



**Anais do Simpósio Acadêmico de Engenharia
de Produção (SAEPRO) da EEL-USP**

IX SAEPRO – 25 e 26 de novembro de 2025

**Modelo de Predição de Demanda por Veículos Automotores no Brasil:
Um Sistema Baseado em Suavização Exponencial Tripla
(Holt-Winters)**

Jáed Fonseca Toledo

Centro Estadual de Educação Tecnológica Paula Souza - CEETEPS
(jaed.toledo@cpspos.sp.gov.br)

Marcelo Duduchi Feitosa

Centro Estadual de Educação Tecnológica Paula Souza - CEETEPS
(marcelo.duduchi@cpspos.sp.gov.br)



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Resumo

A indústria automotiva possui elevada relevância econômica e social, envolvendo múltiplos setores produtivos e exigindo decisões precisas sobre planejamento e produção. A previsão de demanda por veículos é uma atividade essencial, dada a influência de fatores econômicos, sociais e comportamentais. Este estudo tem como objetivo desenvolver e avaliar um sistema computacional para previsão de demanda de veículos baseado nos emplacamentos de veículos automotores no Brasil, por marca e modelo, utilizando exclusivamente dados históricos e o método de suavização exponencial tripla de Holt-Winters. A pesquisa adota a *Design Science Research Methodology* (DSRM) e utiliza dados públicos de emplacamentos entre 2019 e 2025, processados em Python. O artefato proposto foi avaliado por métricas reconhecidas, como MAE, MAPE e RMSE, demonstrando resultados com baixo erro percentual e elevado potencial de aplicação prática. Constatou-se que o modelo é mais preciso em previsões por marca do que por modelo, confirmando a hipótese de que métodos clássicos e simples podem gerar previsões eficazes com baixo custo computacional. O estudo contribui para a Engenharia de Produção ao oferecer uma solução replicável e de fácil implementação, reduzindo riscos de superprodução ou escassez na indústria automotiva.

Palavras-chave: Engenharia e Gerenciamento de Produção, Projeções e Predições, Veículos Automotores, Sistemas de Computação, Sistemas Produtivos.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Abstract

The automotive industry holds significant economic and social relevance, involving multiple productive sectors and requiring accurate decisions regarding planning and production. Forecasting vehicle demand is an essential activity, given the influence of economic, social, and behavioral factors. This study aims to develop and evaluate a computational system for forecasting demand based on motor vehicle registrations in Brazil, by brand and model, using exclusively historical data and the Holt-Winters triple exponential smoothing method. The research adopts Design Science Research Methodology (DSRM) and uses public registration data from 2019 to 2025, processed in Python. The proposed artifact was evaluated using recognized metrics such as MAE, MAPE, and RMSE, showing results with low percentage error and high potential for practical application. It was found that the model is more accurate in brand-level forecasts than in model-level ones, confirming the hypothesis that classical and simple methods can generate effective predictions with low computational cost. The study contributes to Production Engineering by offering a replicable and easy-to-implement solution, reducing the risks of overproduction or shortage in the automotive industry.

Keywords: Production Engineering and Management, Projections and Predictions, Motor Vehicles, Computer Systems, Production Systems.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Resumen

La industria automotriz posee una alta relevancia económica y social, al involucrar múltiples sectores productivos y exigir decisiones precisas sobre planificación y producción. La previsión de la demanda de vehículos es una actividad esencial, dada la influencia de factores económicos, sociales y de comportamiento. Este estudio tiene como objetivo desarrollar y evaluar un sistema computacional para la predicción de la demanda de vehículos con base en las matriculaciones de vehículos automotores en Brasil, por marca y modelo, utilizando exclusivamente datos históricos y el método de suavización exponencial triple de Holt-Winters. La investigación adopta la *Design Science Research Methodology* (DSRM) y utiliza datos públicos de matriculación entre 2019 y 2025, procesados en Python. El artefacto propuesto fue evaluado mediante métricas reconocidas, como MAE, MAPE y RMSE, mostrando resultados con bajo error porcentual y alto potencial de aplicación práctica. Se constató que el modelo es más preciso en las predicciones por marca que por modelo, confirmando la hipótesis de que los métodos clásicos y sencillos pueden generar previsiones eficaces con bajo costo computacional. El estudio contribuye a la Ingeniería de Producción al ofrecer una solución replicable y de fácil implementación, reduciendo los riesgos de sobreproducción o escasez en la industria automotriz.

Palabras clave: Ingeniería y Gestión de Producción, Proyecciones y Predicciones, Vehículos a Motor, Sistemas de Computación, Sistema Productivo.



1. INTRODUÇÃO

A indústria automotiva desempenha papel estratégico na economia global devido ao envolvimento de empresas de múltiplos setores em sua cadeia produtiva, desde o fornecimento de insumos e componentes até a montagem, distribuição, comercialização e financiamento dos veículos (DULCI, 2021).

A capacidade de prever adequadamente a demanda por modelos específicos de automóveis é importante para as organizações participantes desse ecossistema produtivo, pois viabiliza eficiência operacional, sustentabilidade financeira e competitividade. Todavia, a criação de modelos de predição para esse setor é complexa dada a influência de diversos fatores econômicos, sociais e comportamentais que influenciam a tomada de decisão dos consumidores e demais partes envolvidas nessa cadeia, tornando as demandas desse mercado extremamente voláteis e de difícil predição (CANOVA; CUGNASCA, 2025).

De acordo com Winters (1960), coautor do modelo de suavização exponencial tripla, a técnica estatística para previsão de séries temporais utilizada nesta pesquisa dada sua confiabilidade e versatilidade, modelos de predição que incorporam variáveis exógenas, como indicadores macroeconômicos, comportamento do consumidor e tendências de mercado, tendem a demandar elevado esforço computacional e de manutenção, limitando sua aplicabilidade nos ambientes corporativos que demandam soluções ágeis, replicáveis e de fácil manutenção futura.

Diante desse contexto, torna-se relevante investigar a viabilidade da utilização de modelos preditivos simples, baseados exclusivamente em séries históricas e técnicas de suavização, para prover resultados satisfatórios com baixo custo computacional e facilidade de uso e adaptação pelas equipes envolvidas no planejamento, produção e logística desse processo produtivo, contribuindo para o aprimoramento das tomadas de decisão (WINTERS, 1960) visando reduzir a superprodução ou escassez de veículos.

Nesse sentido, esta pesquisa busca responder à seguinte questão: “É possível criar um sistema, baseado apenas no histórico de emplacamentos e em suavização exponencial



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

tripla, para prever a demanda futura de veículos automotores no Brasil com baixa margem de erro e baixo esforço computacional para fácil uso pelas equipes das múltiplas empresas de múltiplas indústrias envolvidas no processo de produção de veículos automotores?”.

Parte-se da hipótese de que é possível criar um sistema preditivo eficaz baseado somente no histórico de emplacamentos e suavização exponencial tripla para prever a demanda de veículos automotores com baixa margem de erro e baixo esforço computacional para fácil uso pelas equipes das múltiplas empresas de múltiplas indústrias envolvidas no processo de produção brasileira de veículos automotores.

A relevância acadêmica deste trabalho está em demonstrar que métodos consolidados e amplamente conhecidos podem ser utilizados de maneira eficiente para a criação de modelos de previsão de demanda que conciliem simplicidade, precisão e baixo custo computacional, contribuindo para o avanço do conhecimento na área de Engenharia da Produção através da criação de uma solução replicável que sirva de ferramenta de apoio à decisão para a otimização de processos de produção de outros bens e serviços, promovendo o uso racional de recursos materiais e humanos.

