



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

Análise de previsão da exportação de soja: Uma avaliação comparativa entre os modelos ARIMA e Holt-Winters

Bianca Chemure dos Anjos

Departamento de Engenharia de Produção – Universidade Estadual do Paraná/Campus Paranaguá

Heloisa Serafim Kuakoski

Departamento de Engenharia de Produção – Universidade Estadual do Paraná/Campus Paranaguá

Leonardo Iankoski

Departamento de Engenharia de Produção – Universidade Estadual do Paraná/Campus Paranaguá

Camila Matos

Departamento de Engenharia de Produção – Universidade Estadual do Paraná/Campus Paranaguá

Fernando Henrique Lermen

Departamento de Engenharia de Produção – Universidade Estadual do Paraná/Campus Paranaguá
Departamento de Ingeniería Industrial – Universidad Tecnológica de Perú

Resumo: Este estudo se concentra na aplicação de métodos de previsão de demanda para a exportação de soja nos Portos do Paraná. Utilizando as ferramentas disponíveis no *software RStudio*[®], adotamos os modelos ARIMA e Holt-Winters para previsões e comparações. O principal objetivo deste estudo é avaliar a eficácia desses modelos na previsão da exportação de soja, considerando os desafios impostos por fatores externos como a pandemia global e questões políticas. Ao aplicar os modelos ARIMA e Holt-Winters, buscamos entender as tendências subjacentes e fornecer insights significativos para a tomada de decisões informadas. Os resultados indicam que, embora os modelos tenham oferecido previsões, a especificidade das previsões não atingiu os níveis desejados devido à complexidade do cenário. No entanto, a compreensão das limitações desses modelos nos permitiu reconhecer a influência de fatores externos e o contexto em constante mudança. Através dessa análise, destacamos a importância de considerar as abordagens de previsão dentro do contexto global, levando em conta a volatilidade inerente ao mercado e aos eventos atuais. Como próxima etapa de pesquisa, sugerimos explorar técnicas avançadas de modelagem que possam capturar com mais precisão os efeitos dos fatores externos imprevisíveis. Este estudo oferece uma base sólida para entender a exportação de soja nos Portos do Paraná e ressalta a necessidade de adaptação constante e aprimoramento das técnicas de previsão em resposta às mudanças em um cenário complexo e dinâmico.

Palavras-chave: Previsão de demanda, Exportação de soja, ARIMA, Holt-Winters.

Soybean export forecast analysis: A comparative assessment between the ARIMA and Holt-Winters Models

Abstract: This study applies demand forecasting methods for soybean exports in the Ports of Paraná. Using the tools available in *RStudio*[®] software, we adopted the ARIMA and Holt-Winters models for predictions and comparisons. This study's main objective is to evaluate these models'

effectiveness in forecasting soybean exports, considering the challenges imposed by external factors such as the global pandemic and political issues. By applying the ARIMA and Holt-Winters models, we seek to understand underlying trends and provide meaningful insights for making informed decisions. The results indicate that although the models offered predictions, the specificity of the predictions did not reach the desired levels due to the complexity of the scenario. However, understanding the limitations of these models has allowed us to recognize the influence of external factors and the constantly changing context. Through this analysis, we highlight the importance of considering forecasting approaches within the global context, considering the market's inherent volatility and current events. As a next step in research, we suggest exploring advanced modeling techniques that can more accurately capture the effects of unpredictable external factors. This study offers a solid basis for understanding soybean exports in the Ports of Paraná. It highlights the need for constant adaptation and improvement of forecasting techniques in response to changes in a complex and dynamic scenario.

Keywords: Forecasting, Soybean Exports, ARIMA, Holt-Winters.

1. Introdução

Ao longo das últimas décadas, a soja estabeleceu-se como a mercadoria de exportação mais significativa e proeminente do Brasil. Apenas em 2008, a safra de soja em grão alcançou a marca de 60 milhões de toneladas. Dentro de todo o contexto do complexo de produtos relacionados à soja - incluindo grãos, farelo e óleo - um total de 39 milhões de toneladas foi exportado nesse mesmo ano. Essa quantidade equivale a 26% de todas as exportações do setor agropecuário. Em termos isolados, a soja em grão sozinha representou 62% do volume exportado, contribuindo com mais de 24 milhões de toneladas. Isso significa que 41% da produção nacional de soja em grão foi vendida nos mercados internacionais (Conab, 2009).

