

**UNIVERSIDADE DO ESTADO DO AMAZONAS
ESCOLA SUPERIOR DE TECNOLOGIA
CURSO DE ENGENHARIA DE PRODUÇÃO**

**INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE SÉRIES TEMPORAIS COM
MODELOS DE BASE**

**MANAUS
2025**

KAMILY PRADO LOPES NONATO

**INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE SÉRIES TEMPORAIS COM
MODELOS DE BASE**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Escola Superior de Tecnologia da Universidade do Estado do Amazonas, como parte dos requisitos para a obtenção do grau de Bacharel em Engenharia de Produção.

Orientador: Prof. Dr. Alessandro de Souza Bezerra.

**MANAUS
2025**

Ficha Catalográfica

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).
Sistema Integrado de Bibliotecas da Universidade do Estado do Amazonas.

N812i

Nonato, Kamily Prado Lopes

Inteligência artificial para previsão de séries temporais com modelos de base / Kamily Prado Lopes Nonato. Manaus : [s.n], 2025.
42 f.: color.; 21.0 cm.

TCC - Graduação em Engenharia de Produção- Universidade do Estado do Amazonas, Manaus, 2025.

Inclui Anexo.

Orientador: Alessandro de Souza Bezerra.

1. Timesfm. 2. Chronos-t5. 3. Inteligência artificial. 4. Zona Franca de Manaus. 5. Engenharia de produção. I. Alessandro de Souza Bezerra (Orient.) II. Universidade do Estado do Amazonas. III. Título

CDU(1997)658.5

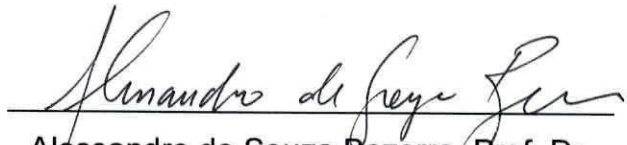
KAMILY PRADO LOPES NONATO

**INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE SÉRIES TEMPORAIS COM
MODELOS DE BASE**

Trabalho apresentado ao curso de Engenharia de Produção da Universidade do Estado do Amazonas, como requisito parcial para a obtenção do grau de Bacharel em Engenharia de Produção.

Data de aprovação: Manaus (AM), 13 de novembro de 2025.

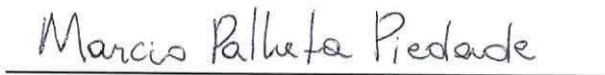
Banca examinadora:



Alessandro de Souza Bezerra, Prof. Dr.
Universidade do Estado do Amazonas



Renata da Encarnação Onety, Profa. Dra.
Universidade do Estado do Amazonas



Marcio Palheta Piedade, Prof. Dr.
Universidade do Estado do Amazonas

DEDICATÓRIA

Dedico este trabalho a Deus que me sustentou e me guiou até este momento, aos meus pais que sempre me apoiaram e me deram todo suporte que eu sempre precisei. Sou eternamente grata por cada um deles, pois sem eles jamais teria conseguido chegar até aqui.

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me proporcionado momentos tão incríveis de aprendizado ao longo desses anos de graduação, por ter me sustentado até aqui, por ter me dado todos os caminhos e respostas quando só me restavam dúvidas e incertezas. Por ter me permitido viver esse momento tão sonhado e almejado na minha vida profissional, a ele agradeço e dedico toda minha vida.

Agradeço aos meus pais por ter me dado todo apoio que precisei, pois sem eles não seria possível continuar.

Agradeço ao meu esposo, pelo apoio e incentivo ao longo dessa jornada, pela compreensão nos momentos de dedicação ao estudo e por estar ao meu lado em cada etapa deste percurso.

Agradeço em especial os meus amigos Eduardo, Thalia e Izabelle por ter me apoiado e me acompanhado desde o início nesse desafio que foi a graduação até esse momento, por ter vivido cada etapa comigo, cada prova, cada trabalho, sou eternamente grato a cada um deles e os levarei comigo pra sempre.

Agradeço ao meu professor orientador Alessandro Bezerra por ter me instruído e me dado os melhores caminhos para obter os melhores resultados na minha pesquisa científica, ele teve um papel fundamental para que eu pudesse alcançar o resultado que esperava.

Agradeço aos professores e à universidade pelo conhecimento compartilhado, pelas oportunidades de aprendizado e pelo ambiente de incentivo ao desenvolvimento acadêmico e profissional. Cada contribuição, orientação e recurso disponibilizado foram fundamentais para a realização deste trabalho e para minha formação ao longo da graduação.

Por fim, agradeço aos meus chefes Fernando Souza e Cláudio Ramalho pela oportunidade profissional que transformou minha trajetória. Essa experiência foi determinante para o meu crescimento técnico e analítico, e contribuiu diretamente para o desenvolvimento deste trabalho, no qual pude aplicar com propósito tudo o que aprendi.

RESUMO

Este trabalho tem como objetivo avaliar a eficiência dos *foundation models* (FMs) na previsão de séries temporais aplicadas ao faturamento do setor de termoplásticos da Zona Franca de Manaus, comparando-os com métodos estatísticos tradicionais, como Média Móvel e Suavização Exponencial. Utilizou-se abordagem quantitativa e experimental, com dados públicos da SUFRAMA referentes ao período de 2020 a 2025. Para aprimorar a robustez dos modelos, aplicou-se a Simulação de Monte Carlo, expandindo a série histórica. Os modelos analisados incluíram o *Amazon Chronos-T5* e o *Google TimesFM*, ambos baseados na arquitetura *Transformer*. As métricas de desempenho adotadas foram MSE, MAE e MAPE. Os resultados demonstraram que os modelos de base superaram os métodos clássicos em precisão e estabilidade, sendo o *TimesFM* o mais eficiente, seguido pelo *Chronos-T5*. Conclui-se que o uso de FMs melhora significativamente a acurácia das previsões, oferecendo suporte mais confiável à tomada de decisão e ao planejamento industrial na região amazônica.

Palavras-chave: *timesfm*; *chronos-t5*; inteligência artificial; Zona Franca de Manaus; engenharia de produção.

ABSTRACT

This study aims to evaluate the efficiency of Foundation Models (FMs) in time series forecasting applied to the revenue of the thermoplastics sector in the Manaus Free Trade Zone, comparing them with traditional statistical methods such as Moving Average and Exponential Smoothing. A quantitative and experimental approach was employed, using public data from SUFRAMA covering the period from 2020 to 2025. To enhance the robustness of the models, Monte Carlo Simulation was applied to expand the historical series. The analyzed models included Amazon Chronos-T5 and Google TimesFM, both based on the Transformer architecture. The performance metrics adopted were MSE, MAE, and MAPE. The results demonstrated that the foundation models outperformed classical methods in terms of accuracy and stability, with TimesFM being the most efficient, followed by Chronos-T5. It is concluded that the use of FMs significantly improves forecasting accuracy, providing more reliable support for decision-making and industrial planning in the Amazon region.

Keywords: timesfm; chronos-t5; artificial intelligence; Manaus Free Trade Zone; production engineering.

SUMÁRIO

1	INTRODUÇÃO	10
1.1	CONTEXTUALIZAÇÃO, PROBLEMA E JUSTIFICATIVA DA PESQUISA	11
1.2	HIPÓTESES	12
1.3	OBJETIVOS	12
1.3.1	Objetivo geral	12
1.3.2	Objetivos específicos	12
1.4	USO DE INTELIGÊNCIA ARTIFICIAL (IA) E CONSIDERAÇÕES ÉTICAS	13
1.5	ESTRUTURA DO TRABALHO.....	13
2	FUNDAMENTAÇÃO TEÓRICA	14
2.1	SIMULAÇÃO DE MONTE CARLO	14
2.2	PREVISÃO DE SÉRIES TEMPORAIS	15
2.3	MÉTODOS CLÁSSICOS DE PREVISÃO	15
2.3.1	Média móvel	16
2.3.2	Suavização exponencial	16
2.4	INTELIGÊNCIA ARTIFICIAL	17
2.5	IA GENERATIVA	17
2.5.1	ChatGPT	18
2.5.2	Gemini	18
2.5.3	Deepsek	19
2.6	<i>LARGE LANGUAGE MODEL</i>	19
2.7	MODELOS DE BASE	21
2.7.1	<i>TimesFM</i>	22
2.7.2	<i>Chronos-T5</i>	24
2.8	<i>MEAN SQUARED ERROR</i>	25
2.9	<i>MEAN ABSOLUTE ERROR</i>	25
2.10	<i>MEAN ABSOLUTE PERCENTAGE ERROR</i>	25
2.11	<i>ROOT MEAN SQUARED ERROR</i>	25

2.12	<i>BOXPLOT</i>	26
3	MATERIAIS E MÉTODOS	27
3.1	APRESENTAÇÃO DO CASO	27
3.2	TRATAMENTO DOS DADOS	27
3.3	APLICAÇÃO DAS FERRAMENTAS	28
3.3.1	Simulação de Monte Carlo	28
3.3.2	Média móvel	29
3.3.3	Suavização exponencial	29
3.3.4	Modelo Amazon <i>Chronos-T5</i>	29
3.3.5	Modelo Google <i>Timesfm</i>	30
3.4	APRESENTAÇÃO E ANÁLISE DOS RESULTADOS	30
4	RESULTADOS E DISCUSSÃO	31
5	CONCLUSÃO	36
	REFERÊNCIAS	37

1 INTRODUÇÃO

Nas últimas décadas, a previsão de séries temporais consolidou-se como uma das atividades centrais na gestão da produção e na tomada de decisões estratégicas em diversos setores econômicos. Métodos estatísticos tradicionais, como a média móvel e a suavização exponencial, vêm sendo amplamente utilizados por sua simplicidade e capacidade de capturar tendências históricas. No entanto, a crescente complexidade dos mercados, aliada ao aumento exponencial na geração de dados, exige abordagens mais adaptativas e inteligentes.

Nesse panorama, os *Foundation Models* (FMs) emergem como uma inovação promissora na previsão de séries temporais. Tais modelos são treinados em grandes volumes de dados e capazes de generalizar para múltiplas tarefas, extraíndo representações latentes profundas (Das *et al.*, 2024).

No contexto de *forecasting*, os FMs especializados em séries temporais, como *Chronos-T5* e *TimesFM*, são concebidos para capturar dependências temporais complexas e adaptarem-se a diferentes domínios (Das *et al.*, 2024). Eles se diferenciam claramente dos modelos de linguagem (LLMs), pois seus insumos e saídas são vetores numéricos ao longo do tempo, e não sequências de texto.