O objetivo central deste trabalho é desenvolver e avaliar um sistema computacional para previsão de demanda baseado em emplacamentos de veículos automotores no Brasil por modelo e por marca. Mais especificamente: (i) obter automaticamente os dados de bases públicas sobre os emplacamentos de veículos automotores disponíveis na Internet e armazená-los localmente para processamento posterior; (ii) limpar e normalizar os dados para uso pelo modelo de predição; (iii) processar os dados através do modelo proposto e avaliar o desempenho das predições de um ano no passado; (iv) gerar a previsão de emplacamentos para um ano no futuro e (v) discutir as contribuições do artefato para a Engenharia de Produção e sistemas produtivos.



2. FUNDAMENTAÇÃO TEÓRICA

A cadeia de produção da indústria automotiva é complexa e envolve múltiplas empresas de diversos setores econômicos: pneumáticos e câmaras de ar, metais, plásticos, tintas e vernizes, cabines, carrocerias, reboques, peças, acessórios, lubrificantes, elétricos e eletrônicos, baterias, tapeçaria, vendas, financiamentos, seguros, dentre outros, sendo uma grande geradora de empregos diretos e indiretos (DULCI, 2021).

Uma das maneiras de reduzir custos relacionados a produção - insuficiente ou em excesso - por essas múltiplas empresas envolvidas no processo de produção de veículos automotores, decorrente da flutuação de demanda da indústria automotiva, é o uso de modelos de predição de demanda que as suportem (CANOVA; CUGNASCA, 2025).

Diversos fatores influenciam o comportamento dos consumidores no processo de decisão, por exemplo, mas não limitado à, (i) fatores psicológicos e internos, como motivação, percepção, subjetividade, categorização, seletividade, expectativas e experiências passadas; (ii) fatores sociais, como família, grupos de referência, papéis sociais e status; (iii) fatores culturais, como cultura, subcultura e classe social; (iv) fatores econômicos, como renda pessoal e familiar, expectativas de renda futura, economias, liquidez de bens e acesso à crédito; (v) fatores pessoais, como idade, ocupação e estilo de vida e (vi) outros fatores externos, como promoções, preço e local de venda (RAMYA; ALI, 2016). Isso torna desafiadora a construção de modelos de predição amplos, utilizando todas as variáveis exógenas conhecidas, dado o grande número de fatores externos que influenciam as vendas e emplacamentos. Estudos correlatos para a previsão de emplacamentos e vendas de veículos são múltiplos, com uso de variáveis exógenas e abordagens distintas, normalmente utilizando modelos que utilizam *machine learning*. Alguns exemplos são os trabalhos de (i) Canova e Cugnasca (2025), que utilizaram variáveis macroeconômicas como Produto Interno Bruto (PIB), taxa de desemprego e taxa básica de juros; (ii) Pai e Liu (2018), que utilizaram cotações da bolsa de valores e análise de sentimentos na rede social X; (iii) Zhang, Xu, Ma e Pan (2022), que utilizaram opinião pública e índice de pesquisas online; (iv) Xia, Xue, Wu, Sun, Chen e Zhang (2020), que utilizaram as características dos veículos, como motorização, consumo,



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

número de assentos dentre outros, e dos locais de venda; (v) Chiu e Shu (2017), que utilizaram dados de fóruns de discussão na Internet e popularidade de busca de palavras chave no Google Trends; (vi) Yeh e Wang (2023), que utilizaram o índice de desenvolvimento humano, expectativa de vida e nível de educação, dentre outras variáveis, para prever a venda de veículos.

O método de suavização exponencial tripla é um método de predição que (i) apresenta resultados confiáveis, (ii) exige baixo armazenamento e pouco esforço de processamento quando comparado com outros métodos de previsão e (iii) responde mais rapidamente a mudanças no comportamento das séries utilizando somente variáveis endógenas, sendo ideal para a previsão de vendas individuais de produtos e materiais de forma rotineira, podendo ser aplicado a inventários com milhares de produtos sem elevar os custos de processamento, ao contrário de outros métodos de predição tradicionais e modernos (WINTERS, 1960).

O modelo de suavização exponencial tripla criado por Charles Holt e refinado por Peter Winters passou por inúmeras validações durante suas mais de 6 décadas de existência, sendo possível identificar múltiplas aplicações acadêmicas dele. Buscas simples pelo termo ‘Holt-Winters’ em três bases acadêmicas distintas retornaram os seguintes resultados: Google Scholar, 24.300; Scopus, 4.995; IEEE Xplore, 326 resultados. A versatilidade do modelo pode ser observada pelos múltiplos tipos de previsão realizados, como os apresentados a seguir como amostra: (i) emissão de vistos de trabalho para estrangeiros (SANTOS; BARFEH, 2019); (ii) tendências de exportação de durião, um fruto similar à jaca (DEETHONG; BOONNAM, 2022); (iii) emissão de gás carbônico na Arábia Saudita (ALAM; ALARJANI, 2021); (iv) necessidades de corte de flores para colheita (SAPUTRI; FITRIYADI; KHUSNULIAWATI, 2024); (v) demanda de energia fotovoltaica (KANCHANA; SIRISUKPRASERT, 2020); (vi) interferências na ionosfera que prejudicam sistemas de GPS (ELMUNIM; ABDULLAH; HASBI; BAHARI, 2013); (vii) passageiros de sistemas metroviários (AKPINAR; DURRANI; AKPINAR; SALEH, 2025); (viii) número de contaminados pelo COVID-19 (DJAKARIA; SALEH, 2021);

(ix) produção de gás natural (RIBEIRO; MARQUES; JÚNIOR; ALMEIDA; CAMPOS; CHASE, 2019); e (x) falhas em aeronaves (YANG; YU; SUN, 2017).

Atualmente o modelo de Holt-Winters está implantado em múltiplos pacotes estatísticos reconhecidos no mercado, dentre eles: R (MEYER, 2025), SPSS (IBM, 2021), Stata (STATACORP, 2025), Julia (BRINKMANN, 2025), Calc (THE DOCUMENT FOUNDATION, 2025), Excel (MICROSOFT, 2016) e Python (PERKTOLD; SEABOLD; TAYLOR, 2024), o que reforça seu amplo uso e confiabilidade.

3. MÉTODO

Esta pesquisa adota uma abordagem quantitativa e experimental para desenvolver e avaliar um sistema de previsão de demanda de veículos utilizando uma base de dados pública com os registros de emplacamentos mensais ocorridos entre janeiro de 2019 e setembro de 2025.

A investigação seguiu a Design Science Research Methodology (DSRM) de Hevner, March, Park e Ram (2004), indicada para a construção e avaliação de artefatos tecnológicos. A **Tabela 1** lista as atividades da DSRM com as seções deste artigo.

Tabela 1 - Etapas da Metodologia DSRM

Atividade DSRM	Descrição	Seção no Artigo
Atividade 1	Identificação e motivação do problema	Seção 1. Introdução
Atividade 2	Definição dos objetivos da solução	Final da Seção 1. Introdução
Atividade 3	Projeto e construção do artefato	Seção 3. Método
Atividade 4	Demonstração do uso do artefato	Seção 4. Resultados e Discussões
Atividade 5	Avaliação do artefato	Seção 5. Resultados e Discussões
Atividade 6	Comunicação dos resultados	Todo o artigo

Fonte: Adaptado de Hevner, March, Park e Ram (2004) pelos autores.


