automobilística, calçadista e de infraestrutura. O objetivo principal é identificar padrões históricos e tendências de preços, utilizando modelos estatísticos para projeção futura e suporte à tomada de decisão.

A Borracha, com suas propriedades únicas como resistência à tração, amortecimento de vibrações e alta durabilidade, é essencial para uma ampla gama de aplicações industriais. A demanda por borracha é impulsionada principalmente pela indústria automotiva, que utiliza esse material para fabricar pneus, mangueiras e peças diversas. Além disso, o crescimento econômico em países como China, Índia e Brasil tem contribuído significativamente para o aumento da procura pelo produto.

Os maiores produtores mundiais de borracha incluem Tailândia, Malásia e Indonésia, enquanto a China se destaca como o principal consumidor, devido ao seu papel dominante no setor de manufatura e à dependência de importações.

É de grande importância entender os principais países ofertantes, pois a partir da oferta e demanda traçamos premissas sobre como o mercado deve se comportar nos próximos meses. Dessa forma, além da previsão estatística que apresentamos nesse capítulo, é possível realizar ajustes com base nessas ideias de acordo com o comportamento do mercado.

6.1 Análise Descritiva da Série Histórica

A análise descritiva da série histórica é fundamental para identificar padrões e tendências nos preços do produto Borracha. A Figura 6.2 apresenta a evolução do custo da borracha ao longo dos últimos anos, destacando períodos de alta e baixa, bem como possíveis impactos de eventos externos, como a pandemia de COVID-19.




Figura 6.1: Série Histórica do Custo do Produto Borracha.

A Figura 6.2 ilustra que, a partir do período de 2020, os preços da borracha experimentaram um aumento significativo, atribuído à crescente demanda por equipamentos de proteção individual (EPIs), como luvas e máscaras, durante a pandemia de COVID-19.

Essa demanda também foi intensificada pelo crescimento do setor automotivo em países emergentes, bem como pelo aumento no preço do petróleo, que impactou diretamente os custos de produção e transporte.

No entanto, após o pico observado durante o período de crise, os preços tiveram uma queda, refletindo a recuperação gradual do mercado e os ajustes na oferta e demanda globais.

Essa análise inicial fornece uma base para a aplicação de modelos de previsão, visando oferecer projeções para o custo da borracha nos próximos períodos.

6.2 Metodologia

Antes do ajuste, foi realizado o teste de Friedman para verificar a presença de sazonalidade na série histórica. Como indicado pelos resultados apresentados na Tabela 6.1, o p-valor ($p = 0.4942$) está acima do nível de significância de 10%, indicando que não há evidência suficiente para rejeitar a hipótese nula de ausência de sazonalidade. Dessa forma, optou-se por ajustar o modelo sem o componente sazonal.

Tabela 6.1: Resultados do Teste de Friedman para a Série de Preços da Borracha.

Estatística Qui-quadrado	Graus de Liberdade	p-valor	Conclusão
10.407	11	0.4942	Não Rejeitar H_0

Dessa forma, a metodologia adotada para o produto Borracha baseia-se no modelo de alinhamento exponencial de Holt-Winters. Este modelo foi ajustado considerando diferentes combinações dos parâmetros α (alpha) e β (beta), responsáveis, respectivamente, pela suavização dos níveis da série e pela suavização da tendência. O objetivo é minimizar o RMSE (Root Mean Square Error) e obter uma previsão baseada nos dados históricos.

6.2.1 Escolha dos Parâmetros

Como já explicado em 4.2.1, os dados foram divididos em treino e teste, de modo que os respectivos erros quadráticos médios fossem calculados com diferentes parâmetros, para que, dessa forma, a busca pelos melhores parâmetros fosse eficiente.

Para selecionar os melhores valores para α e β , foi realizada uma busca inicial, considerando combinações possíveis em um intervalo de valores entre 0.1 e 1.0, com incrementos de 0.1. Os resultados foram avaliados com base no RMSE (Root Mean Square Error), conforme apresentado na Tabela 6.2.

Tabela 6.2: Melhores Modelos Selecionados com Base no RMSE.

α	β	RMSE
0.8	1.0	0.0962
0.9	0.9	0.0975

Os dois melhores modelos identificados nesta etapa apresentaram valores de α e β que melhor capturam as variações de nível e tendência na série histórica, reduzindo significativamente o RMSE (Root Mean Square Error).

