



ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01
de dezembro 2023

Explorando técnicas de previsão de demanda para aprimorar a movimentação de cargas portuárias: Estudo de caso na Portos do Paraná

Emerson Ramos Cordeiro

Departamento de Engenharia de Produção – Universidade Estadual do Paraná

Camila Matos

Departamento de Engenharia de Produção – Universidade Estadual do Paraná

Fernando Henrique Lermen

Departamento de Engenharia de Produção – Universidade Estadual do Paraná

Departamento de Ingeniería Industrial – Universidad Tecnológica de Perú

Gustavo de Souza Matias

Departamento de Engenharia de Produção – Universidade Estadual do Paraná

Resumo: O artigo aborda a importância crítica da previsão de demanda nas operações portuárias no estado do Paraná. No cenário de comércio global, compreender e antecipar as necessidades de transporte de mercadorias é essencial para otimizar a capacidade de resposta dos portos e garantir uma gestão fluida e eficaz. A previsão de demanda emerge como uma ferramenta fundamental para atingir esse objetivo. O artigo destaca que a previsão de demanda é baseada na análise de dados históricos de importação e exportação dos últimos anos. Essa análise proporciona uma visão clara das tendências passadas e, portanto, ajuda os gestores portuários a antecipar cenários futuros. Isso permite uma alocação mais eficiente de recursos e a tomada de decisões estratégicas informadas. A investigação conduzida no artigo concentra-se na movimentação portuária nos portos do Paraná, utilizando técnicas avançadas de previsão de demanda. Os resultados fornecem insights valiosos para melhorar a tomada de decisões estratégicas no setor portuário. A capacidade de antecipar as flutuações do mercado e as demandas dos clientes é fundamental para garantir uma resposta adequada e o melhor aproveitamento da infraestrutura portuária disponível.

Palavras-chave: Previsão de demanda, Movimentação de carga, Setor portuário.

Exploring forecasting techniques to enhance port cargo movement: A case study at Portos do Paraná

Abstract: The paper addresses the critical importance of forecasting in port operations in Paraná state. Understanding and anticipating freight transport needs in the global trade scenario is essential to optimize ports' responsiveness and ensure fluid and effective management. Demand forecasting emerges as a fundamental tool to achieve this aim. The paper highlights that the demand forecast is based on the analysis of historical import and export data from recent years. This analysis provides a clear view of past trends and helps port managers anticipate future scenarios. This allows for more efficient allocation of resources and informed strategic decision-making. The investigation conducted

in the article focuses on port movement in the Portos do Paraná, using advanced demand forecasting techniques. The results provide valuable insights to improve strategic decision-making in the port sector. The ability to anticipate market fluctuations and customer demands is essential to ensure adequate response and the best use of available port infrastructure.

Keywords: Forecasting, Cargo movement, Port sector.

1. Introdução

O desenvolvimento do setor portuário, desempenha um papel fundamental no cenário econômico do país, facilitando o comércio internacional e impulsionando o desenvolvimento regional (Brito et al., 2023). Este sistema, está relacionado a integração logística e a orientação destinada a indústria portuária e marítima, definindo o impacto da movimentação de importação e exportação no sistema econômico, visto que, a funcionalidade e a vitalidade dos portos, são fatores que auxiliam na construção de novas cadeias de valor e geram padrões de distribuição de cargas.

O sistema operacional portuário, no contexto dos portos do Paraná, lida com toda a questão de movimentação de cargas, analisando essas operações, nota-se ainda mais a importância, devido à sua localização estratégica e ao papel central que desempenha no fluxo de mercadorias que circulam no setor portuário a cada período. Segundo Bomfim et al. (2014) e Caetano e Araújo (2023), as mercadorias presentes em toda a extensão do setor portuário, são caracterizadas como: granel líquido (petróleo e seus subprodutos, óleos vegetais, entre outros.) e granel sólido (milho, soja, farelos, trigo, açúcar, sal entre outros). Os produtos, passam por todo um processo de movimentação em toneladas, envolvendo carga, descarga e transporte, esse percurso necessita de abordagens que direcionem as mercadorias de acordo com rumo que elas devem tomar, sendo importação ou exportação. Essa intensa movimentação fornece dados estipulados de mercadoria que passam pelos portos, mensal e anualmente.

A importação e exportação portuária, são atividades fundamentais de comercialização, desempenhando um papel crucial na distribuição de mercadorias de diferentes categorias, entre diferentes países (Kleinschmitt et al., 2013). A exportação caracteriza-se como o envio de produtos nacionais para mercados estrangeiros, impulsionando a economia ao gerar receitas e fortalecer a balança comercial. Por outro lado, a importação envolve a entrada de bens e produtos estrangeiros no país, abastecendo o mercado interno com uma ampla variedade de produtos que vão desde matérias-primas até bens de consumo acabados. A eficiência e o desempenho desses processos de importação e exportação estão intimamente ligados à movimentação portuária, que engloba uma série de atividades logísticas, operacionais e de planejamento (Goebel, 2002).

