

UNIVERSIDADE FEDERAL DE JUIZ DE FORA

FACULDADE DE ECONOMIA

CIÊNCIAS ECONÔMICAS

Brunária de Souza Bruno

Previsão de Vendas de Veículos Elétricos no Brasil: competição entre os métodos

Box & Jenkins e Amortecimento Exponencial

Juiz de Fora

2025

Brunária de Souza Bruno

**Previsão de Vendas de Veículos Elétricos no Brasil: competição entre os métodos
Box & Jenkins e Amortecimento Exponencial**

Monografia apresentada ao curso de Ciências
Econômicas da Universidade Federal de Juiz de
Fora como requisito parcial à obtenção do título
de bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Alexandre Zanini

Juiz de Fora

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Bruno, Brunária de Souza.

Previsão de Vendas de Veículos Elétricos no Brasil : competição entre os métodos Box & Jenkins e Amortecimento Exponencial / Brunária de Souza Bruno. -- 2025.

51 f. : il.

Orientador: Alexandre Zanini

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2025.

1. Veículos elétricos. 2. Eletromobilidade. 3. Séries Temporais. 4. Amortecimento Exponencial. 5. Box-Jenkins. I. Zanini, Alexandre, orient. II. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 11/12/2025, a Banca Examinadora, composta pelos professores

1 - Alexandre Zanini - orientador; e

2 - Douglas Sad Silveira,

reuniu-se para avaliar a monografia da acadêmica **BRUNÁRIA DE SOUZA BRUNO**, intitulada: **PREVISÃO DE VENDAS DE VEÍCULOS ELÉTRICOS NO BRASIL: COMPETIÇÃO ENTRE OS MÉTODOS BOX & JENKINS E AMORTECIMENTO EXPONENCIAL**.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu **APROVAR** a referida monografia.

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Alexandre Zanini, Professor(a)**, em 11/12/2025, às 15:49, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Douglas Sad Silveira, Professor(a)**, em 11/12/2025, às 16:00, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2790329** e o código CRC **99E3553D**.

Referência: Processo nº 23071.955637/2025-63

SEI nº 2790329

Dedico este trabalho à minha trajetória — à menina que fui e à mulher que me tornei. Àquela que, mesmo diante de limitações, medos e dificuldades, persistiu e acreditou que seria possível construir um futuro melhor.

AGRADECIMENTOS

Aos meus pais, devo o aprendizado precoce sobre responsabilidade e de valores que sustentam meu caráter até hoje. Sou grata especialmente, pela repetição quase pedagógica do meu pai que, se eu não estudasse, eu não teria futuro. Inocentemente acreditei nisso com tanta convicção que cheguei a temer que todos tivesse tal coisa menos eu. Hoje reconheço que essa crença ingênua me ajudou a ser dedicada nos estudos e foi um dos pilares da construção do futuro que, graças a Deus, tenho hoje.

Quero agradecer ao meu colega Bernardo, que, enquanto eu, desmotivada, nem sequer conferi o resultado do vestibular, foi quem acessou o site da universidade, inseriu meus dados, viu que eu havia sido aprovada e realizou a minha primeira inscrição. Às vezes, é o olhar do outro que nos revela capacidades que ainda não conseguimos enxergar em nós mesmos.

Agradeço enormemente ao meu companheiro Ricardo, que me ofereceu estrutura e apoio nos momentos de altos e baixos. À minha amiga “Doutora Advogada Tayene”, que assumiu o papel de pastora e fiscal acadêmica, orando por mim e me lembrando frequentemente de realizar todos os trabalhos correta e honestamente.

Registro, ainda, meu muito obrigada, ao meu orientador Zanini, que, com a ajuda de muita meditação, teve paciência em me orientar na minha terceira e indecisa troca de tema, em um curtíssimo prazo de pouco mais de um mês.

A todos os amigos e professores que participaram da minha jornada, deixo minha sincera gratidão.

“Seja a mudança que você quer ver no mundo”. (Mahatma Gandhi, 1948).

RESUMO

Nos últimos anos, a oferta de veículos elétricos — automóveis que utilizam energia elétrica em substituição aos combustíveis fósseis, principais responsáveis pela poluição atmosférica — vem crescendo em diversos países, inclusive no Brasil, principalmente com seu compromisso de reduzir pela metade as emissões de CO₂ até 2030. Diante desse cenário, a integração da econometria e economia ambiental, contribui para antecipar as necessidades tanto do setor privado — como no planejamento da infraestrutura de novas montadoras e instalações de postos de recarga — quanto do setor público, ao oferecer subsídios técnicos para políticas de incentivo fiscal e estímulo a adoção de veículos sustentáveis.

Este estudo realiza uma competição de métodos de previsão para analisar o comportamento do mercado de veículos elétricos no Brasil e identificar o modelo mais eficiente para projeções de curto prazo. Foram estimados dois modelos autoprojativos amplamente consolidados na literatura: o Modelo Box–Jenkins (MBJ) e o Método de Amortecimento Exponencial (MAE). O procedimento metodológico incluiu a organização e tratamento da base de dados, composta por vendas mensais de veículos elétricos de janeiro de 2020 a novembro de 2025, bem como a avaliação comparativa dos modelos por meio de métricas quantitativas de acurácia (MAPE, R^2 ajustado e GMRAE) e do teste de Ljung–Box para diagnóstico dos resíduos.