6.2.2 Refinamento dos Parâmetros

Com base nos melhores modelos da etapa anterior, foi realizado um refinamento dos valores de α e β , adicionando uma casa decimal à análise. Essa etapa permitiu uma avaliação mais detalhada das combinações dos parâmetros, conforme os resultados apresentados na Tabela 6.3.

Tabela 6.3: Resultados Refinados com os Melhores Parâmetros.

α	β	RMSE
0.82	1.0	0.0953
0.83	0.99	0.0954
0.84	0.97	0.0959
0.85	0.96	0.0962

Com o refinamento, o melhor modelo foi identificado com $\alpha = 0.82$ e $\beta = 1.0$, apresentando o menor RMSE (0.0953). Este modelo foi selecionado para a previsão final, esperando maior assertividade na análise a partir disso.

6.3 Resultados

Com os parâmetros selecionados, o modelo foi aplicado à série histórica completa para realizar a previsão dos próximos 18 meses (setembro de 2024 a março de 2026).

A Figura 6.2 apresenta a previsão do custo do produto Borracha para o período futuro. O gráfico diferencia os dados históricos observados (linha azul) e os valores previstos (linha tracejada vermelha).




Figura 6.2: Previsão de 18 Meses para o Produto Borracha.

A partir da Figura 6.2, observa-se uma tendência de crescimento nos custos projetados, com uma inclinação constante ao longo do período de previsão. Este padrão reflete a continuidade dos movimentos históricos mais recentes, que indicam variações crescentes no custo da borracha.

Notavelmente, a curva de previsão demonstra alinhamento com os dados históricos, reforçando a adequação do modelo Holt-Winters. Os parâmetros $\alpha = 0.82$ e $\beta = 1.00$ foram ajustados para capturar as tendências predominantes, minimizando possíveis desvios bruscos e garantindo maior confiabilidade nas estimativas.

Por fim, pela previsão, temos um aumento de aproximadamente 13% no custo, um valor bem aceitável devido ao comportamento recente do produto em questão.

Capítulo 7

Previsão de Custo de Energia Elétrica

Neste capítulo, apresentamos a análise e previsão do custo de energia elétrica no Brasil, utilizando o modelo de alisamento exponencial de Holt-Winters com a inclusão do parâmetro γ . Essa abordagem foi necessária devido à sazonalidade identificada na série histórica, como indicado pelos resultados do teste de Friedman. O objetivo principal é estimar os custos futuros com base nos dados históricos, fornecendo subsídios para estratégias de planejamento no setor energético.

O primeiro ponto a ser destacado nesse mercado é o fator das estações durante o ano, que determinam momentos de maiores e menores consumos. No verão, por exemplo, o consumo energético aumenta significativamente, principalmente devido ao aumento do uso de ar condicionado pela população no geral. Isso tende a desequilibrar a oferta e demanda e, conseqüentemente, arrastar o preço para cima. No entanto, sabemos que o mercado não é tão simplista assim, temos outros fatores envolvidos, que devem ser levados em conta em uma análise detalhista.

O setor de energia elétrica no Brasil está ligado ao regime de chuvas que abastecem as hidrelétricas, responsáveis por grande parte da geração de energia. Períodos de seca, como os observados em anos críticos, resultam em menor oferta de energia e aumento das tarifas devido à aplicação das bandeiras tarifárias. Adicionalmente, o cenário energético global e os preços do petróleo também exercem influência nos custos da energia elétrica, tornando essencial a análise de tendências e a aplicação de modelos robustos para previsões.

Dessa forma, além da previsão realizada pela metodologia em questão, é de grande importância que seja feito o acompanhamento desses outros setores para que se obtenha a melhor tomada de decisão em relação ao controle de gastos com energia elétrica durante o período previsto.

7.1 Análise Descritiva da Série de Dados

A análise descritiva da série histórica de preços da energia elétrica destaca a variabilidade característica desse mercado, refletindo eventos como períodos de seca e oscilações no preço do petróleo. A Figura 7.1 apresenta a evolução dos preços entre 2017 e 2024, evidenciando picos relacionados a crises hídricas e períodos de menor oferta energética.




