

UTILIZAÇÃO DE INTELIGÊNCIA ARTIFICIAL PARA SIMULAÇÃO DE DEMANDAS EM PERÍODOS SAZONAIS: UM ESTUDO APLICADO AO VAREJO BRASILEIRO DE TECIDOS, VESTUÁRIO E CALÇADOS

USE OF ARTIFICIAL INTELLIGENCE FOR DEMAND SIMULATION IN
SEASONAL PERIODS: A STUDY APPLIED TO BRAZILIAN TEXTILE, APPAREL
AND FOOTWEAR RETAIL

Engenharias • 26/10/2026

REGISTRO DOI: [10.70773/revistatopicos/792986326](https://doi.org/10.70773/revistatopicos/792986326)

Francisco Kevin Lima Alves¹

RESUMO

Este artigo compara métodos estatísticos e modelos de aprendizado de máquina na previsão do índice agregado de volume de vendas do varejo brasileiro de tecidos, vestuário e calçados e na geração de cenários probabilísticos para períodos sazonais. Utiliza-se a série mensal da Pesquisa Mensal de Comércio do IBGE, de janeiro de 2000 a julho de 2026. Random Forest, XGBoost, LightGBM e rede neural Multilayer Perceptron (MLP) são comparados com o sazonal ingênuo, Holt-Winters e SARIMA. A avaliação por origem móvel compreende 744 previsões por modelo na validação e 510 no teste, também analisadas pela data de divulgação dos dados. Os cenários são gerados por simulação de Monte Carlo com bootstrap de trajetórias de erros históricos. O Holt-Winters apresenta o menor erro geral no teste (MAPE de 3,09%); os modelos baseados em árvores têm MAPE superior ao da referência ingênua. Em dezembro, a MLP tem o menor MAPE no teste (2,35%, contra 4,00% do Holt-Winters), com vantagem em três dos quatro dezembros pós-pandemia, mas não nos seis dezembros da validação. Os intervalos simulados são conservadores no teste, sobretudo por incluírem erros da recessão de 2015–2016, e subestimam a incerteza em 2022. Para dezembro de 2026, as medianas são 172,5 pontos no Holt-Winters e 166,2 na MLP, sendo as do Holt-Winters sensíveis ao histórico reamostrado. Os resultados indicam desempenho distinto conforme o mês-alvo e o período, sem permitir generalização direta para a demanda de empresas ou produtos. Código e dados estão disponíveis em repositório público.

Palavras-chave: Previsão de demanda; Inteligência artificial; Sazonalidade; Simulação de Monte Carlo; Vestuário e calçados.

ABSTRACT

This article compares statistical methods and machine learning

models for forecasting the aggregate sales volume index of Brazilian textile, apparel and footwear retail and generating probabilistic scenarios for seasonal periods. It uses the monthly series from the IBGE Monthly Trade Survey, from January 2000 to July 2026. Random Forest, XGBoost, LightGBM and a Multilayer Perceptron (MLP) neural network are compared with seasonal naive, Holt-Winters and SARIMA methods. Rolling-origin evaluation comprises 744 forecasts per model for validation and 510 for testing, also analysed by data release date. Scenarios are generated through Monte Carlo simulation with bootstrap resampling of historical error trajectories. Holt-Winters has the lowest overall test error (MAPE of 3.09%); tree-based models have higher MAPE than the naive benchmark. In December, the MLP has the lowest test MAPE (2.35%, compared with 4.00% for Holt-Winters), with an advantage in three of the four post-pandemic Decembers, but not in the six validation Decembers. Simulated intervals are conservative in the test period, mainly because they include errors from the 2015–2016 recession, and underestimate uncertainty in 2022. For December 2026, the medians are 172.5 index points for Holt-Winters and 166.2 for the MLP, with Holt-Winters results sensitive to the resampled error history. The results indicate performance differences by target month and period, without allowing direct generalization to demand at company or product level. Code and data are available in a public repository.

Keywords: Demand forecasting; Artificial intelligence; Seasonality; Monte Carlo simulation; Apparel and footwear.

1. INTRODUÇÃO

O planejamento da demanda é uma das atividades centrais da Engenharia de Produção. É a partir das previsões de vendas que as

empresas dimensionam a capacidade produtiva, programam compras de matérias-primas, definem níveis de estoque e organizam a distribuição (Tubino, 2020; Slack; Brandon-Jones; Johnston, 2018). Na cadeia de suprimentos, a qualidade dessas previsões afeta diretamente o nível de serviço e os custos de toda a rede (Syntetos et al., 2016), e erros de previsão podem representar perdas financeiras relevantes para as organizações (Veiga et al., 2012).

O desafio é maior em setores com forte sazonalidade, como o de tecidos, vestuário e calçados. Nesse segmento, datas comemorativas e eventos comerciais (Dia das Mães, *Black Friday* e Natal) concentram parcela expressiva das vendas em poucos meses, enquanto os prazos de desenvolvimento, produção e abastecimento são longos, o que obriga as empresas a decidir com meses de antecedência quanto produzir para cada pico (Thomassey, 2010; Nenni; Giustiniano; Pirolo, 2013). Nos dados da Pesquisa Mensal de Comércio (PMC) do Instituto Brasileiro de Geografia e Estatística (IBGE), o volume de vendas do varejo brasileiro desse segmento em dezembro chega a quase o dobro do volume de um mês típico, como se detalha na seção 4. Superestimar o pico gera excesso de estoque, remarcações e capital imobilizado; subestimá-lo provoca rupturas e perda de vendas justamente no período de maior faturamento.

Nas últimas décadas, os métodos estatísticos clássicos de séries temporais, como o amortecimento exponencial de Holt-Winters e os modelos SARIMA de Box e Jenkins, consolidaram-se como referência para a previsão de demandas sazonais (Box et al., 2015; Hyndman; Athanasopoulos, 2021). Mais recentemente, técnicas de inteligência artificial (IA), em especial os algoritmos de aprendizado de máquina (*machine learning*), como florestas aleatórias, *gradient*

boosting e redes neurais artificiais, passaram a ser aplicadas com frequência crescente à previsão de demanda (Carbonneau; Laframboise; Vahidov, 2008; Januschowski et al., 2022).

As evidências sobre a superioridade dessas técnicas, porém, não são unânimes. Makridakis, Spiliotis e Assimakopoulos (2018) observaram que métodos estatísticos superaram diversos métodos de aprendizado de máquina na previsão de séries mensais. Na competição M4, o melhor resultado foi obtido por um método híbrido que combina amortecimento exponencial e redes neurais (Makridakis; Spiliotis; Assimakopoulos, 2020; Smyl, 2020), enquanto na competição M5, baseada em dados de varejo, os modelos de *gradient boosting* do tipo LightGBM dominaram as primeiras posições (Makridakis; Spiliotis; Assimakopoulos, 2022). No Brasil, estudos aplicados encontraram vantagem das redes neurais em casos específicos (Veiga et al., 2012; Jacobs; Zanini; Costa, 2014), geralmente com dados de uma única empresa e com foco apenas na previsão pontual.

A previsão probabilística é amplamente discutida na literatura, mas sua utilidade para o planejamento depende da avaliação no contexto em que será aplicada. Uma previsão pontual informa um único valor e não explicita a incerteza envolvida. Para discutir capacidade e estoques em períodos sazonais, o planejador precisa examinar faixas de valores plausíveis e probabilidades associadas aos cenários (Gneiting; Katzfuss, 2014; Petropoulos et al., 2022). Neste estudo, a simulação de Monte Carlo utiliza trajetórias históricas de erros para gerar cenários do índice setorial de vendas e avaliar a qualidade dessas distribuições. O interesse aplicado está em verificar conjuntamente a acurácia pontual e a previsão probabilística para essa série agregada do varejo brasileiro.

Diante desse contexto, este estudo busca responder à seguinte questão: como modelos de inteligência artificial e métodos estatísticos tradicionais se comparam na previsão do índice de volume de vendas e na geração de cenários probabilísticos para os períodos sazonais do varejo brasileiro de tecidos, vestuário e calçados?

O objetivo geral é avaliar o desempenho de modelos de IA (Random Forest, XGBoost, LightGBM e rede neural Multilayer Perceptron) em comparação com métodos estatísticos (sazonal ingênuo, Holt-Winters e SARIMA) na previsão do índice agregado de vendas e na simulação de cenários sazonais, utilizando a série histórica oficial do IBGE de janeiro de 2000 a julho de 2026. Os objetivos específicos são: (i) caracterizar o padrão sazonal da série e suas mudanças recentes; (ii) comparar a acurácia fora da amostra dos modelos em diferentes horizontes de previsão e nos meses de pico; (iii) examinar a cobertura dos intervalos e a qualidade das distribuições geradas por simulação de Monte Carlo; e (iv) aplicar o procedimento para gerar cenários do índice de vendas para o fim de ano de 2026 e maio de 2027.