Conforme detalhado na **Tabela 1**, (i) a Atividade 1 se refere à identificação e motivação do problema apresentado na Seção “1. Introdução”; (ii) a Atividade 2 trata da definição dos objetivos da solução e se localiza ao final da Seção “1. Introdução”; (iii) a Atividade 3 é voltada ao projeto e construção do artefato e é contemplada na Seção “3. Método”; (iv) a Atividade 4 aborda a demonstração do uso do artefato e a Atividade 5, a validação do artefato, ambas listadas na Seção “4. Resultados e Discussões”; e, por fim, (v) a

Atividade 6, que corresponde à comunicação dos resultados, é realizada ao longo de todo este artigo, incluindo a seção “5. Considerações Finais”.

3.1. Fluxo interno do artefato – visão geral

O fluxo de funcionamento geral do artefato criado é apresentado na **Figura 1**, que utiliza a notação BPMN 2.0 do Object Management Group (2013), onde os círculos indicam o início (verde) ou o fim (vermelho) do processo, os retângulos azuis de pontas arredondadas indicam as ações e os losangos amarelos indicam os pontos de bifurcação ou junção.

Figura 1 - Fluxo do sistema de predição de demanda de veículos automotores



Fonte: Elaborado pelos autores utilizando a ferramenta Bizagi.

Os passos do processo são (1) iniciar o processo de carga dos dados de marcas, (2) verificar se já existe arquivo salvo com as informações de marca e caso negativo (4) conectar com o site origem e buscar as informações mês a mês e (5) salvar num arquivo local para uso na execução atual ou em execuções futuras ou, caso negativo, (6) realizar a carga de arquivo salvo previamente em execuções anteriores. Em seguida é feita a (7) limpeza dos dados, (8) a identificação dos mais vendidos nos últimos 12 meses, (9) o cálculo das previsões dos próximos 12 meses e (10) o cálculo das previsões dos 12 meses anteriores para medição de performance. Concluídas essas etapas, são (11) impressos na tela os gráficos com os dados reais e as previsões futuras para cada marca e (12) os mesmos gráficos salvos em disco no formato Portable Network Graphics (PNG). Em seguida é (13) gerado um gráfico com as informações consolidadas de previsão de

emplacamentos para os próximos 12 meses, (14) armazenado em disco, também no formato PNG, esse gráfico. Por fim, os dados capturados do site, assim como as informações das predições, são salvos em planilhas Excel (XLSX) para facilitar análises adicionais futuras. O sistema (16) verifica se acabou de concluir a análise para marcas ou veículos e, no caso de ter concluído a análise de marcas e não a de veículos, inicia uma nova iteração, desta vez em busca dos dados dos veículos, repetindo nesse novo contexto os passos de 2 a 16.

3.2. Base de dados

Para o desenvolvimento do artefato foram utilizadas as informações das páginas públicas do site Autoo, que contém os emplacamentos por marca de veículo (MIOTTO; MEIER, 2025b) e por modelo de veículo (MIOTTO; MEIER, 2025a), replicando em formato de tabela HTML os dados da Secretaria Nacional de Trânsito (SENATRAN). As informações são extraídas pelo próprio artefato, utilizando a técnica de Web Scrapping, que permite a captura automatizada de dados de páginas HTML para reuso dos dados para outras aplicações (MALIK; RIZVI, 2011). As seguintes bibliotecas e classes foram utilizadas no processo de Web Scrapping: (i) para a extração dos dados brutos foi utilizada *'urllib.request'*; (ii) para detecção da codificação da página, *'chardet'*; (iii) para localização das tabelas e conversão em *datasets*, *'pandas.read_html'*; (iv) para armazenar os dados em disco, *'pickle'* e *'os'*. Da extração realizada, considerando os emplacamentos entre janeiro de 2019 e setembro de 2025, foram gerados dois *datasets*: (i) o primeiro com 2.953 registros com as informações de emplacamentos de veículos agrupados por marca e (ii) o segundo com 17.200 registros, armazenando as informações de emplacamentos por modelo de veículo.

3.3. Pré-processamento

Os passos comuns de um pré-processamento consistem na limpeza, na integração, no enriquecimento, na filtragem e na transformação de dados antes do processamento propriamente dito para minimizar o volume de dados e reduzir custos de infraestrutura, em especial armazenamento e processamento (DESAI; A, 2021).

O primeiro passo do pré-processamento do artefato consiste na exclusão de linhas e colunas existentes nas tabelas originais, mas irrelevantes para o processo de predição, tais como ‘Categoria’, ‘Posição no Ranking’, totalizadores, valores do ano anterior, dentre outros. São mantidas apenas a coluna com o índice (data), a marca ou o modelo (de acordo com a iteração em execução) e o número de emplacamentos.


Em seguida o sistema cria um *dataset* segregado somente com as informações de emplacamentos dos últimos 12 meses, somando o total de emplacamentos por marca e modelo para identificar os 10 mais vendidos de cada. Essa listagem é então aplicada como filtro nos *datasets* principais, que passam a conter somente os emplacamentos dos *top 10*.

Todas as ações de pré-processamento são realizadas utilizando as funções *drop*, *dropna*, *sort_values*, *set_index*, *reset_index*, *loc*, *iloc*, *groupby*, *sum*, *nlargest*, *rename* e *concat* da biblioteca pandas.

3.4. Processamento

O processamento se inicia com a decomposição sazonal, utilizando o modelo aditivo, o período sazonal de 12 meses e a função *seasonal_decompose*. Os resultados da função são três componentes: a tendência (*trend*), a sazonalidade (*seasonal*) e os resíduos, ruído e flutuações aleatórias encontradas na série (*residual*) (PERKTOLD; SEABOLD; TAYLOR, 2025), conforme exemplo apresentado na **Figura 2**, que contém os resultados para a análise da marca Fiat.

Figura 2 - Decomposição sazonal dos dados de emplacamento da marca Fiat entre 2019 e 2025.



Fonte: Elaborado pelos autores utilizando Python, *statsmodels.tsa.seasonal* e *matplotlib*.

A **Figura 2** apresenta quatro blocos com gráficos distintos. (i) No primeiro bloco é apresentado o gráfico com a série temporal original; (ii) no segundo a tendência de movimentação dos dados no longo prazo; (iii) no terceiro a sazonalidade, isto é, os padrões que se repetem em intervalos fixos de tempo e; (iv) no quarto e último, os resíduos, que são ruídos e flutuações aleatórias identificadas nos dados.