Figura 7.1: Série Histórica do Custo da Energia Elétrica no Brasil

Observando a Figura 7.1, é notável que, até o ano de 2022, temos um movimento sazonal dos preços, com flutuações para cima e para baixo de forma bem evidente e sequencial.

No entanto, a partir de 2022, esse movimento não ocorreu com a mesma intensidade, os preços se demonstraram mais estáveis no período, talvez explicado por medidas governamentais ou outros movimento macroeconômicos ocorridos.

Por fim, é importante ressaltar que, nos últimos 3 meses observados, é visível um movimento crescente nos custos, nos levando a imaginar que o movimento sazonal ocorrido até 2022 pode voltar a ocorrer, com novos picos de preço, seguidos por novos decréscimos, conforme o movimento sazonal já observado no início da série.

7.2 Metodologia

A metodologia empregada baseia-se no modelo de Holt-Winters, escolhido devido à sua capacidade de capturar padrões de sazonalidade, nível e tendência. O teste de Friedman foi

aplicado previamente para confirmar a presença de sazonalidade na série histórica, com resultados apresentados na Tabela 7.1, que apontaram para a rejeição da hipótese nula de ausência de sazonalidade ($p = 0.01322$).

Tabela 7.1: Resultados do Teste de Friedman para a Série de Preços de Energia Elétrica.

Estatística Qui-quadrado	Graus de Liberdade	p-valor
23.886	11	0.01322

Com base nesses resultados, o parâmetro γ foi incluído no ajuste do modelo, sendo responsável por capturar as flutuações sazonais da série.

7.2.1 Escolha dos Parâmetros

Para ajustar o modelo de Holt-Winters, foram realizadas buscas nos intervalos de 0.1 a 1.0 para os parâmetros α , β e γ , com incrementos de 0.1. Os resultados obtidos estão apresentados na Tabela 7.2.

Tabela 7.2: Melhores Combinações de Parâmetros para o Modelo de Energia Elétrica.

Alpha	Beta	Gamma	RMSE
0.9	0.5	0.8	0.00065
0.1	0.9	0.6	0.00169
0.7	0.6	0.2	0.00201

Dado que o modelo inclui o parâmetro γ , que introduz uma terceira dimensão no espaço de busca, o refinamento detalhado dos parâmetros foi desconsiderado. Testar todas as combinações possíveis de α , β e γ com uma casa decimal a mais resultaria em uma quantidade extremamente alta de cálculos, tornando o processo computacionalmente inviável dentro do escopo deste trabalho. Portanto, utilizamos as melhores combinações identificadas na busca inicial, priorizando a didática e o foco nos conceitos aplicados.

7.3 Resultados e Discussão

Com os parâmetros selecionados através do modelo de Holt-Winters ($\alpha = 0.9$, $\beta = 0.5$ e $\gamma=0,8$) definidos na Tabela 7.2, foi possível aplicar o método à série histórica completa para realizar a previsão dos próximos 18 meses (outubro de 2024 a março de 2026).

O modelo incluiu a sazonalidade, capturada pelo parâmetro γ , devido ao comportamento sazonal detectado previamente pelo teste de Friedman.

A Figura 7.2 apresenta a previsão do custo de energia elétrica no Brasil para os próximos 18 meses. A linha azul corresponde aos dados históricos observados, enquanto a linha tracejada vermelha representa os valores projetados.




Figura 7.2: Previsão de 18 Meses para a Energia Elétrica no Brasil.

De acordo com a Figura 7.2, observa-se um comportamento sazonal bem definido na série histórica e nas projeções futuras. A previsão sugere flutuações significativas nos custos ao longo do período, com picos previstos no meio e no final do horizonte de previsão. Este padrão está alinhado com os fatores climáticos que afetam a matriz energética brasileira, como variações nos períodos de seca e chuvas, impactando a oferta de energia das hidrelétricas.

Além disso, o modelo projeta um aumento geral no custo ao longo do período de previsão, o que pode ser explicado pela crescente demanda energética e pelas incertezas relacionadas ao preço do petróleo, que afeta a geração térmica.

Capítulo 8

Previsão de Custo do Produto Chapa de Aço

As chapas de aço, como produto fundamental para diversas cadeias produtivas, possuem uma forte ligação com o comportamento macroeconômico global. O mercado desse material é altamente influenciado por fatores econômicos, como a dinâmica da oferta e demanda, as oscilações de preços de commodities e o impacto de eventos globais, como crises financeiras e pandemias.