A pesquisa justifica-se por sua aplicação ao Planejamento e Controle da Produção (PCP) e ao planejamento de vendas e operações de empresas do setor. Sua contribuição é oferecer evidências para uma série pública agregada e apresentar a avaliação conjunta de previsões pontuais e cenários probabilísticos, acompanhada de análises de robustez quanto à composição da amostra, à defasagem de divulgação dos dados e ao histórico de erros utilizado na simulação. Os scripts, a série extraída e as instruções de execução estão disponíveis em repositório público (Alves, 2026), o que permite a reprodução integral do experimento. Além desta introdução, o

artigo apresenta a fundamentação teórica (seção 2), a metodologia (seção 3), os resultados e discussões (seção 4) e as conclusões (seção 5).

2. FUNDAMENTAÇÃO TEÓRICA

2.1. Demanda Sazonal e Planejamento da Produção

Uma série temporal apresenta sazonalidade quando é influenciada por fatores que se repetem em períodos fixos e conhecidos, como o mês do ano ou o dia da semana (Hyndman; Athanasopoulos, 2021). No varejo de vestuário e calçados, a sazonalidade decorre de datas comemorativas, das estações do ano, do calendário de pagamentos e de eventos comerciais, e convive com tendências de longo prazo e com choques econômicos que alteram o nível das vendas (Thomassey, 2010; Fildes; Ma; Kolassa, 2022).

No PCP, a previsão da demanda é o ponto de partida do planejamento estratégico e tático da produção, pois orienta o plano de produção, o plano-mestre e a programação das compras (Tubino, 2020). Slack, Brandon-Jones e Johnston (2018) destacam que, quando a demanda é sazonal, a organização precisa escolher entre acompanhar a demanda, manter capacidade constante formando estoques ou gerenciar a própria demanda, e qualquer dessas estratégias depende de uma estimativa confiável do tamanho e do momento dos picos. Na indústria da moda, em que os produtos têm ciclo de vida curto e os prazos de reposição são longos, a previsão de vendas é considerada fator-chave de sucesso da cadeia de suprimentos (Thomassey, 2010; Nenni; Giustiniano; Pirolo, 2013).

2.2. Métodos Estatísticos de Previsão

Os métodos estatísticos de previsão de séries temporais exploram a estrutura de dependência temporal dos próprios dados. O método mais simples para séries sazonais é o sazonal ingênuo, que repete o valor observado no mesmo mês do ano anterior; apesar da simplicidade, ele é amplamente usado como referência mínima de desempenho (Hyndman; Athanasopoulos, 2021). Uma ferramenta complementar é a decomposição STL, que separa a série em tendência, sazonalidade e resíduo por meio de regressões locais (Cleveland et al., 1990).

O amortecimento exponencial, proposto por Holt (2004) e estendido para séries sazonais por Winters (1960), atualiza recursivamente estimativas de nível, tendência e sazonalidade, atribuindo pesos maiores às observações recentes. Hyndman et al. (2008) formalizaram essa família em modelos de espaço de estados (ETS), o que permite estimar os parâmetros por máxima verossimilhança e selecionar a especificação mais adequada por critérios de informação. Os modelos ARIMA sazonais (SARIMA), por sua vez, descrevem a série por meio de componentes autorregressivos e de médias móveis aplicados à série diferenciada nas defasagens regular e sazonal (Box et al., 2015). Esses métodos são transparentes, exigem poucos dados e costumam apresentar bom desempenho em séries mensais agregadas (Makridakis; Spiliotis; Assimakopoulos, 2018).

2.3. Inteligência Artificial e Aprendizado de Máquina na Previsão de Demanda

A inteligência artificial pode ser entendida como o estudo de agentes capazes de perceber o ambiente e agir de forma a alcançar objetivos, e o aprendizado de máquina é o ramo da IA em que o desempenho de um sistema melhora a partir da experiência, isto é,

dos dados (Russell; Norvig, 2020). Na previsão de séries temporais, o problema é tratado como uma regressão supervisionada: o algoritmo aprende a relação entre valores passados da série (defasagens) e variáveis explicativas, como o mês e o calendário, e o valor futuro que se deseja prever (Januschowski et al., 2022).

Entre os algoritmos mais utilizados estão os conjuntos de árvores de decisão. O Random Forest combina centenas de árvores treinadas em amostras aleatórias dos dados e dos atributos, reduzindo a variância das previsões individuais (Breiman, 2001). O *gradient boosting* constrói as árvores de forma sequencial, cada uma corrigindo os erros das anteriores (Friedman, 2001); suas implementações XGBoost (Chen; Guestrin, 2016) e LightGBM (Ke et al., 2017) tornaram-se populares pela eficiência computacional e pelo desempenho em competições de previsão, incluindo a M5 (Makridakis; Spiliotis; Assimakopoulos, 2022). As redes neurais artificiais do tipo *Multilayer Perceptron* (MLP) aproximam relações não lineares por meio de camadas de neurônios interligados e foram das primeiras técnicas de IA aplicadas à previsão (Zhang; Patuwo; Hu, 1998); arquiteturas recorrentes, como as redes LSTM, ampliaram esse uso em séries longas e numerosas (Hewamalage; Bergmeir; Bandara, 2021).

Na cadeia de suprimentos, Carbonneau, Laframboise e Vahidov (2008) compararam técnicas de aprendizado de máquina com métodos tradicionais e encontraram ganhos limitados quando a demanda apresenta forte ruído. As revisões de Fildes, Ma e Kolassa (2022) e de Petropoulos et al. (2022) indicam que o desempenho relativo das técnicas depende das características dos dados: a vantagem da IA tende a aparecer quando há muitas séries relacionadas e variáveis explicativas, enquanto em séries agregadas

e curtas os métodos estatísticos permanecem competitivos. A literatura também mostra que combinar previsões de modelos diferentes costuma reduzir o erro e o risco de escolher um único modelo inadequado (Werner; Ribeiro, 2006; Petropoulos et al., 2022).

2.4. Simulação de Monte Carlo e Previsão Probabilística

A simulação de Monte Carlo é um método numérico que estuda o comportamento de um sistema por meio da geração de um grande número de cenários aleatórios (Metropolis; Ulam, 1949). Associada ao *bootstrap*, técnica de reamostragem que estima distribuições a partir dos próprios dados sem impor hipóteses paramétricas (Efron, 1979), ela permite construir distribuições de probabilidade para a demanda futura a partir dos erros de previsão observados no passado.

Esse tipo de saída caracteriza a previsão probabilística, que expressa a incerteza por meio de uma distribuição completa ou de quantis, em vez de um único valor (Gneiting; Katzfuss, 2014). A qualidade de uma previsão probabilística é avaliada por sua calibração, isto é, se os intervalos de, por exemplo, 80% contêm o valor real em cerca de 80% dos casos, e por regras de pontuação apropriadas, como o *Continuous Ranked Probability Score* (CRPS), que penaliza simultaneamente a falta de calibração e a falta de precisão (Gneiting; Raftery, 2007). A competição M5 dedicou uma trilha específica à previsão de incerteza no varejo, reforçando a importância de quantificar o risco para decisões de estoque (Makridakis et al., 2022).

3. METODOLOGIA

3.1. Caracterização da Pesquisa

Quanto à natureza, a pesquisa é aplicada, pois busca gerar conhecimento para a solução de um problema prático de planejamento. Quanto à abordagem, é quantitativa e, quanto aos objetivos, descritiva, já que caracteriza o comportamento da série e compara o desempenho de diferentes métodos. Quanto aos procedimentos técnicos, trata-se de pesquisa documental, por utilizar dados secundários oficiais, combinada a um experimento computacional de previsão, no qual todos os métodos são aplicados sob as mesmas condições e comparados por métricas objetivas (Gil, 2022).

3.2. Dados e Tratamento

A série analisada é o índice de volume de vendas do comércio varejista de tecidos, vestuário e calçados para o Brasil, divulgado pela Pesquisa Mensal de Comércio (PMC) do IBGE na tabela 8882 do Sistema IBGE de Recuperação Automática (SIDRA). Utilizou-se o número-índice sem ajuste sazonal (2022 = 100), pois o objetivo é modelar a sazonalidade. A série compreende 319 observações mensais, de janeiro de 2000 a julho de 2026, sem valores ausentes (IBGE, 2026a). O dado referente a julho de 2026 foi divulgado em 15 de setembro de 2026; julho identifica, portanto, o mês de referência da última observação utilizada, e não sua data de disponibilidade (IBGE, 2026b). O índice representa vendas efetivamente realizadas e é empregado como aproximação da demanda setorial. Ele não mede quantidades vendidas por empresa ou produto nem a demanda não atendida por falta de estoque.