Segundo Rossi *et al.* (2023), a inteligência artificial tem desempenhado um papel cada vez mais relevante nas práticas de *previsão*, especialmente devido ao avanço de modelos generativos como os *Large Language Models*. Esses sistemas potencializam a identificação e interpretação de sinais fracos e tendências emergentes, permitindo que organizações e gestores realizem análises preditivas mais profundas e automatizadas. Assim, a integração entre IA e a *previsão* amplia a capacidade de antecipação estratégica, tornando os processos de decisão mais ágeis e embasados em grandes volumes de dados.

1.1 CONTEXTUALIZAÇÃO, PROBLEMA E JUSTIFICATIVA DA PESQUISA

A Zona Franca de Manaus (ZFM) constitui um dos pilares econômicos mais relevantes da região Norte do Brasil, sendo responsável por promover o desenvolvimento industrial, tecnológico e social da Amazônia Ocidental. Criada em 1967, sua principal função é estimular a industrialização e a integração econômica regional por meio de incentivos fiscais. Atualmente, o Polo Industrial de Manaus (PIM) abriga centenas de empresas nos segmentos de eletroeletrônicos, duas rodas,

termoplásticos, e componentes de informática, movimentando bilhões em faturamento anual.

Nesse contexto de alta complexidade produtiva, a previsão de séries temporais desempenha papel estratégico para o planejamento da produção, controle de estoques e alocação de recursos. Segundo Chopra e Meindl (2023), previsões imprecisas podem gerar tanto ociosidade quanto sobrecarga produtiva, afetando diretamente o desempenho financeiro e a competitividade das organizações. Tradicionalmente, as indústrias da ZFM utilizam modelos estatísticos clássicos, como médias móveis e suavização exponencial, por sua simplicidade e fácil implementação. Entretanto, esses métodos possuem limitações ao lidar com dados voláteis e comportamentos não lineares, características comuns em ambientes industriais e macroeconômicos (Hyndman & Athanasopoulos, 2021).

Com o avanço da Inteligência Artificial (IA) e do aprendizado profundo (*Deep Learning*), surgem novas abordagens que permitem capturar relações temporais complexas em grandes volumes de dados. Dentro desse cenário emergem os *Foundation Models* (FMs), que, conforme Bommasani *et al.* (2021), são modelos de base treinados em larga escala e capazes de generalizar para múltiplas tarefas com mínima adaptação. Aplicados a séries temporais, esses modelos, como o *Chronos-T5*, e o *TimesFM*, demonstram desempenho superior em tarefas de *forecasting* multivariado, apresentando resultados competitivos em relação aos métodos estatísticos tradicionais.

Apesar dos avanços teóricos e tecnológicos, ainda há escassez de estudos aplicados sobre o uso de *Foundation Models* em previsões de séries temporais em contextos industriais brasileiros, especialmente na região amazônica. Dessa forma, a questão que norteia este trabalho é: “Como os *Foundation Models* (*Chronos-T5* e *TimesFM*), se comparam aos métodos estatísticos tradicionais na previsão de faturamento no setor de termoplásticos do Polo Industrial de Manaus?”

O estudo justifica-se pela necessidade crescente de aprimorar as práticas de previsão em setores industriais estratégicos, como o da Zona Franca de Manaus. A adoção de técnicas inovadoras pode representar vantagem competitiva significativa, permitindo otimizar estoques, reduzir custos e melhorar a eficiência operacional.

Além disso, pesquisas que abordam *Foundation Models* aplicados à engenharia de produção ainda são incipientes, especialmente no contexto nacional. Segundo Vaswani *et al.* (2017), a arquitetura *Transformer*, base de modelos como

Chronos-T5 e *TimesFM*, revolucionou o campo da IA ao possibilitar aprendizado contextual em longas dependências temporais, tornando-se um marco para modelagem de séries complexas.

Assim, o presente trabalho busca contribuir tanto para o avanço científico quanto para a aplicação prática da IA na previsão de séries temporais, oferecendo uma análise comparativa entre modelos tradicionais e atuais. Espera-se que os resultados obtenham relevância acadêmica, tecnológica e regional, promovendo maior integração entre inovação e sustentabilidade industrial na Amazônia.

1.2 HIPÓTESES

H1: Os modelos de base (FMs) não apresentam desempenho estatisticamente superior aos métodos tradicionais de previsão de séries temporais (média móvel simples e suavização exponencial) na previsão do faturamento setorial da Zona Franca de Manaus.

H2: Os modelos de base (FMs) apresentam desempenho estatisticamente superior aos métodos tradicionais de previsão de séries temporais (média móvel simples e suavização exponencial) na previsão do faturamento setorial da Zona Franca de Manaus.

1.3 OBJETIVOS

1.3.1 Objetivo geral

Avaliar a eficiência de modelos de base (FMs) na previsão do faturamento mensal para o setor de termoplásticos da Zona Franca de Manaus, comparando seu desempenho com os métodos tradicionais de média móvel simples e suavização exponencial.

1.3.2 Objetivos específicos

- a) Identificar os principais métodos tradicionais utilizados na previsão de séries temporais, com foco na média móvel simples e na suavização exponencial;
- b) Coletar e tratar os dados públicos de faturamento setorial disponibilizados pela SUFRAMA;

- c) Aplicar modelos de base (FMs) à previsão do faturamento setorial da Zona Franca de Manaus;
- d) Avaliar métricas de desempenho do modelo através do RMSE(Root Mean Squared Error), MSE(*Mean Squared Error*) e MAE (*Mean Absolute Error*) e compará-las com as previsões obtidas por métodos tradicionais.

1.4 USO DE INTELIGÊNCIA ARTIFICIAL (IA) E CONSIDERAÇÕES ÉTICAS

A utilização de ferramentas baseadas em Inteligência Artificial (IA) neste trabalho ocorreu de forma auxiliar e não autoral, com o objetivo de aprimorar aspectos técnicos do texto. A IA foi empregada exclusivamente para apoio na correção ortográfica e gramatical, sem interferência na formulação das ideias, análises ou conclusões apresentadas pela autora.

Ferramentas como o Gemini 2.0 Flash e o ChatGPT (modelo GPT-5) foram utilizadas para revisão de ortografia, gramática e clareza textual, seguindo as normas da língua portuguesa e da ABNT. Todas as sugestões automatizadas foram analisadas, ajustadas e validadas manualmente, garantindo a integridade acadêmica, a originalidade e a responsabilidade ética na produção do conteúdo.

1.5 ESTRUTURAÇÃO DO TRABALHO

O presente trabalho está organizado em seis seções que se articulam de forma lógica para atender ao objetivo proposto. A primeira apresenta a introdução, com a contextualização, justificativa, objetivos, hipótese e aspectos éticos relacionados ao uso da Inteligência Artificial. A segunda reúne a fundamentação teórica sobre previsão de séries temporais, abordando desde métodos estatísticos tradicionais até os avanços com modelos de base.

A terceira descreve os materiais e métodos utilizados, incluindo a coleta e o tratamento dos dados, as simulações e a aplicação dos modelos analisados. A quarta expõe e compara os resultados obtidos, enquanto a quinta discute esses achados à luz da literatura científica recente. Por fim, a sexta seção apresenta as conclusões do estudo, suas contribuições e recomendações para futuras pesquisas.

2 FUNDAMENTAÇÃO TEÓRICA

O referencial teórico que se segue visa embasar a compreensão sobre métodos de previsão, abordando desde técnicas clássicas até as inovações impulsionadas pela inteligência artificial. Inicialmente, serão exploradas as principais abordagens estatísticas e seus papéis na tomada de decisão, destacando ferramentas como média móvel e suavização exponencial.

Em seguida, adentra-se o universo da IA, com ênfase nos modelos de linguagem de grande porte (LLMs) e modelos de base (FMs). Por fim, discutem-se métricas fundamentais para avaliação de desempenho, como MSE, MAE e MAPE que orientam a escolha e o aprimoramento dos modelos preditivos. Ao trilhar esse percurso, este capítulo revela como a evolução tecnológica tem potencializado a capacidade das organizações de antecipar demandas e se adaptar de forma mais inteligente e eficiente aos desafios do mercado.

2.1 SIMULAÇÃO DE MONTE CARLO

A simulação de Monte Carlo é uma técnica probabilística que permite analisar a propagação de incertezas em modelos complexos, fornecendo distribuições de probabilidade para as variáveis de saída em vez de apenas valores pontuais. De acordo com Gabbay (2010), esse método se baseia em sucessivas iterações, nas quais são sorteados valores de entrada a partir de distribuições estatísticas previamente definidas, permitindo estimar intervalos de confiança e cenários diversos para auxiliar na tomada de decisão.

Segundo Ulhôa *et al.* (2024), a aplicação da simulação de Monte Carlo em projetos possibilita avaliar riscos relacionados a prazos e custos, oferecendo maior transparência na comunicação com *stakeholders* e favorecendo a elaboração de planos de contingência. Os autores destacam que essa abordagem é superior à análise determinística tradicional, pois incorpora explicitamente a variabilidade presente nos processos.

Nesse sentido, autores como Dos Santos *et al.* (2017) reforçam que o uso da simulação de Monte Carlo em engenharia permite quantificar probabilidades de falhas estruturais ou atrasos em cronogramas, orientando gestores a alocar recursos de forma mais eficiente. Assim, a técnica consolida-se como uma ferramenta

essencial para a gestão de incertezas em diversos contextos, como finanças, logística, manutenção e engenharia civil.

2.2 PREVISÃO DE SÉRIES TEMPORAIS

A previsão de séries temporais fundamenta decisões em produção, gestão de estoques e planejamento financeiro. Lima e Oliveira (2016) observam que a aplicação dessas técnicas aprimora a elaboração de orçamentos, direciona ações de *marketing* e otimiza recursos, além de reduzir custos operacionais e garantir a disponibilidade de produtos no momento adequado.

Nas cadeias de suprimento, redes neurais artificiais têm se destacado por sua capacidade de modelar padrões complexos e variações sazonais, superando métodos convencionais em precisão (Silva *et al.*, 2023).

Sellitto (2022) ressalta que a eficácia das previsões depende da escolha de modelos compatíveis com o contexto de aplicação e da qualidade dos dados disponíveis. Entre as abordagens estatísticas, o modelo ARIMA é frequentemente citado por sua eficácia em explorar a autocorrelação temporal para reduzir erros de estimativa. O autor também chama atenção para fatores como a integridade das informações e a volatilidade do mercado, ressaltando a importância de soluções robustas para aprimorar o processo decisório.