Nesse contexto, compreender e antecipar a demanda por meio da previsão torna-se essencial para otimizar a capacidade de resposta dos portos, garantindo uma gestão fluida e eficaz das operações voltadas para o comércio global. Assim, a previsão de demanda surge como uma ferramenta crucial para otimizar e auxiliar as operações portuárias, garantindo uma visão de qual o cenário mais provável que o sistema portuário se encontrará futuramente, com base na análise de seus dados de importação e exportação durante os últimos anos, isso ajudará aos gestores a buscar novos recursos e uma resposta adequada sobre às variações de mercado. Este artigo se propõe a investigar a movimentação portuária nos portos do Paraná, por meio de técnicas de previsão de demanda, oferecendo insights valiosos para aprimorar a tomada de decisões estratégicas e a alocação de recursos, dentro do setor.

2. Técnicas de Previsão

As técnicas de previsão abrangem conjuntos diversificados de abordagens analíticas (Honaiser e Sauaia, 2008), visando a antecipação de eventos futuros com base em dados históricos e padrões identificados. Essas técnicas oferecem uma ampla gama de ferramentas para prever uma variedade de fenômenos, como vendas, condições climáticas, movimentos de mercado etc. Neste estudo, serão utilizados alguns modelos de previsão, sendo eles: média móvel, média móvel exponencial, manutenção e monitorização do modelo, tendência linear, sazonalidade com tendência e correlação.

A média móvel simples, é conceituada como, a média calculada simplesmente somando um número fixo de pontos de dados consecutivos e dividindo pelo número de pontos selecionados (Correia, 2016). Por outro lado, a média móvel exponencial é quando se atribui pesos nos cálculos, optando por dar maior peso aos valores mais recentes, diminuindo a influência dos valores mais antigos (Baruchi e Midorikawa, 2010).

A manutenção e monitorização do modelo é realizada através do cálculo e acompanhamento do erro da previsão, que é a diferença que ocorre, entre o valor real da demanda e o valor previsto pelo modelo, para um dado período (Marins, 2011). A técnica de tendência linear pode ser usada para analisar o comportamento, ao longo do tempo de um conjunto de dados (Ackermann et al., 2022). Ela é útil quando se suspeita que existe uma relação linear entre as variáveis e se deseja fazer previsões de curto prazo com base nessa relação.

A sazonalidade com tendência, pode ser vista em alguns casos de previsão, lidar com dados que exibem tanto sazonalidade quanto tendência é uma situação comum na análise de séries temporais. Quando apresentados ambos os padrões presentes nos dados, é importante considerá-los como componentes fundamentais ao modelar e prever as séries temporais (Gonçalves e Back, 2018). Quanto a correlação, tende a verificar se alguma familiaridade entre duas vertentes de dados, esse fator de análise baseia-se em interpretar como os dados se comportam em relação a outro, se há alguma influência (Figueiredo Filho e Silva Júnior, 2009). As fórmulas das abordagens citadas, estão elencados no Quadro 1 conforme os índices sendo representadas nas Equações de (1) a (16) conforme a descrição da Técnica para Previsão do Quadro.

Quadro 1 – Fórmulas das técnicas de previsão

Técnicas para previsão	Fórmulas
Média Móvel Simples	$Mm_n = \frac{\sum_{i=1}^n D_i}{n}$ (1)
Média Móvel Exponencial	$Mme = P_{t-1} + \alpha (D_{t-1} - P_{t-1})$ (2)
Manutenção e Monitorização do Modelo	$erroabs = \sum D_{atual} - D_{prevista} $ (3)
	$MAD = \frac{\sum D_{atual} - D_{prevista} }{n}$ (4)
	$\sum ERRO \leq 4 * MAD$ (5)
Tendência Linear	$y = a + bx$ (6)
	$a = \frac{\sum y - b(\sum x)}{n}$ (7)
	$b = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2}$ (8)

Sazonalidade com Tendência	$Previsão_n = Y.ISn$	(9)
	$y = a + bx$	(10)
	$a = \frac{\sum y - b(\sum x)}{n}$	(11)
	$b = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2}$	(12)
Correlação	$y = a + bx$	(13)
	$a = \frac{\sum y - b(\sum x)}{n}$	(14)
	$b = \frac{n(\sum xy) - (\sum x)(\sum y)}{n(\sum x^2) - (\sum x)^2}$	(15)
	$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n(\sum x^2) - (\sum x)^2][n(\sum y^2) - (\sum y)^2]}}$	(16)

Fonte: Elaborado pelos autores.