De acordo com Brum et al. (2005), a soja desempenhou um papel central na introdução do conceito de agronegócio no país. Isso ocorreu não apenas devido ao seu impacto em termos de volume físico e financeiro, mas também à demanda por uma abordagem empresarial na gestão da atividade, envolvendo produtores, fornecedores de insumos, processadores de matéria-prima e negociantes. Nesse cenário, o mercado da soja desempenha um papel crucial, ao ocupar uma posição proeminente no contexto global, visto que o Brasil é atualmente o segundo maior produtor dessa commodity no mundo, atrás apenas dos Estados Unidos e à frente da Argentina, China e Índia, a influência se estende para elementos que conectam desde a produção até a logística em território nacional (Fao, 2010; Becerra, 2007; IICA, 2007).

Devido a essa particularidade, uma variedade de técnicas de previsão é disponibilizada para auxiliar os tomadores de decisão entre os envolvidos. Isso tem como objetivo gerenciar os riscos de mercado, principalmente as flutuações nos preços que impactam a dinâmica e a eficácia do mercado da soja (Abitante, 2008; Bressan, 2004). Dentro desse contexto, a presente análise visa fazer uma perspectiva sobre a Previsão da Exportação de Soja nos Portos do Paraná, com um foco específico na cidade de Paranaguá. As séries de dados com os valores mensais de exportação de soja foram obtidas no site portosdoparana.com.

Reconhecendo a natureza dinâmica desse mercado, exploraremos as potencialidades de duas abordagens de previsão amplamente utilizadas: os modelos ARIMA (*AutoRegressive Integrated Moving Average*) e Holt-Winters. O objetivo central é avaliar a eficácia desses métodos para fornecer insights valiosos sobre as tendências da exportação de soja e, ao entendermos a limitação e o alcance dessas abordagens, estaremos melhor preparados para tomar decisões informadas e aplicar análises sólidas no cenário em constante mudança.

O artigo está estruturado da seguinte forma: a seção 2 discutirá os modelos utilizados, sendo eles o ARIMA e Holt-winters, a seção 3 apresentará o procedimento metodológico;

a seção 4 mostrará os resultados obtidos, sua interpretação, discussão e, por fim, a seção 5 apresentará as conclusões.

2. Referencial teórico

2.1. Métodos qualitativos e quantitativos

As previsões realizadas por meio de métodos qualitativos são fundamentadas em perspectivas individuais. Em outras palavras, esses métodos se apoiam nos julgamentos e opiniões de pessoas a respeito de tendências futuras, preferências e evoluções tecnológicas (Schwitzk, 2001). Dessa forma, esses métodos levam em conta as observações ou visões de pessoas com experiência em diversos setores de atividade, como gestores, vendedores, clientes e fornecedores.

De acordo com Armstrong e Collopy (1998), os métodos qualitativos se mostram vantajosos devido ao fato de que especialistas frequentemente possuem informações sobre eventos recentes cujos efeitos ainda não se refletem em séries temporais ou sobre eventos ocorridos no passado, mas que são esperados no futuro. Apesar da natureza subjetiva desse método e de seu caráter informal, ele tem sido empregado em situações específicas.

Conforme observado por Armstrong e Collopy (1998), os métodos quantitativos ou estatísticos apresentam uma tendência menor para viés e fazem um uso mais eficiente dos dados históricos. Ademais, essas abordagens são caracterizadas pela confiabilidade, uma vez que, ao utilizar os mesmos dados, geram previsões consistentes. Seguindo a análise desses autores, os processos estatísticos exibem uma certa miopia, pois se limitam a representar apenas os dados a que estão diretamente associados.

Uma série temporal ou histórica é uma sequência de dados coletados em intervalos regulares ao longo de um período específico. Na análise de uma série temporal, é fundamental modelar o fenômeno em questão. Isso permite descrever o comportamento da série, realizar estimativas e, por fim, avaliar os fatores que afetam seu comportamento, com o objetivo de identificar relações de causa e efeito.

Conforme mencionado por Montgomery (2008), as etapas envolvidas no processo de previsão são as seguintes: a) Identificação do problema; b) Aquisição de dados; c) Análise dos dados; d) Escolha e ajuste do modelo; e) Validação do modelo; f) Implementação da previsão; e, g) Avaliação contínua do desempenho.