A série contém o choque da pandemia de COVID-19, quando as restrições ao funcionamento do comércio coincidiram com o mínimo histórico de 18,2 pontos em abril de 2020. Os sete meses de

março a julho de 2020 e março a abril de 2021 foram tratados como observações atípicas apenas para fins de estimação dos modelos, para reduzir a influência desse choque na estimação dos padrões sazonais. Os valores desses meses foram substituídos por interpolação linear da série dessazonalizada em escala logarítmica, com fatores sazonais obtidos por decomposição STL robusta (Cleveland et al., 1990) ajustada somente aos dados anteriores à pandemia. O tratamento não utiliza informação posterior ao início do período de teste e não altera os valores usados na avaliação das previsões. A escolha dessa imputação constitui uma limitação, e sua influência no desempenho pode ser examinada por análises de sensibilidade.

3.3. Modelos Avaliados

Foram comparados três métodos estatísticos e quatro modelos de IA, além de duas combinações definidas antes da avaliação final (Quadro 1). Os modelos estatísticos foram ajustados ao logaritmo do índice, o que torna a sazonalidade multiplicativa na escala original. No Holt-Winters (ETS), a especificação foi escolhida em cada origem de previsão pelo critério de informação de Akaike corrigido (AICc), entre versões sem tendência, com tendência aditiva e com tendência amortecida (Hyndman et al., 2008). No SARIMA, a ordem foi selecionada pelo AICc no início de cada período de avaliação, entre as combinações $(p,1,q)(P,1,Q)_{12}$ com $p, q \leq 2$ e $P, Q \leq 1$, e os parâmetros foram reestimados a cada nova origem (Box et al., 2015).

Os modelos de IA foram treinados para prever a variação anual em logaritmo, $d_t = \ln y_t - \ln y_{t-12}$, o que remove a sazonalidade principal e evita que os algoritmos baseados em árvores precisem extrapolar níveis nunca observados. Como atributos de entrada, foram

utilizados: (i) as variações defasadas d_{t-1} , d_{t-2} , d_{t-3} , d_{t-6} e d_{t-12} ; (ii) o mês do ano; e (iii) variáveis de calendário conhecidas antecipadamente, isto é, a diferença em relação ao mesmo mês do ano anterior no número de sábados, domingos e feriados nacionais. As previsões de 1 a 12 meses foram obtidas de forma recursiva, e o nível foi reconstruído por $\hat{y}_{t+h} = y_{t+h-12} \cdot \exp(d_{t+h})$, em que d_{t+h} é a variação anual prevista para o mês $t + h$. A rede neural recebeu os atributos padronizados e o mês codificado em variáveis binárias. O padronizador, isto é, as médias e os desvios-padrão dos atributos e da variável-alvo, foi ajustado exclusivamente à amostra de treino de cada origem e depois aplicado, sem novo ajuste, às entradas usadas nas previsões; essa propriedade foi verificada por um teste automatizado incluído no pacote de reprodução. Para reduzir a sensibilidade à inicialização aleatória, a previsão da rede é a média de cinco redes treinadas com as sementes 0, 1, 2, 3 e 4. Os hiperparâmetros de cada modelo de IA foram escolhidos pelo menor erro no período de validação, a partir das grades apresentadas no Quadro 1.

Quadro 1. Modelos avaliados, especificações e hiperparâmetros

Grupo	Modelo	Especificação	Hiperparâmetros: grade testada → escolhido
Estatístico	Sazonal ingênuo	Repete o valor do mesmo mês do ano anterior	—
Estatístico	Holt-Winters (ETS)	Log do índice; erro e sazonalidade aditivos; tendência escolhida por AICc em cada origem	Sem tendência, aditiva ou amortecida

Estatístico	SARIMA	Log do índice; ordem escolhida por AICc em $(p,1,q)(P,1,Q)_{12}$, $p, q \leq 2$; $P, Q \leq 1$	Validação: $(0,1,1)(0,1,1)_{12}$; teste e simulação: $(0,1,1)(1,1,1)_{12}$
IA	Random Forest	500 árvores; alvo d_t ; previsão recursiva	Fração de atributos $\{0,5; 1,0\} \rightarrow 1,0$; mínimo por folha $\{1; 5\} \rightarrow 1$
IA	XGBoost	400 árvores; taxa de aprendizado 0,03; subamostragem 0,8	Profundidade $\{2; 4\} \rightarrow 4$; peso mínimo $\{1; 5\} \rightarrow 5$
IA	LightGBM	400 árvores; taxa de aprendizado 0,03; subamostragem 0,8	Folhas $\{4; 8\} \rightarrow 8$; mínimo por folha $\{5; 15\} \rightarrow 15$
IA	Rede neural MLP	Uma camada oculta (ReLU), otimizador L-BFGS; média de 5 redes	Neurônios $\{8; 16\} \rightarrow 8$; regularização L2 $\{0,1; 1,0\} \rightarrow 1,0$
Combinação	Combinação o IA	Média geométrica das previsões dos quatro modelos de IA	—
Combinação	Combinação o geral	Média geométrica das previsões de ETS, SARIMA e dos quatro modelos de IA	—

Fonte: elaborado pelo autor (2026).

Nota: nos modelos de IA, d_t é a variação anual em logaritmo; os hiperparâmetros foram escolhidos pelo menor MAPE no período de validação.


3.4. Delineamento da Avaliação

A acurácia foi medida fora da amostra pelo procedimento de origem móvel (rolling origin) com janela de treino expansível, recomendado para séries temporais por respeitar a ordem cronológica dos dados (Tashman, 2000; Bergmeir; Hyndman; Koo, 2018). Em cada origem, os modelos são estimados com a série de treino encerrada naquele mês e geram previsões para os 12 meses seguintes; em seguida, a origem avança um mês e o processo se repete. As origens são identificadas pelo mês de referência da última observação incluída no treino. Assim, os horizontes expressam a distância entre meses de referência; sua utilização em decisões de planejamento deve considerar também a defasagem de divulgação da PMC. Para examinar esse aspecto, as previsões do período de teste foram também reindexadas pela data oficial de divulgação do último dado utilizado, em uma avaliação em pseudo-tempo real (IBGE, 2026b). Nessa avaliação, a antecedência é contada a partir do mês em que o dado é divulgado, e as previsões para meses já encerrados nessa data são excluídas. Das 55 divulgações referentes a janeiro de 2022 a julho de 2026, 54 ocorreram no segundo mês após o de referência e uma, a de janeiro de 2023, no terceiro. Como a série foi extraída em sua versão vigente e não foram obtidas as versões históricas de cada divulgação, as revisões dos dados não foram reproduzidas.

O experimento foi dividido em dois períodos (Figura 1). No período de validação, com 62 origens mensais entre janeiro de 2014 e fevereiro de 2019 (744 previsões por modelo, todas com alvo anterior à pandemia), foram escolhidos os hiperparâmetros dos modelos de IA. No período de teste, com 48 origens entre julho de 2022 e junho de 2026, os modelos foram reavaliados com as configurações já fixadas, gerando 510 previsões por modelo com valor real conhecido, de agosto de 2022 a julho de 2026. Como a avaliação se encerra em julho de 2026, o número de previsões disponíveis varia de 48 no

horizonte de um mês a 37 no de doze meses, e os conjuntos de meses-alvo diferem entre horizontes. Por isso, a comparação por horizonte foi repetida com os mesmos 37 meses-alvo, de julho de 2023 a julho de 2026, disponíveis em todos os horizontes. Por fim, a partir da origem de referência julho de 2026, foram simulados os cenários de agosto de 2026 a julho de 2027.

Figura 1. Delineamento temporal da avaliação: períodos de treino, validação, teste e simulação



Fonte: elaborado pelo autor (2026).

3.5. Métricas de Desempenho

A acurácia pontual foi medida pelo erro percentual absoluto médio (MAPE), pela raiz do erro quadrático médio (RMSE), expressa em pontos do índice, e pelo erro absoluto médio escalonado (MASE). O MASE divide o erro absoluto pelo erro absoluto médio do método sazonal ingênuo calculado na amostra de treino; valores inferiores a 1 indicam erro menor que essa referência histórica de escala, sem implicar necessariamente superioridade sobre o sazonal ingênuo no período de teste (Hyndman; Koehler, 2006). A comparação fora da amostra depende do confronto entre os resultados dos modelos para os mesmos alvos. Os erros também foram analisados por horizonte e, separadamente, para os meses de maio (Dia das Mães), novembro (*Black Friday*) e dezembro (Natal).

As diferenças entre pares de modelos foram examinadas, em cada horizonte h , pelo teste de Diebold e Mariano (1995). A função de perda é o erro percentual absoluto, e o teste usa a série das diferenças de perda entre os dois modelos, ordenada pelas origens de previsão. A variância de longo prazo da média dessas diferenças foi estimada pela soma das autocovariâncias amostrais, com divisor n , até a defasagem $h - 1$ e pesos uniformes, o que acomoda a autocorrelação esperada entre previsões de h passos feitas em origens consecutivas; quando essa soma não foi positiva, o que ocorreu em 2 dos 192 testes realizados, utilizou-se apenas a variância. Aplicou-se a correção para amostras pequenas de Harvey, Leybourne e Newbold (1997), com distribuição t de Student com $n - 1$ graus de liberdade e teste bilateral ao nível de 5%. Para cada par de modelos, os p -valores dos 12 horizontes foram ajustados pelo método de Holm (1979), e os resultados são reportados com e sem ajuste. As conclusões inferenciais permanecem exploratórias, pois o ajuste não abrange as comparações entre diferentes pares de modelos nem a dependência entre previsões de horizontes distintos, que compartilham origens e meses-alvo.