Sendo:

D_i – Demanda no tempo de índice i ;

n – Tamanho da amostra;

P_{t-1} – Demanda no tempo posterior;

erroabs – Desvio absoluto;

MAD – Desvio Médio Absoluto;

D_{atual} – Demanda Atual;

$D_{prevista}$ – Demanda Estimada pelo modelo;

$\sum ERRO$ – Erro acumulado;;

a – Coeficiente Linear da Reta;

b - Coeficiente Angular da Reta;

$Previsão_n$ – Previsão no período;

Y – Variável dependente;

r – Coeficiente de correlação.

3. Metodologia

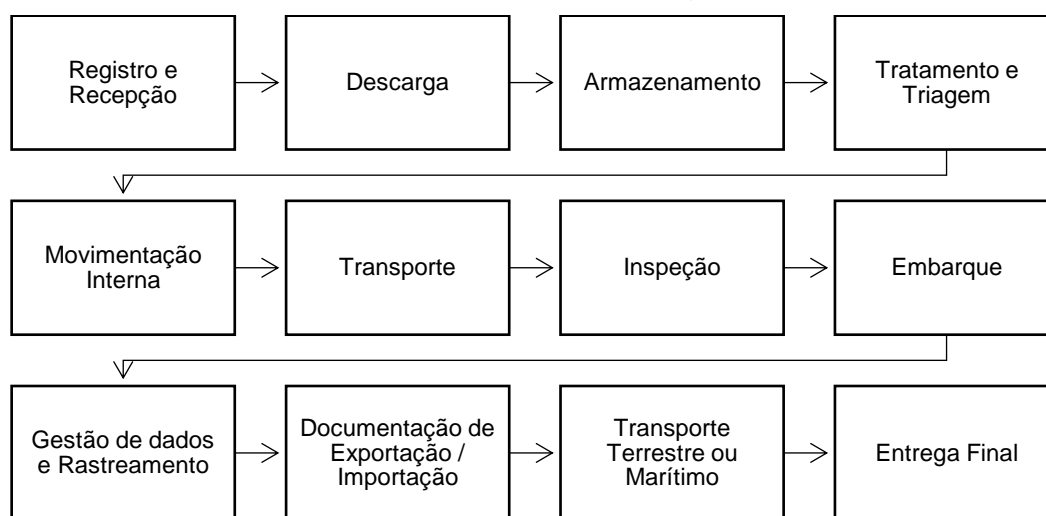
O presente estudo, utiliza o método de abordagem quantitativa, com histórico de dados gerais da movimentação de carga, entre exportação e importação dos portos do Paraná, situados nas cidades Antonina/Paranaguá, os dados foram coletados, no site do porto, ao qual mostra as estatísticas operacionais portuárias feita ao longo dos anos. O estudo partiu de uma investigação, visando a previsão de demanda portuária para os próximos períodos, buscando conhecer o sistema de movimentação portuária e fazer uma abordagem com técnicas de previsão (Agostino et al., 2019). Nesse processo, as informações coletadas passaram por um processo de transformação e estruturação de dados, garantindo a consistência e a qualidade das informações. Para a etapa de previsão, aplicam-se modelos estatísticos, baseadas em séries temporais, visando a verificação de média móvel, média móvel exponencial, tendência e sazonalidade.

Segundo Kusters (2023) as análises de previsão de demanda, consideram uma abordagem que integra tanto dados históricos quanto técnicas de análise. A extração de dados consiste em duas etapas: (i) coleta das amostras temporais baseada em estatísticas detalhadas das atividades portuárias, focando no volume de carga movimentada, tipos de mercadorias, sazonalidades e variações anuais. E (ii) tratamento de dados com foco na extração de dados mensais no período de 2017 a 2023, o que corrobora, para com a veracidade da análise de previsão de demanda. Esses modelos foram elaborados utilizando o *software Microsoft Office Excel®*. A combinação dessas etapas metodológicas busca não apenas fornecer insights acionáveis para a gestão portuária, mas também contribuir para a compreensão mais profunda das tendências e dinâmicas das movimentações de cargas nos portos do Paraná.

4. Movimentação de cargas nos Portos do Paraná

A movimentação de cargas nos portos do Paraná, como o Porto de Paranaguá e o Porto de Antonina, segue um processo complexo que envolve várias etapas e atores. O fluxograma é apresentado na Figura 1.

Figura 1 - Fluxograma de movimentação de carga



Fonte: Elaborado pelos autores.

A movimentação de cargas nos portos do Paraná envolve uma colaboração entre várias partes interessadas, incluindo autoridades portuárias, empresas de transporte, operadores de terminais, aduaneiros, agentes de carga, entre outros. O processo pode variar dependendo do tipo de carga, regulamentações locais e outros fatores específicos. O desenvolvimento desse fluxograma dos processos que contemplam a movimentação portuária, se deu, a partir da interpretação dos dados apresentados no relatório de movimentação de cargas dos portos.

