

ANÁLISE E PREVISÃO DE DEMANDA DE CARGAS RODOVIÁRIAS EM UM MARKETPLACE LOGÍSTICO BRASILEIRO UTILIZANDO O MODELO ARIMA.Atilio F. P. Neto¹ (IC), Renato S. Lima (PQ)¹¹Universidade Federal de Itajubá.**Palavras-chave:** ARIMA. *Marketplaces* logísticos. Previsão de demanda. Séries temporais.**Introdução**

O setor de transporte rodoviário de cargas, pilar da economia brasileira ao movimentar cerca de 60% das cargas do país (CONFEDERAÇÃO NACIONAL DO TRANSPORTE, 2023), tem nos *marketplaces* digitais uma ferramenta essencial para a otimização de fretes (COLLIGNON; COOK; LI, 2020). Um desafio central para essas plataformas é a previsão da demanda, cuja precisão impacta diretamente a eficiência operacional. Contudo, essa previsão torna-se particularmente complexa em cenários de instabilidade, como o provocado pela pandemia de COVID-19, que gerou profundas rupturas nos padrões históricos do setor logístico (ALMEIDA; TAVARES, 2024; BHUIYAN et al., 2024). Tais cenários demandam modelos preditivos robustos, como o ARIMA (*Autoregressive Integrated Moving Average*), reconhecido por sua eficácia em séries temporais (YADAV; GOSWAMI, 2024). Diante disso, o objetivo deste estudo foi analisar e prever a demanda de cargas em um *marketplace* logístico, avaliando a aplicação do ARIMA em uma série temporal de 2019 a maio de 2022, marcada por alta volatilidade. A pesquisa justifica-se por oferecer *insights* práticos ao planejamento do setor e por contribuir academicamente com a validação do modelo em um contexto pouco explorado. A metodologia utilizada foi quantitativa, seguindo as etapas de tratamento da série, verificação de estacionariedade, identificação de parâmetros, estimação do modelo e validação de sua capacidade preditiva.

Metodologia

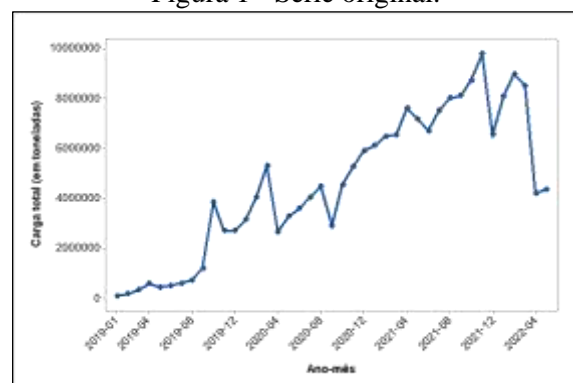
A presente pesquisa, de natureza quantitativa, empregou a modelagem de séries temporais para analisar e prever a demanda de cargas em um *marketplace* logístico brasileiro. A base de dados, fornecida pela empresa, compreende 41 instâncias mensais (2019 a maio de 2022) da quantidade de carga anunciada (em toneladas). A modelagem foi executada no *software Minitab 18*, seguindo as etapas para o modelo ARIMA propostas por

Sinu, Kleden e Atti (2024). O procedimento iniciou-se com a verificação de estacionariedade da série através do teste Dickey-Fuller Aumentado (ADF), conforme recomendado por Mushtaq (2011). Constatada a não estacionariedade, aplicou-se a diferenciação para estabilização da série. Na sequência, os parâmetros p , d e q do modelo foram determinados por meio da análise dos gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF). Após o ajuste inicial e a verificação da significância dos coeficientes, a validação do modelo foi realizada por meio da análise dos resíduos, que incluiu os gráficos ACF e PACF e o teste Ljung-Box, para assegurar seu comportamento como ruído branco. Finalmente, o modelo validado foi utilizado para gerar previsões para períodos futuros.

Resultados e discussão

A análise da série temporal iniciou-se com o teste de estacionariedade ADF, que resultou em um valor-p de 0,337. Como o valor-p foi superior a 0,05, concluiu-se que a série não é estacionária, o que é visualmente corroborado pelo movimento crescente dos dados no gráfico da série temporal original. A Figura 1 apresenta a série original e a Figura 2 a série após a aplicação da primeira diferenciação para estabilização.


Figura 1 - Série original.