O segundo passo do processo é a execução das previsões propriamente ditas utilizando a função *ExponentialSmoothing* da biblioteca *statsmodels.tsa.holwinters*, considerando o modelo aditivo e período sazonal de 12 meses. Essa função encapsula as equações utilizadas no modelo Holt-Winters, adequadas para a previsão de demandas que sejam compostas de nível, tendência e fator sazonal. A seguir seguem as definições de cálculo do modelo aditivo de suavização exponencial tripla conforme apresentado por Nurhamidah, Nusyirwan e Faisol (2020):

- **Suavização exponencial (S_t)**

$$S_t = \alpha(X_t - I_{t-L}) + (1 - \alpha)(S_{t-1} + b_{t-1})$$

- **Estimativa de tendência (b_t)**

$$b_t = \beta(S_t - S_{t-1}) + (1 - \beta)b_{t-1}$$

- **Estimativa de sazonalidade (I_t)**

$$I_t = \gamma(X_t - S_t) + (1 - \gamma)I_{t-L}$$

- **Previsão de suavização exponencial tripla de Holt-Winters (F_{t+m})**

$$F_{t+m} = S_t + mb_t + I_{t-L+m}$$

Onde:

t = intervalo (exemplos: dias, meses, trimestres, semestres, anos etc)

S_t = suavização exponencial em t

S_{t-1} = suavização exponencial em $t - 1$

b_t = elemento de tendência suavizados em t

b_{t-1} = elemento de tendência suavizados em $t - 1$

F_t = valor a ser previsto

F_{t+m} = resultado da predição ($t + m$)

m = o período a ser previsto

X_t = dados observados em t

α = parâmetro de suavização exponencial para os dados ($0 < \alpha < 1$)

β = parâmetro de suavização exponencial para a tendência ($0 < \beta < 1$)

γ = parâmetro de suavização exponencial para a sazonalidade ($0 < \gamma < 1$)

I_t = fator de suavização sazonal

L = comprimento sazonal (exemplos: 3, 4, 6, 12 etc)

As previsões são realizadas individualmente para cada marca e cada modelo de veículo e consideram os 12 meses futuros. Como entrada de dados são considerados os dados de janeiro de 2019 até setembro de 2025, exceto para a marca BYD, cujos dados considerados são a partir de janeiro de 2022 em decorrência de sua operação no Brasil ter iniciado mais recentemente do que das demais marcas. Em seguida são realizadas as

previsões dos 12 meses passados, através da remoção dos dados reais desses meses e realizando novas chamadas para a função *ExponentialSmoothing*, gerando os dados necessários para a avaliação dos resultados.

O terceiro passo é composto (i) da geração de gráficos que facilitem a interpretação dos dados, (ii) da geração e arquivamento desses gráficos em disco, (iii) da geração de arquivos com os dados origem, após pré-processamento, e previsões em formato de planilha Excel. Para a geração dos gráficos e seu arquivamento em disco é utilizada a biblioteca *matplotlib.pyplot* e para a geração das planilhas a função *to_excel*.

3.5. Avaliação dos resultados

Seguindo as indicações de Chopra e Meindl (2010) foram utilizadas as seguintes medidas para avaliar os desvios entre o previsto e o realizado: (i) Erro Médio Absoluto (MAE), (ii) Erro Percentual Absoluto Médio (MAPE), (iii) Erro Percentual Médio (MPE), (iv) Erro Quadrático Médio (MSE), (v) Raiz do Erro Quadrático Médio (RMSE) e (vi) Raiz do Erro Quadrático Médio Percentual (RMSE%), cujas fórmulas são apresentadas a seguir, onde P representa os valores preditos e D os valores observados. As medições foram realizadas individualmente, para cada marca e modelo de veículo, e de forma agrupada, considerando todas as marcas e modelos. O intervalo de avaliação de resultados foi de um ano, entre outubro de 2024 e setembro de 2025.

- **Erro Médio Absoluto – *Mean Absolute Error* (MAE)**

Média dos desvios absolutos de cada período.

$$MAE = \frac{1}{n} \sum_{t=1}^n |P_t - D_t|$$

- **Erro Percentual Absoluto Médio – *Mean Absolute Percentage Error* (MAPE)**

Média dos erros percentuais absolutos de cada observação.

$$MAPE = \frac{100}{n} \sum_{t=1}^n \frac{|P_t - D_t|}{D_t}$$

- **Erro Percentual Médio – *Mean Percentage Error* (MPE)**

Média dos erros percentuais de cada observação, para identificar o viés do modelo.

- MPE próximo de zero: sem viés.
- MPE grande e negativo: previsão subestimada.
- MPE grande e positivo: previsão superestimada.

$$MPE = \frac{100}{n} \sum_{t=1}^n \frac{(P_t - D_t)}{D_t}$$

- **Erro Quadrático Médio – *Mean Squared Error* (MSE)**

Erros de cada observação são elevados ao quadrado, penalizando os grandes erros.

$$MSE = \frac{1}{n} \sum_{t=1}^n (P_t - D_t)^2$$

- **Raiz do Erro Quadrático Médio – *Root Mean Squared Error* (RMSE)**

Aplicação da raiz quadrada ao MSE.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n (P_t - D_t)^2}$$

- **Raiz do Erro Quadrático Médio Percentual – *Root Mean Squared Error* (RMSE%)**

Conversão da raiz do erro quadrático médio em percentual.


$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n \left[\frac{(P_t - D_t)}{P_t} \right]^2}$$

4. RESULTADOS E DISCUSSÕES

Os resultados das previsões são apresentados e comparados com os emplacements reais nos gráficos a seguir. Os resultados do cálculo das métricas recomendadas por Chopra e Meindl (2010) são apresentadas subsequentemente, incluindo comentários sobre o desempenho das predições geradas pelo artefato.

A **Figura 3** consolida o histórico real de emplacamentos, em azul, e as previsões de emplacamentos, em laranja, calculadas pelo artefato para as marcas de veículos. A **Figura 4**, por sua vez, apresenta o mesmo para os modelos de veículos.

Figura 3 - Previsões de emplacamentos por marca (10 mais vendidas)




Fonte: Elaborado pelos autores utilizando a biblioteca *matplotlib* e linguagem Python.

Através da análise visual dos gráficos apresentados na **Figura 3** é possível notar sobreposição das linhas azuis (real) e laranjas (previsões), o que indica relativa precisão do modelo preditivo. O último gráfico apresenta somente as previsões futuras para todas as marcas sobrepostas, sem dados reais históricos. Segundo as previsões do artefato, em

setembro de 2026 Fiat e Volkswagen se manterão em posição de liderança, seguidos por Chevrolet que, no caso de o modelo utilizado pelo artefato acertar suas previsões, perderá a terceira colocação para a Hyundai apenas nos meses de abril, maio e junho de 2026.

Figura 4 - Previsões de emplacamentos por modelo (10 mais vendidos)



Fonte: Elaborado pelos autores utilizando a biblioteca *matplotlib* e linguagem Python.

Similar ao observado na **Figura 3**, através da análise dos gráficos da **Figura 4** se nota a sobreposição das linhas azuis (real) e laranjas (previsões), reforçando a precisão satisfatória do modelo de previsão. O último gráfico apresenta somente as previsões para todos os modelos, sem dados reais históricos. Se concretizadas as previsões do artefato,

em 2026 o veículo Volkswagen Polo será o mais emplacado, seguido pela Fiat Strada, e o Chevrolet Onix sofrerá brusca queda entre dezembro de 2025 e junho de 2026, quando cai para a última posição dentre os 10 mais emplacados.

As previsões geradas pelo artefato, tanto para as marcas quanto para os modelos de veículos, no intervalo de outubro de 2024 a setembro de 2026 são apresentadas na **Tabela 2** e na **Tabela 3**, respectivamente. Os primeiros 12 registros, isto é, os dados entre outubro de 2024 e setembro de 2025, foram utilizados em conjunto com os dados reais observados no mesmo período para o cálculo das métricas de erro das previsões (MAE, MPE, MAPE, MSE, RMSE e RMSE%) apresentadas na **Tabela 4**.