Os resultados indicam que o MBJ apresentou desempenho superior dentro da amostra, mas, fora da amostra, o MAE performou com melhor precisão. Portanto, com base no MAE, projeta-se a continuidade da trajetória ascendente das vendas, com crescimento anual estimado de aproximadamente 21% para 2025 e de 29% para 2026. Embora o ritmo de adoção brasileiro ainda seja inferior ao observado em economias desenvolvidas, as projeções sugerem uma expansão gradual e consistente no curto prazo.

Palavras-chaves: Amortecimento Exponencial. Box-Jenkins. Eletromobilidade. Previsão de vendas. Séries Temporais. Sustentabilidade. Veículos elétricos.

ABSTRACT

In recent years, the supply of electric vehicles—automobiles that use electric energy instead of fossil fuels, which are the main contributors to atmospheric pollution—has been increasing in several countries, including Brazil, especially in light of the country's commitment to reduce CO₂ emissions by half by 2030. In this context, the integration of econometrics and environmental economics contributes to anticipating the needs of both the private sector—such as planning infrastructure for new automakers and the installation of new charging stations—and the public sector, by providing technical support for fiscal incentive policies and measures to stimulate the adoption of sustainable vehicles.

This study conducts a forecasting methods competition to analyze the behavior of the electric vehicle market in Brazil and identify the most efficient model for short-term projections. Two autoregressive forecasting models widely established in the literature were estimated: the Box–Jenkins Model (BJM) and the Exponential Smoothing Method (ESM). The methodological procedure included data organization and treatment, based on monthly electric vehicle sales from January 2020 to November 2025, as well as a comparative evaluation of the models using quantitative accuracy metrics (MAPE, adjusted R², and GMRAE) and the Ljung–Box test for residual diagnostics.

The results indicate that the BJM showed superior performance within the sample, whereas out-of-sample forecasting accuracy was higher for the ESM. Therefore, based on the ESM, the continuation of the upward sales trajectory is projected, with an estimated annual growth of approximately 21% for 2025 and 29% for 2026. Although the pace of adoption in Brazil remains lower than that observed in developed economies, the projections suggest a gradual and consistent expansion in the short term.

Keywords: Box–Jenkins. Electric Vehicles. Electromobility. Exponential Smoothing. Sales forecast. Sustainability. Time Series.

LISTA DE FIGURAS

FIGURA 1 - GERAÇÃO DA SÉRIE TEMPORAL	25
FIGURA 2 - PROCEDIMENTO DE OUT-OF-SAMPLE ROLLING EVALUATION	32
FIGURA 3 - EVOLUÇÃO MENSAL DAS VENDAS DE VEÍCULOS ELETRIFICADOS NO BRASIL (2012–2025)	34
FIGURA 4 – CORRELOGRAMA DA FUNÇÃO DE AUTOCORRELAÇÃO DOS ERROS GERADO PELO MAE	38
FIGURA 5 – PREVISÃO DAS VENDAS DE VEÍCULOS ELÉTRICOS ATRAVÉS DO MAE	38
FIGURA 6 - CORRELOGRAMA DO ERRO GERADO PELO MAE	41
FIGURA 7 – PREVISÃO DAS VENDAS DE VEÍCULOS ELÉTRICOS ATRAVÉS DO MBI	41

LISTA DE TABELAS

TABELA 1 - PARÂMETROS E HIPERPARÂMETROS DO MÉTODO MAE.....	35
TABELA 2 - PARÂMETROS SAZONAIS	36
TABELA 3 – ESTATÍSTICAS DO DESEMPENHO PREDITIVO DO MAE	37
TABELA 4 – PROJEÇÃO DE VENDAS DE VEÍCULOS ELÉTRICOS OBTIDA PELO MÉTODO MAE	39
TABELA 5 – ESTATÍSTICAS DO DESEMPENHO PREDITIVO DO MBJ.....	40
TABELA 6 - PROJEÇÃO DE VENDAS DE VEÍCULOS ELÉTRICOS OBTIDA PELO MÉTODO MBJ	42
TABELA 7 - ANÁLISE <i>IN-SAMPLE</i> E <i>OUT-OF-SAMPLE</i>	43
TABELA 8 - VALORES ANUALIZADOS	45

LISTA DE SIGLAS

ABVE – Associação Brasileira do Veículo Elétrico.

BEV – *Battery Electric Vehicle* (Veículo Elétrico a Bateria). Tipo de veículo movido exclusivamente por motor elétrico, cuja energia é armazenada em baterias recarregáveis.

BYD – *Build Your Dreams*. Montadora chinesa de veículos elétricos e híbridos e de energia.

CV – *Conventional Vehicle* (Veículo Convencional a Gasolina). Veículo movido por motor de combustão interna, utilizando gasolina ou derivados de petróleo.

EVCS – *Electric Vehicle Charging System* (Sistema de Carregamento de Veículos Elétricos). Infraestrutura e conjunto de sistemas de gestão (hardware e software) responsáveis pelo processo de recarga de veículos elétricos.

FPW – *Forecast Pro for Windows*: Software de previsão econométrica utilizado para modelagem e análise de séries temporais.