Fonte: Autoria própria.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

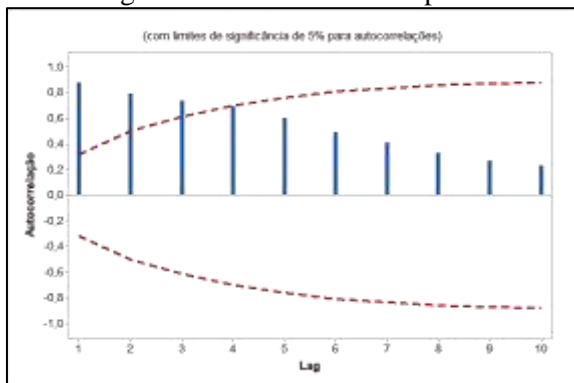
Figura 2 - Série diferenciada na primeira ordem.



Fonte: Autoria própria.


Não foi identificado um padrão de sazonalidade. A análise dos gráficos de Autocorrelação (ACF) e Autocorrelação Parcial (PACF) da série original (Figuras 3 e 4) confirmou a não estacionariedade, com um decrescimento gradual na ACF. Contudo, a PACF apresentou um valor significativo no lag 1, sugerindo que um modelo AR(1) poderia ser adequado aos dados.

Figura 3 - ACF da série temporal.



Fonte: Autoria própria.

Figura 4 – PACF da série temporal.



Fonte: Autoria própria.

A Tabela 1 mostra a estimativa final do parâmetro desse modelo. As somas residuais dos quadrados são dadas pela Tabela 2. E a Estatística Qui-Quadrado de Box-Pierce (Ljung-Box) modificada é mostrada na Tabela 3.

O modelo AR(1) foi ajustado, e a análise dos resíduos por meio do teste Ljung-Box (Tabela 3) revelou valores-p superiores a 0,05, indicando que os resíduos são independentes e que o modelo se adequa satisfatoriamente aos dados.

Tabela 1 - Estimativas finais dos parâmetros.

Tipo	Coefficiente	Erro-padrão de coeficiente	Valor-t	Valor-p
AR 1	0,9815	0,0364	26,95	0,000

Fonte: Autoria própria.

Tabela 2 - Somas residuais dos quadrados.

Graus de liberdade	Soma dos quadrados	Quociente médio
40	6,14244 · 1013	1,53 · 1012

Fonte: Autoria própria.

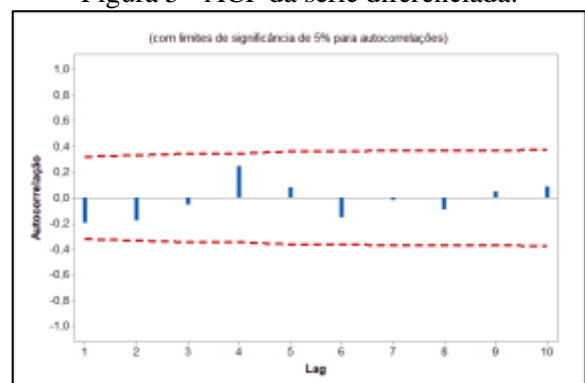
Tabela 3 - Estatística Qui-Quadrado de Box-Pierce (Ljung-Box) modificada.

Lag	Qui-quadrado	Graus de liberdade	Valor-p
12	9,41	11	0,584
24	19,74	23	0,657
36	33,36	35	0,547

Fonte: Autoria própria.

Paralelamente, a análise da série diferenciada (Figuras 5 e 6) demonstrou um comportamento de ruído branco, indicando que a diferenciação foi eficaz. Isso apontou que o modelo ARIMA(0,1,0), conhecido como *Random Walk* (processo aleatório), também descreve adequadamente a série.

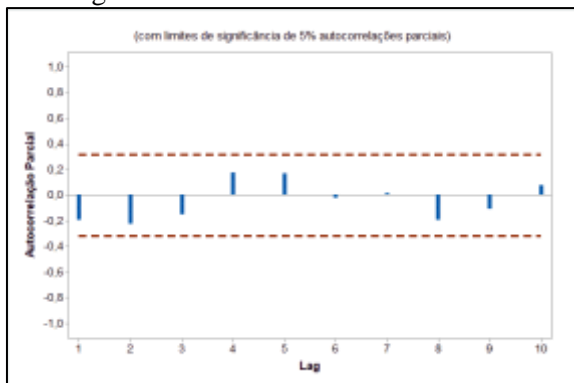
Figura 5 - ACF da série diferenciada.