5. Resultados e Discussão

Nesta seção, serão apresentados os dados referentes as análises desenvolvidas, relacionados à movimentação de cargas no setor portuário. Os dados quantitativos revelam padrões sazonais e tendências que refletem a demanda durante os anos, as discussões frequentemente abordam a eficiência operacional dos portos, destacando a importância da previsão de demanda nos volumes crescentes de carga. Para estas análises, foram recolhidos dados dos últimos seis anos de forma mensal, o que resultou em um total de

setenta e oito meses, os valores estão estipulados em toneladas, voltados a movimentação de carga, granel sólido e granel líquido.

5.1. Média Móvel Simples

O cálculo da média móvel, consiste em demonstrar a previsão de demanda, conforme os dados de anos anteriores, neste caso, foram analisados os meses mais recentes, com intuito de descobrir qual será a previsão para o mês de julho. O cálculo é feito utilizando a soma dos três valores de demanda e divide pelo número de mês, o resultado dessa abordagem mostra que a previsão é de 5.585.168 toneladas para o mês de julho. Conforme mostra a Tabela 1.

Tabela 1 – Cálculo da Média Móvel

Ano	Mês	Toneladas totais	Média Móvel
2022	Janeiro	4.158.355	
	Fevereiro	5.076.757	
	Março	4.846.360	
	Abril	4.613.609	4.693.824
	Maió	5.267.950	4.845.575
	Junho	5.052.924	4.909.306
	Julho	5.517.517	4.978.161
	Agosto	5.280.712	5.279.464
	Setembro	4.779.212	5.283.718
	Outubro	5.062.722	5.192.480
	Novembro	4.315.742	5.040.882
	Dezembro	4.385.497	4.719.225
2023	Janeiro	4.208.706	4.587.987
	Fevereiro	4.571.512	4.303.315
	Março	5.357.799	4.388.572
	Abril	4.952.059	4.712.672
	Maió	6.125.887	4.960.457
	Junho	5.677.557	5.478.582
	PREVISÃO PARA JULHO		5.585.168

Fonte: Elaborado pelos autores.

Utilizando o cálculo de média móvel, foi possível fazer a previsão de demanda para o próximo ano de 2023, que resultou em uma previsão de 57.744.269 toneladas. Conforme apresentado na Tabela 2.

Tabela 2 – Média Móvel para o ano de 2023.

Ano	Toneladas totais	Média Móvel	Erro
2017	51.526.490		
2018	53.030.223		
2019	53.187.703		
2020	57.352.364	52.581.472	4.770.892
2021	57.523.086	54.523.430	2.999.656
2022	58.357.357	56.021.051	2.336.306
2023	PREVISÃO	57.744.269	10.106.854

Fonte: Elaborado pelos autores.

5.2. Média Móvel Exponencial

Foi calculada a média móvel exponencial com base na Equação (2); a média móvel exponencial serve para fazer a previsão do próximo mês, porém, visando a atribuição de coeficientes que verificam a acuracidade da previsão, para essa abordagem, deve-se repetir o primeiro valor de demanda, como sendo a primeira previsão e logo após aplica-se a fórmula, que consiste em somar o valor do coeficiente ao valor do primeiro período e multiplicá-lo pela subtração da demanda menos previsão. Logo após, aplicasse o cálculo do erro MAD conforme a Equação (4), para verificar se a previsão gera valores aceitáveis, no caso em questão, o coeficiente de 0,9 é o que menos apresenta erros, isso significa que a previsão que deve ser mais bem considerada para o mês de julho é 5.710.975,38 toneladas, conforme mostram as Tabelas 3 e 4.

Tabela 3 – Média Móvel Exponencial

Período	Demanda	0,5			0,9		
		Previsão	Erro	Erro Abs	Previsão	Erro	Erro Abs
1	4.158.355						
2	5.076.757	4.158.355	918.402,00	918.402,00	4.158.355,00	918.402	918.402
3	4.846.360	4.617.556,00	228.804,00	228.804,00	4.984.916,80	-138.557	138.557
4	4.613.609	4.731.958,00	-118.349,00	118.349,00	4.860.215,68	-246.607	246.607
5	5.267.950	4.672.783,50	595.166,50	595.166,50	4.638.269,67	629.680	629.680
6	5.052.924	4.970.366,75	82.557,25	82.557,25	5.204.981,97	-152.058	152.058
7	5.517.517	5.011.645,38	505.871,63	505.871,63	5.068.129,80	449.387	449.387
8	5.280.712	5.264.581,19	16.130,81	16.130,81	5.472.578,28	-191.866	191.866
9	4.779.212	5.272.646,59	-493.434,59	493.434,59	5.299.898,63	-520.687	520.687
10	5.062.722	5.025.929,30	36.792,70	36.792,70	4.831.280,66	231.441	231.441
11	4.315.742	5.044.325,65	-728.583,65	728.583,65	5.039.577,87	-723.836	723.836
12	4.385.497	4.680.033,82	-294.536,82	294.536,82	4.388.125,59	-2.629	2.629
13	4.208.706	4.532.765,41	-324.059,41	324.059,41	4.385.759,86	-177.054	177.054
14	4.571.512	4.370.735,71	200.776,29	200.776,29	4.226.411,39	345.101	345.101
15	5.357.799	4.471.123,85	886.675,15	886.675,15	4.537.001,94	820.797	820.797
16	4.952.059	4.914.461,43	37.597,57	37.597,57	5.275.719,29	-323.660	323.660
17	6.125.887	4.933.260,21	1.192.626,79	1.192.626,79	4.984.425,03	1.141.462	1.141.462
18	5.677.557	5.529.573,61	147.983,39	147.983,39	6.011.740,80	-334.184	334.184
	Σ	5.603.565,30	2.890.420,61	6.808.347,56	5.710.975,38	1.725.134	7.347.407