Por fim, Linhares (2021) demonstra que, no varejo *omnichannel*, a incorporação de múltiplas fontes de dados — internas e externas — potencializa a acurácia das redes neurais, tornando o planejamento de estoques e a gestão logística ainda mais eficientes. Esse uso integrado de informações reforça a capacidade das empresas de antecipar demandas e ajustar rapidamente suas operações às mudanças do mercado.

2.3 MÉTODOS CLÁSSICOS DE PREVISÃO

Há diversas técnicas e modelos para previsão de demanda, incluindo métodos estatísticos e de otimização. Nesse contexto, as redes neurais emergem como uma alternativa promissora, especialmente para lidar com padrões complexos e não lineares nos dados de demanda (Ballou, 2006). Alguns dos métodos clássicos de previsão de demanda são: média móvel e suavização exponencial.

2.3.1 Média móvel

A média móvel (MM) é uma técnica estatística usada para suavizar séries temporais e reduzir flutuações de curto prazo, permitindo a visualização de tendências de longo prazo. Esse método calcula a média de um conjunto de observações anteriores, o que ajuda a identificar o comportamento subjacente da demanda. O principal benefício da média móvel é sua simplicidade e a facilidade de implementação, o que a torna ideal para empresas com poucos recursos computacionais (Viletti *et al.*, 2016).

As médias móveis desempenham um papel importante na análise de séries temporais, especialmente na suavização de flutuações de curto prazo e na identificação de tendências subjacentes. De acordo com Majka (2023), diferentes tipos de médias — como a simples, ponderada e exponencial — podem ser aplicadas com base na característica dos dados e no objetivo da análise, sendo úteis na construção de modelos preditivos mais robustos. A equação da média móvel é expressa a seguir na equação (1).

$$MM = \frac{X_1 + X_2 + \dots + X_N}{N} \quad (1)$$

2.3.2 Suavização exponencial

A suavização exponencial é uma técnica que atribui pesos decrescentes a observações passadas, priorizando dados mais recentes para a previsão. Souza *et al.* (2022) destacam que esse método é eficaz para ambientes em que a demanda sofre alterações rápidas, permitindo uma atualização constante das previsões. Ele pode ser implementado de várias formas, como a suavização exponencial simples, que é ideal para dados sem tendência ou sazonalidade, e as variantes de *Holt* e *Holt-Winters*, que lidam com séries temporais com tendência e sazonalidade, respectivamente.

Apesar de suas vantagens, a suavização exponencial também tem suas limitações. Moraes (2024) ressalta que o desempenho do modelo depende do ajuste adequado dos parâmetros, especialmente do fator de suavização alfa. Se os parâmetros não forem bem ajustados, a previsão pode se tornar imprecisa. Além

disso, a suavização exponencial não é adequada para séries com comportamentos altamente não lineares ou com mudanças abruptas, já que a técnica assume que as tendências são suaves e contínuas, o que limita sua eficácia em ambientes com grandes variações.

2.4 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) é uma área da Ciência da Computação dedicada ao desenvolvimento de sistemas capazes de executar tarefas que, tradicionalmente, requerem a inteligência humana. Esses sistemas têm a habilidade de aprender, raciocinar, tomar decisões e resolver problemas, simulando processos cognitivos humanos (Carraro, 2023).

Considerando os avanços recentes, especialmente com os modelos de linguagem de grande porte, a IA tem se mostrado uma tecnologia transformadora, capaz de redefinir práticas analíticas em diversas áreas, incluindo a previsão de demanda, onde oferece ganhos significativos em precisão e adaptabilidade frente aos métodos convencionais.

A Inteligência Artificial refere-se à habilidade de dispositivos eletrônicos operarem de modo semelhante ao pensamento humano, percebendo variáveis, tomando decisões e solucionando problemas. Em essência, seu objetivo é criar sistemas capazes de simular o raciocínio, a percepção e a tomada de decisão humanas (Barbosa, Portes, 2023).

2.5 IA GENERATIVA

A IA Generativa é um campo da inteligência artificial focado em algoritmos que criam novos conteúdos. Diferentemente de outras IAs que se concentram em tarefas como classificação, predição e reconhecimento de padrões, a IA generativa se distingue pela sua capacidade de produzir material inédito, como textos, imagens, músicas ou códigos, com base nos dados em que foi treinada (Kanbach *et al*, 2024; Chiu, 2023).

O Aprendizado de Máquina (*machine learning*) é um pilar da IA Generativa e uma vertente da inteligência artificial que se baseia em técnicas conexionistas. Seu

foco é desenvolver modelos e algoritmos que capacitam os sistemas de computador a aprender por meio da análise de grandes volumes de dados (Zhou, 2021).

Em vez de seguir instruções programadas de forma rígida, o *machine learning* utiliza métodos estatísticos para identificar padrões e extrair informações, permitindo que os modelos façam previsões e classificações precisas, mesmo com dados novos, por meio da capacidade de generalização. Essa tecnologia é fundamental para diversas aplicações, incluindo análise de imagens, reconhecimento de voz, recomendações personalizadas e diagnósticos (Zhou, 2021).

2.5.1 ChatGPT

O *ChatGPT* é uma inteligência artificial do tipo generativa, destacando-se como uma das plataformas pioneiras a alcançar ampla popularidade a partir de 2015. Inicialmente disponibilizado de forma gratuita, o sistema evoluiu ao longo dos anos, chegando às versões mais recentes que oferecem modalidades de acesso tanto gratuito quanto pago. Segundo Kaufman (2022), o GPT-3, lançado em junho de 2020, foi treinado com aproximadamente 500 bilhões de palavras.

A *OpenAI* desenvolveu o GPT (*Generative Pre-trained Transformer*), que consiste em duas fases principais: o pré-treinamento e o ajuste fino. O pré-treinamento ocorre em grandes volumes de textos da internet, permitindo que o modelo aprenda padrões gerais da linguagem e do conhecimento humano. Já o ajuste fino pode ser feito com técnicas como *supervised fine-tuning* (SFT) ou *Reinforcement Learning with Human Feedback* (RLHF), que adicionam camadas de alinhamento com preferências humanas, garantindo respostas mais úteis, seguras e coerentes (Ouyang *et al.*, 2022).

2.5.2 Gemini

Gemini é um modelo de inteligência artificial (IA) multimodal desenvolvido pelo *Google*, projetado para projetar e gerar informações a partir de diferentes tipos de dados, como texto, imagens, áudio e vídeo. O interesse acadêmico e prático pela *Gemini* cresce devido às suas emoções e potencial de aplicação em áreas como educação, saúde, robótica e atendimento ao cliente (Imran, Almusharraf, 2024).

A versão inicial, *Gemini 1.0*, foi disponibilizada em três variantes: Ultra, para tarefas complexas; Pro, para escalabilidade em diversas funções; e Nano, otimizada

para dispositivos móveis. O modelo já começou a ser incorporado a produtos do *Google*, como o *Bard* e o *Pixel 8 Pro*, e deve se expandir para outros serviços, incluindo Busca, Ads, *Chrome* e *Duet AI*. Além disso, desenvolvedores e clientes corporativos poderão acessar suas capacidades mais avançadas por meio da API do *Gemini* no *Google AI Studio* e no *Vertex AI* (CNN Brasil, 2023).

2.5.3 Deepseek

No dia 27 de janeiro de 2025, a *startup* chinesa *DeepSeek* provocou forte queda nas ações de grandes empresas de tecnologia, como *Nvidia*, *Oracle*, *Apple* e *Microsoft*, após lançar um assistente digital gratuito que utiliza menos dados e custa significativamente menos do que os modelos das companhias ocidentais. Fundada em 2023 por Liang Wenfeng, ligado ao fundo de *hedge High-Flyer*, a empresa ultrapassou o *ChatGPT* em *downloads* na *App Store*, oferecendo uma alternativa viável e acessível de inteligência artificial (CNN BRASIL, 2025).

O fundador defende que o objetivo da *DeepSeek* não é capturar usuários ou gerar lucros excessivos, mas promover a inovação global de forma barata e eficiente, aproveitando a escala econômica da China. A empresa afirma ainda que sua tecnologia supera o *GPT-4o* em 20 das 22 métricas avaliadas. O movimento, considerado disruptivo, levanta debates sobre a sustentabilidade dos altos investimentos em IA e reforça a importância da acessibilidade tecnológica no cenário internacional (CNN BRASIL, 2025).

2.6 LARGE LANGUAGE MODEL

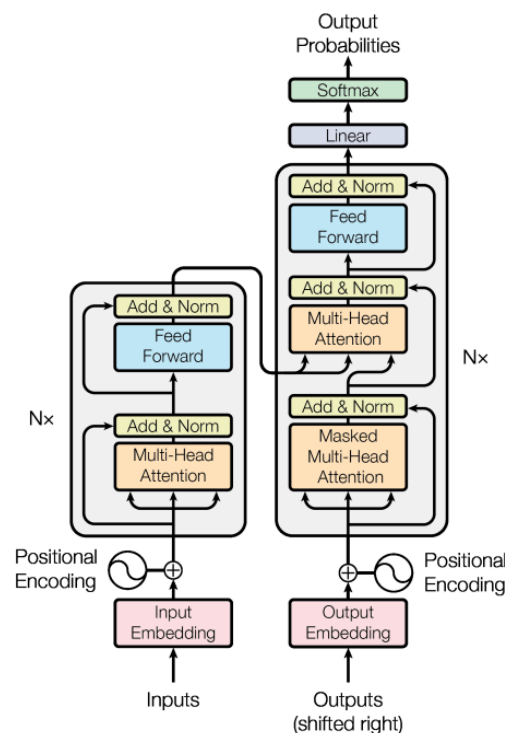
Modelos de linguagem de grande porte (LLMs) são sistemas de inteligência artificial treinados com enormes volumes de dados, capazes de interpretar e gerar diferentes tipos de conteúdo, como textos, imagens e conversas. Ao contrário dos modelos específicos para cada tarefa, os LLMs oferecem versatilidade, podendo ser aplicados em diversas funções sem a necessidade de múltiplos treinamentos custosos (IBM, 2023).

Para Ozdemir (2023) LLMs representam um dos maiores avanços da inteligência artificial nos últimos anos, sendo desenvolvidos com base em arquiteturas de redes neurais profundas, especialmente os *Transformers*.