Como as previsões de dezembro feitas a partir de diferentes origens recaem sobre poucos meses-alvo, a comparação nesse mês também foi feita por evento: os erros foram agregados por dezembro, e cada dezembro foi tratado como uma unidade de comparação. Para ampliar o número de eventos, incluíram-se os seis dezembros do período de validação (2014 a 2019), e a frequência com que cada modelo teve o menor erro foi avaliada pelo teste exato do sinal.

3.6. Simulação de Monte Carlo

Para transformar cada previsão pontual em um conjunto de cenários, adotou-se uma simulação de Monte Carlo baseada no *bootstrap* dos erros históricos de previsão (Efron, 1979). Para cada modelo, registraram-se as trajetórias de erro em logaritmo, $e_{o,h} = \ln y_{o+h} - \ln \hat{y}_{o+h}$, de todas as origens anteriores cujos 12 meses seguintes já eram conhecidos. A cada simulação, sorteia-se com reposição uma trajetória completa, o que preserva a dependência entre os erros de horizontes próximos, e o cenário de cada horizonte h é obtido multiplicando a previsão pontual por $\exp(e_h)$, em que e_h é o erro sorteado para aquele horizonte. Com 10.000 cenários por origem, estimaram-se os percentis 5, 10, 50, 90 e 95 da demanda, bem como probabilidades de interesse gerencial.

A calibração do procedimento foi avaliada no período de teste respeitando a ordenação temporal da série: em cada origem, o conjunto de trajetórias reamostradas incluiu as 62 trajetórias da validação e apenas as trajetórias do teste cujos doze meses seguintes já estavam completamente observados até o mês de referência daquela origem (de 62 a 98 trajetórias). Mediram-se a cobertura empírica dos intervalos de 80% (P10 a P90) e de 90% (P5 a P95) e o CRPS, regra de pontuação que avalia a distribuição simulada como um todo (Gneiting; Raftery, 2007). Para os cenários finais, utilizaram-se 99 trajetórias. A interpretação dos percentis e das probabilidades depende de os erros históricos representarem adequadamente os erros futuros. As coberturas agregadas podem ocultar diferenças entre meses, horizontes e regimes econômicos; além disso, os 10.000 sorteios reduzem a variabilidade numérica da simulação, mas não ampliam o histórico de trajetórias disponíveis. Como as origens históricas se sobrepõem, as trajetórias também não constituem amostras independentes; a reamostragem de uma

trajetória completa preserva a dependência dentro dela, mas não elimina a dependência entre trajetórias.

A sensibilidade da simulação ao histórico reamostrado foi avaliada com três conjuntos alternativos de trajetórias: sem as trajetórias cujos meses-alvo abrangem 2015 ou 2016, período de retração econômica; apenas com as 36 trajetórias mais recentes disponíveis em cada origem; e apenas com trajetórias do próprio período de teste, avaliadas nas origens com pelo menos 12 trajetórias disponíveis, isto é, a partir de junho de 2024. A cobertura e o CRPS foram também calculados por horizonte e por mês-alvo. Para refletir a dependência entre origens na incerteza das coberturas, estimaram-se intervalos de confiança de 95% por *bootstrap* circular em blocos de 12 origens consecutivas, com 2.000 replicações.

3.7. Ferramentas e Disponibilidade dos Dados

O experimento foi implementado em Python 3.13.16, com as bibliotecas statsmodels 0.15.0 (Seabold; Perktold, 2010), scikit-learn 1.9.1 (Pedregosa et al., 2011), XGBoost 3.4.1, LightGBM 4.7.0, NumPy 2.5.3, pandas 3.0.5 e SciPy 1.18.1. As sementes aleatórias foram fixadas em 0 a 4 para as cinco redes neurais, em 42 para os modelos baseados em árvores, em 2026 para a simulação de Monte Carlo e em 7 para o *bootstrap* em blocos. Os scripts, a série extraída do SIDRA em 10 de outubro de 2026, o calendário de divulgação, as versões completas das dependências e as instruções de execução estão disponíveis em repositório público (Alves, 2026). A execução de todas as etapas a partir de uma cópia limpa desse repositório reproduziu integralmente as previsões e as tabelas de resultados.


4. RESULTADOS E DISCUSSÕES

4.1. Caracterização da Série e da Sazonalidade

A Figura 2 apresenta a série histórica do índice de volume de vendas do segmento. Observa-se crescimento expressivo entre 2000 e 2013, quando a média anual do índice passou de 87,3 para 132,7 pontos e foi registrado o máximo da série (250,7 pontos em dezembro de 2013), seguido de queda acentuada em 2015 e 2016, período de retração da economia brasileira, e de recuperação parcial até 2019 (média de 114,1). Após o choque da pandemia, o segmento passou a operar em patamar mais baixo: a média anual foi de 95,4 pontos em 2023 e de 99,4 em 2025, cerca de 13% abaixo do nível de 2019. Essa mudança de patamar, ocorrida justamente no início do período de teste, torna a avaliação mais exigente e mais próxima das condições reais de planejamento.


A sazonalidade é pronunciada. Como mostra a Figura 3, dezembro concentra o maior pico do ano, seguido, em escala menor, por maio, junho e novembro, enquanto fevereiro é o mês de menor volume. O índice sazonal de dezembro caiu de 191% da média móvel centrada de 12 meses no período 2010–2019 para 174% em 2022–2025, enquanto maio passou de 105% para 109% e novembro, de 104% para 105%. Esses resultados descrevem a redução do peso relativo de dezembro e o aumento relativo de maio e novembro no calendário de vendas do segmento. Os dados mensais agregados, porém, não permitem atribuir essa mudança à antecipação de compras ou a um evento comercial específico. A mudança do padrão sazonal pode afetar os erros dos modelos, dependendo de sua especificação e da atualização dos fatores sazonais.

Figura 2. Índice de volume de vendas do varejo de tecidos, vestuário e calçados – Brasil, jan. 2000 a jul. 2026



Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Figura 3. Índices sazonais mensais antes e depois da pandemia (média móvel centrada de 12 meses = 100)



Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

4.2. Desempenho Preditivo dos Modelos

A Tabela 1 resume a acurácia dos modelos. No período de teste, o Holt-Winters (ETS) obteve o melhor desempenho nas três métricas de acurácia pontual, com MAPE de 3,09%, RMSE de 4,09 pontos e MASE de 0,49, seguido pelo SARIMA (MAPE de 3,66%). Entre os modelos de IA, o menor MAPE coube à rede neural MLP, com 4,04%,

abaixo dos 4,53% do sazonal ingênuo. Random Forest, XGBoost e LightGBM tiveram MAPE superior ao do sazonal ingênuo e viés positivo de cerca de 2%, indicando tendência a superestimar o índice de vendas. A combinação dos seis modelos, com MAPE de 3,80%, foi mais precisa que qualquer modelo de IA isolado, mas não superou o Holt-Winters. Os métodos estatísticos também apresentaram os menores MAPes na validação, o que indica a manutenção de sua vantagem geral nos dois períodos avaliados.

Tabela 1. Acurácia fora da amostra nos períodos de validação e de teste

Modelo	MAPE validação (%)	MAPE teste (%)	RMSE teste	MASE teste	Viés teste (%)
<i>Métodos estatísticos</i>					
Sazonal ingênuo	7,00	4,53	6,18	0,70	+0,6
...	...	...	...	...	...

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: validação com 744 previsões por modelo (alvos de fev. 2014 a fev. 2020) e teste com 510 previsões (alvos de ago. 2022 a jul. 2026). Viés positivo indica superestimação. A última coluna informa o número de horizontes, entre 12, em que o teste de Diebold-Mariano

indicou erro significativamente menor que o do sazonal ingênuo ao nível de 5%, sem ajuste e, entre parênteses, após o ajuste de Holm; detalhes no Apêndice A. As comparações inferenciais são interpretadas como exploratórias. Melhores valores em negrito.