HEV – *Hybrid Electric Vehicle* (Veículo Elétrico Híbrido). Combina motor elétrico e motor a combustão interna, sem necessidade de recarga externa.

HEV FLEX – *Hybrid Electric Vehicle Flex* (Veículo Elétrico Híbrido Flex). Versão híbrida que utiliza motor a combustão compatível com combustíveis flexíveis (gasolina e etanol).

ICCT – *International Council on Clean Transportation* (Conselho Internacional de Transporte Limpo). Organização independente voltada à promoção de políticas públicas para transporte sustentável.

IPI – Imposto sobre Produtos Industrializados

MAE – *Método de Amortecimento Exponencial*

MAD – *Mean Absolute Deviation* (Desvio Médio Absoluto)

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

MBJ – Modelo Box–Jenkins

MHEV – *Mild Hybrid Electric Vehicle* (Veículo Elétrico Híbrido Leve). Utiliza um pequeno motor elétrico auxiliar para melhorar a eficiência do motor a combustão, sem tração elétrica plena.

MOVER - Mobilidade Verde

ONU – Organização das Nações Unidas.

PNUMA – *Programa das Nações Unidas para o Meio Ambiente*. Agência das Nações Unidas responsável pela coordenação das ações ambientais globais.

PHEV – *Plug-in Hybrid Electric Vehicle* (Veículo Elétrico Híbrido Plugável). Possui motor a combustão e elétrico, podendo ser recarregado por meio de conexão à rede elétrica.

PND II – Segundo Plano Nacional de Desenvolvimento.

PNMC - Política Nacional sobre Mudança do Clima

P&D – Pesquisa e Desenvolvimento.

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

UNICAMP – Universidade Estadual de Campinas.

USP – Universidade de São Paulo.

CO₂ – Gás Carbônico

CH₄ – Gás Metano

N₂O – Óxido Nitroso

VEs – Veículos elétricos

SUMÁRIO

1 INTRODUÇÃO	13
2 REFERENCIAL TEÓRICO	18
3 METODOLOGIA.....	22
3.1 SÉRIE TEMPORAL	22
3.2 MÉTODO DE AMORTECIMENTO EXPONENCIAL	22
3.4 MÉTODO DE BOX & JENKINS	25
3.5 COMPETIÇÃO DE MÉTODOS: ACURÁCIA E DESEMPENHO PREDITIVO.....	28
4 ANÁLISE DE DADOS E RESULTADOS	33
4.1 BASE DE DADOS.....	33
4.2 ANÁLISE EXPLORATÓRIA DOS DADOS	34
4.3 PREVISÃO E ANÁLISE DO MÉTODO DE AMORTECIMENTO EXPONENCIAL	35
4.4 PREVISÃO E ANÁLISE DO MÉTODO BOX-JENKINS.....	40
4.5 COMPETIÇÃO DE MÉTODOS.....	42
4.6 PREVISÃO DE VEÍCULOS ELÉTRICOS NO BRASIL	44
5 CONCLUSÃO.....	46
REFERÊNCIAS.....	48

1 INTRODUÇÃO

De acordo com Giambiagi (2017), os choques do petróleo de 1973 e 1979 expuseram de forma significativa a dependência do Brasil em relação às importações de energia e bens de capital, impondo restrições externas à sua política de crescimento. Em resposta a esse contexto, o governo implementou o Segundo Plano Nacional de Desenvolvimento (PND II), voltado à redução dos pontos de estrangulamento da economia e à diversificação da matriz produtiva e energética nacional, buscando ampliar a capacidade interna de produção e diminuir a vulnerabilidade decorrente das oscilações internacionais do petróleo. Essas iniciativas representaram um marco na política econômica e industrial brasileira, ao introduzir de forma mais estruturada a preocupação com a autossuficiência energética e com o uso mais eficiente dos recursos naturais — elementos que, nas décadas seguintes, tornaram-se centrais nas discussões sobre transição energética e sustentabilidade ambiental.

Nesse contexto, a busca pela autossuficiência energética, iniciada ainda nas décadas de 1970 e 1980 como resposta à vulnerabilidade externa do país, evoluiu nas últimas décadas para um debate global sobre a diversificação das matrizes energéticas e a substituição gradual dos combustíveis fósseis por fontes renováveis. Essa transição também se reflete na recarga de veículos elétricos (VEs), cujo crescimento acelerado tem impulsionado a adoção de estratégias que visam integrar energias limpas à infraestrutura de carregamento, contribuindo para a estabilidade e eficiência das redes elétricas (Fernandes, Frías e Latorre, 2012; Khardenavis et al., 2023).

A incorporação de eletricidade proveniente de fontes renováveis nesses sistemas tem se mostrado uma medida relevante para reduzir a emissão líquida de carbono e fortalecer a segurança energética, ao mesmo tempo em que favorece o consumo de energia sustentável e diminui a dependência de derivados de petróleo (Zhang, Wei et al., 2023; Tarroja e Hittinger, 2021; Weis, Jaramillo e Michalek, 2016).

Segundo Lyu et al. (2021), o avanço desse tipo de integração tecnológica é especialmente relevante para economias emergentes, nas quais a redução das emissões do setor de transportes e o uso racional de energia constituem elementos centrais para o alcance de metas de descarbonização e estabilidade energética.