O *Transformer* é uma arquitetura de redes neurais projetada para lidar com dados sequenciais e que transformou o campo do processamento de linguagem natural (Vaswani *et al.*, 2017). Baseado na estrutura *encoder-decoder*, o modelo recebe, codifica e decodifica informações para gerar a saída, tendo como principal diferencial o mecanismo de atenção, responsável por analisar diferentes partes do contexto, identificar os elementos mais relevantes e acelerar o aprendizado.

Sua arquitetura é composta por camadas que desempenham funções complementares: a de *embedding*, que converte dados, como textos, em vetores preservando o contexto; a de atenção, que relaciona os vetores entre si e enfatiza os mais importantes; e a Rede Neural Totalmente Conectada, que processa essas informações e realiza o aprendizado. Dessa forma, os *Transformers* se consolidaram como modelos altamente eficientes e de grande desempenho em tarefas de linguagem natural (Vaswani *et al.*, 2017), como demonstra a Figura 1.

Figura 1 - Arquitetura de um *Transformer*



Fonte: Vaswani *et al.* 2017

Diferentemente de abordagens anteriores, os LLMs não se limitam a regras explícitas ou bancos de respostas fixos, mas operam a partir de representações estatísticas que possibilitam prever a próxima palavra em uma sequência com alto

grau de coerência e contextualização. Dessa forma, a inovação dos *Transformers* permitiu a evolução dos LLMs para sistemas cada vez mais poderosos, capazes de generalizar tarefas e se aproximar da forma como os humanos processam e produzem a linguagem.

Por fim, Malinen (2024) afirma que os modelos de linguagem de grande porte estão entre as inovações mais significativas no campo da inteligência artificial e do processamento de linguagem natural. Baseados em arquiteturas avançadas de redes neurais, esses sistemas são capazes de analisar e gerar textos com notável coerência, fluidez e sensibilidade ao contexto, aproximando-se cada vez mais da forma como os humanos se comunicam.

2.7 MODELOS DE BASE

Treinados com volumes massivos de dados, os *foundation models* (modelos de base) são redes neurais profundas de grande porte que transformaram a maneira de pensar do cientista de dados. Em vez de criar Inteligência Artificial do zero, esses modelos já pré existentes servem como alicerce para o desenvolvimento de aplicações de *machine learning*, acelerando o processo e reduzindo custos (AWS, 2024).

O termo “modelo de base” refere-se a modelos treinados com uma vasta gama de dados gerais, muitas vezes não rotulados, e capazes de desempenhar tarefas diversas, compreender linguagem, gerar texto ou imagens e interagir em linguagem natural (AWS, 2024).

Bommasani *et al.*(2021) abordam os *foundation models* como sistemas de aprendizado em larga escala, treinados de forma abrangente e projetados para adaptação a múltiplas tarefas com mínima necessidade de ajuste. Embora amplamente aplicados em domínios como o processamento de linguagem natural e a visão computacional, sua aplicação em séries temporais ainda desponta como um campo emergente e em expansão.

Os modelos de base caracterizam-se por uma abordagem de aprendizado abrangente e generalista. Fundamentam-se em arquiteturas de redes neurais profundas, treinadas sobre grandes volumes de dados amplos, heterogêneos e predominantemente não rotulados. Esse processo demanda expressiva capacidade computacional, rigorosos procedimentos de coleta e tratamento de dados, além de elevado nível de expertise técnica. Após o treinamento, o modelo de base torna-se

capaz de ser ajustado e especializado para a execução de uma ampla variedade de tarefas, podendo inclusive ser disponibilizado para uso público (Kelly, 2024).

A principal característica dos *foundation models* é a capacidade de atuarem como estrutura universal para diversas tarefas subsequentes. Essa versatilidade é alcançada por meio de um processo em duas etapas: pré-treinamento e ajuste fino.

- a) **Pré-treinamento:** nessa fase, o modelo é exposto a grandes conjuntos de dados, com o objetivo de capturar padrões gerais, estruturas e dependências. No contexto das séries temporais, o pré-treinamento busca aprender representações que descrevam relações temporais, interações multivariadas e padrões periódicos presentes em bases de dados diversas (Bommasani *et al.*, 2021). Assim, o modelo é capaz de compreender estruturas comuns das séries, como sazonalidade e mudanças de tendência, sem estar vinculado a uma tarefa específica (Wen *et al.*, 2023).
- b) **Ajuste fino para tarefas específicas:** após o pré-treinamento, o modelo pode ser ajustado para tarefas particulares, como previsão, detecção de anomalias ou classificação. Essa etapa permite adaptar o conhecimento generalizado adquirido anteriormente às peculiaridades de um conjunto de dados específico, frequentemente com necessidade mínima de dados rotulados (Bommasani *et al.*, 2021).

2.7.1 *TimesFM*

O *TimesFM* (*Time Series Foundation Model*), desenvolvido pelo *Google Research*, representa uma inovação no campo da previsão de séries temporais, ao transpor a lógica dos modelos de fundação utilizados em Processamento de Linguagem Natural (PLN) para o domínio temporal. De acordo com os pesquisadores do *Google*, o *TimesFM* é um modelo baseado em *transformers* do tipo *decoder-only*, pré-treinado em aproximadamente 100 bilhões de pontos de séries temporais reais, oriundos de múltiplos domínios (Das *et al.*, 2024). Essa estratégia permite que o modelo seja capaz de realizar previsões em cenários inéditos por meio do chamado *zero-shot forecasting*, sem necessidade de treinamento específico.

Portanto, o *TimesFM* configura-se como uma mudança de paradigma: um modelo fundacional capaz de aprender a partir de uma massa colossal de dados temporais e, a partir desse repertório, gerar previsões precisas e adaptáveis em diferentes domínios. Essa característica o consolida como referência no avanço da inteligência artificial aplicada à previsão, alinhando-se à tendência de modelos cada vez mais generalistas e escaláveis.

2.7.2 *Chronos-T5*

O *Chronos* é um modelo de base da *Amazon*, projetado para prever séries temporais. Sendo univariado, ele se concentra na previsão de uma única variável por vez, como por exemplo, o pico diário de preço de uma ação. O modelo processa as séries temporais, transformando-as em "*tokens*" (elementos discretos) através de normalização e quantização, permitindo que o mecanismo de aprendizado os interprete. O treinamento do *Chronos* utiliza uma função de perda de entropia cruzada, capacitando-o a capturar e representar padrões de alta complexidade nos dados (Wong *et al.*, 2023).

Ansari *et al.*(2024) destaca que o *Chronos* realiza a tokenização de séries temporais ao discretizar os valores contínuos por meio de processos de escalonamento e quantização. Essa estratégia possibilita o treinamento de modelos de linguagem pré-existentes nessa "linguagem de séries temporais", sem a necessidade de modificações estruturais na arquitetura do modelo.

De forma notável, essa abordagem demonstra elevada eficácia e eficiência, evidenciando o potencial das arquiteturas de modelos de linguagem em lidar com uma ampla variedade de problemas relacionados a séries temporais, demandando apenas ajustes mínimos (Ansari *et al.*, 2024) .

Versões ajustadas do modelo, como o *Chronos T5 Small*, têm sido aplicadas em contextos industriais, como na previsão de discrepâncias em sistemas de transferência de custódia de petróleo e gás. Nesses estudos, o *Chronos T5* superou modelos estatísticos e de aprendizado profundo em métricas como erro absoluto médio (MAE) e erro percentual simétrico médio (SMAPE), destacando-se por capturar incertezas probabilísticas e fornecer previsões mais precisas (Hidayat; Nasution, 2025).

2.8 MEAN SQUARED ERROR

O Erro Quadrático Médio (MSE) é uma métrica amplamente adotada na avaliação de modelos de regressão, por medir a média dos quadrados das diferenças entre os valores previstos e os valores observados, conforme expresso na equação 2. Quanto menor for o valor do MSE, melhor é o desempenho do modelo, sendo que um MSE igual a zero representa a situação ideal, indicando que as previsões coincidem exatamente com os dados reais (Montgomery, Runger, 2018).

$$\text{MSE} = \frac{1}{n} \sum (Y_i - \hat{Y}_i)^2 \quad (2)$$

2.9 MEAN ABSOLUTE ERROR

IBM (2023) afirma que o Erro Médio Absoluto (MAE) é uma métrica estatística que representa a média das diferenças absolutas entre os valores previstos por um modelo (em um horizonte de previsão de um passo à frente) e os valores reais observados. Em termos matemáticos, o MAE é definido pela equação 3.

$$\text{MAE} = \frac{1}{n} \sum (Y_i - \hat{Y}_i) \quad (3)$$

2.10 MEAN ABSOLUTE PERCENTAGE ERROR

O Erro Percentual Absoluto Médio (MAPE, do inglês *Mean Absolute Percentage Error*) é uma métrica amplamente utilizada para avaliar a acurácia de modelos de previsão, especialmente em séries temporais e regressão (Das *et al.*, 2024). O MAPE é calculado pela média dos valores absolutos dos erros percentuais entre as previsões e os valores reais, conforme na equação 4.

$$\text{MAPE} = \frac{1}{n} \sum \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (4)$$

2.11 ROOT MEAN SQUARED ERROR

O *Root Mean Squared Error* (RMSE) é uma das métricas mais amplamente utilizadas para avaliar a qualidade de modelos de previsão em séries temporais. Ele

mede a magnitude média dos erros cometidos pelo modelo, atribuindo maior penalidade aos desvios maiores por meio da elevação ao quadrado. O RMSE corresponde à raiz quadrada da média dos erros quadráticos, o que o torna especialmente sensível a picos de erro ou valores aberrantes (Frost, 2025).

Essa característica é relevante em contextos industriais, nos quais desvios expressivos podem gerar impactos significativos no planejamento de capacidade, custos e alocação de recursos. Assim, quanto menor o RMSE, maior a aderência do modelo aos valores reais observados, indicando previsões mais precisas e confiáveis. Além disso, por manter a mesma unidade da variável analisada, o RMSE facilita a interpretação e comparação direta dos resultados entre diferentes modelos preditivos (DataCamp, 2023).

$$RSME = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{N - P}} \quad (5)$$

2.12 BOXPLOT

O *boxplot* é uma representação gráfica que sintetiza a distribuição estatística de um conjunto de dados por meio de cinco medidas essenciais: mínimo, primeiro quartil (Q1), mediana, terceiro quartil (Q3) e máximo. A área retangular destaca o intervalo interquartil (IQR), que contém 50% das observações centrais, permitindo visualizar rapidamente a dispersão e a concentração dos valores (Rabello, 2024).