Fonte: Elaborado pelos autores.

Tabela 4 – Cálculo MAD

MAD E 4 MAD	
$\alpha = 0,5$	$\alpha = 0,9$
MAD = erroabs/n	MAD = erroabs/n
400.491,03	432.200,43
4 MAD	4 MAD
1.601.964,13	1.728.801,71
Erro <=MAD	Erro <=MAD
2.890.420,61 => 1.601.964,13	1.725.134 <= 1.728.801,71


Fonte: Elaborado pelos autores.

5.3. Sazonalidade

O problema da sazonalidade consiste em averiguar, se os dados apresentam algum tipo de comportamento, que seja considerado similar em determinados períodos. Para verificar se

os dados apresentam esse comportamento, com a ajuda da ferramenta *Excel*, deve-se selecionar toda a coluna de dados e inserir um gráfico de linha. O *Software* mostra, se há ou não sazonalidade, neste caso, é evidente que os dados referentes as movimentações de cargas possuem comportamento sazonal, pois, no período de dezembro e janeiro a movimentação despensa, nos meses seguintes ela retoma a frequência, e por meados do mês de junho e julho, é onde se concentram os maiores picos de movimentação de cargas, conforme mostra a Figura 2.

Figura 2 – Sazonalidade



Fonte: Elaborado pelos autores.

5.4. Tendência Linear

A tendência linear consiste em modelar e compreender o comportamento de uma variável ao longo do tempo ou de acordo com alguma outra dimensão. Trata-se de uma relação direta e constante entre duas variáveis, representada por uma linha reta em um gráfico de dispersão. Através da determinação da inclinação e do intercepto dessa linha, é possível fazer previsões e extrapolações, tornando-a uma ferramenta valiosa para a projeção de padrões e comportamentos futuros com base em dados históricos observados. Apesar de sua simplicidade, a tendência linear oferece insights importantes que podem servir como base para análises mais complexas e tomadas de decisão informadas. Para o cálculo de tendência linear, são necessários três fatores, a inclinação da reta cujo coeficiente angular que a representa pode ser determinado pela Equação (8), a intercepção e o período em que a demanda se localiza cujo coeficiente linear que a representa pode ser determinado pela Equação (7). Neste caso, será verificado se há alguma tendência na movimentação de cargas ao longo dos anos, conforme a Tabela 5.