Os testes de Diebold-Mariano, interpretados de forma exploratória, indicaram que o Holt-Winters foi significativamente mais preciso que o sazonal ingênuo em quatro dos doze horizontes ao nível de 5%, dos quais um permaneceu significativo após o ajuste de Holm, e nenhum modelo apresentou vantagem significativa sobre o Holt-Winters em qualquer horizonte. Na comparação direta entre o melhor modelo estatístico e o melhor modelo de IA, os p-valores sem ajuste foram inferiores a 5% nos horizontes de 1 a 6 meses (entre 0,001 e 0,039), favorecendo o Holt-Winters; após o ajuste de Holm, a diferença permaneceu significativa apenas nos horizontes de 2 e 5 meses. Entre 7 e 12 meses, não foi detectada diferença significativa (p-valores sem ajuste entre 0,27 e 0,74), o que não demonstra equivalência entre os modelos (Apêndice A). A Figura 4 mostra que o erro do Holt-Winters permanece entre 2,8% e 3,5% em todos os horizontes, enquanto o da rede neural atinge o máximo no horizonte de 3 meses e diminui nos horizontes seguintes.

Como os conjuntos de meses-alvo diferem entre horizontes (dezembro de 2022, por exemplo, aparece apenas nos horizontes de 1 a 5 meses), a comparação foi repetida com os mesmos 37 meses-alvo em todos os horizontes (Apêndice A). Nessa amostra comum, o MAPE médio dos horizontes de 1 a 6 meses foi de 2,74% no Holt-Winters e 3,64% na MLP, e o dos horizontes de 7 a 12 meses, de 3,15% e 3,32%, respectivamente; nos horizontes de 8 e 9 meses, os erros dos dois modelos praticamente coincidiram. A aproximação da MLP nos prazos mais longos persiste, portanto, quando a composição da

amostra é idêntica. Nessa amostra menor, nenhuma diferença entre os dois modelos permaneceu significativa após o ajuste de Holm.

Na avaliação em pseudo-tempo real (Apêndice B), a antecedência efetiva é, em geral, dois meses menor que o horizonte entre meses de referência: a previsão de dezembro feita com o dado de julho, por exemplo, só se torna disponível em setembro, com três meses de antecedência. Considerando as 461 previsões para meses ainda não encerrados na data de divulgação, a ordenação dos modelos se manteve, com MAPE de 3,12% no Holt-Winters, 3,73% no SARIMA, 3,83% na combinação geral, 4,07% na MLP e 4,44% no sazonal ingênuo. Essa avaliação utiliza a versão vigente da série e, por isso, não incorpora o efeito das revisões dos dados.

Figura 4. MAPE por horizonte de previsão no período de teste (ago. 2022 a jul. 2026)



Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Esses resultados estão alinhados com os de Makridakis, Spiliotis e Assimakopoulos (2018), que observaram vantagem dos métodos

estatísticos em séries mensais, e com as revisões de Fildes, Ma e Kolassa (2022) e Januschowski et al. (2022), segundo as quais os modelos de aprendizado de máquina, em especial os baseados em árvores, rendem mais quando treinados com muitas séries relacionadas e variáveis explicativas. A vitória do LightGBM na competição M5, por exemplo, ocorreu em um ambiente com milhares de séries de produtos (Makridakis; Spiliotis; Assimakopoulos, 2022). No presente estudo, com uma única série agregada e algumas centenas de observações, a estrutura parcimoniosa dos métodos estatísticos mostrou-se mais eficiente.

4.3. Desempenho nos Meses de Pico

A análise por mês-alvo apresenta diferenças em relação ao desempenho global (Tabela 2). Em maio e novembro, o Holt-Winters teve o menor MAPE, de 3,41% e 4,15%, respectivamente. Em dezembro, a rede neural MLP apresentou o menor MAPE observado, de 2,35%, contra 4,00% do Holt-Winters e 3,88% do SARIMA. Nas 41 previsões de dezembro do período de teste, a MLP teve erro menor que o Holt-Winters em 78% dos casos. Essas previsões, contudo, recaem sobre apenas quatro dezembros, de 2022 a 2025, previstos a partir de diferentes origens, e não são independentes. A proporção de vitórias e o menor MAPE são apresentados como evidência descritiva e exploratória. Não se utiliza o teste de Wilcoxon convencional para sustentar superioridade estatística nesse recorte, pois a dependência entre as diferenças compromete sua aplicação. O pequeno número de picos anuais distintos limita a generalização do resultado.

Para respeitar essa dependência, os erros foram agregados por dezembro e a análise foi estendida aos seis dezembros da validação

(Apêndice C). No teste, a MLP teve erro médio menor que o Holt-Winters em 3 dos 4 dezembros (2023, 2024 e 2025), mas não em 2022. Na validação, o padrão se inverteu: a MLP foi mais precisa em apenas 2 dos 6 dezembros, e seu MAPE de dezembro (7,70%) superou o do Holt-Winters (4,82%). Nos dez dezembros avaliados, cada modelo teve o menor erro em cinco (teste do sinal, $p = 1,00$). A vantagem da MLP em dezembro restringe-se, assim, aos anos posteriores à pandemia, período em que o peso relativo do mês diminuiu (seção 4.1), e não se mostra estável ao longo da série.

Tabela 2. MAPE (%) nos meses de pico sazonal no período de teste

Modelo	Maio (Dia das Mães)	Novembro (<i>Black Friday</i>)	Dezembro (Natal)
<i>Métodos estatísticos</i>			
Sazonal ingênuo	7,89	7,11	3,54
Holt-Winters (ETS)	3,41	4,15	4,00
SARIMA	4,22	5,79	3,88
<i>Modelos de inteligência artificial</i>			
Random Forest	6,16	6,06	4,72
XGBoost	6,99	7,57	5,05
LightGBM	6,99	8,00	5,26
Rede Neural MLP	7,47	4,93	2,35
<i>Combinações de previsões</i>			

Combinação IA	6,64	6,29	3,80
Combinação geral	5,40	5,67	3,75

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: médias sobre todas as origens e horizontes cujo mês-alvo é maio (n = 46), novembro (n = 40) ou dezembro (n = 41). Os valores de n representam previsões, e não eventos independentes. As previsões de dezembro recaem sobre quatro anos distintos, de 2022 a 2025. Menores erros em negrito.

A Tabela 3 detalha as previsões de dezembro com origem no mês de referência julho do mesmo ano. Trata-se de um horizonte de cinco meses entre referências da série; como o dado de julho foi divulgado em setembro em todos os anos avaliados (IBGE, 2026b), essas previsões ficam disponíveis com três meses de antecedência em relação a dezembro. Em 2022, os quatro modelos apresentados superestimaram o pico, com erros entre 10,3% e 12,4%. De 2023 a 2025, o Holt-Winters também superestimou dezembro, com erros de 4,6%, 2,9% e 6,4%, enquanto a MLP apresentou erros menores, de 2,7%, 1,5% e 2,4%. Uma hipótese para essa diferença é a mudança do padrão sazonal descrita na seção 4.1. A formulação dos modelos de IA sobre a variação anual pode ter contribuído para seu desempenho no padrão recente; o experimento, porém, não isolou esse mecanismo. Como o algoritmo e a representação dos dados diferem dos métodos estatísticos, os resultados não permitem atribuir a vantagem observada exclusivamente a uma adaptação mais rápida da rede neural.

Tabela 3. Previsões de dezembro com origem no mês de referência julho do mesmo ano (horizonte de 5 meses)

Ano	Real	Holt-Winters (ETS)	SARIMA	Rede Neural MLP	Combinação
Dez. 2022	167,2	184,4 (+10,3%)	186,4 (+11,4%)	187,7 (+12,3%)	188,1 (+12,4%)
Dez. 2023	168,2	176,0 (+4,6%)	172,2 (+2,4%)	172,7 (+2,7%)	176,1 (+5,1%)
Dez. 2024	174,2	179,2 (+2,9%)	177,9 (+2,1%)	176,7 (+1,5%)	176,1 (+1,0%)

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).
Nota: valores do índice de volume (2022 = 100); entre parênteses, o erro percentual da previsão em relação ao valor real. A origem é o último mês de referência incluído no treino; como os dados de julho foram divulgados em setembro, a antecedência efetiva dessas previsões em relação a dezembro é de três meses.

4.4. Simulação de Monte Carlo dos Cenários de Demanda

A Tabela 4 apresenta a cobertura dos intervalos e o CRPS dos cenários simulados no período de teste. Para todos os modelos, a cobertura empírica dos intervalos de 80% ficou entre 86% e 94%, e a dos intervalos de 90%, entre 93% e 99%. Considerando a dependência entre origens, os intervalos de confiança de 95% da

cobertura de 80% foram de 87,5% a 97,4% no Holt-Winters e de 81,7% a 89,4% na MLP, ambos acima do valor nominal, o que indica intervalos conservadores no conjunto avaliado. A análise por ano do mês-alvo revelou cobertura de apenas 33% no Holt-Winters e 53% na MLP em 2022, ano com 15 previsões avaliadas (agosto a dezembro), indicando que as distribuições simuladas não representaram adequadamente os erros daquele período; de 2023 a 2025, a cobertura anual variou entre 89,6% e 99,3% nos dois modelos e, nos meses de 2026 avaliados, foi de 90,5% no Holt-Winters e de 71,4% na MLP. O Holt-Winters teve o menor CRPS, de 2,68, indicando a melhor qualidade global das distribuições segundo essa métrica.