Nos últimos anos, o mercado global do aço enfrentou desafios intensos. A pandemia de COVID-19, por exemplo, trouxe um cenário de incertezas, com interrupções significativas nas cadeias de suprimento, aumento nos custos de transporte e dificuldades logísticas em nível mundial. Essas condições não só dificultaram a produção como também limitaram a oferta em muitos mercados, ao mesmo tempo em que a demanda se manteve aquecida em setores como construção civil, infraestrutura e bens de consumo duráveis.

Outro fator relevante foi a recuperação econômica em algumas regiões após os períodos mais críticos da pandemia, impulsionada por pacotes de estímulos governamentais. Esse movimento gerou uma demanda acelerada por aço e seus derivados, pressionando ainda mais os preços. Além disso, a desvalorização cambial em mercados emergentes, como o Brasil, e os altos preços do minério de ferro e carvão — insumos essenciais para a produção de aço — aumentaram ainda mais os custos de produção e comercialização.

O comportamento do preço das chapas de aço também reflete as características do mercado de commodities. Em períodos de alta incerteza, é comum observar movimentos de volatilidade, com ajustes bruscos nos preços à medida que a oferta e a demanda tentam se equilibrar. Além disso, fatores como políticas ambientais e mudanças nos padrões de consumo global vêm

exercendo uma influência crescente sobre o setor, direcionando investimentos para tecnologias mais sustentáveis e novas estratégias de produção.

Por fim, o mercado de chapas de aço responde rapidamente a flutuações em setores estratégicos, como construção, energia e transporte, além de ser sensível a fatores como tensões geopolíticas e políticas comerciais. A análise desse cenário exige um acompanhamento constante de variáveis econômicas e setoriais, especialmente em momentos de transformações significativas na economia mundial.

8.1 Análise Descritiva da Série Histórica




Figura 8.1: Série Histórica do Custo do Produto Chapas de Aço

A série histórica do produto Chapa de Aço, ilustrada pela Figura 8.1, analisada de janeiro de 2017 a julho de 2024, apresenta um comportamento predominantemente crescente. Esse crescimento é influenciado tanto por fatores externos, como a regulação do mercado internacional,

quanto internos, como a retomada do consumo no Brasil, como já citado na seção anterior.

É notável que, dos fatores que impactaram o preço do aço nos últimos anos, talvez o mais relevante tenha sido a pandemia do COVID-19, já que, é bem claro o aumento de preço durante o período pós início da pandemia, que teve sua parte mais intensa no meio de 2020. Isso ressalta a complexidade desse mercado, que se mostra um grande espelho das tendências macroeconômicas globais.

8.2 Metodologia

A metodologia aplicada consistiu em avaliar a série histórica para identificar padrões e realizar previsões futuras.

Primeiramente, foi realizado o teste de Friedman, que foi utilizado para verificar a presença de sazonalidade na série.

Tabela 8.1: Resultado do Teste de Friedman para Chapa de Aço.

Estatística Qui-quadrado	GL	p-valor
12.099	11	0.3563

Como indicado pelos resultados apresentados na Tabela 8.1, o p-valor ($p = 0.3563$) está acima do nível de significância de 10%, indicando que não há evidência suficiente para rejeitar a hipótese nula de ausência de sazonalidade. Dessa forma, optou-se por ajustar o modelo sem o componente sazonal.

8.2.1 Escolha dos Parâmetros

Para ajustar o modelo de previsão, foram testadas diversas combinações dos parâmetros α e β utilizando o método de Holt-Winters sem sazonalidade ($\gamma = 0$). A Tabela 8.2 apresenta os dois melhores modelos obtidos na etapa inicial de busca por parâmetros.

Tabela 8.2: Melhores Modelos - Refinamento Inicial.

Alpha	Beta	RMSE
0.4	0.2	0.0384
0.3	0.3	0.0405

8.2.2 Refinamento dos Parâmetros

Os dois melhores modelos da etapa inicial foram refinados com incrementos menores nos parâmetros α e β , de 0.01. A Tabela 8.3 apresenta os cinco melhores modelos após o refinamento.

Tabela 8.3: Melhores Modelos - Refinamento Adicional.