As linhas externas (*whiskers*) estendem-se até os limites inferior e superior, sinalizando o alcance dos dados, enquanto pontos fora desses limites correspondem a potenciais outliers. Em análises de desempenho de modelos de previsão, o *boxplot* é particularmente útil por evidenciar não apenas o erro médio, mas também a variabilidade e a estabilidade das estimativas ao longo do tempo. Modelos com caixas mais estreitas e medianas mais baixas tendem a produzir previsões mais consistentes (Neto *et al.*, 2017).

Assim, o *boxplot* se torna uma ferramenta visual importante para comparar diferentes abordagens preditivas, destacando padrões, assimetrias e dispersões que complementam a análise numérica das métricas.

3 MATERIAIS E MÉTODOS

O estudo utilizou uma abordagem quantitativa e experimental, baseada na aplicação de *foundation models* (FMs) para a previsão de séries temporais, comparando suas performances com os resultados obtidos por métodos tradicionais (Média Móvel e Suavização Exponencial).

3.1 APRESENTAÇÃO DO CASO

O estudo concentra-se na previsão de demanda do Setor Termoplástico do Polo Industrial de Manaus (PIM), cuja dinâmica é marcada por alta volatilidade e forte influência de fatores econômicos, tributários e logísticos — características que exigem modelos robustos para apoiar decisões de supply chain e investimento.

Os dados utilizados consistem em séries históricas mensais de faturamento, disponibilizadas publicamente no site oficial do Governo (gov.br), na página de Indicadores Industriais da SUFRAMA. O período considerado vai de janeiro de 2020 a julho de 2025. Como os dados originais são apresentados em múltiplas colunas por setor, foi necessário realizar um processo de despivotamento para convertê-los para o formato longo.

Tabela 1 - Fonte de dados

MÊS	(Valores Nominais em R\$ 1,00)						(Valores em US\$ 1,00)					
	Termoplástico						Termoplástico					
	2020	2021	2022	2023	2024	2025(*)	2020	2021	2022	2023	2024	2025(*)
JANEIRO	598.200.168	959.936.765	1.249.049.187	1.286.318.242	1.397.718.685	1.518.031.442	139.603.306	178.095.875	233.144.657	252.253.886	282.167.898	260.378.285
FEVEREIRO	568.095.563	1.105.863.297	1.165.162.920	1.147.716.152	1.431.784.366	1.542.994.009	127.082.201	199.968.048	226.711.857	220.384.069	287.316.510	263.813.775
MARÇO	592.663.279	1.263.726.446	1.368.695.498	1.326.732.681	1.426.079.290	1.569.286.295	114.015.367	221.811.463	288.888.408	261.147.288	285.432.787	273.290.080
ABRIL	493.833.269	1.168.297.192	1.217.153.946	1.243.671.069	1.517.247.384	1.589.342.161	91.005.689	216.207.194	249.324.828	248.699.396	293.369.307	280.762.818
MAIO	472.403.473	1.219.216.255	1.287.563.563	1.383.654.567	1.570.242.366	1.668.636.097	87.067.747	233.021.722	272.275.490	271.523.100	302.132.372	292.297.037
JUNHO	612.238.650	1.232.045.162	1.255.051.713	1.307.115.490	1.618.218.205	1.636.461.474	111.816.242	246.300.660	239.605.138	271.230.804	293.703.506	299.877.494
JULHO	689.489.668	1.184.718.610	1.422.561.653	1.285.192.639	1.780.456.165	1.795.711.588	132.525.356	231.318.067	274.181.184	271.051.912	314.451.558	320.542.580
SUB-TOTAL	4.026.924.070	8.133.803.727	8.965.238.480	8.980.400.840	10.741.746.461	11.320.463.064	803.115.908	1.526.723.029	1.784.131.562	1.796.290.455	2.058.573.938	1.990.962.069
CRESC. PERÍODO	0,00 %	101,99 %	10,22 %	0,17 %	19,61 %	5,39 %	0,00 %	90,10 %	16,86 %	0,68 %	14,60 %	-3,28 %
AGOSTO	710.221.472	1.222.786.612	1.481.778.653	1.351.931.878	1.768.063.413	-	129.808.541	237.743.591	286.112.889	274.676.828	312.588.560	-
SETEMBRO	874.313.024	1.252.983.526	1.331.754.488	1.296.085.705	1.561.418.215	-	155.000.802	230.353.261	246.320.144	258.823.729	286.598.670	-
OUTUBRO	1.014.573.276	1.228.440.921	1.204.372.009	1.103.065.139	1.566.549.155	-	175.781.087	217.692.880	229.098.727	218.104.822	271.127.772	-
NOVEMBRO	1.004.790.032	1.237.473.453	1.245.193.827	1.075.591.553	1.409.727.868	-	188.455.846	220.194.924	235.204.062	217.929.602	232.878.148	-
DEZEMBRO	928.068.029	1.162.302.354	1.131.640.939	1.063.303.315	1.306.240.110	-	178.587.956	208.297.913	216.885.014	219.631.776	210.945.870	-
TOTAIS	8.558.889.903	14.237.790.593	15.359.978.396	14.870.378.430	18.353.745.222	11.320.463.064	1.630.750.140	2.641.005.598	2.997.752.398	2.985.457.212	3.372.712.958	1.990.962.069

Fonte: SUFRAMA, 2025.

3.2 TRATAMENTO DOS DADOS

Todo o processamento e a análise dos dados foram realizados no ambiente *Google Colaboratory* (Colab), que utiliza a versão 3.12 da linguagem *Python*. Essa plataforma é amplamente empregada em pesquisas e projetos de ciência de dados

devido à sua interface intuitiva, facilidade de uso e acesso simplificado a recursos computacionais em nuvem.

O tratamento dos dados foi realizado integralmente utilizando a linguagem *Python* (bibliotecas *Pandas* e *NumPy*), seguindo três etapas principais:

- a) Transformação estrutural: A tabela original, onde os setores e os anos eram apresentados em colunas, foi convertida para o formato longo;
- b) Filtragem: Em seguida, o *dataset* foi filtrado para isolar apenas a série histórica do Setor de Termoplásticos, que é o foco da pesquisa;
- c) Simulação de Monte Carlo: Para aumentar a robustez do treinamento dos FMs, foram gerados 100 meses de dados sintéticos através da Simulação de Monte Carlo, baseada na distribuição probabilística normal.

A série temporal utilizada no treinamento foi ampliada para 167 meses, composta por 67 meses reais combinados a 100 meses sintéticos. Os 13 meses reais, equivalentes a 20% do total de dados observados, foram reservados exclusivamente para a etapa de teste e validação da acurácia.

3.3 APLICAÇÃO DAS FERRAMENTAS

A pesquisa focou na aplicação e comparação de dois modelos de *foundation model* para séries temporais com métodos estatísticos tradicionais.

3.3.1 Simulação de Monte Carlo

A limitação da série histórica original impossibilitava o uso adequado de modelos avançados de previsão, que exigem longas janelas temporais. Para contornar essa restrição, foi adotada uma abordagem de Simulação Monte Carlo com Movimento Geométrico Browniano, calibrado a partir dos log-retornos reais para reproduzir tendência e volatilidade do processo. Essa técnica permitiu gerar 100 meses sintéticos retroativos, formando um histórico mais amplo e consistente para o treinamento dos modelos.

A metodologia incorporou sazonalidade explícita, extraída por decomposição temporal da série real. O padrão sazonal anual foi identificado, normalizado e replicado ao longo do período sintético, sendo integrado às trajetórias estocásticas

por meio de um modelo multiplicativo, abordagem mais realista para séries econômicas crescentes. Além disso, foram executadas 1.000 simulações independentes, cuja agregação pela mediana garantiu robustez contra trajetórias extremas.

Por fim, os dados sintéticos foram concatenados aos dados reais, originando uma série expandida que preserva continuidade temporal, tendência, volatilidade e ciclos sazonais observados. Esses valores serviram exclusivamente para ampliar o contexto de treinamento dos modelos; todas as validações e métricas de desempenho foram calculadas apenas sobre dados reais, assegurando rigor metodológico e confiabilidade estatística.

3.3.2 Média móvel

Esta técnica suaviza as flutuações de curto prazo e destaca tendências de longo prazo. A média móvel é calculada a partir da média de um subconjunto de dados sequenciais, ajudando a reduzir o ruído e a identificar a direção geral da série. No *script*, implementa-se uma função que utiliza uma janela deslizante de 12 meses, calculado iterativamente a média dos últimos 12 pontos para gerar cada previsão futura, com os valores previstos sendo incorporados à série para previsões subsequentes.

3.3.3 Suavização exponencial

Este método atribui pesos exponencialmente decrescentes às observações passadas. Ou seja, dados mais recentes recebem maior importância, o que torna o modelo ágil para se adaptar a novas tendências. A implementação utiliza o modelo *Exponential Smoothing* com componentes aditivos tanto para tendência quanto para sazonalidade, configurado com período sazonal de 12 meses e método de inicialização estimado automaticamente. Para séries com menos de 24 observações, o modelo degrada graciosamente para *Simple Exponential Smoothing* sem componente sazonal.

3.3.4 Modelo *Amazon Chronos-T5*

O modelo utilizado foi o *amazon/chronos-t5-small*, aplicado por meio da biblioteca *Chronos* com a classe *ChronosPipeline*. Este *foundation model* baseado

na arquitetura T5 foi configurado para usar GPU quando disponível (com precisão *bfloat16* para economia de memória) ou CPU como *fallback*. O modelo gera 100 amostras probabilísticas para cada previsão, utilizando a mediana da distribuição como previsão pontual, permitindo assim quantificação de incerteza nas previsões.

3.3.5 Modelo *Google Timesfm*

O modelo utilizado foi o *TimesFM 2.5* com 200M parâmetros. Ele foi aplicado por meio da biblioteca *timesfm* com configurações específicas para séries temporais financeiras. A alta capacidade do *TimesFM* em lidar com longos contextos temporais, alcançando até 1024 pontos de contexto, foi explorada para permitir a absorção de séries históricas estendidas.

O modelo foi configurado com horizonte máximo de 256 passos, normalização automática de *inputs*, cabeçalho quantílico contínuo para previsões probabilísticas, invariância a inversões, inferência de positividade para valores monetários, e correção de cruzamento de quantis para garantir coerência nas previsões intervalares.