Tabela 2 - Previsão de emplacamentos por marca de veículo entre out.24 e set.26

Marca / Mês.Ano	Fiat	Volkswagen	Chevrolet	Hyundai	Toyota	Renault	Jeep	BYD	Honda	Nissan
out.24	50.002	36.869	28.820	15.672	21.179	14.750	11.833	6.700	8.666	8.326
nov.24	53.980	41.902	32.195	19.917	21.005	14.523	11.970	7.470	9.820	8.498
dez.24	50.651	46.126	34.654	25.933	20.975	17.873	12.430	8.967	9.762	7.172
jan.25	39.641	29.034	18.320	17.090	8.612	12.234	7.822	9.173	6.437	5.278
fev.25	36.075	20.560	19.101	13.684	12.088	9.432	7.961	7.886	7.829	6.448
mar.25	41.616	28.895	16.441	14.206	17.895	10.597	10.043	8.046	8.329	6.818
abr.25	34.003	23.659	14.766	9.721	12.333	8.399	7.235	8.247	7.261	5.071
mai.25	43.470	36.011	21.237	14.741	16.132	9.878	9.420	7.775	8.618	6.311
jun.25	49.594	39.966	21.496	18.620	16.311	14.247	10.625	8.875	9.748	5.366
jul.25	45.537	41.067	26.137	18.722	17.083	11.076	10.391	8.841	9.574	6.122
ago.25	51.646	44.424	25.830	17.897	16.355	8.735	10.363	9.904	8.467	6.732
set.25	44.337	38.513	24.255	16.539	14.353	11.783	9.076	9.907	8.205	6.548
out.25	47.786	41.905	26.885	18.837	17.333	11.328	11.521	10.770	8.054	7.738
nov.25	49.119	41.799	29.852	19.317	17.393	12.750	11.463	11.369	7.780	7.282
dez.25	50.534	46.633	34.335	20.949	20.451	14.888	12.256	12.832	8.513	7.996
jan.26	38.829	32.627	20.289	15.179	13.835	9.051	9.396	11.328	5.901	6.649
fev.26	41.300	33.744	19.863	15.918	14.491	9.218	8.922	11.775	6.347	6.820
mar.26	44.081	36.257	20.516	17.585	15.639	9.839	9.949	12.787	6.273	7.676
abr.26	42.424	31.024	15.230	15.769	15.131	6.882	8.502	13.106	5.186	6.093
mai.26	43.670	34.533	15.873	16.503	15.154	7.084	9.562	13.035	5.603	6.953
jun.26	45.635	36.779	15.654	17.384	15.608	10.320	9.941	12.777	6.044	6.972
jul.26	50.225	40.774	19.733	18.819	17.896	10.274	10.818	13.533	6.138	8.230
ago.26	50.817	42.293	21.042	19.263	16.877	9.101	10.959	13.926	6.859	7.326
set.26	49.503	41.317	23.379	18.695	15.952	10.370	10.626	13.983	7.514	7.926

Fonte: Elaborado pelos autores com dados previstos pelo modelo preditivo.

Se destaca na **Tabela 2** a tendência de crescimento constante da marca BYD, que ocupará a sexta posição do *ranking* em setembro caso as previsões de crescimento se concretizem, ultrapassando Renault e Jeep no total de emplacamentos.

Tabela 3 - Previsão de emplacamentos por modelo de veículo entre out.24 e set.26

Modelo / Mês.Ano	Fiat Strada	Volkswagen Polo	Fiat Argo	Volkswagen T-Cross	Hyundai HB20	Chevrolet Onix	Hyundai Creta	Fiat Mobi	Chevrolet Tracker	Volkswagen Saveiro
out.24	13.426	13.537	8.975	7.157	7.272	8.993	5.562	5.276	6.720	4.858
nov.24	14.962	14.546	9.672	7.634	9.064	9.564	7.389	6.214	6.883	4.783
dez.24	12.942	16.123	9.278	9.687	11.048	12.595	7.765	6.306	7.284	6.469
jan.25	13.740	12.890	4.794	7.255	8.490	5.053	4.231	4.843	5.599	5.359
fev.25	10.037	9.552	5.937	7.572	6.308	5.618	5.145	5.197	5.350	2.995
mar.25	10.931	10.114	5.852	7.738	6.619	3.008	5.298	6.377	5.270	4.581
abr.25	9.650	7.647	6.836	5.723	4.567	3.148	4.123	4.283	3.809	5.486
mai.25	10.471	9.223	8.408	7.346	5.777	5.047	5.399	6.110	4.472	5.353
jun.25	11.060	12.234	9.668	8.748	8.162	6.298	5.385	6.554	3.900	5.928
jul.25	12.495	13.114	9.365	9.641	8.643	8.843	6.199	6.693	5.178	5.650
ago.25	13.840	11.980	9.709	9.647	7.711	8.429	7.556	8.355	7.240	6.081
set.25	11.116	12.497	9.463	8.403	7.042	6.632	6.626	6.797	6.008	5.683
out.25	12.101	12.434	10.631	8.102	7.930	7.419	6.849	4.965	6.176	7.896
nov.25	12.600	12.537	10.860	8.069	8.161	8.528	6.800	4.612	6.124	7.490
dez.25	12.717	13.151	10.146	9.318	8.301	10.871	7.918	4.945	7.147	8.039
jan.26	10.918	10.471	7.465	6.749	6.200	6.282	5.616	3.808	4.405	6.760
fev.26	10.803	11.726	8.567	7.602	6.247	6.409	5.868	4.873	4.187	7.222
mar.26	11.534	13.080	8.448	7.969	7.474	4.812	6.100	5.488	5.179	7.507
abr.26	10.734	12.418	7.818	6.226	5.882	2.244	5.625	4.881	4.716	7.343
mai.26	11.252	12.387	8.742	7.361	5.864	1.823	6.388	5.203	4.861	7.401
jun.26	10.856	12.812	9.200	8.242	6.849	1.868	6.537	5.445	4.489	7.610
jul.26	11.997	13.964	10.554	9.118	7.872	3.813	6.807	5.719	5.070	8.380
ago.26	13.056	13.107	10.519	9.229	8.236	4.468	6.953	6.361	5.248	8.804
set.26	11.762	12.893	10.025	8.309	7.653	5.287	6.537	6.062	6.005	9.295

Fonte: Elaborado pelos autores com dados previstos pelo modelo preditivo.

Se destaca na **Tabela 3** a disputa entre os modelos Volkswagen Polo e Fiat Strada pela primeira posição e a queda abrupta do Chevrolet Onix, caso as previsões se concretizem. Os emplacamentos dos demais modelos variam, e algumas posições são alternadas no decorrer do ano, mas não com variação tão elevada quanto no caso do Chevrolet Onix.

Na **Tabela 4**, que consolida as métricas de erro, é possível notar que modelo apresenta viés variável por marca e modelo, sendo mais recorrente a subestimação, identificada

através do sinal negativo do MPE. Os maiores vieses negativos foram de -11,3% para o modelo Volkswagen Polo e -3,6% para a marca Renault. O viés geral para as 10 marcas de veículo avaliadas foi de -1,3% e para os 10 modelos de veículo de -3,6%.