2.2. ARIMA

Conforme destacado por DeLurgio (1998), nenhum outro modelo de previsão univariada recebeu tanta atenção quanto a construção dos modelos ARIMA. A popularização desse modelo ocorreu na década de 1970, por meio do trabalho de George Box e Gwilym Jenkins, cujos nomes frequentemente são usados de forma intercambiável na aplicação geral dos modelos ARIMA (conhecidos como Box-Jenkins) para análise de séries temporais e realização de previsões. Esse processo visa identificar os padrões de autocorrelação presentes nos valores da série temporal (Ballou, 2006).


O objetivo da análise ARIMA é identificar um modelo que captura de maneira precisa os padrões presentes tanto no passado quanto no futuro das séries temporais. Os modelos ARIMA são denotados como $ARIMA(p, d, q)$, onde:

- (p) refere-se à quantidade de termos de autocorrelação;
- (d) refere-se ao número de diferenciações; e
- (q) indica o número de termos de média móvel.

Segundo Zhang (2003), a abordagem de Box-Jenkins envolve três processos iterativos: identificação do modelo, estimativa dos parâmetros e verificação diagnóstica. Durante a identificação, os dados são transformados para tornar a série temporal estacionária. A

especificação do modelo é seguida pela estimação direta dos parâmetros, visando minimizar a medida geral dos erros. O último passo é a verificação diagnóstica para avaliar a adequação do modelo. Essas fases são geralmente repetidas até que um modelo satisfatório seja escolhido para realizar previsões. O procedimento completo é ilustrado na Figura 1.

Figura 1 – Modelo para realização de previsões



Fonte: Zhang (2003)

2.3. Holt-Winters

O modelo Holt-Winters, também conhecido como suavização exponencial triplo, é uma técnica de previsão que combina a consideração de tendência, sazonalidade e níveis de suavização. Esse modelo é especialmente útil quando os dados apresentam padrões de variação ao longo do tempo devido a fatores sazonais (Martins e Laugeni, 2009).

Existem duas abordagens principais no modelo Holt-Winters: multiplicativa e aditiva. Na abordagem multiplicativa, a sazonalidade é multiplicada pelo valor atual da série, enquanto na abordagem aditiva, a sazonalidade é adicionada ao valor atual da série. A principal diferença entre elas reside na forma como os índices sazonais são tratados e na natureza da sazonalidade.

O modelo Holt-Winters é caracterizado por três componentes principais: nível, tendência e sazonalidade. Cada componente é atualizado usando coeficientes de suavização (α , β e γ) que determinam a influência relativa dos valores passados e atuais. Esses coeficientes de suavização são ajustados para otimizar a precisão da previsão.

3. Procedimento metodológico

A metodologia adotada neste estudo é de cunho quantitativo, visando a análise e previsão da exportação de soja nos Portos do Paraná. Para alcançar esse objetivo, os dados foram obtidos a partir do site oficial portosdoparana.com.br, que disponibiliza informações relevantes sobre as operações portuárias na região. Especificamente, foram coletados os dados mensais de exportação de soja no período compreendido entre 2017 e 2022, totalizando 72 meses de informações.

Após a coleta, os dados brutos foram submetidos a um processo de tratamento e organização no software *Microsoft Excel*[®]. Nessa etapa, foram realizadas atividades como a correção de possíveis discrepâncias, tratamento de valores faltantes e outras manipulações necessárias para garantir a integridade dos dados. A planilha resultante foi preparada para análise posterior.

Em seguida, os dados tratados foram importados para o ambiente do software RStudio[®], uma plataforma amplamente reconhecida para análise estatística e processamento de dados. Utilizando o RStudio[®], foram aplicados os códigos e algoritmos correspondentes aos métodos de previsão escolhidos: ARIMA (*AutoRegressive Integrated Moving Average*) e Holt-Winters.

Para a aplicação do método ARIMA, foram identificados os parâmetros do modelo de acordo com os padrões de autocorrelação e sazonalidade presentes nos dados. Quanto ao método Holt-Winters, os coeficientes de suavização foram ajustados, levando em consideração os elementos de tendência e sazonalidade.

A execução dos modelos ARIMA e Holt-Winters gerou projeções para a exportação de soja nos Portos do Paraná. Essas previsões foram então comparadas com os valores reais disponíveis, permitindo uma avaliação da acurácia e desempenho dos modelos. O conjunto de procedimentos metodológicos adotados proporcionou insights relevantes sobre os padrões de exportação de soja na região, bem como uma análise informada das tendências futuras com base em dados históricos.

4. Resultados e discussão

A Tabela 1 mostra a série de dados da exportação de soja em toneladas pelo Portos do Paraná entre os anos de 2017 e 2022.