As categorias comumente utilizadas para classificar os grandes emissores de gases do efeito estufa compreendem os setores de eletricidade, industrial, comercial e residencial, agropecuário e de transporte. Este último reproduz a maior fonte de emissões CO₂ e alguns outros gases que contribuem para o aquecimento global, como o metano (CH₄) e óxido nitroso (N₂O). O setor de transporte é responsável por cerca de um quarto das emissões totais globais e tem como principal fonte emissora os veículos terrestres (Lyu et al., 2021).

Nos esforços para combater as mudanças climáticas e apoiar o desenvolvimento tecnológico interno, o governo federal tem enfatizado a necessidade de promover a transição energética em diversos setores da economia, com destaque para o setor de transportes. Nesse contexto, são adotadas medidas de incentivo à produção e ao consumo de bens mais sustentáveis, guiadas pela Política Nacional sobre Mudança do Clima (PNMC), com o objetivo de honrar os compromissos assumidos pelo Brasil em direção à meta de neutralidade de carbono. Entre essas metas, destaca-se a redução de 50% das emissões globais de CO₂ até 2030. A eletromobilidade, nesse sentido, é um dos principais instrumentos para atingir tais objetivos, sendo fomentada por programas específicos de incentivos fiscais ou isenção do IPI, como o Programa Carro Sustentável (IPI Verde) e o programa Mover (Brasil, 2024).

A implementação de estratégias voltadas à mitigação das emissões no setor de transporte, revela-se fundamental para a conservação energética e para a redução da liberação de gases poluentes (Lyu et al., 2021). Neste contexto, a adoção de veículos elétricos no mercado automobilístico configura-se como condição *sine qua non*¹ para a transição energética global rumo a uma economia sustentável e de baixo carbono. Tal panorama, por sua vez, reforça a importância de analisar as tendências de incorporação tecnológica no setor, bem como identificar e monitorar padrões de eletromobilidade, de modo a situar o posicionamento do Brasil nesse processo (ABVE, 2025).

Os veículos elétricos (VEs) são a opção mais necessária e viável economicamente para a descarbonização de transportes em nível global, especialmente se combinados com um sistema de energia de baixo carbono (Kennedy; Ibrahim; Hoornweg, 2014). O setor de mobilidade está passando por muitas mudanças tecnológicas significativas, levando muitos

¹ Refere-se a uma condição indispensável para que algo aconteça.

países a priorizarem e aumentarem a demanda do transporte sustentável para atender as demandas energéticas futuras (Chatterjee; Byun, 2023).

De acordo com Chatterjee e Byun (2023), é preciso implementar um sistema de previsão para antecipar as necessidades futuras de um produto ou serviço orientados por dados do setor de transportes, pois antecipar as necessidades dos clientes é fundamental para o sucesso, a fim de eliminar perdas financeiras e aumentar os negócios.

Segundo Nielsen (2020), a previsão de séries temporais evoluiu da ciência e meteorologia, de Aristóteles, passando por FitzRoy (1863), o pai da previsão, para a previsão econômica no fim do século XIX e início do século XX devido a ansiedade desencadeada por crises bancárias nos Estados Unidos e Europa a fim de prever cenários econômicos futuros com base no passado, relacionando a economia a um sistema cíclico, tal como o clima se comportava. Gerando uma atmosfera rica em dados públicos, essa antecipação de prováveis condições futuras do mercado contribuiu não somente para benefício estatal, como também para diversas empresas privadas.

Em 2020, as vendas de veículos elétricos e híbridos contribuíram para um aumento de 7% nas vendas globais de automóveis de passageiros. O mercado mundial de veículos híbridos elétricos (HEV) foi estimado em cerca de US\$256 bilhões, com projeções indicando que poderá atingir aproximadamente US\$2 trilhões até 2026 (Menes, 2021; Zhu et al., 2024). No Brasil, o mercado de veículos eletrificados segue uma trajetória de crescimento exponencial, especialmente no período pós-pandemia (ABVE, 2025).

Feitas estas considerações e evidenciada a importância de se utilizar métodos que possam auxiliar na previsão futura da venda de veículos elétricos inserida num contexto de busca por eficiência energética, atenta-se que, neste trabalho monográfico, realiza uma competição entre os métodos preditivos de Box-Jenkins² e de Amortecimento Exponencial³. O objetivo é identificar qual abordagem apresenta o melhor desempenho na modelagem das vendas de veículos elétricos no Brasil, tomando como base uma análise recursiva fora da amostra. Para isso, utiliza-se um conjunto de dados referentes ao período entre janeiro de 2020

² Box & Jenkins (1994).

³ Montgomery (1990).

e novembro de 2025, com projeções para 13 meses à frente, até o final de 2026, de modo a subsidiar decisões estratégicas no setor automotivo e na formulação de políticas públicas.

A pesquisa busca identificar tendências e padrões sazonais nas vendas nacionais de veículos elétricos, aplicar os modelos Box-Jenkins (SARIMA) e Amortecimento Exponencial (Holt-Winters) por meio do software FPW, comparar seu desempenho preditivo utilizando métricas como R^2 ajustado, MAPE, GMRAE e Ljung-Box.