Tabela 4 - Métricas de erro das predições de emplacamento de veículos

Marca / Modelo	MAE	MPE	MAPE	MSE	RMSE	RMSE%
Fiat	4.192	-1,4%	+9,7%	23.855.875	4.884	10,9%
Volkswagen	3.985	+0,7%	+12,6%	23.928.308	4.891	13,6%
Chevrolet	2.183	+0,5%	+10,1%	7.257.607	2.694	11,4%
Hyundai	4.038	-2,8%	+24,5%	21.626.424	4.650	26,9%
Toyota	2.351	-0,9%	+15,3%	8.050.951	2.837	17,8%
Renault	1.552	-3,6%	+14,9%	3.725.788	1.930	16,5%
Jeep	1.390	-0,2%	+14,3%	2.347.404	1.532	15,4%
BYD	791	-0,2%	+9,9%	1.121.058	1.059	12,4%
Honda	851	-1,9%	+10,3%	988.075	994	11,8%
Nissan	863	-2,8%	+13,6%	1.303.943	1.142	17,6%
Todas as marcas	2.220	-1,3%	+13,5%	9.420.544	3.069	16,8%
Fiat Strada	1.697	-2,3%	+14,5%	4.857.993	2.204	18,3%
Volkswagen Polo	2.133	-11,3%	+24,0%	7.927.882	2.816	24,7%
Fiat Argo	1.003	+1,9%	+12,8%	1.741.768	1.320	15,7%
Volkswagen T-Cross	1.595	-7,2%	+23,1%	3.453.895	1.858	23,6%
Hyundai HB20	2.206	-9,8%	+34,3%	6.604.213	2.570	33,6%
Chevrolet Onix	1.324	+2,2%	+20,5%	2.686.304	1.639	23,5%
Hyundai Creta	1.002	+0,5%	+16,1%	1.326.687	1.152	19,2%
Fiat Mobi	1.052	-5,6%	+18,6%	1.474.994	1.214	20,6%
Chevrolet Tracker	884	-4,4%	+16,8%	1.225.822	1.107	20,0%
Volkswagen Saveiro	1.006	+0,1%	+20,7%	1.688.945	1.300	23,5%
Todos os modelos	1.390	-3,6%	+20,2%	3.298.850	1.816	23,5%
Todas as marcas e modelos	1.805	-2,4%	+16,8%	6.359.697	2.522	19,4%

Fonte: Elaborado pelos autores utilizando Python e Microsoft Word.

O erro percentual varia ligeiramente de acordo com a metodologia de cálculo, sendo para as marcas de veículo de 13,5% utilizando MAPE e 16,8% utilizando RMSE%. Já para os veículos, 20,2% utilizando MAPE e 23,5% utilizando RMSE%.

As margens de erro são baixas, considerando que as previsões são realizadas considerando somente uma variável endógena, o próprio número de emplacamentos, e nenhuma variável exógena (por exemplo, PIB, taxa de desemprego, cotação da bolsa de valores e opinião dos consumidores e notícias abonadoras ou desabonadoras), e a natureza errática dos emplacamentos no decorrer dos meses, fato observável nos gráficos da **Figura 3** e da **Figura 4**.



Avaliando as métricas destacadas nos parágrafos anteriores e as demais detalhadas na **Tabela 4** é possível notar que o modelo é mais preciso na previsão de emplacamentos por marca do que por veículo.

5. CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo desenvolver e avaliar um sistema computacional para a previsão de demanda de veículos no Brasil por marca e modelo utilizando emplacamentos como base para as previsões. Fundamentada na *Design Science Research Methodology* (DSRM), a pesquisa buscou responder à questão central “É possível criar um sistema - baseado apenas no histórico de emplacamentos e em suavização exponencial tripla - para prever a demanda futura de veículos automotores no Brasil com baixa margem de erro e baixo esforço computacional para fácil uso pelas equipes das múltiplas empresas de múltiplas indústrias envolvidas no processo de produção de veículos automotores?”. A hipótese formulada é que sim, é possível criar um sistema preditivo eficaz baseado somente no histórico de emplacamentos e suavização exponencial tripla para prever demanda futura de veículos automotores com baixa margem de erro e baixo esforço computacional para fácil uso pelas equipes das múltiplas empresas de múltiplas indústrias envolvidas no processo de produção brasileira de veículos automotores. A hipótese foi confirmada pela análise dos resultados empíricos.

As análises demonstraram baixo viés (-1,3% para marcas e -3,6% para veículos) e erro percentual baixo (entre 13,5% e 16,8% para marcas e 20,2% e 23,5% para modelos), levando em conta a volatilidade do mercado, o grande número de fatores que influenciam os emplacamentos e o uso de apenas uma variável endógena para a previsão da série.

O desenvolvimento do estudo seguiu as etapas da DSRM. A identificação e a motivação do problema foram tratadas na Introdução, com destaque para a importância da indústria automotiva e a importância de modelos previsão de demanda. A definição dos objetivos da solução foi estabelecida e desdobrada em metas específicas relacionadas à obtenção, ao pré-processamento, ao processamento e à avaliação de resultados. A etapa de projeto

e construção do artefato foi detalhada na seção de Método, seguida pela demonstração de uso sobre bases públicas. A avaliação conduzida com base em métricas quantitativas reconhecidas, e a comunicação dos resultados realizada ao longo de todas as seções.

A análise quantitativa confirmou a hipótese de pesquisa, demonstrando que métodos consolidados - que conciliam simplicidade, precisão e baixo custo computacional, como a suavização exponencial tripla de Holt-Winters - podem ser utilizados para criação de modelos de previsão eficientes.

Algumas limitações do artefato são reconhecidas e abrem espaço para oportunidades futuras, como: (i) melhorar o modelo de previsão para lidar de forma automática com marcas e modelos novos, por exemplo BYD, evitando a necessidade de tratamentos especiais *hard-coded*; (ii) realizar a previsão do mercado como um todo e ajustar as previsões por marca e modelo com base nessa previsão geral, correlacionando aumentos de emplacamentos em uma marca ou modelo com reduções em outro; (iii) ajustar o modelo para previsão de demanda de outros tipos de veículos, como motocicletas e caminhões; (iv) comparar o resultado com previsões realizadas por outros modelos de predição utilizando as mesmas variáveis e variáveis diferentes; (v) combinar os modelos de predição mais eficientes para criação de um comitê com múltiplos níveis visando aumentar a precisão das previsões, conforme experimento de Silva, Toledo, Haddad, Feitosa e Orsi (2025), (vi) aplicar e avaliar a performance de modelos mais modernos de previsão que, similar ao modelo de Holt-Winters, foquem em eficiência combinada com minimização do uso de recursos, como XGBoost (CHEN; GUESTIN, 2016).

Conclui-se, portanto, que é possível criar um sistema preditivo eficaz, baseado somente no histórico de emplacamentos e suavização exponencial tripla para prever a demanda futura de veículos automotores com baixa margem de erro e baixo esforço computacional para fácil uso pelas equipes das múltiplas empresas de múltiplas indústrias envolvidas no processo de produção brasileira de veículos automotores. Esse tipo de solução representa uma abordagem eficaz e confiável, fundamentada e alinhada aos princípios da Engenharia de Produção para redução de superprodução ou escassez em processos produtivos.



6. REFERÊNCIAS

AKPINAR, Mustafa; DURRANI, Usman; AKPINAR, Kevser Ovaz; SALEH, Mohamed. Subway Ridership Forecasting Using Seasonal and Holt-Winters Models with Calendar Effects. **2025 International Conference On Computer, Information And Telecommunication Systems (Cits)**, Colmar, p. 1-5, 16 jul. 2025. IEEE. Disponível em: <http://dx.doi.org/10.1109/cits65975.2025.11099483>. Acesso em: 05 out. 2025.