Tabela 1 – Dados utilizados

Mês/Ano	Quantidade (t)	Mês/Ano	Quantidade (t)	Mês/Ano	Quantidade (t)
jan/17	432.380	jan/19	575.570	jan/21	30.000
fev/17	1.452.907	fev/19	1.092.517	fev/21	494.899
mar/17	1.399.967	mar/19	1.178.618	mar/21	2.284.133
abr/17	1.355.493	abr/19	1.134.219	abr/21	2.090.110
mai/17	859.197	mai/19	616.284	mai/21	1.983.809
jun/17	1.168.391	jun/19	1.151.205	jun/21	810.388
jul/17	1.085.063	jul/19	981.582	jul/21	1.736.218
ago/17	1.125.206	ago/19	984.766	ago/21	861.702
set/17	637.866	set/19	640.603	set/21	911.243
out/17	788.511	out/19	1.187.391	out/21	495.510
nov/17	626.042	nov/19	918.618	nov/21	851.992
dez/17	451.261	dez/19	779.329	dez/21	650.191
jan/18	361.637	jan/20	320.182	jan/22	714.847
fev/18	988.619	fev/20	1.077.196	fev/22	1.095.865
mar/18	1.669.721	mar/20	2.159.898	mar/22	1.492.811
abr/18	2.129.348	abr/20	2.246.744	abr/22	808.001
mai/18	1.335.025	mai/20	2.114.806	mai/22	817.163
jun/18	1.414.880	jun/20	1.324.739	jun/22	984.878
jul/18	1.261.833	jul/20	1.419.228	jul/22	1.386.000
ago/18	1.499.826	ago/20	1.411.707	ago/22	852.768
set/18	1.467.362	set/20	1.170.714	set/22	459.640
out/18	1.067.006	out/20	824.414	out/22	664.524
nov/18	1.286.388	nov/20	918.618	nov/22	327.161
dez/18	893.974	dez/20	779.329	dez/22	371.482

Fonte: Portos do Paraná.

Com base nos dados coletados, foram empregados os códigos apropriados para efetuar as análises e realizar uma comparação detalhada entre os dois métodos selecionados. A análise começou com a implementação do modelo ARIMA, como ilustrado na Figura 2 abaixo.




Figura 2 – Comparação dos resultados ARIMA (1,0,0) e ARIMA (0,0,3)

Após a análise gráfica dos resultados obtidos por meio da aplicação do modelo ARIMA, foi possível comparar os dois modelos mais adequados. O primeiro modelo, ARIMA (1,0,0), apresentou uma média superior de 1.049.494,5 toneladas e uma média inferior de 102.992,3 toneladas, representadas pela linha azul. Isso significa que, considerando a variabilidade das previsões, a exportação de soja nos Portos do Paraná pode variar dentro dessa faixa de tonelagem. Por sua vez, o segundo modelo, ARIMA (0,0,3), resultou em uma média superior de 1.055.780,82 toneladas e uma média inferior de 82.528,09 toneladas, indicadas pela linha vermelha. Essas estimativas fornecem insights importantes para os tomadores de decisão, permitindo considerar diferentes cenários possíveis para a exportação de soja, levando em conta as flutuações previstas e ressaltam a variabilidade nas previsões entre os dois modelos, permitindo uma melhor compreensão das possíveis faixas de valores previstos.

Na continuação da análise das previsões do modelo ARIMA, observamos os gráficos apresentados na Figura 3, que incluem o diagrama de correlação, a verificação dos resíduos e a conferência na realização do teste de normalidade.