O crescimento do mercado de veículos elétricos (VEs) representa uma das transformações mais significativas da indústria automobilística mundial. A busca por alternativas de mobilidade sustentável, impulsionada pela necessidade de redução das emissões de gases de efeito estufa e pela transição para matrizes energéticas mais limpas, tem levado diversos países a implementarem políticas de incentivo à eletrificação do transporte. No Brasil, embora a participação dos VEs ainda seja incipiente, o setor apresenta ritmo de expansão acelerado, impulsionado por investimentos em infraestrutura de recarga, incentivos fiscais e maior conscientização ambiental dos consumidores (ABVE, 2025).

Modelos de previsão como Box-Jenkins e Amortecimento Exponencial destacam-se pela capacidade de capturar tendências, sazonalidades e volatilidades das séries temporais, permitindo análises quantitativas robustas em um mercado emergente, caracterizado por alta variabilidade e por fatores exógenos como inovação tecnológica, políticas ambientais e comportamento do consumidor. Assim, a comparação entre esses métodos oferece contribuições práticas e acadêmicas, ao avaliar a precisão de diferentes abordagens estatísticas e fornecer subsídios relevantes para empresas, formuladores de políticas e pesquisadores interessados na mobilidade sustentável e na redução da dependência de combustíveis fósseis.

Em termos acadêmicos, o estudo contribui para o campo da Econometria Aplicada e da Economia Ambiental, ao combinar técnicas quantitativas de previsão com um tema de relevância socioeconômica e ambiental. A análise comparativa entre os métodos Box-Jenkins e Amortecimento Exponencial pretende, portanto, avaliar qual modelo apresenta maior desempenho na previsão da demanda por veículos elétricos no Brasil, fornecendo uma ferramenta analítica útil para pesquisadores, formuladores de políticas e empresas do setor.

Este trabalho está organizado da seguinte forma: a Seção 2 apresenta uma revisão da literatura sobre o mercado nacional de veículos elétricos e os principais fatores que influenciam

sua adoção. A seção 3 introduz os modelos estatísticos empregados na comparação entre os métodos Box-Jenkins e Amortecimento Exponencial. Na seção 4, descreve o processo de coleta e manipulação dos dados, são apresentados e interpretados os resultados obtidos, discutindo implicações práticas ligadas ao setor. Por fim, a Seção 5 reúne as conclusões do estudo, destacando suas limitações e propondo direções para pesquisas futuras.

2 REFERENCIAL TEÓRICO

Dados da ABEV apontam um expressivo crescimento nas vendas de veículos eletrificados no Brasil entre 2022 e 2025. No primeiro quadrimestre de 2022, o mercado já havia contabilizado 12.976 unidades comercializadas em comparação a 7.290 no mesmo período do ano anterior. As vendas de veículos eletrificados leves registraram um aumento de 78% na comparação anual. Nesse ínterim, o presidente da ABVE, Adalberto Maluf, destacou que, nesse período, observou-se um nítido contraste entre o avanço dos eletrificados e a queda ou estagnação das vendas de veículos a combustão no país (ABVE, 2022).

Abrangendo as tecnologias de veículos elétricos BEV, PHEV, HEV, HEV FLEX e MHEV, em 2024 foram comercializadas 177.358 unidades, o que corresponde a um aumento de 88,8% em relação ao ano anterior (93.927 unidades), evidenciando um acelerado ritmo de adoção da eletromobilidade no país, (ABVE, 2025).

Entre as tecnologias mencionadas, os BEV — veículos 100% elétricos — apresentaram o maior crescimento percentual, de aproximadamente 220%, o que demonstra que o consumidor brasileiro começa a adotar de forma mais expressiva os modelos totalmente elétricos, impulsionado pela expansão da infraestrutura de recarga e pela entrada de novas montadoras asiáticas no mercado nacional. Um exemplo é o investimento da indústria automotiva sul-coreana, Hyundai Motor Group, que anunciou um aporte de 1,1 bilhão de dólares no Brasil até 2032. Segundo informações do Planalto, os recursos serão direcionados a P&D⁴, com foco em veículos híbridos, elétricos e movidos a hidrogênio verde, em consonância com o programa de Mobilidade Verde (MOVER) do governo brasileiro (Rádio GOV, 2024; EBC, 2025).

Além desta empresa, com investimentos de aproximadamente 5,5 bilhões de reais, a montadora chinesa BYD inaugurou, em 9 de outubro de 2024, sua unidade industrial em Camaçari, na Bahia, destinada à fabricação de veículos elétricos e híbridos. O empreendimento deverá gerar em torno de 20 mil empregos diretos e indiretos, abrangendo colaboradores, prestadores de serviços e fornecedores de autopeças. Com uma área de 4,6 milhões de metros

⁴ Pesquisa e Desenvolvimento (P&D) refere-se ao conjunto de atividades sistemáticas realizadas por empresas, governos ou instituições com o objetivo de criar novos produtos, melhorar processos, desenvolver tecnologias e gerar inovação.

quadrados, o complexo industrial foi projetado para ser o maior da BYD fora da Ásia, com capacidade inicial de produção de 150.000 veículos por ano, podendo dobrar esse volume futuramente. Além de Camaçari, a empresa mantém a instalação de outras duas unidades de produção no Brasil: uma localizada em Campinas (São Paulo), responsável pela fabricação de painéis solares e chassis de ônibus elétricos, e outra em Manaus (Amazonas), dedicada à produção de baterias (EBC, 2025).