3.4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

A comparação entre os modelos baseados em *Foundation Models* (*Chronos-T5* e *TimesFM*) e os métodos tradicionais (Média Móvel e Suavização Exponencial) foi realizada utilizando indicadores de acurácia como MSE, MAE e MAPE, aplicados sobre seis meses de dados de teste. Além disso, a análise dos resultados contemplou a discussão sobre o desempenho relativo dos FMs, destacando sua vantagem percentual em relação aos métodos estatísticos convencionais e a capacidade desses modelos de lidar melhor com a incerteza das previsões.

4 RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados os resultados obtidos a partir da aplicação dos modelos de previsão. A análise comparativa concentrou-se na acurácia dos *foundation models* (*Chronos-T5* e *TimesFM*) em relação aos métodos tradicionais (Média Móvel e Suavização Exponencial de *Holt-Winters*), com base nas métricas de erro e na inspeção visual das previsões.

A série histórica de faturamento do setor termoplástico foi expandida por meio da Simulação de Monte Carlo, com o objetivo de fornecer aos modelos um contexto temporal mais robusto. Conforme argumenta Agdestein (2025), a geração de dados sintéticos amplia a capacidade de generalização de modelos baseados em *deep learning*, permitindo que aprendam padrões de longo prazo antes de enfrentarem a volatilidade dos dados reais. Essa abordagem mostrou-se particularmente vantajosa para os modelos *TimesFM* e *Chronos-T5*, que dependem de contextos amplos para capturar sazonalidades e tendências mais complexas.

Como ilustrado no Gráfico 1, os 100 meses de dados sintéticos (linha laranja), gerados por meio de uma simulação de Monte Carlo com inclusão explícita de sazonalidade e tendência, permitiram estender a série histórica de forma realista e coerente. Essa ampliação fornece um contexto temporal mais rico e consistente para o treinamento dos *foundation models*.

A linha azul representa os dados reais de faturamento, cobrindo o período de janeiro de 2020 a julho de 2025. A linha pontilhada vertical marca o ponto de transição entre os dados sintéticos e os dados observados, indicando com precisão o início da série real.

Gráfico 1 - Série histórica expandida



Fonte: elaborado pela autora (2025).


Essa prática está alinhada à perspectiva de Aria, Iranmanesh e Hassani, (2024), que apontam que o pré-treinamento em dados híbridos (reais e simulados)

tende a reduzir o *overfitting* e a melhorar a estabilidade preditiva, especialmente em contextos corporativos onde as oscilações de demanda e faturamento são comuns. No presente estudo, essa abordagem mostrou-se particularmente benéfica para o *TimesFM*, cuja arquitetura foi projetada para aproveitar contextos temporais extensos com múltiplos horizontes de previsão.

A avaliação do desempenho foi conduzida por meio de um teste de validação referente ao período de janeiro a julho de 2025, abrangendo seis meses de teste. Conforme apresentado no Gráfico 2, tanto o *TimesFM 2.5* quanto o *Chronos-T5* demonstraram alta capacidade de acompanhar a trajetória dos valores reais, com previsões mais aderentes à tendência observada em comparação aos métodos tradicionais.

O *Chronos-T5* apresentou o menor Erro Absoluto Médio (MAE), de R\$ 93 milhões, seguido pelo *TimesFM*, com R\$ 113 milhões. Já o *Holt-Winters* alcançou um MAE de R\$ 182 milhões, capturando parcialmente a direção da tendência, mas com menor precisão. O método de Média Móvel, por sua vez, apresentou o maior erro médio (R\$ 249 milhões), indicando limitação na adaptação à volatilidade específica da série no período analisado.

Gráfico 2 - Teste consolidado



Fonte: elaborado pela autora (2025).

Legenda:



Conforme mostra a Tabela 1, o *Chronos-T5* obteve o menor erro médio absoluto e percentual, seguido de perto pelo *TimesFM 2.5*. Esses achados estão em consonância com Achour *et al.* (2025), que observaram desempenho superior dos *foundation models Chronos* e *TimesFM* em comparação com métodos estatísticos em contextos de dados limitados. Tal vantagem decorre da capacidade de generalização proporcionada pelo pré-treinamento extensivo e pela arquitetura *Transformer*, que permite maior sensibilidade a dependências de longo prazo.

Tabela 2 - Métricas de Erro dos Modelos

Modelo	MSE	RMSE	MAE	MAPE
Média Móvel	6,24E+31	249.877.412,66	214.668.964,48	12,95%
Holt-Winters	3,32E+32	182.275.559,24	161.889.544,84	10,51%
TimesFM 2.5	1,93E+31	138.853.212,05	113.903.798,00	7,12%
Chronos-T5	1,53E+32	123.594.376,18	93.363.730,15	5,73%

Fonte: elaborada pela autora (2025).

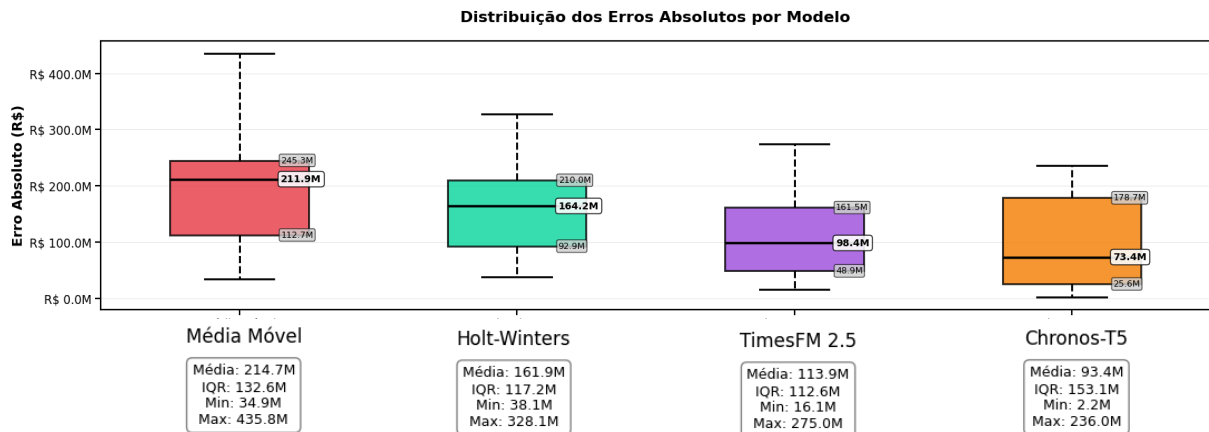
Legenda: MSE - *Mean Squared Error*, MAE - *Mean Absolute Error*, MAPE - *Mean absolute percentage error*, RMSE - *Root Mean Squared Error*

A análise das métricas de erro apresentadas na Tabela 1 permite comparar, de forma objetiva, o desempenho dos métodos tradicionais de previsão (Média Móvel e Holt-Winters) com os *foundation models TimesFM 2.5* e *Chronos-T5*.

A análise comparativa dos boxplots de Erro Absoluto (R\$) e Erro Percentual (%) nos Gráficos 1 e 2 demonstram que o modelo *Chronos-T5* é o mais preciso, apresentando as menores médias e medianas de erro em ambas as métricas (Erro Absoluto mediano de R\$ 73,4M e Erro Percentual mediano de 4,4%). No entanto, o *Chronos-T5* exibe a maior variabilidade (maior Intervalo Interquartil - IQR) entre todos os modelos, sugerindo uma menor consistência e um risco superior de ocorrência de erros de grande magnitude.

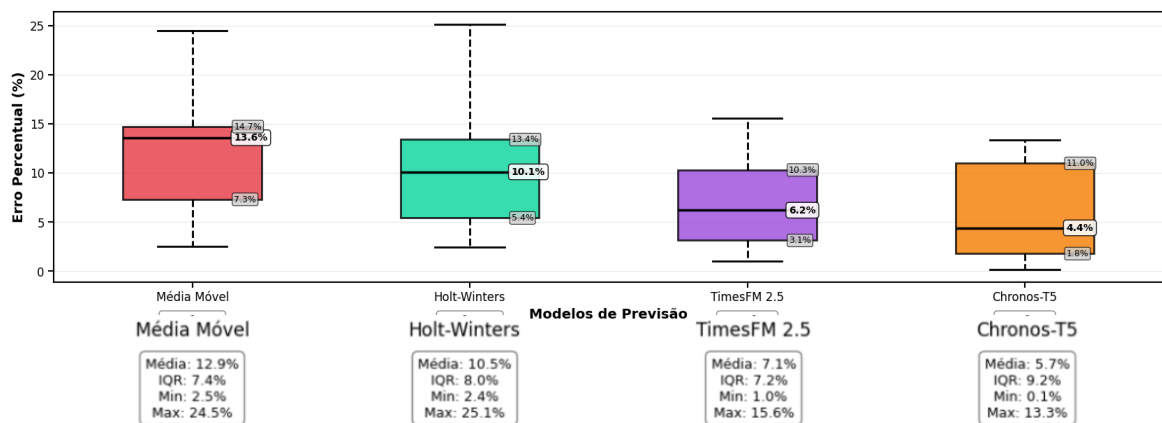
Em contraste, o modelo *TimesFM 2.5* se posiciona como o segundo mais preciso, o mais consistente, registrando o menor IQR de Erro Percentual (7.2%). O modelo Média Móvel consistentemente apresentou o pior desempenho em todos os critérios. Conclui-se que a escolha ideal reside entre a alta precisão do *Chronos-T5* e a elevada consistência do *TimesFM 2.5*.

Gráfico 3 - Gráfico Boxplot dos Erros Absolutos



Fonte: elaborado pela autora (2025).

Gráfico 4 - Gráfico Boxplot dos Erros Percentuais



Fonte: elaborado pela autora (2025).

Os resultados mostram que os modelos clássicos apresentaram os maiores valores em todas as métricas, evidenciando limitações para capturar a dinâmica complexa e volátil do setor termoplástico. A Média Móvel exibiu o pior desempenho geral, com altos erros quadráticos e absolutos, refletindo sua incapacidade de incorporar tendência ou sazonalidade. O Holt-Winters, embora mais robusto, ainda mostrou erros elevados, indicando que sua estrutura paramétrica não foi suficiente para modelar adequadamente as oscilações da série.