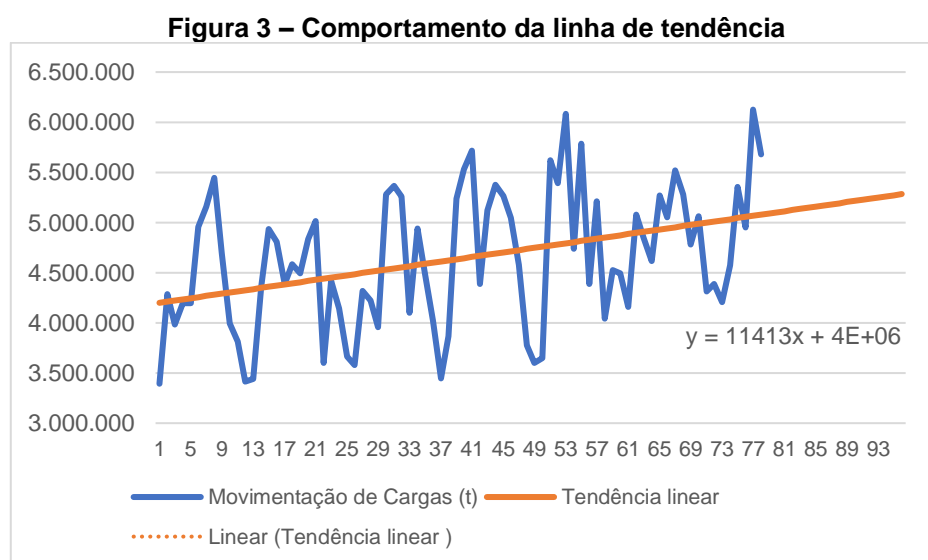
Tabela 5 – Tendência Linear até 2024

Ano	Mês	Movimentação de Cargas (t)	Tendência linear
73	Janeiro	4.208.706	5.021.715,49
74	Fevereiro	4.571.512	5.033.128,83
75	Março	5.357.799	5.044.542,18
76	Abril	4.952.059	5.055.955,52
77	Maio	6.125.887	5.067.368,86
78	Junho	5.677.557	5.078.782,21
79	Julho		5.090.195,55
80	Agosto		5.101.608,89

81		Setembro	5.113.022,23
82		Outubro	5.124.435,58
83		Novembro	5.135.848,92
84		Dezembro	5.147.262,26
85	2024	Janeiro	5.158.675,61
86		Fevereiro	5.170.088,95
87		Março	5.181.502,29
88		Abril	5.192.915,64
89		Maio	5.204.328,98
90		Junho	5.215.742,32
91		Julho	5.227.155,66
92		Agosto	5.238.569,01
93		Setembro	5.249.982,35
94		Outubro	5.261.395,69
95		Novembro	5.272.809,04
96		Dezembro	5.284.222,38

Fonte: Elaborado pelos autores.

A partir do cálculo da tendência linear foi possível visualizar a previsão da demanda, até o final de 2024, cujo resultado enfatiza o comportamento linear e crescente na movimentação de cargas, conforme apresenta a Figura 3.



Fonte: Elaborado pelos autores.

5.5. Sazonalidade com Tendência

A análise dos dados exibe tanto uma tendência quanto sazonalidade é essencial para compreender padrões complexos e variações ao longo do tempo. Enquanto a tendência representa a direção geral e persistente de mudança em uma série temporal, a sazonalidade revela padrões recorrentes e cíclicos que ocorrem em intervalos regulares. A combinação desses dois elementos permite uma visão mais completa e precisa das variações em dados, como vendas de produtos sazonais ou demanda por serviços, possibilitando a identificação de fatores sazonais superpostos à tendência subjacente. Esse

entendimento aprofundado é crucial para previsões precisas e estratégias informadas, pois considera tanto as mudanças graduais de longo prazo quanto os efeitos periódicos e previsíveis que ocorrem em determinados períodos. As previsões baseando-se no cálculo de sazonalidade com tendência, são exibidos na Tabela 6.

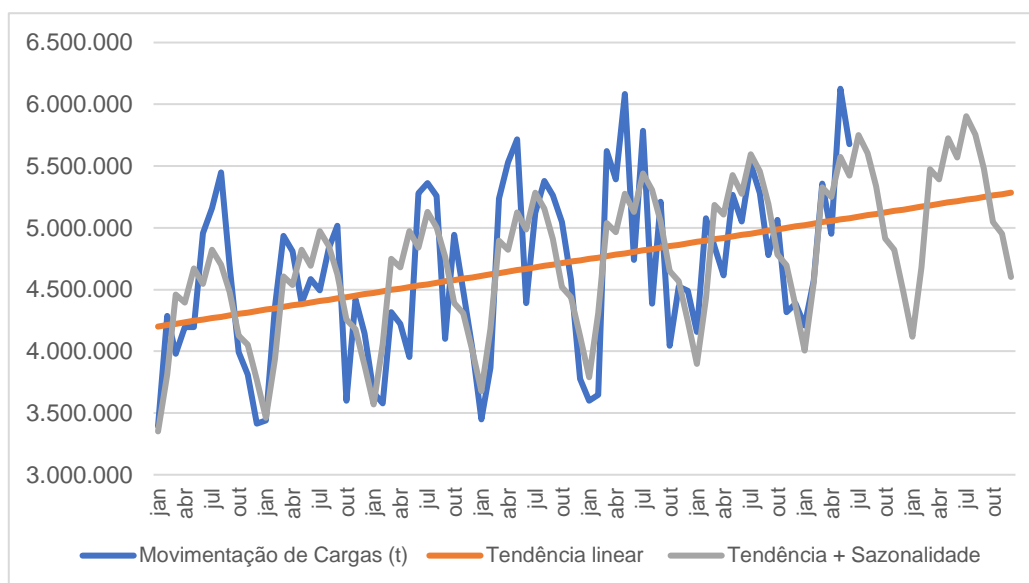
Tabela 6 – Sazonalidade com tendência até 2024.