A análise de sensibilidade indica que a folga dos intervalos decorre, em grande parte, da inclusão dos erros da validação que abrangem a retração econômica de 2015 e 2016 (Apêndice E). Sem essas trajetórias, a cobertura do intervalo de 80% do Holt-Winters caiu de 93,1% para 85,7%, a largura média passou de 17,7% para 11,8% da mediana e o CRPS diminuiu de 2,68 para 2,30; o uso apenas das 36 trajetórias mais recentes produziu efeito semelhante (84,3%, 13,4% e 2,42). Na MLP, a cobertura pouco mudou (de 86,3% para 85,5%), mas o CRPS diminuiu de 3,58 para 3,21. Com trajetórias exclusivamente do período de teste, avaliadas a partir de junho de 2024, a cobertura de 80% ficou abaixo do valor nominal nos dois modelos (76,9% e 78,6%), o que sugere que históricos muito curtos tendem a subestimar a incerteza.

A desagregação por horizonte e por mês-alvo (Apêndice D) mostra comportamentos distintos. No Holt-Winters, a cobertura de 80% ficou entre 85% e 91% nos horizontes de até quatro meses e entre 93% e 98% nos demais, nos quais a cobertura de 90% foi de 100%, de modo que a folga cresce com o horizonte. Na MLP, ao contrário, a

cobertura caiu para 82%, 74% e 70% nos horizontes de 10, 11 e 12 meses, indicando subestimação da incerteza nos prazos mais longos. Por mês-alvo, a cobertura de 80% foi inferior ao valor nominal em novembro nos dois modelos (67,5% e 72,5%) e, na MLP, também em maio (58,7%) e março (75,0%). Em dezembro, a cobertura foi de 92,7% no Holt-Winters e de 95,1% na MLP. Os maiores valores de CRPS concentraram-se em maio, novembro e dezembro, os meses de pico.

Tabela 4. Calibração dos cenários simulados por Monte Carlo no período de teste

Modelo	Cobertura do intervalo de 80% (%)	Cobertura do intervalo de 90% (%)	Largura média do intervalo de 80% (% da mediana)	CRPS	Cobert de 80 em no dez. (%)
<i>Métodos estatísticos</i>					
Sazonal	87,8	96,7	21,3	3,66	85,2
ingênuo					
MLP	88,3	98,6	19,9	3,48	89,1
Holt-Winters	82,0	92,7	22,5	3,78	92,7

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).
Nota: 510 previsões por modelo, cada uma com 10.000 cenários. Coberturas acima do valor nominal indicam intervalos conservadores no conjunto avaliado e não garantem calibração em cada horizonte ou período. Menor CRPS em negrito.


A partir da origem de referência julho de 2026, foram simulados 10.000 cenários para agosto de 2026 a julho de 2027 (Figura 5 e Tabela 5). Para dezembro de 2026, o Holt-Winters apresenta mediana de 172,5 pontos e probabilidade simulada de 63% de superar os 170,0 pontos observados em dezembro de 2025. A MLP apresenta mediana de 166,2 pontos e probabilidade de 33%. Esses valores descrevem distribuições distintas condicionadas aos modelos e ao histórico de erros reamostrados. A MLP apresentou menor erro nos dezembros do teste, mas não nos da validação, e esse resultado não estabelece, por si só, o peso que cada modelo deve receber em uma decisão futura. Para maio de 2027, as medianas são 105,3 pontos no Holt-Winters e 100,4 pontos na MLP; as probabilidades simuladas de superar os 112,7 pontos de maio de 2026 são 18% e 2%, respectivamente. O melhor desempenho histórico do Holt-Winters em maio oferece uma referência para comparação, cuja adequação deve ser acompanhada conforme novas observações se tornem disponíveis.

Nos cenários simulados para dezembro de 2026, o percentil 90 está aproximadamente 8% acima da mediana em ambos os modelos. Esse quantil delimita o valor abaixo do qual se encontram 90% dos cenários gerados para o índice setorial, sob as hipóteses do procedimento. A diferença pode servir como referência para discutir cenários, mas não determina diretamente o estoque ou a capacidade necessária de uma empresa nem garante seu nível de serviço. Essa conversão exige relacionar o indicador às vendas da empresa e considerar demanda por produto, estoques existentes, prazos de reposição e custos de excesso e falta. De modo semelhante, o percentil 10 descreve um cenário baixo da distribuição, sem assegurar compromissos mínimos de produção com baixo risco de sobra. O uso dos quantis no PCP e no

planejamento de vendas e operações depende de validação com dados e condições operacionais próprios (Tubino, 2020; Syntetos et al., 2016).

Os cenários de dezembro de 2026 do Holt-Winters também são sensíveis ao histórico reamostrado (Apêndice E). Sem as trajetórias da retração de 2015 e 2016, a mediana passa de 172,5 para 175,8 pontos, a probabilidade de superar dezembro de 2025 sobe de 63% para 78% e a margem entre o percentil 90 e a mediana cai de 8,1% para 5,1%; com as 36 trajetórias mais recentes, esses valores são 176,4 pontos, 83% e 4,2%. Na MLP, a mediana varia apenas entre 166,2 e 167,8 pontos, e a probabilidade, entre 33% e 41%. A escolha do histórico de erros é, portanto, uma decisão relevante do procedimento e deve ser explicitada sempre que os cenários forem utilizados.

Figura 5. Cenários de demanda simulados por Monte Carlo para ago. 2026 a jul. 2027



Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Tabela 5. Cenários simulados para os picos sazonais de 2026 e 2027 (índice, 2022 = 100)

Modelo	Mês	P5	P10	P50	P90
Holt-Winters (ETS)	Nov. 2026	95,3	97,1	103,2	111,1
	Dez. 2026	159,6	161,8	172,5	186,1
	Maio 2027	91,2	94,2	105,3	114,5

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: 10.000 cenários a partir da origem de referência jul. 2026, cujos dados foram divulgados em set. 2026. Valores observados no ano anterior: nov. 2025 = 105,2; dez. 2025 = 170,0; maio 2026 = 112,7. As probabilidades são condicionadas aos modelos e ao histórico de erros utilizado. A sensibilidade desses valores ao histórico reamostrado é apresentada no Apêndice E.

4.5. Implicações para o Planejamento da Produção

Os resultados oferecem referências para o planejamento do setor. O Holt-Winters apresentou a maior acurácia global, também na avaliação pela data de divulgação dos dados, e pode ser usado como referência inicial, a ser validada no nível de agregação relevante para cada empresa. O menor erro da MLP nos dezembros pós-pandemia, não observado nos dezembros da validação, justifica investigar sua utilização complementar em períodos sazonais sujeitos a mudanças

de padrão, sem estabelecer uma regra de seleção já validada. A literatura indica benefícios potenciais da combinação de previsões (Werner; Ribeiro, 2006; Petropoulos et al., 2022), mas a combinação geral deste estudo não superou o Holt-Winters; uma estratégia de seleção por mês ou horizonte precisa de avaliação adicional fora da amostra. Os cenários probabilísticos permitem discutir a incerteza, desde que suas probabilidades sejam tratadas como condicionais ao modelo e ao histórico de erros utilizado, cuja escolha alterou de forma relevante a largura dos intervalos e os cenários do Holt-Winters. A baixa cobertura em 2022 e a subcobertura da MLP nos horizontes longos e nos meses de 2026 avaliados reforçam a necessidade de acompanhar a calibração e considerar cenários de estresse. A inclusão do sazonal ingênuo também foi relevante: os modelos de árvores não o superaram em MAPE no teste, embora a comparação possa variar conforme a métrica considerada.

5. CONCLUSÃO

Este estudo comparou métodos estatísticos e modelos de aprendizado de máquina na previsão do índice agregado de volume de vendas do varejo brasileiro de tecidos, vestuário e calçados, utilizando dados mensais oficiais do IBGE de janeiro de 2000 a julho de 2026. A análise caracterizou a sazonalidade e suas mudanças recentes, avaliou a acurácia fora da amostra por horizonte e mês-alvo, examinou a cobertura dos intervalos e o CRPS dos cenários simulados e gerou projeções para o fim de ano de 2026 e maio de 2027. Os resultados se referem ao índice setorial de vendas realizadas e não medem diretamente a demanda de empresas ou produtos nem a demanda não atendida por falta de estoque.