Fonte: Autoria própria.

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

Figura 6 - PACF da série diferenciada.



Fonte: Autoria própria.

Embora ambos os modelos tenham se ajustado bem estatisticamente, com pequena diferença na soma dos quadrados dos resíduos, acredita-se que o modelo ARIMA(0,1,0) seja conceitualmente mais adequado por considerar a natureza não estacionária do processo, comum em séries com tendência de crescimento. A implicação de um modelo *Random Walk* é que a melhor previsão para o próximo período é o último valor observado (4.359.699 toneladas em maio de 2022), o que evidencia a imprevisibilidade da série e a baixa confiabilidade de previsões de longo prazo.

A tendência de crescimento nos dados é possivelmente explicada pela expansão da base de usuários da plataforma, impulsionada por investimentos. A ausência de sazonalidade, um comportamento atípico para o setor logístico brasileiro influenciado pelo agronegócio, sugere que os *marketplaces* atendem a uma demanda complementar ou esporádica, funcionando como uma ferramenta de ajuste para picos e interrupções na cadeia de suprimentos, em vez de refletir a demanda logística total. Um fator crítico que limita a previsibilidade é a qualidade dos dados, pois representam postagens de cargas, não necessariamente fretes realizados. O comportamento de repostagens pelos embarcadores pode inflar os volumes e introduzir ruídos, mascarando os padrões reais.

Esses achados implicam que os *marketplaces* devem focar em estratégias para atrair cargas primárias e aumentar a confiabilidade dos dados, enquanto os planejadores logísticos devem combinar dados históricos com informações operacionais em tempo real. Para trabalhos futuros, recomenda-se a qualificação dos dados (diferenciando postagens únicas de repetidas) e a exploração de modelos híbridos para melhorar o desempenho preditivo.

Conclusões

Este estudo analisou a demanda de cargas em um *marketplace* logístico brasileiro (2019-2022) e avaliou a eficácia do modelo ARIMA em um cenário volátil. Concluiu-se que o modelo ARIMA(0,1,0), ou *Random Walk*, foi o mais adequado para descrever a série, que apresentou uma forte tendência de crescimento não estacionária. A adequação deste modelo, no entanto, implica em baixa previsibilidade para períodos futuros, sugerindo que a melhor estimativa para a demanda futura é o volume do período mais recente. A ausência de padrões de sazonalidade, esperados para o setor, indica que a plataforma atende a uma demanda complementar e esporádica, em vez de refletir o mercado logístico primário. A análise foi limitada por ruídos nos dados, possivelmente gerados por repostagens de cargas, o que dificulta a identificação de padrões consistentes. O trabalho contribui ao evidenciar os desafios de previsão nesse modelo de negócio e sugere que estudos futuros devem focar na qualificação dos dados e na integração do ARIMA com modelos híbridos ou de aprendizado de máquina para aprimorar a capacidade preditiva.

Agradecimentos

Agradecemos à Universidade Federal de Itajubá pelo apoio institucional e ao CNPq pelo apoio financeiro concedido para o desenvolvimento deste trabalho.

Referências

- ALMEIDA, L.; TAVARES, F. Impact COVID-19 pandemic in supply chain. In: REFERENCE MODULE IN SOCIAL SCIENCES. [s. l.]: Elsevier, 2024. p. B9780443137013000220. Disponível em: <https://linkinghub.elsevier.com/retrieve/pii/B9780443137013000220>.
- ARUMUGAM, P.; SARANYA, R. Outlier Detection and Missing Value in Seasonal ARIMA Model Using Rainfall Data. *Materials Today: Proceedings*, [s. l.], v. 5, n. 1, p. 1791–1799, 2018.
- BARROS, C. P.; GIL-ALANA, L. A.; WANKE, P. An empirical analysis of freight transport traffic modes in Brazil, 1996–2012. *Transportation Planning and Technology*, [s. l.], v. 38, n. 3, p. 305–319, 2015.
- BHUIYAN, M. R. *et al.* Assessing the impact of COVID-19 on global supply chain management in small and medium-sized

“Do conhecimento acadêmico à transformação sustentável: inovação com validação científica”

enterprises (SMES). *Academic Journal on Science, Technology, Engineering & Mathematics Education*, [s. l.], v. 4, n. 3, p. 163–177, 2024.