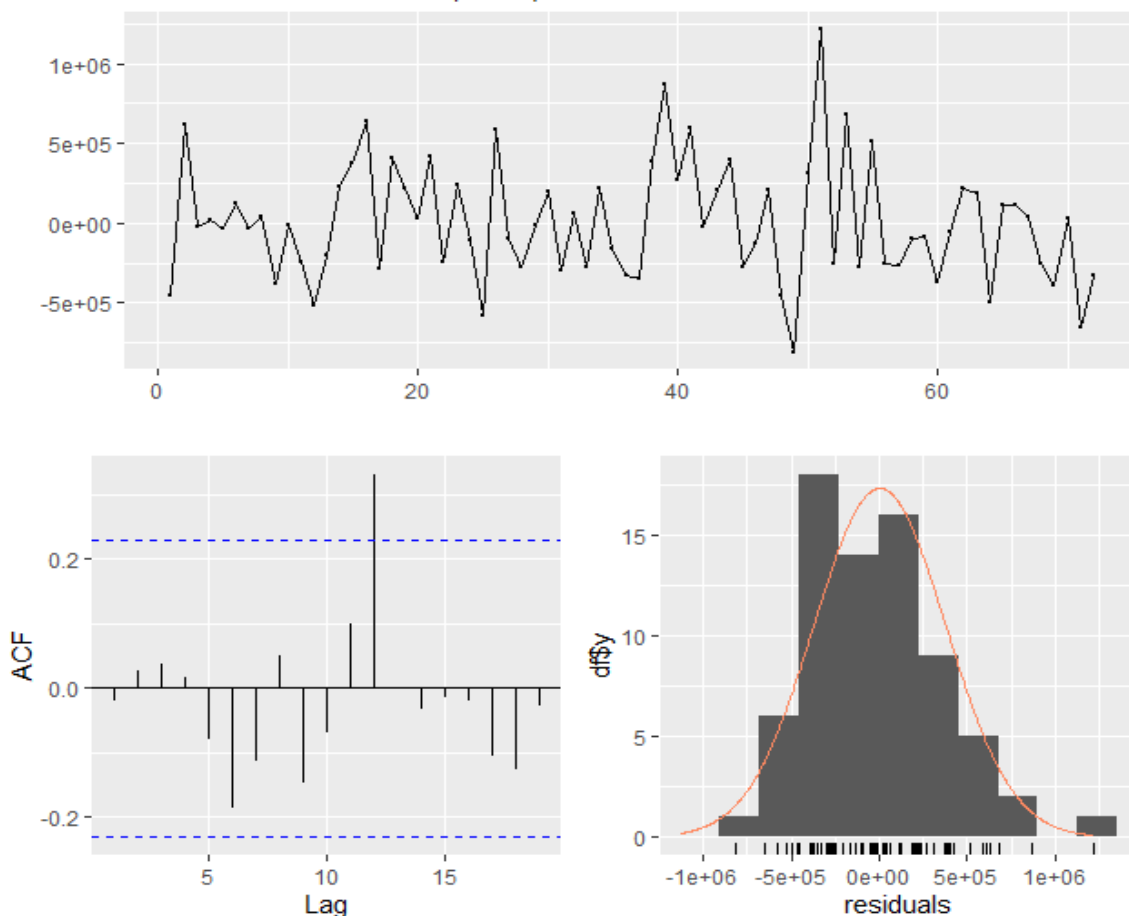


Figura 3 – Resultados teste Ljung-Box

Os resultados do teste Ljung-Box, realizado com base nos resíduos do modelo ARIMA(0,0,3) com média não nula, indicam um valor de p-value igual a 0.4225. Esse valor de p-value é usado para avaliar se os resíduos do modelo são independentes, ou seja, se não há autocorrelação remanescente nos resíduos. No contexto do teste Ljung-Box, um p-value maior que um determinado nível de significância (geralmente 0.05) sugere que os resíduos podem ser considerados como ruído branco, ou seja, não há autocorrelação significativa nos resíduos. Portanto, um p-value de 0.4225 sugere que os resíduos do modelo ARIMA(0,0,3) parecem ser independentes e não exibem autocorrelação significativa. Isso é uma indicação favorável para a qualidade do ajuste do modelo.

O teste de normalidade Shapiro-Wilk realizado nos resíduos do modelo resultou em um p-value de 0.1978. Esse teste é usado para verificar se os resíduos do modelo ARIMA seguem uma distribuição normal. Um p-value maior que o nível de significância (geralmente 0.05) sugere que os resíduos podem ser considerados normalmente distribuídos. Nesse caso, o p-value de 0.1978 indica que os resíduos podem ser aproximados a uma distribuição normal, o que é um aspecto positivo para a validade das suposições do modelo.

A partir da Figura 4, serão apresentados os resultados da aplicação do método Holt-Winters. Esses resultados fornecerão insights valiosos sobre como o modelo se ajusta aos dados de exportação de soja nos Portos do Paraná, considerando suas características sazonais e tendências ao longo do período de análise.