Em contraste, os foundation models TimesFM 2.5 e Chronos-T5 apresentaram reduções expressivas em todas as métricas, demonstrando maior capacidade de aprendizado dos padrões temporais. O TimesFM já evidenciou ganhos substanciais, especialmente ao reduzir o RMSE e o MAPE, indicando previsões mais próximas das variações reais.

Entretanto, o melhor desempenho foi obtido pelo Chronos-T5, que registrou os menores valores para as métricas de erros, consolidando-se como o modelo mais preciso. Seu MAPE de 5,73% representa um erro percentual significativamente baixo para séries industriais, enquanto o MAE e o RMSE indicam uma redução notável no erro absoluto e na dispersão das previsões.

De modo semelhante, Puvvada e Chaudhuri (2024) identificaram o *TimesFM* como o modelo com melhor desempenho em métricas de acurácia em diferentes granularidades temporais, especialmente em séries com forte sazonalidade e variabilidade. Essa evidência sustenta o resultado encontrado neste estudo, no qual o *TimesFM* se destacou em previsões de curto e médio prazo.

Por outro lado, o desempenho inferior do modelo de *Holt-Winters* indica que, embora métodos clássicos sejam eficazes em séries com padrão sazonal bem definido, sua estrutura paramétrica tende a falhar em ambientes com comportamento não linear e ruído elevado, uma limitação já destacada por Ahmadpour, Haghghat Jou e Mirhashemi (2023). Assim, o contraste entre o *Holt-Winters* e os modelos base reforça a transição paradigmática da modelagem estatística tradicional para abordagens baseadas em aprendizado profundo.

Além disso, a arquitetura *Transformer*, utilizada tanto no *TimesFM* quanto no *Chronos-T5*, permite um aprendizado hierárquico de padrões temporais complexos, captando relações de longo alcance entre observações distantes no tempo — algo que modelos como *Holt-Winters* não são capazes de representar adequadamente.

Do ponto de vista teórico, o desempenho dos FMs também dialoga com o conceito de aprendizado transferível discutido por Smith e Brown (2025), no qual o conhecimento adquirido em domínios amplos (pré-treinamento) é transferido para contextos específicos. Essa transferência de aprendizado explica a habilidade dos modelos de se adaptarem rapidamente a novas séries.

Os resultados desta pesquisa indicam que os *foundation models* oferecem vantagens expressivas em precisão, robustez e adaptabilidade em relação aos métodos tradicionais.

Essas evidências reforçam que os modelos baseados em *deep learning* são mais adequados para aplicações corporativas que exigem previsões confiáveis em ambientes dinâmicos e incertos.

5 CONCLUSÃO

Os resultados obtidos neste estudo demonstram que os Modelos de Base (*foundation models*), em especial o *TimesFM 2.5* e o *Chronos-T5*, superam de forma significativa os métodos estatísticos tradicionais na tarefa de previsão do faturamento do setor de Termoplásticos da Zona Franca de Manaus. A análise revelou que ambos os modelos apresentaram menores valores de erro (MAE e MAPE) e maior estabilidade preditiva, confirmando sua capacidade de capturar padrões temporais complexos e dinâmicos mesmo em ambientes de alta volatilidade.

Esses achados corroboram as evidências de Achour *et al.* (2025), que destacam o desempenho superior dos *Time Series Foundation Models* devido ao pré-treinamento massivo e à utilização de técnicas de *Conformal Prediction*, e de Puvvada e Chaudhuri (2024), que apontam o *TimesFM* como referência em previsão de demanda em diferentes granularidades temporais. Dessa forma, o estudo valida empiricamente a aplicabilidade e robustez desses modelos no contexto industrial amazônico.

Do ponto de vista prático, a adoção de modelos de base na previsão de demanda pode contribuir diretamente para a otimização da produção, redução de custos operacionais e melhoria na tomada de decisão estratégica das empresas do Polo Industrial de Manaus. Do ponto de vista científico, a pesquisa amplia o entendimento sobre o uso de IA e modelos pré-treinados em contextos econômicos.

Dessa forma, os resultados obtidos reforçam o papel estratégico da Inteligência Artificial como instrumento de inovação e competitividade para o Polo Industrial de Manaus. A aplicação de modelos de base na previsão de séries temporais mostra-se não apenas tecnicamente superior, mas também viável como suporte à gestão industrial e ao planejamento econômico. Assim, este estudo contribui para aproximar o campo da engenharia de produção das tecnologias emergentes em aprendizado profundo, evidenciando o potencial da ciência de dados para impulsionar decisões mais assertivas

REFERÊNCIAS

- ACHOUR, Sami *et al.* Foundation models for time series forecasting: Application in conformal prediction. **ArXiv preprint arXiv:2507.08858**, 2025. Disponível em: <https://arxiv.org/abs/2507.08858>. Acesso em: 19 out. 2025.
- AGDESTEIN, I. **Dados sintéticos na IA: o que são e porque são importantes**. Focalx. 2025. Disponível em: <https://focalx.ai/pt-pt/inteligencia-artificial/dados-sinteticos-na-ia-o-que-sao-e-porque-sao-importantes/>. Acesso em: 31 out. 2025.
- AHMADPOUR, Abbas; HAGHIGHAT JOU, Parviz; MIRHASHEMI, Seyed Hassan. Comparison of classic time series and artificial intelligence models, various Holt-Winters hybrid models in predicting the monthly flow discharge in Marun dam reservoir. **Applied water science**, v. 13, n. 6, 2023. Disponível em: <https://link.springer.com/article/10.1007/s13201-023-01944-z>. Acesso em: 31 out. 2025.
- ANSARI, Abdul Fatir *et al.* Chronos: Learning the language of time series. **ArXiv preprint arXiv:2403.07815**, 2024. Disponível em: <https://arxiv.org/abs/2403.07815>. Acesso em: 12 set. 2025.
- ARIA, Seyed Sina; IRANMANESH, Seyed Hossein; HASSANI, Hossein. Optimizing Multivariate Time Series Forecasting with Data Augmentation. **Journal of Risk and Financial Management**, v. 17, n. 11, p. 485, 2024. Disponível em: <https://www.mdpi.com/1911-8074/17/11/485>. Acesso em: 31 out. 2025.
- AWS. **O que são Modelos de Base?**, 2023. Disponível em: <https://aws.amazon.com/what-is/foundation-models/>. Acesso em: 15 set. 2025.
- BALLOU, Ronald H. **Gerenciamento da cadeia de suprimentos: logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.
- BARBOSA, Lucia Martins; PORTES, Luiza Alves Ferreira. A inteligência artificial. **Revista Tecnologia Educacional**, Rio de Janeiro, n. 236, p. 16-27, 2023. Disponível em: https://abt-br.org.br/wp-content/uploads/2023/03/RTE_236.pdf#page=16. Acesso em: 9 jun. 2025.
- BOMMASANI, Rishi. On the opportunities and risks of foundation models. **ArXiv preprint arXiv:2108.07258**, 2021. Disponível em: <https://arxiv.org/abs/2108.07258>. Acesso em: 12 set. 2025.
- CARRARO, Fabrício. **Inteligência Artificial e ChatGPT: da revolução dos modelos de IA generativa à Engenharia de Prompt**. São Paulo: Casa do Código, 2023. 223 p.
- CHIU, Thomas KF. The impact of Generative AI (GenAI) on practices, policies and research direction in education: A case of ChatGPT and Midjourney. **Interactive Learning Environments**, v. 32, n. 10, p. 6187-6203, 2024. Disponível em:

<https://www.tandfonline.com/doi/abs/10.1080/10494820.2023.2253861>. Acesso em: 17 set. 2025.

CHOPRA, Sunil; MEINDL, Peter. **Supply Chain Management: Strategy, Planning, and Operation**. 8. ed. New York: Pearson, 2023.

CNN BRASIL. Entenda o que é DeepSeek, IA que derrubou ações de tecnologia nesta segunda. **CNN Brasil**, São Paulo, 27 jan. 2025. Disponível em: <https://www.cnnbrasil.com.br/economia/entenda-o-que-e-deepseek-ia-que-derrubou-aco-es-de-tecnologia-nesta-segunda/>. Acesso em: 25 ago. 2025.

CNN BRASIL. Tudo sobre Gemini, nova inteligência artificial do Google. **CNN Brasil**, São Paulo, 6 dez. 2023. Disponível em: <https://www.cnnbrasil.com.br/tecnologia/tudo-sobre-gemini-nova-inteligencia-artificial-do-google/>. Acesso em: 28 ago. 2025.

DAS, Abhimanyu *et al.* A decoder-only foundation model for time-series forecasting. In: **Forty-first International Conference on Machine Learning**. 2024. Disponível em: <https://openreview.net/forum?id=jn2iTJas6h>. Acesso em: 14 out. 2025.

DAS, Abhimanyu *et al.* In-Context Fine-Tuning for Time-Series Foundation Models. **arXiv preprint arXiv:2410.24087**, 2024. Disponível em: <https://arxiv.org/abs/2410.24087>. Acesso em: 24 ago. 2025.

DATA CAMP. **Root Mean Square Error (RMSE): o que é e como calcular**. DataCamp, 2023. Disponível em: <https://www.datacamp.com/pt/tutorial/rmse>. Acesso em: 28 nov. 2025.

DOS SANTOS, Danilo Silva et al. **Análise de confiabilidade geotécnica de um edifício comercial construído em fundações profundas**. 2019. Disponível em: http://pvista.proevento.com.br/qe/subpaper/upload/594961_216_Artigo___Confiabilidade_rev_4.pdf. Acesso em: 25 ago. 2025.

FROST, Jim. **Root Mean Square Error (RMSE)**. Statistics By Jim, 2023. Disponível em: <https://statisticsbyjim.com/regression/root-mean-square-error-rmse/> Acesso em: 28 nov. 2025.

GABBAY, M. **Simulação de Monte Carlo para mensuração do risco operacional: aplicação do modelo LDA**. 2010. Dissertação do Curso de Pós-Graduação em Administração de Empresas – Universidade Presbiteriana Mackenzie, São Paulo, 2010. Disponível em: <https://dspace.mackenzie.br/bitstreams/bbb2a820-1335-4720-af18-cc3aa4fda0ef/download>. Acesso em: 15 set. 2025.

HIDAYAT, Fiki et al. Leveraging Large Language Models for Discrepancy Value Prediction in Custody Transfer Systems: a comparative analysis of probabilistic and point forecasting approaches. **IEEE Access**, 2025. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10964215>. Acesso em: 17 set. 2025.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 3. ed. Melbourne: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>. Acesso em: 12 out. 2025.