ALAM, Teg; ALARJANI, Ali. Forecasting CO2 Emissions in Saudi Arabia Using Artificial Neural Network, Holt-Winters Exponential Smoothing, and Autoregressive Integrated Moving Average Models. **2021 International Conference On Technology And Policy In Energy And Electric Power (Ict-Pep)**, Jakarta, p. 125-129, 29 set. 2021. IEEE. Disponível em: <http://dx.doi.org/10.1109/ict-pep53949.2021.9601031>. Acesso em: 05 out. 2025.

BRINKMANN, Stefan D. **TrendDecomposition.jl**: exponential smoothing. Exponential Smoothing. 2025. Disponível em: <https://sdbrinkmann.github.io/TrendDecomposition.jl/stable/man/exponential/>. Acesso em: 05 out. 2025.

CANOVA, Alessandro; CUGNASCA, Carlos Eduardo. Parametric and non-parametric learning models for time series: case study of vehicle sales based on exogenous variables in Brazil. **Gestão & Produção**, [S.L.], v. 32, e11824, 2025. FapUNIFESP (SciELO). Disponível em: <https://doi.org/10.1590/1806-9649-2025v32e11824>. Acesso em: 28 set. 2025.

CHEN, Tianqi; GUESTIN, Carlos. XGBoost. **Proceedings Of The 22Nd Acm Sigkdd International Conference On Knowledge Discovery And Data Mining**, Washington, p. 785-794, 13 ago. 2016. ACM. Disponível em: <http://dx.doi.org/10.1145/2939672.2939785>. Acesso em: 14 out. 2025.

CHIU, Chaochang; SHU, Chia-Houng. Monthly car sales prediction using Internet Word-of-Mouth (eWOM). **2017 Ieee International Conference On Innovations In**



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Intelligent Systems And Applications (Inista), [S.L.], p. 345-348, jul. 2017. IEEE. Disponível em: <http://dx.doi.org/10.1109/inista.2017.8001183>. Acesso em: 29 set. 2025.

CHOPRA, Sunil; MEINDL, Peter. Planning Demand and Supply in a Supply Chain: demand forecasting in a supply chain. In: CHOPRA, Sunil; MEINDL, Peter. **Supply Chain Management: strategy, planning, and operation**. 4. ed. New Jersey: Prentice Hall, 2010. p. 198-226.

DEETHONG, Thapanee; BOONNAM, Nathaphon. Forecasting Analysis of the Durian Yield Trends in Southern Thailand Using Holt-Winters Exponential Smoothing Method and Box-Jenkins' Techniques. **2022 Joint International Conference On Digital Arts, Media And Technology With Ecti Northern Section Conference On Electrical, Electronics, Computer And Telecommunications Engineering (Ecti Damt & Ncon)**, Chiang Rai, p. 29-32, 26 jan. 2022. IEEE. Disponível em: <http://dx.doi.org/10.1109/ectidamtncon53731.2022.9720330>. Acesso em: 05 out. 2025.

DESAI, Vinod; A, Dinesha H. A Hybrid Approach to Data Pre-processing Methods. **2020 Ieee International Conference For Innovation In Technology (Inocon)**, Bangluru, p. 1-4, 6 nov. 2020. IEEE. Disponível em: <http://dx.doi.org/10.1109/inocon50539.2020.9298378>. Acesso em: 12 out. 2025.

DJAKARIA, I; SALEH, S e. Covid-19 forecast using Holt-Winters exponential smoothing. **Journal Of Physics: Conference Series**, Gorontalo, v. 1882, n. 1, p. 012033, 1 maio 2021. IOP Publishing. Disponível em: <http://dx.doi.org/10.1088/1742-6596/1882/1/012033>. Acesso em: 05 out. 2025.

DULCI, João Assis. CRISE, EMPREGO E RENDA NA INDÚSTRIA AUTOMOTIVA: os casos do sul fluminense, camaçari e grande abc paulista em perspectiva comparada. **Sociologia & Antropologia**, [S.L.], v. 11, n. 1, p. 219-247, abr. 2021. FapUNIFESP (SciELO). Disponível em: <https://doi.org/10.1590/2238-38752021v1119>. Acesso em: 28 set. 2025.

ELMUNIM, N.A.; ABDULLAH, M.; HASBI, A.M.; BAHARI, S.A.. Short-term forecasting ionospheric delay over UKM, Malaysia, Using the Holt-Winter method. **2013**



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Ieee International Conference On Space Science And Communication (Iconspace), Melaka, p. 106-109, jul. 2013. IEEE. Disponível em: <http://dx.doi.org/10.1109/iconspace.2013.6599443>. Acesso em: 05 out. 2025.

HEVNER, Alan R.; MARCH, Salvatore T.; PARK, Jinsoo; RAM, Sudha. Design Science in Information Systems Research. **Mis Quarterly**, Minneapolis, v. 28, n. 1, p. 75, 2004. JSTOR. Disponível em: <http://dx.doi.org/10.2307/25148625>. Acesso em: 05 out. 2025.

HOLT, Charles C.. Forecasting seasonals and trends by exponentially weighted moving averages. **International Journal Of Forecasting**, Austin, v. 20, n. 1, p. 5-10, jan. 2004. Elsevier BV. Disponível em: <http://dx.doi.org/10.1016/j.ijforecast.2003.09.015>. Acesso em: 29 set. 2025.

IBM. **IBM SPSS Modeler: Forecasting Catalog Sales (Time Series) - Exponential Smoothing**. 2021. Disponível em: <https://www.ibm.com/docs/en/spss-modeler/saas?topic=series-exponential-smoothing>. Acesso em: 05 out. 2025.

KANCHANA, Wutthipum; SIRISUKPRASERT, Siriroj. PV Power Forecasting with Holt-Winters Method. **2020 8Th International Electrical Engineering Congress (Ieecon)**, Chiang Mai, p. 1-4, mar. 2020. IEEE. Disponível em: <http://dx.doi.org/10.1109/ieecon48109.2020.229517>. Acesso em: 05 out. 2025.

MALIK, Sanjay Kumar; RIZVI, Sam. Information Extraction Using Web Usage Mining, Web Scrapping and Semantic Annotation. **2011 International Conference On Computational Intelligence And Communication Networks**, Gwalior, out. 2011. IEEE. Disponível em: <http://dx.doi.org/10.1109/cicn.2011.97>. Acesso em: 05 out. 2025.

MEYER, David. **R Documentation: Holt-Winters Filtering**. Disponível em: <https://search.r-project.org/R/refmans/stats/html/HoltWinters.html>. Acesso em: 05 out. 2025.

MICROSOFT. **FORECAST.ETS.SEASONALITY function**. 2016. Disponível em: <https://support.microsoft.com/en-us/office/forecast-ets-seasonality-function-32a27a3b-d22f-42ce-8c5d-ef3649269f3c>. Acesso em: 05 out. 2025.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

MIOTTO, Rafael; MEIER, Ricardo. **Carros mais vendidos do Brasil**. 2025a. Disponível em: <https://www.autoo.com.br/emplacamentos/veiculos-mais-vendidos/2025/>. Acesso em: 29 set. 2025.

MIOTTO, Rafael; MEIER, Ricardo. **Marcas de carros mais vendidas**. 2025b. Disponível em: <https://www.autoo.com.br/emplacamentos/marcas-mais-vendidas/2025/>. Acesso em: 29 set. 2025.