COLLIGNON, S.; COOK, D. F.; LI, Y. Motor carrier spot market: trust-building in public e-marketplaces. *International Journal of Physical Distribution & Logistics Management*, [s. l.], v. 50, n. 2, p. 191–214, 2020.

CONFEDERAÇÃO NACIONAL DO TRANSPORTE. Painel CNT do emprego no transporte. [s. l.], 2023. Disponível em: <https://cnt.org.br/painel-emprego-transporte>.

CONFEDERAÇÃO NACIONAL DO TRANSPORTE. Pesquisa CNT perfil empresarial 2021: transporte rodoviário de cargas. Brasília: CNT, 2022.

FRETEBRAS. Relatório Fretebras: uma visão de 2021. [s. l.]: Fretebras, 2022.

FU, T. A review on time series data mining. *Engineering Applications of Artificial Intelligence*, [s. l.], v. 24, n.1, p. 164–181, 2011.

GOTTWALD, G. A. A model for Dansgaard–Oeschger events and millennial-scale abrupt climate change without external forcing. *Climate Dynamics*, [s. l.], v. 56, n. 1–2, p. 227–243, 2021.

GUO, J.; SUN, Y. Research on Freight Scheduling Route Redistribution Based on Data Prediction and Optimization Algorithm. *In: 2023 IEEE 5TH INTERNATIONAL CONFERENCE ON POWER, INTELLIGENT COMPUTING AND SYSTEMS (ICPICS), 2023, Shenyang, China. 2023 IEEE 5th International Conference on Power, Intelligent Computing and Systems (ICPICS). Shenyang, China: IEEE, 2023. p. 709–714. Disponível em: <https://ieeexplore.ieee.org/document/10235491/>.*

KHASHEI, M.; BIJARI, M. A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, [s. l.], v. 11, n. 2, p. 2664–2675, 2011.

LU, Y. Research on express transport based on the ARIMA model. *Highlights in Business, Economics and Management*, [s. l.], v. 14, p. 234–242, 2023.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. Introduction to time series analysis and forecasting. Hoboken, N.J.: Wiley-Interscience, 2008. (Wiley series in probability and statistics).

MUSHTAQ, R. Augmented Dickey Fuller Test. *SSRN Electronic Journal*, [s. l.], 2011. Disponível em: <http://www.ssrn.com/abstract=1911068>.

PRASAD, S. Time Series. *In: PRASAD, S. Advanced Statistical Methods*. Singapore: Springer Nature Singapore, 2024. p. 109–162. Disponível em: https://link.springer.com/10.1007/978-981-99-7257-9_3.

SCHWIND, M.; STENGER, A.; APONTE, S. Electronic Transportation Marketplaces: How Can Green-IS Help to Promote Sustainable Logistics? *In: 2011 44TH HAWAII INTERNATIONAL CONFERENCE ON SYSTEM SCIENCES (HICSS 2011), 2011, Kauai, HI. 2011 44th Hawaii International Conference on System Sciences*. Kauai, HI: IEEE, 2011. p. 1–8. Disponível em: <http://ieeexplore.ieee.org/document/5718561/>.

SINU, E. B.; KLEDEN, M. A.; ATTI, A. Application of ARIMA model for forecasting national economic growth: A focus on Gross Domestic Product data. *BAREKENG: Jurnal Ilmu Matematika dan Terapan*, [s. l.], v. 18, n. 2, p. 1261–1272, 2024.

VILARINHO, A. *et al.* Challenges and Opportunities for the Development of Inland Waterway Transport in Brazil. *Sustainability*, [s. l.], v. 16, n. 5, p. 2136, 2024.

WANG, Z.-H. *et al.* Short-term Forecast Model of Vehicles Volume Based on ARIMA Seasonal Model and HoltWinters. *ITM Web of Conferences*, [s. l.], v. 12, p. 04028, 2017.

YADAV, D. K.; K, S.; GOSWAMI, L. Autoregressive Integrated Moving Average Model for Time Series Analysis. *In: 2024 INTERNATIONAL CONFERENCE ON OPTIMIZATION COMPUTING AND WIRELESS COMMUNICATION (ICOCWC), 2024, Debre Tabor, Ethiopia. 2024 International Conference on Optimization Computing and Wireless Communication (ICOCWC). Debre Tabor, Ethiopia: IEEE, 2024. p.1–6. Disponível em: <https://ieeexplore.ieee.org/document/10470488/>.*