	Ano	Mês	Movimentação de Cargas (t)	Tendência linear	Tendência + Sazonalidade
73	2023	Janeiro	4.208.706	5.021.715,49	4.006.730,32
74		Fevereiro	4.571.512	5.033.128,83	4.554.990,67
75		Março	5.357.799	5.044.542,18	5.327.647,78
76		Abril	4.952.059	5.055.955,52	5.248.413,98
77		Mai	6.125.887	5.067.368,86	5.575.306,69
78		Junho	5.677.557	5.078.782,21	5.423.102,87
79		Julho		5.090.195,55	5.748.512,15
80		Agosto		5.101.608,89	5.605.254,98
81		Setembro		5.113.022,23	5.337.620,45
82		Outubro		5.124.435,58	4.913.783,40
83		Novembro		5.135.848,92	4.823.488,50
84		Dezembro		5.147.262,26	4.481.520,08
85	2024	Janeiro		5.158.675,61	4.116.008,16
86		Fevereiro		5.170.088,95	4.678.939,82
87		Março		5.181.502,29	5.472.294,26
88		Abril		5.192.915,64	5.390.587,58
89		Mai		5.204.328,98	5.725.995,28
90		Junho		5.215.742,32	5.569.348,32
91		Julho		5.227.155,66	5.903.185,36
92		Agosto		5.238.569,01	5.755.736,21
93		Setembro		5.249.982,35	5.480.596,77
94		Outubro		5.261.395,69	5.045.113,45
95		Novembro		5.272.809,04	4.952.118,75
96		Dezembro		5.284.222,38	4.600.765,90

Fonte: Elaborado pelos autores.

A resultante dos cálculos de sazonalidade com tendência acompanha a divergência dos dados em todos os períodos analisados e com base nessas nuances, ele prevê o caminho para o próximo ano, a previsão acontece até o final de 2024 e revelam uma crescente nas demandas de movimentações de cargas, conforme mostra a Figura 4.

Figura 4 – Comportamento da sazonalidade com tendência até 2024.



Fonte: Elaborado pelos autores.

5.6. Correlação de Pearson

Para verificação do coeficiente de correlação calculado conforme a Equação (16), foram levantados dados referentes as toneladas de carga e descarga de granel sólido e líquido. Conforme apresentados na Tabela 7.

Tabela 7 – Granel Sólido e Granel Líquido.

Ano	Mês	Movimentação de cargas (t)	Granel sólido	Granel Líquido
2022	Janeiro	4.158.355	2.424.681	644.939
	Fevereiro	5.076.757	3.469.252	627.746
	Março	4.846.360	3.023.847	621.588
	Abril	4.613.609	2.674.020	821.236
	Maio	5.267.950	3.397.467	639.193
	Junho	5.052.924	3.268.248	660.245
	Julho	5.517.517	3.666.866	561.073
	Agosto	5.280.712	3.170.021	909.132
	Setembro	4.779.212	2.675.007	898.237
	Outubro	5.062.722	3.074.455	778.238
	Novembro	4.315.742	2.422.947	766.137
	Dezembro	4.385.497	2.495.832	791.292
2023	Janeiro	4.208.706	2.475.456	722.073
	Fevereiro	4.571.512	2.722.016	785.644
	Março	5.357.799	3.341.475	902.221
	Abril	4.952.059	3.121.556	821.086
	Maio	6.125.887	4.177.005	900.794
	Junho	5.677.557	3.748.971	753.253


Fonte: Elaborado pelos autores.

A correlação de Pearson é uma medida estatística utilizada para quantificar a relação linear entre duas variáveis. Ela avalia a força e a direção da associação entre os dados, variando de -1 a 1 (Figueiredo Filho e Silva Júnior, 2009). Um coeficiente de correlação próximo a 1 indica uma correlação positiva forte, o que significa que à medida que uma variável aumenta, a outra tende a aumentar também de forma proporcional. Por outro lado, um

coeficiente próximo a -1 denota uma correlação negativa forte, indicando que, à medida que uma variável aumenta, a outra tende a diminuir de maneira proporcional. Um coeficiente de correlação próximo a 0 sugere uma fraca associação linear entre as variáveis. A correlação de Pearson é amplamente utilizada em diversas áreas, como estatísticas, economia, ciências sociais e biologia, para analisar relações entre variáveis contínuas e avaliar a intensidade e a direção de tais associações.

Nesse estudo, a abordagem consistiu em verificar a correlação entre movimentação de cargas e granel sólido e movimentação de carga e granel líquido, visando verificar como esses fatores se relacionam durante todo o processo de operação de carga. Quanto a movimentação de granel líquido ($y = -0,7689x - 610444$), o coeficiente apresentou um valor igual a 0,93, isso significa dizer que os dois fatores possuem uma correlação forte, conforme apresentado na Figura 5.


Figura 5 – Correlação entre granel líquido e movimentação de carga.



Fonte: Elaborado pelos autores.