No período de teste, o Holt-Winters apresentou o menor erro geral nas métricas avaliadas, resultado mantido na avaliação pela data de divulgação dos dados, enquanto os modelos baseados em árvores tiveram MAPE superior ao do sazonal ingênuo. Os testes empregados, interpretados de forma exploratória, indicaram vantagem do Holt-Winters sobre a MLP nos horizontes de 1 a 6 meses sem ajuste para múltiplas comparações e nos horizontes de 2 e 5 meses após o ajuste de Holm; entre 7 e 12 meses, não foi identificada diferença estatisticamente significativa, o que não demonstra equivalência entre os métodos, e a aproximação entre eles nesses prazos persistiu com os mesmos meses-alvo em todos os horizontes. Nas previsões de dezembro, a MLP apresentou o menor MAPE no teste, com vantagem em três dos quatro dezembros pós-pandemia; nos seis dezembros da validação, porém, o Holt-Winters foi mais preciso na maioria dos casos, de modo que a vantagem não se mostrou estável entre períodos. A hipótese de maior adaptação da MLP à mudança do padrão sazonal não foi isoladamente testada. A simulação por *bootstrap* produziu intervalos conservadores no conjunto de teste, em grande parte pela inclusão dos erros da retração de 2015 e 2016, mas subestimou a incerteza em 2022 e, na MLP, nos horizontes mais longos e nos meses de 2026 avaliados. Os quantis obtidos descrevem os cenários do índice agregado; sua utilização em decisões de estoque ou capacidade requer dados e condições operacionais específicos de cada empresa.

A contribuição do trabalho é oferecer evidências aplicadas sobre o desempenho dos métodos nesta série pública e apresentar um procedimento reprodutível de avaliação conjunta de previsões pontuais e cenários probabilísticos, acompanhado de análises de robustez. Os achados justificam investigar a seleção ou combinação de modelos conforme o horizonte e o mês-alvo, sem demonstrar

que essa estratégia produzirá ganhos futuros ou que os resultados se estendem a outros setores e níveis de agregação. As principais limitações são o uso de uma única série agregada, o número reduzido de picos anuais avaliados, o tratamento das observações da pandemia, a busca restrita de hiperparâmetros, a ausência de variáveis econômicas explicativas e a avaliação em pseudo-tempo real sem as versões históricas da série, o que impede medir o efeito das revisões dos dados. Os dados, os scripts e as instruções de execução estão disponíveis em repositório público (Alves, 2026), permitindo a verificação independente do procedimento. Trabalhos futuros podem ampliar a análise para séries por produto e região e para outras atividades do varejo, incorporar variáveis macroeconômicas e de calendário promocional, reconstruir as versões históricas da PMC, testar outras arquiteturas e avaliar estratégias de combinação com procedimentos que considerem a dependência das previsões.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, Francisco Kevin Lima. **ia-demanda-sazonal-pmc**: pacote de reprodução do estudo sobre inteligência artificial para simulação de demandas em períodos sazonais. [S. l.]: GitHub, 2026. Disponível em: <https://github.com/kevinlimaeng20/ia-demanda-sazonal-pmc>. Acesso em: 10 out. 2026.

BERGMEIR, Christoph; HYNDMAN, Rob J.; KOO, Bonsoo. A note on the validity of cross-validation for evaluating autoregressive time series prediction. **Computational Statistics & Data Analysis**, v. 120, p. 70-83, 2018.

BOX, George E. P. *et al.* **Time series analysis:** forecasting and control. 5. ed. Hoboken: Wiley, 2015.

BREIMAN, Leo. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001.

CARBONNEAU, Real; LAFRAMBOISE, Kevin; VAHIDOV, Rustam. Application of machine learning techniques for supply chain demand forecasting. **European Journal of Operational Research**, v. 184, n. 3, p. 1140-1154, 2008.

CHEN, Tianqi; GUESTRIN, Carlos. XGBoost: a scalable tree boosting system. In: ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 22., 2016, San Francisco. **Proceedings** [...]. New York: ACM, 2016. p. 785-794.

CLEVELAND, Robert B. *et al.* STL: a seasonal-trend decomposition procedure based on loess. **Journal of Official Statistics**, v. 6, n. 1, p. 3-73, 1990.

DIEBOLD, Francis X.; MARIANO, Roberto S. Comparing predictive accuracy. **Journal of Business & Economic Statistics**, v. 13, n. 3, p. 253-263, 1995.

EFRON, Bradley. Bootstrap methods: another look at the jackknife. **The Annals of Statistics**, v. 7, n. 1, p. 1-26, 1979.

FILDES, Robert; MA, Shaohui; KOLASSA, Stephan. Retail forecasting: research and practice. **International Journal of Forecasting**, v. 38, n. 4, p. 1283-1318, 2022. DOI: <https://doi.org/10.1016/j.ijforecast.2019.06.004>.

FRIEDMAN, Jerome H. Greedy function approximation: a gradient boosting machine. **The Annals of Statistics**, v. 29, n. 5, p. 1189-1232, 2001.

GIL, Antonio Carlos. **Como elaborar projetos de pesquisa**. 7. ed. São Paulo: Atlas, 2022.

GNEITING, Tilmann; KATZFUSS, Matthias. Probabilistic forecasting. **Annual Review of Statistics and Its Application**, v. 1, p. 125-151, 2014.

GNEITING, Tilmann; RAFTERY, Adrian E. Strictly proper scoring rules, prediction, and estimation. **Journal of the American Statistical Association**, v. 102, n. 477, p. 359-378, 2007.

HARVEY, David; LEYBOURNE, Stephen; NEWBOLD, Paul. Testing the equality of prediction mean squared errors. **International Journal of Forecasting**, v. 13, n. 2, p. 281-291, 1997.

HEWAMALAGE, Hansika; BERGMEIR, Christoph; BANDARA, Kasun. Recurrent neural networks for time series forecasting: current status and future directions. **International Journal of Forecasting**, v. 37, n. 1, p. 388-427, 2021.

HOLM, Sture. A simple sequentially rejective multiple test procedure. **Scandinavian Journal of Statistics**, v. 6, n. 2, p. 65-70, 1979.

HOLT, Charles C. Forecasting seasonals and trends by exponentially weighted moving averages. **International Journal of Forecasting**, v. 20, n. 1, p. 5-10, 2004.

HYNDMAN, Rob J. *et al.* **Forecasting with exponential smoothing: the state space approach**. Berlin: Springer, 2008.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. 3. ed. Melbourne: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>. Acesso em: 10 out. 2026.

HYNDMAN, Rob J.; KOEHLER, Anne B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v. 22, n. 4, p. 679-688, 2006.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Pesquisa Mensal de Comércio: calendário de divulgação e principais resultados de julho de 2026. Rio de Janeiro: IBGE, 2026b. Disponível em: <https://www.ibge.gov.br/estatisticas/economicas/comercio/9227-pesquisa-mensal-de-comercio.html>. Acesso em: 10 out. 2026.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Pesquisa Mensal de Comércio: tabela 8882 – índice e variação da receita nominal e do volume de vendas no comércio varejista, por atividades (2022 = 100). Rio de Janeiro: IBGE, 2026a. Disponível em: <https://sidra.ibge.gov.br/tabela/8882>. Acesso em: 10 out. 2026.

JACOBS, William; ZANINI, Roselaine Ruviano; COSTA, Manfred. Estudo comparativo de séries temporais para previsão de vendas de um produto. **Iberoamerican Journal of Industrial Engineering**, Florianópolis, v. 6, n. 12, p. 112-133, 2014. DOI: <https://doi.org/10.13084/2175-8018/ijie.v6n12p112-133>.

JANUSCHOWSKI, Tim *et al.* Forecasting with trees. **International Journal of Forecasting**, v. 38, n. 4, p. 1473-1481, 2022.

KE, Guolin *et al.* LightGBM: a highly efficient gradient boosting decision tree. In: CONFERENCE ON NEURAL INFORMATION

PROCESSING SYSTEMS, 31., 2017, Long Beach. **Advances in Neural Information Processing Systems 30**. [S. l.: s. n.], 2017. p. 3146-3154.

MAKRIDAKIS, Spyros *et al*. The M5 uncertainty competition: results, findings and conclusions. **International Journal of Forecasting**, v. 38, n. 4, p. 1365-1385, 2022.

MAKRIDAKIS, Spyros; SPILIOTIS, Evangelos; ASSIMAKOPOULOS, Vassilios. M5 accuracy competition: results, findings, and conclusions. **International Journal of Forecasting**, v. 38, n. 4, p. 1346-1364, 2022.

MAKRIDAKIS, Spyros; SPILIOTIS, Evangelos; ASSIMAKOPOULOS, Vassilios. Statistical and machine learning forecasting methods: concerns and ways forward. **PLoS ONE**, v. 13, n. 3, e0194889, 2018. DOI: <https://doi.org/10.1371/journal.pone.0194889>.

MAKRIDAKIS, Spyros; SPILIOTIS, Evangelos; ASSIMAKOPOULOS, Vassilios. The M4 Competition: 100,000 time series and 61 forecasting methods. **International Journal of Forecasting**, v. 36, n. 1, p. 54-74, 2020.

METROPOLIS, Nicholas; ULAM, Stanislaw. The Monte Carlo method. **Journal of the American Statistical Association**, v. 44, n. 247, p. 335-341, 1949.