MORE: Mecanismo online para referências, versão 2.0. Florianópolis: UFSC Rexlab, 2013. Disponível em: <http://www.more.ufsc.br/>. Acesso em: 28 set. 2025.

NURHAMIDAH, Nurhamidah; NUSYIRWAN, Nusyirwan; FAISOL, Ahmad. FORECASTING SEASONAL TIME SERIES DATA USING THE HOLT-WINTERS EXPONENTIAL SMOOTHING METHOD OF ADDITIVE MODELS. **Jurnal Matematika Integratif**, [S.L.], v. 16, n. 2, p. 151-157, 5 dez. 2020. Universitas Padjadjaran. Disponível em: <http://dx.doi.org/10.24198/jmi.v16.n2.29293.151-157>. Acesso em: 23 out. 2025.

OBJECT MANAGEMENT GROUP. **Business Process Model and Notation (BPMN)**. 2.0.2. ed. Milford, 2013. 532 p. Disponível em: <https://www.omg.org/spec/BPMN/2.0.2/PDF>. Acesso em: 06 out. 2025.

PAI, Ping-Feng; LIU, Chia-Hsin. Predicting Vehicle Sales by Sentiment Analysis of Twitter Data and Stock Market Values. **Ieee Access**, [S.L.], v. 6, p. 57655-57662, 2018. Institute of Electrical and Electronics Engineers (IEEE). Disponível em: <http://dx.doi.org/10.1109/access.2018.2873730>. Acesso em: 29 set. 2025.

PERKTOLD, Josef; SEABOLD, Skipper; TAYLOR, Jonathan. **Statsmodels 0.14.4: Holt Winter's Exponential Smoothing**. 2024. Disponível em: <https://www.statsmodels.org/stable/generated/statsmodels.tsa.holtwinters.ExponentialSmoothing.html>. Acesso em: 05 out. 2025.

PERKTOLD, Josef; SEABOLD, Skipper; TAYLOR, Jonathan. **Statsmodels 0.15.0 (+824): Seasonal decomposition using moving averages**. 2025. Disponível em:



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

https://www.statsmodels.org/dev/generated/statsmodels.tsa.seasonal.seasonal_decompose.html. Acesso em: 06 out. 2025.

RAMYA, N; ALI, Sa Mohamed. Factors affecting consumer buying behavior. **International Journal Of Applied Research**, Coimbatore, v. 2, n. 10, p. 76-80, 14 set. 2016. Disponível em: <https://www.allresearchjournal.com/archives/2016/vol2issue10/PartB/2-9-151-281.pdf>. Acesso em: 28 set. 2025.

RIBEIRO, Rhuan Carlos Martins; MARQUES, Glauber Tadaiesky; SANTOS JÚNIOR, Paulo Cerqueira dos; ALMEIDA, José Felipe Souza de; CAMPOS, Pedro Silvestre da Silva; CHASE, Otavio. Holt-Winters Forecasting for Brazilian Natural Gas Production. **International Journal For Innovation Education And Research**, [S.L.], v. 7, n. 6, p. 119-129, 30 jun. 2019. International Journal for Innovation Education and Research. Disponível em: <http://dx.doi.org/10.31686/ijier.vol7.iss6.1559>. Acesso em: 05 out. 2025.

SANTOS, Rico S.; BARFEH, Davood Pour Yousefian. Time Series Forecasting for Issuance of Alien Employment Permits by Nationality in the Philippines Using Holt-Winters Method. **2019 International Conference On Computational Intelligence And Knowledge Economy (Iccike)**, Dubai, p. 240-245, dez. 2019. IEEE. Disponível em: <http://dx.doi.org/10.1109/iccike47802.2019.9004243>. Acesso em: 05 out. 2025.

SAPUTRI, Wayan Cishe Fransiska; FITRIYADI, Farid; KHUSNULIAWATI, Hardika. Development of a Web-Based Forecasting System Using the Holt-Winters Exponential Smoothing Method to Improve Accuracy in Predicting Cut Flower Harvest Needs. **2024 6Th International Conference On Cybernetics And Intelligent System (Icoris)**, Surakarta, p. 1-5, 29 nov. 2024. IEEE. Disponível em: <http://dx.doi.org/10.1109/icoris63540.2024.10903767>. Acesso em: 05 out. 2025.

SILVA, Adriana Reigota; TOLEDO, Jáed Fonseca; HADDAD, Matheus Rangel; FEITOSA, Marcelo Duduchi; ORSI, Rafael Nobre. Predição de Fraudes em Anúncios de



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

Emprego: Um Sistema Baseado em Comitê de Classificadores. **Anais do XXXII Simpósio de Engenharia de Produção (Simpep)**, Bauru, nov. 2025.

STATACORP. **Tssmooth shwinters**: Holt-Winters seasonal smoothing. Disponível em: <https://www.stata.com/manuals14/tstssmoothshwinters.pdf#tstssmoothshwinters>.

Acesso em: 05 out. 2025.

THE DOCUMENT FOUNDATION. **Documentation Calc: Functions FORECAST.ETS.SEASONALITY**. Disponível em: https://wiki.documentfoundation.org/Documentation/Calc_Functions/FORECAST.ETS.SEASONALITY. Acesso em: 05 out. 2025.

WINTERS, Peter R.. Forecasting Sales by Exponentially Weighted Moving Averages. **Management Science**, Maryland, v. 6, n. 3, p. 324-342, abr. 1960. Institute for Operations Research and the Management Sciences (INFORMS). Disponível em: <http://dx.doi.org/10.1287/mnsc.6.3.324>. Acesso em: 29 set. 2025.

XIA, Zhenchang; XUE, Shan; WU, Libing; SUN, Jiaxin; CHEN, Yanjiao; ZHANG, Rui. ForeXGBoost: passenger car sales prediction based on xgboost. **Distributed And Parallel Databases**, [S.L.], v. 38, n. 3, p. 713-738, 25 maio 2020. Springer Science and Business Media LLC. Disponível em: <http://dx.doi.org/10.1007/s10619-020-07294-y>. Acesso em: 29 set. 2025.

YANG, Yan-Ming; YU, Hui; SUN, Zhi. Aircraft failure rate forecasting method based on Holt-Winters seasonal model. **2017 Ieee 2Nd International Conference On Cloud Computing And Big Data Analysis (Icccbda)**, Chengdu, p. 520-524, abr. 2017. IEEE. Disponível em: <http://dx.doi.org/10.1109/icccbda.2017.7951969>. Acesso em: 05 out. 2025.

YEH, Jen-Yin; WANG, Yu-Ting. A Prediction Model for Electric Vehicle Sales Using Machine Learning Approaches. **Journal Of Global Information Management**, [S.L.], v. 31, n. 1, p. 1-21, 31 jul. 2023. IGI Global. Disponível em: <http://dx.doi.org/10.4018/jgim.327277>. Acesso em: 29 set. 2025.



Anais do Simpósio Acadêmico de Engenharia de Produção (SAEPRO) da EEL-USP

IX SAEPRO – 25 e 26 de novembro de 2025

ZHANG, Mingyang; XU, Heyan; MA, Ning; PAN, Xinglin. Intelligent Vehicle Sales Prediction Based on Online Public Opinion and Online Search Index. **Sustainability**, [S.L.], v. 14, n. 16, p. 10344, 19 ago. 2022. MDPI AG. Disponível em: <https://doi.org/10.3390/su141610344>. Acesso em: 29 set. 2025.