Alpha	Beta	RMSE
0.37	0.20	0.0336
0.38	0.20	0.0339
0.37	0.21	0.0341
0.36	0.21	0.0344
0.36	0.22	0.0346

Dessa forma, com base nos resultados da Tabela 8.3, adotamos o melhor modelo sendo o com os parâmetros $\alpha = 0.37$ e $\beta = 0.20$, pois estes tiveram o melhor desempenho segundo o RMSE (Root Mean Square Error). A partir desses parâmetros, iremos ajustar o nosso modelo de previsão.

8.3 Resultados

Com base nos melhores parâmetros obtidos pelo processo de refinamento ($\alpha = 0.37$ e $\beta = 0.20$), foi ajustado o modelo final de alisamento exponencial. A previsão dos próximos 18 meses para o preço do produto "Chapas de Aço" é apresentada na Figura 8.2.




Figura 8.2: Previsão de 18 Meses para o Produto Chapas de Aço.

O gráfico mostra uma tendência de crescimento gradual no custo, em linha com o comportamento observado nos últimos anos. Esse crescimento é condizente com a realidade, pois olhando para o cenário macroeconômico atual, temos alguns fatores que podem explicar essa alta nos próximos meses.

O primeiro deles é a taxação do aço importado, que engloba principalmente o de origem chinesa (hoje, o maior país exportador do produto no mundo), medida adotada pelo governo brasileiro, que reduz a competitividade interna e permite uma maior margem para as siderúrgicas nacionais, fato que, mesmo que ajude as siderúrgicas locais, puxa o preço do produto para cima.

Além disso, temos também o aumento da demanda da construção civil no Brasil, impulsionada tanto por iniciativas públicas, como o programa "Minha Casa, Minha Vida", quanto por projetos privados. Devem também aumentar a procura pelo produto e, conseqüentemente, aumentar o preço nos próximos meses.

Os valores previstos, somados às unidades observadas, reforçam a continuidade da tendência de alta no mercado. Mesmo que de forma moderada, em torno de 7% durante os 18 meses, a análise aponta um aquecimento consistente no setor, destacando a importância de um planejamento estratégico eficaz para lidar com as variações nos custos e demandas futuras.

Capítulo 9

Considerações Finais

Este trabalho de conclusão de curso teve como objetivo principal a análise e modelagem de séries temporais de diferentes produtos, visando a obtenção de previsões de preços para um horizonte futuro. Para isso, duas metodologias principais foram testadas: o modelo ARIMA e o modelo de Alisamento Exponencial de Holt-Winters. A comparação entre essas metodologias permitiu identificar aquela que melhor se ajustava às características específicas de cada série, garantindo previsões mais acuradas e adequadas ao comportamento histórico dos preços.

Ao longo da análise, foi possível constatar que a metodologia do Alisamento Exponencial apresentou melhor desempenho em relação ao modelo ARIMA para as séries temporais estudadas. Esse resultado se deve, em grande parte, ao fato de o Alisamento Exponencial ponderar com maior peso as observações mais recentes, tornando-se uma abordagem mais sensível às mudanças de tendência e oscilações recentes do mercado. Além disso, as previsões obtidas por meio do Alisamento Exponencial apresentaram um menor erro quadrático médio (RMSE) em comparação com as previsões geradas pelo modelo ARIMA, reforçando a superioridade desta metodologia para os dados analisados.

Sendo assim, a metodologia adotada neste trabalho seguiu um fluxo bem definido para cada série histórica: primeiramente, foi realizado o teste de Friedman, a fim de identificar a presença de sazonalidade nos dados. A partir desse diagnóstico, decidiu-se qual variante do modelo de Holt seria aplicada — seja o modelo simples, com apenas os parâmetros α e β , ou o modelo sazonal, que inclui o parâmetro γ . Essa abordagem garantiu que cada série fosse tratada de forma individualizada, levando em consideração suas particularidades e garantindo que a modelagem utilizada fosse a mais adequada possível para cada conjunto de dados.

Ao analisar os resultados específicos de cada série, algumas particularidades puderam ser observadas. A série de preços da energia elétrica foi a que mais evidenciou um padrão sazonal

marcante, o que já era esperado, dado que o setor elétrico no Brasil é fortemente influenciado pela sazonalidade climática. O volume de chuvas impacta diretamente a oferta de energia proveniente das hidrelétricas, refletindo-se nos preços ao longo do tempo. Dessa forma, o modelo sazonal de Holt demonstrou ser o mais adequado para essa série, proporcionando previsões mais realistas e alinhadas ao comportamento histórico do setor.