Figura 4 – Correlograma método Holt-Winters

A análise do gráfico de autocorrelação, Figura 4, aplicado pelo método Holt-Winters, revela características importantes da série temporal. Observando o gráfico, é possível identificar a presença de sazonalidade na série, sugerindo que padrões repetitivos ocorrem em intervalos regulares. No entanto, é notável que alguns pontos estão localizados fora da linha azul de previsão. Esses pontos podem indicar a presença de valores atípicos ou outliers que podem afetar a precisão das previsões. Portanto, embora a série exiba sazonalidade, a presença desses pontos fora da linha de previsão sugere que alguns aspectos da série podem não estar totalmente capturados pelo modelo Holt-Winters. Isso destaca a importância de avaliar e considerar esses pontos atípicos ao interpretar as previsões e tomar decisões informadas.

A Figura 5 a seguir, apresenta uma comparação entre as previsões geradas pelo modelo Holt-Winters e os valores reais de exportação de soja nos Portos do Paraná.





Figura 5 – Teste Holt-Winters

Na Figura 5, podemos observar os resultados da comparação entre as previsões geradas pelo método Holt-Winters (representadas pela linha vermelha) e os valores reais de exportação de soja nos Portos do Paraná (representados pela linha preta). Notamos que, em geral, há uma semelhança entre as duas linhas, indicando que o modelo foi capaz de capturar as tendências e padrões da série temporal. No entanto, é possível identificar pontos significativos de variação entre as linhas, sugerindo que o modelo não conseguiu prever com precisão todas as flutuações nos dados reais. Essa variância entre as linhas ressalta a influência de fatores externos, como a pandemia e questões políticas, que podem afetar as previsões.

Modelo Aditivo Hot-Winters



Modelo Multiplicativo Hot-Winters




Figura 6 – Modelo Aditivo e Multiplicativo Hot-Winters

Os resultados obtidos na Figura 6 refletem a avaliação do desempenho dos modelos de previsão aditivo e multiplicativo. Ao analisar o Erro Percentual Médio (EPM), observamos que o modelo aditivo apresentou um valor de EPM de -27.56162. Isso significa que as previsões geradas pelo modelo aditivo subestimaram os valores reais em média, com uma diferença percentual média de aproximadamente -27.56%.

Por outro lado, o modelo multiplicativo obteve um valor de EPM de -13.5498. Isso indica que as previsões do modelo multiplicativo também subestimaram os valores reais, mas com uma diferença percentual média menor, em torno de -13.55%. A diferença nos valores de EPM entre os modelos aditivo e multiplicativo sugere que o modelo multiplicativo teve um desempenho relativamente melhor na previsão, comparado ao modelo aditivo, no contexto desses dados. No entanto, é importante destacar que ambos os modelos ainda apresentaram subestimações significativas em relação aos valores reais, indicando a necessidade de refinamento e ajustes nos parâmetros para melhorar a acurácia das previsões.

Os resultados apresentados na Figura 7 correspondem à aplicação do teste de normalidade de Shapiro-Wilk nos resíduos dos modelos de previsão aditivo, onde o modelo aditivo, o resultado do teste indicou um valor de estatística W igual a 0.97446, com um p-valor associado de 0.4921.

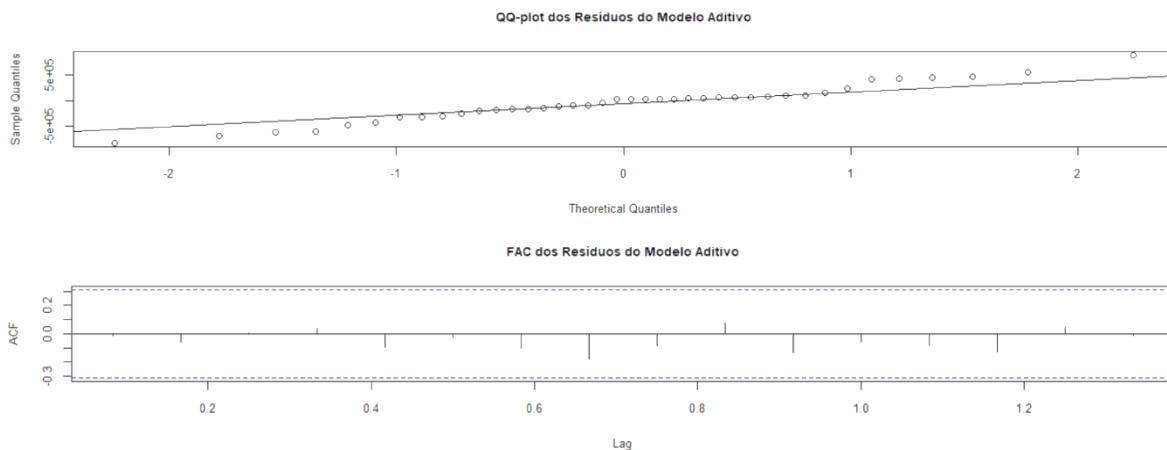


Figura 7 – Modelo Aditivo

No caso do modelo multiplicativo, apresentado na Figura 8, a estatística W foi calculada como 0.95675, e o p-valor correspondente foi de 0.1295.