IBM. **Detalhes estatísticos da previsão**. [S.l.], 2023. Disponível em: <https://www.ibm.com/docs/pt-br/cognos-analytics/11.1.0?topic=forecasting-statistical-details>. Acesso em: 1 mar. 2025.

IBM. **O que é LLM (large language models)?** [S.l.], 2 nov. 2023. Disponível em: <https://www.ibm.com/br-pt/think/topics/large-language-models>. Acesso em: 9 jun. 2025.

IMRAN, Muhammad; ALMUSHARRAF, Norah. **Google Gemini as a next generation AI educational tool: a review of emerging educational technology**. *Smart Learning Environments*, v. 11, n. 1, p. 22, 2024. Disponível em: <https://link.springer.com/article/10.1186/s40561-024-00310-z>. Acesso em: 18 set. 2025.

KANBACH, Dominik K. et al. The GenAI is out of the bottle: generative artificial intelligence from a business model innovation perspective. **Review of Managerial Science**, v. 18, n. 4, 2024. Disponível em: <https://link.springer.com/article/10.1007/s11846-023-00696-z>. Acesso em: 18 set. 2025.

KAUFMAN, Dora. Um projeto de futuro. **Piauí**, São Paulo, 2021. Disponível em: <https://piaui.folha.uol.com.br/um-projeto-de-futuro/>. Acesso em: 27 jul. 2025.

KELLY, Conor. Modelos de fundação: explicados. **Humanloop**, [S.l.], 11 abr. 2024. Disponível em: <https://humanloop.com/blog/foundation-models>. Acesso em: 1 out. 2025.

LIMA, Vladimir de; OLIVEIRA, Pedro. **Previsão de demanda: o básico que você precisa saber**. São Paulo: Baraúna, 2016. *E-book*. Disponível em: https://books.google.com.br/books/about/Previs%C3%A3o_de_Demanda.html?id=TAVVEQAAQBAJ&redir_esc=y. Acesso em: 1 out. 2025.

LINHARES, Eduardo Correia Lima. **Previsão de demanda através de redes neurais em um ambiente de omnicanalidade no varejo**. 2021. 94 f. Dissertação (Mestrado em Engenharia de Produção e Sistemas) – Programa de Pós-Graduação Stricto Sensu, Pontifícia Universidade Católica de Goiás, Goiânia, 2021. Disponível em: <https://tede2.pucgoias.edu.br/bitstream/tede/4759/2/Eduardo%20Correia%20Lima%20Linhares.pdf>. Acesso em: 30 mar. 2025.

MAJKA, M. Moving averages in time series analysis: understanding trends & forecasting. **ResearchGate**, [S.l.], 2023. Disponível em: https://www.researchgate.net/publication/381851904_Moving_Averages_in_Time_Series_Analysis_Understanding_Trends_Forecasting. Acesso em: 21 abr. 2025.

MALINEN, Esko. **Interactive document summarizer using LLM technology**. Dissertação (Mestrado em Ciência e Tecnologia) — School of Engineering Science, LUT University, Lappeenranta, 2024. Disponível em: <https://lutpub.lut.fi/handle/10024/167149>. Acesso em: 9 jun. 2025.

MONTGOMERY, Douglas C.; RUNGER, George C. **Applied statistics and probability for engineers**. John Wiley & Sons, 2010. *E-book* Disponível em: https://books.google.com.br/books?hl=pt-BR&lr=&id=_f4KrEcNAfEC&oi=fnd&pg=PA1&dq=Applied+Statistics+and+Probability+for+Engineers.&ots=ZAuX4hg9Vg&sig=bL_R-9YE69fguFA6pE4sbZ7BZWA#v=onepage&q=Applied%20Statistics%20and%20Probability%20for%20Engineers.&f=false. Acesso em: 18 set. 2025.

MORAES, Sofia Marcon de. **Previsão de demanda com base em séries temporais e análise de desperdício de alimentos: estudo de caso em uma galeteria no Distrito Federal**. 2024. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) – Pontifícia Universidade Católica do Rio Grande do Sul, Porto Alegre, 2024. Disponível em: https://repositorio.pucrs.br/dspace/bitstream/10923/27054/1/2024_2_SOFIA_MARCON_DE_MORAES_TCC.pdf. Acesso em: 20 abr. 2025.

NETO, José Valladares *et al.* Boxplot: um recurso gráfico para a análise e interpretação de dados quantitativos. **Revista Odontológica do Brasil Central**, v. 26, n. 76, p. 1-10, abr. 2017. Disponível em: <https://www.robrac.org.br/seer/index.php/ROBRAC/article/view/1132/897>. Acesso em: 1 dez. 2025.

OUYANG, L. et al. Training language models to follow instructions with human feedback. **ArXiv preprint arXiv:2203.02155**, 2022. Disponível em: <https://arxiv.org/abs/2203.02155>. Acesso em: 9 jun. 2025.

OZDEMIR, Sinan. **Quick Start Guide to Large Language Models: Strategies and Best Practices for Using ChatGPT and Other LLMs**. 1. ed. Boston: Addison-Wesley Professional, 2023. 288 p. *E-book*. Disponível em: https://books.google.com/books?hl=pt-BR&lr=&id=aDvVEAAAQBAJ&oi=fnd&pg=PT18&dq=Quick+Start+Guide+to+Large+Language+Models:+Strategies+and+Best+Practices+for+Using+ChatGPT+and+Other+LLMs&ots=9h1-C6F1YJ&sig=hJhFiV_y4voiAzMIXGSI1LWYRbw. Acesso em: 18 out. 2025.

PUVVADA, Santosh Kumar; CHAUDHURI, Satyajit. Critical Evaluation of Time Series Foundation Models in Demand Forecasting. In: **NeurIPS Workshop on Time Series in the Age of Large Models**. Disponível em: <https://openreview.net/forum?id=TS42sRKINd>. Acesso em: 19 out. 2025.

RABELLO, Guilherme. Boxplot — o que é e como usar essa técnica. **Siteware**. 2024. Disponível em: <https://www.siteware.com.br/blog/gestao-estrategica/boxplot/>. Acesso em: 28 nov. 2025.

ROSSI, Gustavo Aprile Porto et al. O papel da inteligência artificial na prática de foresight. In: **SIMPÓSIO INTERNACIONAL DE GESTÃO DE PROJETOS, INOVAÇÃO E SUSTENTABILIDADE**, 11., 2023, São Paulo. São Paulo: UNINOVE,

2023. Disponível em: <https://submissao.singep.org.br/11singep/arquivos/201.pdf>. Acesso em: 9 jun. 2025.

SELLITTO, Miguel Afonso; ACKERMANN, Andres Eberhard Friedl. Métodos de previsão de demanda: uma revisão da literatura. **Innovar**. [S.l.], jul. 2022. Disponível em: <https://revistas.unal.edu.co/index.php/innovar/article/view/100979>. Acesso em: 30 mar. 2025.

SILVA, Jailson dos Santos et al. Previsão de demanda em cadeias de suprimentos: uma revisão das abordagens baseadas em redes neurais artificiais. In: **ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 43., 2023. Disponível em: https://www.researchgate.net/publication/375109570_PREVISAO_DE_DEMANDA_EM_CADEIAS_DE_SUPRIMENTOS_UMA_REVISAO_DAS_ABORDAGENS_BASEADAS_EM_REDES_NEURAI_ARTIFICIAIS. Acesso em: 30 mar. 2025.

SMITH, J.; BROWN, T. Benchmarking time series forecasting models on real-world hotel industry data. **ArXiv** preprint **arXiv:2502.03395**, 2025. Disponível em: <https://arxiv.org/abs/2502.03395>. Acesso em: 24 ago. 2025.

SOUZA, C. C. et al. Previsão de produção de cana-de-açúcar e seus derivados, através de ARIMA, no período de 2020 a 2025, na macrorregião Centro-Sul do Brasil. **Research, Society and Development**, São Paulo, v. 11, n. 4, 2022. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/27048>. Acesso em: 20 abr. 2025.

SUFRAMA. **Indicadores de Desempenho do Polo Industrial de Manaus**. Manaus, 2025. Disponível em: <https://www.gov.br/suframa/pt-br/centrais-de-conteudo/indicadores/2025/IndicaJUL25>. Acesso em: 12 set. 2025.

ULHÔA, C. G. et al. Avaliação de riscos relacionados a prazos: aplicação da simulação de Monte Carlo. **ResearchGate**, [S.l.], 2024. Disponível em: https://www.researchgate.net/publication/380276679_Avaliacao_de_riscos_relacionados_a_prazos_-_aplicacao_da_simulacao_de_Monte_Carlo. Acesso em: 15 set. 2025.

VASWANI, Ashish et al. Attention is all you need. In: **ADVANCES IN NEURAL INFORMATION PROCESSING SYSTEMS**, 30., 2017. **Proceedings of the 30th Conference on Advances in Neural Information Processing Systems**. [S.l.: s.n.], 2017. p. 5998-6008. Disponível em: <https://arxiv.org/abs/1706.03762>. Acesso em: 9 jun. 2025.

VILETTI, R. et al. Previsão de demanda: uma análise quantitativa baseada em média móvel simples e média móvel centrada em uma empresa fabricante de salgados. In: **ENCONTRO DE ENGENHARIA DE PRODUÇÃO AGROINDUSTRIAL**, 10., 2016. Disponível em: https://www.fecilcam.br/anais/x_eepa/data/uploads/1-engenharia-de-operacoes-e-processos-da-producao/1-02.pdf. Acesso em: 20 abr. 2025.

WEN, Qingsong et al. Transformers in time series: A survey. **ArXiv** preprint **arXiv:2202.07125**, 2023. Disponível em: <https://arxiv.org/abs/2202.07125>. Acesso em: 13 set. 2025.

WONG, Albert et al. Translating Natural Language Queries to SQL Using the T5 Model. In: **2024 IEEE International Systems Conference (SysCon)**. IEEE, 2024. Disponível em: <https://ieeexplore.ieee.org/abstract/document/10553509>. Acesso em: 1 out. 2025.

ZHOU, Zhi-Hua. **Machine learning**. Springer nature, 2021. *E-book*. Disponível em: https://books.google.com.br/books?hl=pt-BR&lr=&id=ctM-EAAAQBAJ&oi=fnd&pg=PR6&dq=Machine+learning.+Springer+Nature.&ots=o_Oh-0Tv1v&sig=hIRoRNjrgHvfRfLAyyTa_f1nPXs. Acesso em: 1 out. 2025.