Quanto a verificação de correlação entre granel líquido e movimentação de carga, o coeficiente resultou em 0,43, o que significa uma correlação moderada, esse tipo de correlação sugere que as mudanças em uma variável tendem a estar associadas a mudanças na outra variável, porém a relação não é tão direta ou proporcional ($y = 0,0673x + 339685$). Uma correlação moderada pode representar um equilíbrio entre influências múltiplas ou fatores intermediários que afetam a associação entre as variáveis. Interpretar essa correlação requer uma análise mais aprofundada para compreender os contextos subjacentes que moldam essa relação intermediária os resultados dessa correlação são exibidos na Figura 6.

Figura 6 – Correlação entre movimentação de cargas e granel líquido.



Fonte: Elaborado pelos autores.

6. Conclusões

Este artigo teve como objetivo investigar a movimentação portuária nos portos do Paraná, por meio de técnicas de previsão de demanda, oferecendo insights valiosos para aprimorar a tomada de decisões estratégicas e a alocação de recursos, dentro do setor. Em suma, com base nas informações analisadas, é possível traçar um panorama significativo para a previsão do próximo ano, estimando um total de 57.744.269 toneladas, com uma expectativa de movimentação de 5.101.608,89 toneladas para o mês de agosto. O pico de atividade ocorre em julho, seguido de uma diminuição entre dezembro e janeiro. A tendência de crescimento é reforçada pela linha de tendência e sazonalidade, projetando um aumento na movimentação ao longo de 2024.

A observação das correlações entre tipos de carga revela uma forte associação entre carga a granel sólido e o movimento total (0,93), enquanto a relação entre carga a granel líquido e o movimento total é moderada (0,43). Esses insights são fundamentais para fomentar a idealização de estratégias futuras, destacando a importância de considerar tanto as tendências quanto as relações entre variáveis para decisões informadas e eficazes. Como limitação têm-se a base de dados com dados mensais de 2017 a 2023, caso tivessem dados diários, seria possível melhorar os resultados da amostra. Como sugestão para futuras pesquisas, sugere-se automatizar o processo de previsão com a entrada automática de dados.

Referências

ACKERMANN, Andres EF; SELLITTO, Miguel A. Métodos de previsão de demanda: uma revisão da literatura. **Inovar**, v. 32, n. 85, p. 83-99, 2022.

AGOSTINO, Icaro et al. Combinação de previsões aplicada à modelagem de operações: um estudo de caso em um terminal portuário. **Exacta**, v. 17, n. 1, p. 99-110, 2019.

BARUCHI, Artur; MIDORIKAWA, Edson Toshimi. Elasticidade de memória em máquinas virtuais utilizando média móvel exponencial. In: **VII Workshop de Sistemas Operacionais (WSO)**. sn, 2010.

BRITO, Daniel; DA SILVA, Gabriel Novais; DA SILVA LEÃO, Airton Pereira. Estratégias de logísticas para o setor exportador de soja no Brasil. **RECIMA21-Revista Científica Multidisciplinar**-ISSN 2675-6218, v. 4, n. 7, p. e473595-e473595, 2023.

- CAETANO, Guilherme Ferreira; ARAÚJO, Vinicius de Souza Machado. **Estudo logístico: indústria de monoetileno glicol verde para produção de PET sustentável**. 2023.
- CORREIA, Flávio Marcelo. **Métodos Estatísticos e Redes Neurais Aplicados a Modelos Preditivos em Digestor Contínuo de Celulose Kraft de Eucalipto**. 2016.
- FIGUEIREDO FILHO, Dalson Britto; SILVA JÚNIOR, José Alexandre. Desvendando os Mistérios do Coeficiente de Correlação de Pearson (r). **Revista Política Hoje**, v. 18, n. 1, p. 115-146, 2009.
- GOEBEL, Dieter. **A competitividade externa e a logística doméstica**. 2002.
- GONÇALVES, Fabiane N.; BACK, Álvaro J. Análise da variação espacial e sazonal e de tendências na precipitação da região sul do Brasil. **Revista de Ciências Agrárias**, v. 41, n. 3, p. 592-602, 2018.
- HONAISSER, Eduardo Henrique Rangel; SAUAIA, Antonio Carlos Aidar. Desenvolvimento e esenvolvimento aplicacao de um modelo para previsao de demanda em jogos de empresas. **RAC-Electronica**, v. 2, n. 3, p. 470-486, 2008.
- KLEINSCHMITT, Sandra Cristiana; AZEVEDO, Paulo Roberto; CARDIN, Eric Gustavo. A tríplice fronteira internacional entre Brasil, Paraguai e Argentina: contexto histórico, econômico e social de um espaço conhecido pela violência e pelas práticas ilegais. **Perspectiva geográfica**, v. 8, n. 9, 2013.
- MARINS, Fernando Augusto Silva. **Técnicas de previsão**. Unesp, São Paulo, 2011.