Durante a cerimônia de inauguração, o presidente da república, Luiz Inácio Lula da Silva, destacou a importância do fortalecimento das relações comerciais entre Brasil e China, enfatizando as oportunidades de exportação de produtos nacionais com maior valor agregado para os continentes americano e africano. Segundo o ministro do desenvolvimento, indústria e comércio, Geraldo Alckmin, a iniciativa marca um novo ciclo de reindustrialização sustentável no Brasil, cujos principais desdobramentos incluem o aumento da empregabilidade, o avanço das exportações no setor automotivo e o fortalecimento da competitividade nacional nos segmentos de veículos elétricos e híbridos (EBC, 2025).

Os PHEV, correspondentes aos híbridos plug-in, mantêm a liderança em volume, totalizando 64.010 unidades em 2024 com crescimento próximo de 100%, (ABVE, 2025). Essa tendência surge devido à promoção de veículos elétricos e híbridos que acompanham a conscientização pública, ou seja, a indústria de fabricação automotiva muda gradualmente para a produção de veículos elétricos híbridos em resposta às mudanças nas preferências do consumidor por energia renovável e apoio a políticas ambientais (Rasool et al., 2019; Solaymani, 2022).

Já os HEV e MHEV — híbridos convencionais e leves — apresentam crescimento constante, embora em menor escala, configurando-se como alternativas mais acessíveis considerando a economia de combustível que também serve de ponte entre os veículos movidos a combustão e os veículos elétricos puros (Huang et al., 2019; Xu et al., 2019). Os pesquisadores acreditam que os HEVs têm perspectivas de desenvolvimento favoráveis, como uma tecnologia promissora, que integra um motor de combustão interna e tecnologias de motor elétrico, representando a tendência de convergência tecnológica em um futuro próximo (Yuan; Cai, 2021).

Ainda com dados da ABVE, a tecnologia HEV FLEX foi a única categoria em queda (-8%) nesse período intra anual, essa redução pode refletir a substituição por modelos de

tecnologia mais avançada como o PHEV e BEV, que são vistos como mais sustentáveis (Yuan; Cai, 2021).

Desde as etapas de fabricação até o uso e descarte dos veículos híbridos (HEV), a produção de baterias constitui o principal fator de preocupação em relação aos impactos ambientais. Embora os HEVs reduzam o consumo de combustível e, consequentemente, as emissões de gases poluentes, o alto gasto energético em sua produção e os desafios relacionados ao descarte das baterias ainda representam obstáculos significativos para este segmento, que se encontra no centro de uma transição tecnológica (Zhu et al., 2024).

A melhoria da compatibilidade ambiental e da eficiência das baterias, bem como a otimização dos processos de descarte e reciclagem, configuram-se medidas essenciais para mitigar os impactos ambientais futuros. Até o momento, à medida que o setor automotivo avança em direção a soluções mais sustentáveis, os HEVs e também os BEVs desempenham papel crucial para o início dessa transição tecnológica rumo a um transporte mais ecológico (Zhu et al., 2024).

A implementação das Estações de Carregamento de Veículos Elétricos (EVCS) depende da demanda local e da densidade e concentração espacial de VEs, que se configura como um fator estratégico para ampliar a adoção desses postos tecnológicos e fomentar o uso sustentável de fontes energéticas mais limpas, especialmente em rotas voltadas ao turismo (Gulzar et al., 2024).

A inserção de veículos elétricos em larga escala pode representar um desafio para a operação eficiente das estações de carregamento no Brasil no futuro. Essa problemática já foi analisada por Kim (2024), que propõe soluções para a otimização do roteamento de veículos elétricos, capturadas por padrões de tempo de espera, de carregamento e pela localização das estações de recarga. Estudos relacionados sugerem estratégias de carregamento parcial, planejamento de estações fixas e móveis, otimização de fluxos e redução de custos operacionais. (Al-dal'ain; Celebi, 2021; Bac e Erdem (2021); Basso et al., 2021; Chakraborty et al., 2021; Hiermann et al., 2016; Kessler; Bogenberger, 2019; Keskin et al., 2019; Luo et al. (2023); Ma et al., 2021; Montoya et al., 2017; Pelletier et al., 2019, apud Kim, 2024). Embora essas questões sejam fundamentais para o planejamento da infraestrutura de recarga, a modelagem detalhada desses processos extrapola o escopo deste trabalho, sendo tais

contribuições mencionadas apenas como referência ao contexto mais amplo da eletromobilidade.

Atualmente o Brasil conta com 545.391 veículos eletrificados, uma participação ainda modesta de 1,18% do mercado automotivo nacional, quando comparado a países desenvolvidos como China, Coreia do Sul, Alemanha e Estados Unidos. Apesar da baixa participação relativa, o país apresenta uma taxa média de crescimento mensal de 6,40%, indicando avanços consistentes na difusão da eletromobilidade (ABVE, 2025).