NENNI, Maria Elena; GIUSTINIANO, Luca; PIROLO, Luca. Demand forecasting in the fashion industry: a review. **International Journal of Engineering Business Management**, v. 5, 2013. DOI: <https://doi.org/10.5772/56840>.

PEDREGOSA, Fabian *et al*. Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825-2830, 2011.

PETROPOULOS, Fotios *et al.* Forecasting: theory and practice. **International Journal of Forecasting**, v. 38, n. 3, p. 705-871, 2022.

RUSSELL, Stuart; NORVIG, Peter. **Artificial intelligence**: a modern approach. 4. ed. Hoboken: Pearson, 2020.

SEABOLD, Skipper; PERKTOLD, Josef. Statsmodels: econometric and statistical modeling with Python. In: PYTHON IN SCIENCE CONFERENCE, 9., 2010, Austin. **Proceedings** [...]. [S. l.: s. n.], 2010. p. 92-96. DOI: <https://doi.org/10.25080/Majora-92bf1922-011>.

SLACK, Nigel; BRANDON-JONES, Alistair; JOHNSTON, Robert. **Administração da produção**. Tradução: Daniel Vieira. 8. ed. São Paulo: Atlas, 2018.

SMYL, Slawek. A hybrid method of exponential smoothing and recurrent neural networks for time series forecasting. **International Journal of Forecasting**, v. 36, n. 1, p. 75-85, 2020.

SYNTETOS, Aris A. *et al.* Supply chain forecasting: theory, practice, their gap and the future. **European Journal of Operational Research**, v. 252, n. 1, p. 1-26, 2016.

TASHMAN, Leonard J. Out-of-sample tests of forecasting accuracy: an analysis and review. **International Journal of Forecasting**, v. 16, n. 4, p. 437-450, 2000.

THOMASSEY, Sébastien. Sales forecasts in clothing industry: the key success factor of the supply chain management. **International Journal of Production Economics**, v. 128, n. 2, p. 470-483, 2010.

TUBINO, Dalvio Ferrari. **Planejamento e controle da produção:** teoria e prática. 3. ed. São Paulo: Atlas, 2020.

VEIGA, Claudimar Pereira da *et al.* Impacto financeiro dos erros na previsão empresarial: um estudo comparativo entre modelos lineares e redes neurais. **Revista Produção Online**, Florianópolis, v. 12, n. 3, p. 629-656, jul./set. 2012.

WERNER, Liane; RIBEIRO, José Luis Duarte. Modelo composto para prever demanda através da integração de previsões. **Produção**, São Paulo, v. 16, n. 3, p. 493-509, set./dez. 2006.

WINTERS, Peter R. Forecasting sales by exponentially weighted moving averages. **Management Science**, v. 6, n. 3, p. 324-342, 1960.

ZHANG, Guoqiang; PATUWO, B. Eddy; HU, Michael Y. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, v. 14, n. 1, p. 35-62, 1998.

APÊNDICE A – TESTES DE DIEBOLD-MARIANO POR HORIZONTE

A tabela apresenta, para cada horizonte h , a comparação entre a rede neural MLP e o Holt-Winters (HW) com todas as previsões do período de teste e com os 37 meses-alvo comuns a todos os horizontes (julho de 2023 a julho de 2026).

Tabela 6. Testes de Diebold-Mariano por horizonte entre a rede neural MLP e o Holt-Winters

	Todas as previsões do teste

h	n	MAPE HW	MAPE MLP	p	p Hol
1	48	2,84	3,76	0,039	0,27
2	47	2,93	4,30	0,004	0,04
3	46	3,15	4,97	0,005	0,05

△ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: perda = erro percentual absoluto; p = p-valor bilateral com correção de Harvey, Leybourne e Newbold e distribuição t com $n - 1$ graus de liberdade; variância de longo prazo com autocovariâncias até a defasagem $h - 1$; p Holm = p-valor ajustado pelo método de Holm sobre os 12 horizontes. Valores inferiores a 0,05 em negrito.

APÊNDICE B – AVALIAÇÃO EM PSEUDO-TEMPO REAL

Tabela 7. MAPE (%) por antecedência efetiva, contada a partir do mês de divulgação do último dado utilizado

Antecedência (meses)	n	Sazonal ingênuo	Holt-Winters (ETS)	SARIMA	Red Neur MLP
0	47	5,43	2,97	3,23	4,41
1	46	5,43	3,14	3,61	5,07
2	45	4,60	3,19	3,66	4,28
3	44	4,48	2,96	3,34	4,01

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: antecedência 0 corresponde à previsão do próprio mês em que o dado foi divulgado. Foram excluídas 49 previsões para meses já encerrados na data de divulgação. Datas de divulgação conforme IBGE (2026b); série em sua versão vigente, sem as revisões históricas. Menor erro de cada linha em negrito.

APÊNDICE C – DEZEMBROS AVALIADOS COMO EVENTOS

Tabela 8. Erro percentual absoluto médio por dezembro: Holt-Winters e rede neural MLP

Mês-alvo	Período	Previsões (n)	MAPE Holt-Winters (%)	MAPE Rede Neural MLP (%)	Menor erro
Dez. 2014	Validação	11	6,34	6,04	Rede Neur MLP
Dez. 2015	Validação	12	9,54	13,81	Holt Winters (ETS)

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: média dos erros de todas as previsões de cada dezembro (origens e horizontes de 1 a 12 meses disponíveis). Teste exato do sinal, bilateral: teste, 3 de 4 favoráveis à MLP ($p = 0,62$); validação, 2 de 6 ($p = 0,69$); total, 5 de 10 ($p = 1,00$). Menor erro de cada dezembro em negrito.

APÊNDICE D – CALIBRAÇÃO POR HORIZONTE E MÊS-ALVO

Tabela 9. Cobertura dos intervalos simulados e CRPS no período de teste, por horizonte e por mês-alvo

		Cobertura de 80% (%)		Cobertura de 90% (%)	
Recorte	n	HW	MLP	HW	MLP
<i>Horizonte (meses)</i>					
1	48	89,6	81,2	100,0	93,8
2	47	87,2	91,5	95,7	91,5
3	46	84,8	84,8	93,5	95,7
4	45	91,1	88,9	95,6	93,3

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: HW = Holt-Winters (ETS); MLP = rede neural MLP; n = previsões avaliadas por modelo. Simulação com o conjunto completo de trajetórias (validação e teste já observado), a mesma da Tabela 4.

APÊNDICE E – SENSIBILIDADE AO HISTÓRICO DE ERROS

Tabela 10. Desempenho da simulação no período de teste conforme o conjunto de trajetórias reamostradas

Modelo	Trajetórias reamostradas		Origens avaliadas	Cobertura (%)	
	Conjunto	Número		80%	90%
Holt-Winters (ETS)	Completo	62-98	Todas	93,1	98,6
	Sem 2015-2016	27-63	Todas	85,7	93,9

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).
Nota: "Sem 2015–2016" exclui as trajetórias com meses-alvo nesses anos; "36 mais recentes" usa as 36 trajetórias completas mais recentes em cada origem; "Só teste" usa apenas trajetórias do período de teste. Com o conjunto completo e todas as origens, os valores coincidem com os da Tabela 4. Intervalos de confiança de 95% das coberturas com o conjunto completo (bootstrap circular em blocos de 12 origens): Holt-Winters, 80%: 87,5–97,4; 90%: 95,8–100,0; MLP, 80%: 81,7–89,4; 90%: 89,5–96,2.

Tabela 11. Cenários de dezembro de 2026 por conjunto de trajetórias reamostradas (índice, 2022 = 100)

Modelo	Trajetórias reamostradas	Nº de trajetórias	P10	P50	P90
Holt-Winters (ETS)	Completo	99	161,8	172,5	186,1
	Sem 2015-2016	64	167,0	175,8	184,1
	36 mais	36	167,9	176,4	183,7

⚠ Esta tabela possui muitas colunas e foi cortada para impressão. Para visualizá-la completa, acesse o artigo original em: <https://revistatopicos.com.br/artigos/utilizacao-de-inteligencia-artificial-para-simulacao-de-demandas-em-periodos-sazonais-um-estudo-aplicado-ao-varejo-brasileiro-de-tecidos-vestuario-e-calcados?noblockage>

Fonte: elaborado pelo autor (2026), com dados do IBGE (2026a).

Nota: 10.000 cenários a partir da origem de referência jul. 2026; o conjunto "Completo" reproduz a Tabela 5. Valor observado em dez. 2025: 170,0.

¹ Engenheiro de Produção pela Faculdade Educacional da Lapa (FAEL). Pós-graduando em Gestão de Projetos e Metodologias Ágeis pela Pontifícia Universidade Católica do Rio Grande do Sul (PUCRS).

E-mail: [acesse o artigo original para visualizar o e-mail](#). Lattes:

<http://lattes.cnpq.br/0532364315391869>