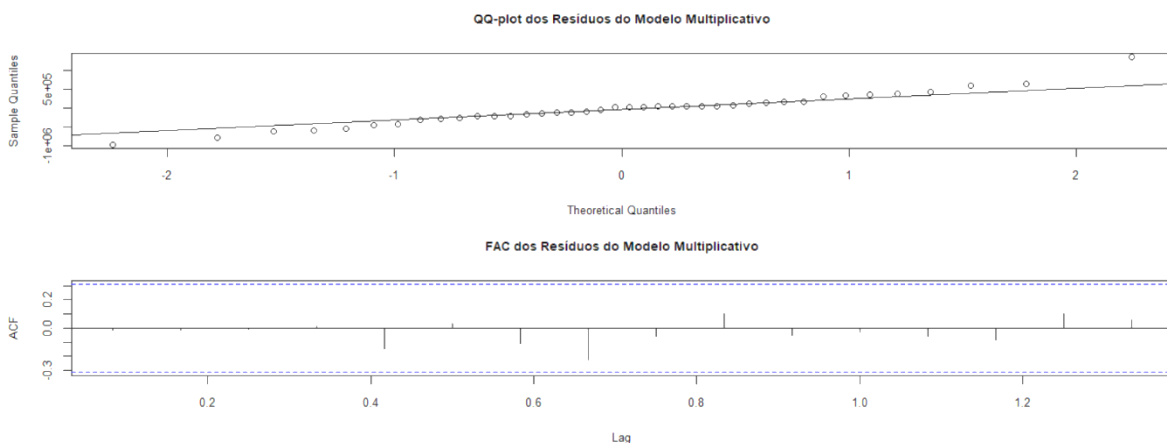


Figura 8 – Modelo Multiplicativo

O teste de normalidade de Shapiro-Wilk avalia se os resíduos seguem uma distribuição normal. Um p-valor maior que um nível de significância (geralmente 0.05) indica que não há evidências suficientes para rejeitar a hipótese nula de que os resíduos seguem uma distribuição normal. Por outro lado, um p-valor menor do que o nível de significância sugere que os resíduos não seguem uma distribuição normal.

No contexto dos resultados obtidos, observamos que ambos os modelos aditivo e multiplicativo apresentaram p-valores acima do nível de significância de 0.05. Isso sugere que não há evidências suficientes para rejeitar a hipótese nula de normalidade para os resíduos de ambos os modelos. No entanto, é importante considerar que a normalidade dos resíduos é uma das premissas dos modelos estatísticos, e a não conformidade com essa premissa pode afetar a interpretação das conclusões. Portanto, uma análise mais detalhada da normalidade dos resíduos é recomendada para garantir a confiabilidade dos resultados.

A Figura 9 exibe o gráfico de previsões obtido a partir do método aditivo de Holt-Winters, projetando os resultados para o próximo ano. No gráfico, a coloração azul mais escura representa a confiabilidade e a precisão da previsão gerada pelo modelo. No entanto, é notável que algumas previsões estão próximas de zero, o que poderia ser considerado um desvio da realidade, visto que os dados reais não apresentam valores tão próximos de zero.




Figura 9 – Previsão método aditivo Holt-Winters

Embora o modelo de previsão Holt-Winters aditivo tenha proporcionado um campo azul escuro, indicando sua força e confiabilidade em várias áreas da previsão, é importante observar os pontos de discrepância em relação aos dados reais. A presença desses pontos sugere que o modelo pode não estar capturando completamente as nuances dos dados reais, resultando em previsões que não se alinham adequadamente com o comportamento observado da série temporal.

A Figura 10 exibe o gráfico de previsões gerado pelo método multiplicativo de Holt-Winters com amortecimento, projetando as previsões para o próximo ano. Similar à Figura 9, neste gráfico, a coloração azul escura denota uma área de alta confiabilidade e precisão nas previsões do modelo.