Com base nos dados disponíveis, de janeiro a setembro de 2025, o mercado brasileiro registrou a venda de 147.602 veículos elétricos, equivalente a um crescimento aproximado de 20,5% em relação ao mesmo intervalo do ano anterior. Esse desempenho é particularmente relevante mesmo diante da ausência temporária dos dados referentes aos veículos MHEV, cuja contabilização ocorre apenas ao final de cada exercício (ABVE, 2025).

Segundo o Conselho Internacional de Transporte Limpo (ICCT Brasil), em parceria com o Programa das Nações Unidas para o Meio Ambiente (PNUMA), a produção nacional de veículos e baterias elétricas tem potencial para dobrar a geração de empregos no Brasil até 2050. Estudos conduzidos por pesquisadores do ICCT, UNICAMP e USP indicam que a maior parte desses empregos projetados estará concentrada nos segmentos de produção de veículos, máquinas e equipamentos elétricos, ao passo que é esperada uma retração gradual em setores tradicionais como combustíveis fósseis, agropecuária e autopeças (ONU, 2025).

Dessa forma, o cenário de eletrificação automotiva deverá gerar 88% mais empregos líquidos do que o modelo atual, baseado em combustíveis fósseis. Entre as medidas que viabilizam essa transição estão os incentivos fiscais, as linhas de crédito à exportação e os acordos comerciais estratégicos, sobretudo com países da América Latina (ONU, 2025).

Feitas estas considerações, atenta-se que no próximo capítulo será apresentada a metodologia a ser utilizada neste presente trabalho monográfico para a modelagem e previsão da série de venda de veículos elétricos no Brasil.

3 METODOLOGIA

Esta seção apresenta os procedimentos metodológicos adotados para a análise e previsão das vendas de veículos elétricos no Brasil. São descritas as etapas de tratamento da série temporal e os critérios empregados na seleção e comparação dos modelos. A seguir, detalham-se os métodos estatísticos aplicados, bem como os indicadores de desempenho que sustentam a avaliação dos resultados.

3.1 SÉRIE TEMPORAL

Uma série temporal é um conjunto de observações de uma dada variável, ordenadas segundo o parâmetro tempo, geralmente em intervalos equidistantes. Se Z_t representa o valor da variável aleatória Z no instante t , denota-se a série temporal por Z_1, Z_2, \dots, Z_N onde N é o tamanho da série ou número de observações seriais da variável (Zanini, 2023).

Além dessa definição, é essencial considerar as características intrínsecas de uma série temporal, como a ordem cronológica das observações que não podem ser reordenadas, a regularidade dos intervalos de tempo (por exemplo, horas, dias, semanas, meses, trimestres ou anos) e compreender os principais componentes que a caracterizam: tendência, ciclo, sazonalidade e ruído (erro aleatório) (Zanini, 2023).

3.2 MÉTODO DE AMORTECIMENTO EXPONENCIAL

Conforme visto no tópico anterior, um modelo de série temporal consiste em projetar o comportamento passado de uma mesma variável de forma estatisticamente controlada e ponderada. Em outras palavras, trata-se da representação do comportamento histórico de uma variável econômica ou financeira — suas aplicações podem se dar em análise de conjuntura econômica; previsão de demanda de linhas de produtos (marketing e planejamento de produção); previsões climáticas; previsões demográficas; taxa de juros; um índice da bolsa de valores; etc. (Pyndick, Rubinfeld, 2004).

A previsão de séries temporais consiste na elaboração de estimativas quantitativas para valores futuros com base em informações presentes e passadas, conforme destaca Zanini (2023). Tal previsão é construída a partir de uma equação estatística de estimação, fundamentada na análise da correlação temporal da série e de seus componentes sistemáticos.

O método de amortecimento exponencial consiste em uma atualização paramétrica automática, na qual se atribui um peso α ao dado mais recente e um peso $(1-\alpha)$ ao dado mais antigo. Assim, séries mais “nervosas” (de maior variância) podem receber um peso mais elevado para as observações recentes, enquanto séries mais “comportadas” (de menor variância) podem ser suavizadas de forma mais equilibrada, tanto aos dados passados, quanto aos dados recentes. De forma geral, essa lógica é expressa por (Zanini, 2023):

$$\alpha * \text{Presente} + (1-\alpha) * \text{Passado}$$

Considerando uma variável que não apresente uma variação significativa ao longo do tempo temos a seguinte equação de previsão:

$$Z_t = a(T) + \varepsilon_t \quad (1)$$

Onde:

Z_t = venda no período t ($t = 1, 2, \dots, T$);

$a(T)$ = parâmetro representativo do nível médio das vendas no instante T ;

ε_t = erro de previsão e $\varepsilon_t \sim N(0, \sigma^2)$.

O modelo vai depender da série, sendo o modelo básico, também conhecido como modelo de Brown, é expresso pela equação:

$$S_T = \alpha * Z_T + (1 - \alpha) * S_{T-1} \quad (2)^5$$

Onde:

S_T = valor amortecido da série;

α = constante de amortecimento ou hiperparâmetro (número entre 0 e 1).

⁵ A equação 2 é também conhecida como Modelo de Brown.

Dessa forma, o método atribui pesos diferenciados às observações de acordo com sua “idade”, preservando a lógica fundamental do amortecimento exponencial (Zanini, 2023)⁶.