Outro destaque foi a série de preços da embalagem de polietileno, que apresentou um comportamento distinto em relação às demais. Essa foi a única série em que foi observada uma tendência de queda nos preços, refletindo um ajuste no mercado após um período de forte crescimento entre os anos de 2021 e 2023. Esse comportamento de queda pode ser atribuído à estabilização da demanda e à normalização da cadeia de suprimentos, após o período de escassez de materiais e alta inflação global enfrentados nos últimos anos. Esse tipo de variação destaca a importância de se utilizar metodologias flexíveis, como o Alisamento Exponencial, que conseguem capturar e se adaptar a diferentes dinâmicas de mercado.

Por fim, um aspecto relevante a ser considerado para trabalhos futuros diz respeito à escalabilidade da metodologia desenvolvida. A ideia inicial deste trabalho foi desenvolver uma abordagem que pudesse ser aplicada a um grande número de produtos, utilizando um código escalável que permitisse a replicação da estratégia para diferentes séries temporais de forma automatizada. No futuro, pretende-se implementar essa metodologia no ambiente de trabalho, onde são analisados mais de 2500 produtos diferentes. O grande objetivo foi aprimorar ainda mais a assertividade das previsões, garantindo uma análise mais robusta e precisa para a tomada de decisão empresarial.

Dessa forma, este estudo contribui para o entendimento e a aplicação prática de técnicas avançadas de previsão de séries temporais, oferecendo um modelo metodológico sólido que pode ser replicado e aprimorado para diferentes setores e contextos econômicos. Os resultados obtidos reforçam a importância de metodologias que consigam capturar a dinâmica do mercado de forma eficiente, permitindo previsões mais precisas e confiáveis para a gestão estratégica de preços e estoques.

Referências Bibliográficas

- Box, G.E.P., Jenkins, G.M., & Reinsel, G.C. (2015). *Time Series Analysis: Forecasting and Control*. 5th ed. Wiley.
- Chatfield, C. (2003). *The Analysis of Time Series: An Introduction*. 6th ed. CRC Press.
- Dickey, D.A., & Fuller, W.A. (1979). Distribution of the Estimators for Autoregressive Time Series with a Unit Root. *Journal of the American Statistical Association*, 74(366), 427-431.
- Friedman, M. (1937). The Use of Ranks to Avoid the Assumption of Normality Implicit in the Analysis of Variance. *Journal of the American Statistical Association*, 32(200), 675-701.
- Gardner, E.S. (1985). Exponential smoothing: The state of the art. *Journal of Forecasting*, 4(1), 1-28.
- Hamilton, J.D. (1994). *Time Series Analysis*. Princeton University Press.
- Hyndman, R.J., & Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts: Melbourne, Australia. Disponível em: <https://otexts.com/fpp3/>.
- Hyndman, R.J., & Khandakar, Y. (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3), 1-22. Disponível em: <https://www.jstatsoft.org/article/view/v027i03>.
- Ministério da Economia, Indústria, Comércio Exterior e Serviços (Brasil). *Comex Stat - Sistema de Estatísticas de Comércio Exterior*. Disponível em: <http://comexstat.mdic.gov.br/>.
- Morettin, P. A., & Toloi, C. M. C. (2006). *Análise de Séries Temporais*. São Paulo: Blucher.
- R Core Team. (2022). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria. Disponível em: <https://www.R-project.org/>.

Apêndice A

Comparação dos Modelos

Neste anexo, apresentamos a análise comparativa entre o modelo de **alisamento exponencial** e o modelo **ARIMA** para a previsão dos custos do produto PNEU.

A Tabela [A.1](#) apresenta uma comparação das métricas de RMSE (Root Mean Square Error) dos dois melhores modelos analisados, um de cada metodologia.

Tabela A.1: Comparação de RMSE entre as Metodologias ARIMA e Alisamento Exponencial.