Figura 10 – Previsão método multiplicativo Holt-Winters

No entanto, um aspecto notável e encorajador da Figura 10 é que as previsões geradas pelo método multiplicativo apresentam valores acima de zero, alinhando-se de forma mais coesa com os dados reais. Diferentemente da Figura 9, onde o modelo aditivo demonstrou discrepâncias entre as previsões e os dados reais próximos a zero, o método multiplicativo com amortecimento parece ser mais preciso ao representar o comportamento observado na série temporal.

5. Conclusões

A análise realizada neste estudo comparativo entre os métodos ARIMA e Holt-Winters para a previsão da exportação de soja nos Portos do Paraná proporcionou insights significativos sobre a complexidade inerente à previsão de séries temporais em um cenário real. Os resultados obtidos indicam que o método ARIMA enfrentou desafios na tarefa de fornecer previsões precisas, demonstrando limitações na sua capacidade de capturar as nuances específicas dos dados da série.

Por outro lado, o método Holt-Winters, especialmente na sua abordagem multiplicativa com amortecimento, emergiu como uma alternativa mais robusta para modelar e prever a exportação de soja. Essa abordagem demonstrou uma melhor adequação para capturar tendências e padrões sazonais presentes nos dados, destacando sua capacidade de se ajustar de forma mais precisa às características intrínsecas da série temporal.

É importante salientar que a interpretação dos resultados deve ser realizada com discernimento, levando em consideração não apenas a precisão das previsões, mas também o contexto complexo no qual os dados foram coletados. As previsões, embora valiosas, não podem ser consideradas de forma isolada, pois fatores externos e inesperados, como questões políticas e a pandemia de Covid-19, influenciaram no desempenho dos modelos de previsão.

Este estudo ressalta a relevância de reconhecer as limitações dos modelos de previsão e enfatiza a importância de adaptar esses modelos a um ambiente em constante mudança. A análise também sublinha a necessidade de uma abordagem cautelosa ao interpretar as previsões e tomar decisões informadas com base nelas.

Como futuras pesquisas, sugere-se continuar monitorando e ajustando os modelos à medida que novos dados e eventos surgem. Além disso, a exploração de técnicas avançadas de modelagem que possam melhor capturar os efeitos de fatores externos é uma direção promissora para melhorar ainda mais a precisão das previsões. Em última análise, este trabalho contribui para uma compreensão mais profunda das complexidades

envolvidas na previsão de séries temporais e destaca a importância de abordagens adaptáveis e sensíveis ao contexto para lidar com os desafios inerentes a esse processo.

Referências

ABITANTE, K. G. Co-integração entre os mercados spot e futuro: evidências dos mercados de boi gordo e soja. **Rev. Econ. Sociol. Rural**, Brasília, v. 46, n. 1, p. 75-96, jan./mar. 2008.

ARMSTRONG, J. S.; COLLOPY, F. **Integration of statistical methods and judgment for time series forecasting: Principles from empirical research**. Forecasting with judgment. New York: John Wiley & Sons, Inc. p 269-293, 1998.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos - Logística empresarial**. - 5ª ed - São Paulo: Bookman, 2006.

BECERRA, K. **Mercado de capitais: Bolsa de Mercadorias e Futuros do Brasil (BM&F)**. 2007. 16p. Monografia (Pósgraduação em Contabilidade para Gestão de Negócios) - Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2007.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAEeletrônica**, São Paulo, v. 3, n. 1, art. 9, jan./jun. 2004.

BRUM, A. L.; HECK, C. R.; LEMES, C. L.; MÜLLER, P. K.: A economia mundial da soja: impactos na cadeia produtiva da oleaginosa no Rio Grande do Sul 1970-2000. Anais dos Congressos. **XLIII Congresso da Sober em Ribeirão Preto**. São Paulo, 2005.

CONAB - Companhia Nacional de Abastecimento; **Séries Históricas**. Disponível em Acesso em 03/02/2011

DeLURGIO, S. A. **Forecasting principles and applications**. 1st Edition. Singapore: McGraw-Hill. 802 p, 1998

FOOD AND AGRICULTURE ORGANIZATION - FAO. **Major food and agricultural commodities and producers**.

INTER-AMERICAN INSTITUTE FOR COOPERATION ON AGRICULTURE - IICA. **Agroenergy and biofuels atlas of the Americas**, 2007.

MONTGOMERY D.C.; JENNINGS, C.L; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. John Wiley & Sons, 2008.

SCHWITZK, M. (2001). **Acuracidade dos métodos de previsão e sua relação com o dimensionamento dos estoques de produtos acabados**. Florianópolis. 137f.. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina.

ZHANG, G. P.; Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, v.50, p. 159–175, 2003.