Metodologia	RMSE
ARIMA	10.3772
Alisamento Exponencial	0.0502

Comparando as métricas, podemos perceber que temos um bom indicativo para optar por continuar com a metodologia do **alisamento exponencial** para realizar as previsões em questão. A diferença entre uma métrica e outra foi significativa, de **10.3772** para **0.0502**, mesmo sendo algo que não consiga garantir fielmente que uma previsão será melhor do que a outra, é um bom indicador. Dessa forma, já temos evidências de que a metodologia ARIMA se ajustou com menos eficiência do que o Alisamento Exponencial, para entender melhor esse movimento, iremos observar os gráficos de previsão tratados pelas figuras [A.1](#) e [A.2](#).

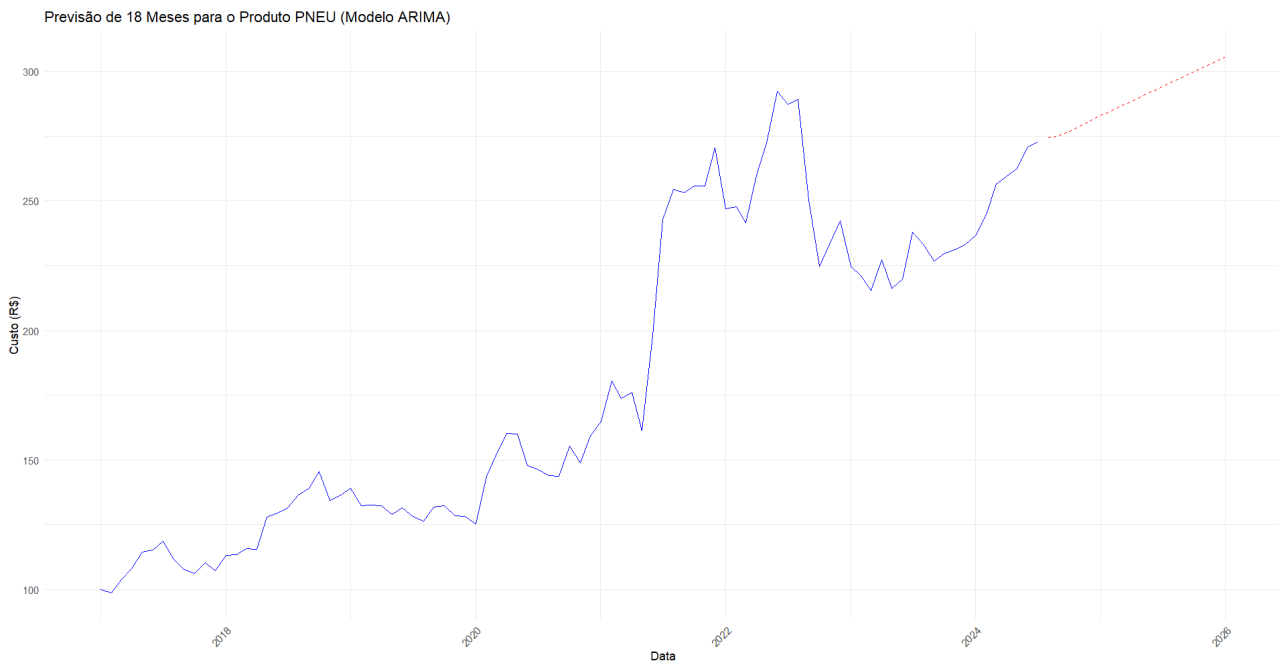


Figura A.1: Previsão do Custo de Pneu (Metodologia ARIMA)




Figura A.2: Previsão do Custo de Pneu (Metodologia Alisamento Exponencial)

A Figura A.1 ilustra a previsão do modelo ARIMA, na qual a linha de previsão inicia-se com um aumento constante e moderado ao passar do tempo. Tal comportamento é inconsistente com o comportamento do mercado, especialmente considerando a tendência de crescimento observada anteriormente.

Em contraste, o modelo de alisamento exponencial (Figura A.2) produz uma previsão que se ajusta aos últimos pontos da série histórica, capturando de forma mais realista as expectativas

futuras para o custo do produto PNEU.

Assim, a escolha do Alisamento Exponencial reflete uma priorização da **coerência com as tendências históricas**, fundamentais para análises de mercado, e por ser um modelo com a maior capacidade de ponderar com mais força as últimas observações, nos dando a possibilidade de um controle melhor sobre o nosso modelo de previsão.