Esse procedimento constitui o Método de Suavização Exponencial Simples (SES), que serve de base para modelos mais avançados da mesma família, tais como

Modelo de Holt (dois parâmetros ou duplo amortecimento), que estende o método de suavização simples ao incorporar explicitamente o componente de tendência da série ao longo do tempo. A ideia central consiste em atualizar simultaneamente o nível ($\hat{a}_1(T)$) e a tendência ($\hat{a}_2(T)$), permitindo que o modelo acompanhe variações ascendentes ou descendentes da série observada (Zanini, 2023).

A projeção t passos à frente é dada por:

$$\hat{Z}(T+t) = \hat{a}_1(T) + t\hat{a}_2(T) + \varepsilon_t \quad (3)^7$$

O método de Holt–Winters generaliza o modelo de Holt ao incorporar ainda o componente sazonal, sendo apropriado para séries que apresentam simultaneamente nível, tendência e sazonalidade. Há duas versões do modelo, de acordo com a forma como a sazonalidade atua (Zanini, 2023):

a) Modelo Aditivo de Holt–Winters: adequado quando a sazonalidade tem magnitude constante. A equação de previsão é dada como:

$$Z_t = a_1(T) + ta_2(T) + \rho_t + \varepsilon_t \quad (4)$$

b) Modelo Multiplicativo de Holt–Winters: adequado quando a sazonalidade cresce ou diminui proporcionalmente ao nível. A equação de previsão é dada como:

$$Z_t = (a_1(T) + ta_2(T)) * \rho_t + \varepsilon_t \quad (5)$$

Onde:

$a_1(T)$: parâmetro de nível no instante T ;

$a_2(T)$: parâmetro de tendência no instante T ;

⁶ Para mais detalhes, ver Montgomery & Johnson (1990).

⁷ Verifique que, diferentemente da equação 6, existem agora dois parâmetros e por isto é feita a diferença entre a_1 e a_2 .

t : variável tempo ($t = 1, 2, \dots, T$ sendo T é a quantidade de dados existentes);

ρ_t : fator sazonal referente ao período t ;

ε_t : é o erro de previsão e $\varepsilon_t \sim N(0, 2)$.


Além disso, o método pode incorporar o chamado *damped trend*, um ajuste que introduz um hiper parâmetro adicional (ϕ) para suavizar a tendência no horizonte de previsão, evitando projeções excessivamente crescentes ou decrescentes. Esse recurso é especialmente útil em contextos em que se espera que o crescimento ou a queda não se mantenham indefinidamente. (Zanini, 2023).

3.4 MÉTODO DE BOX & JENKINS

Os modelos Box–Jenkins constituem uma das metodologias mais consolidadas de previsão de séries temporais, baseando-se na modelagem explícita da dependência serial presente nos dados, por meio de componentes autorregressivos e de médias móveis. Esses modelos são particularmente úteis quando a série apresenta autocorrelação significativa entre as observações ao longo do tempo, exigindo um tratamento adequado capaz de capturar adequadamente essa estrutura dinâmica (Zanini, 2023).

O fundamento teórico de Box & Jenkins baseia-se na Teoria Geral de Sistemas Lineares que diz que a passagem de um ruído branco por um filtro linear de memória infinita gera um processo estacionário de segunda ordem⁸. Podemos observar esse fluxo no esquema abaixo:

Figura 1 - Geração da Série Temporal



Fonte: ZANINI, 2023.

⁸ Em termos gerais, processo estacionário de 2ª ordem é um processo estocástico com média e variância constantes.

Definindo um operador de atraso “B” (*backward shift operator*), como uma ferramenta para representar a estrutura do modelo, onde $B^k Z_t = Z_{t-k}$, ou seja, o operador de atraso “desloca” a série temporal em k períodos para trás. O modelo Box & Jenkins expressam esses polinômios da seguinte forma:

$$\Psi(B) = \theta(B) / \phi(B) \quad (6)$$

onde:

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \Rightarrow \text{Polinômio MA (q)}$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \Rightarrow \text{Polinômio AR (p)}$$

Assim, surgem os modelos ARMA(p,q) que assume a seguinte forma:

$$\phi(B)w_t = \theta(B)a_t \quad (7)$$

A depender da necessidade de tornar a série estacionária, aplica-se o operador de diferenciação $(1-B)^d$, produzindo modelos ARIMA(p,d,q) capazes de capturar tanto dependências seriadas quanto tendências determinísticas (Zanini, 2023). Esse procedimento pode ser repetido quantas vezes forem necessárias até que a série apresente média constante, permitindo o uso de modelos como os ARIMA (p, d, q) (Camargo & Souza, 1996, apud Zanini, 2023).

Dessa forma, a abordagem Box–Jenkins é fundamentada em três componentes principais: o processo autorregressivo (AR), o processo de médias móveis (MA) e o operador de diferenciação (I), responsável por tornar a série estacionária quando necessário.

A combinação desses elementos resulta na classe de modelos ARIMA(p,d,q) (*Auto Regressive Integrated Moving Average*), onde a ordem “d”⁹ representa as diferenças aplicadas na série original, ela pode ser representada pela seguinte formulação geral:

$$\phi(B) \nabla^d Z_t = \theta(B)a_t \quad (8)$$

Onde:

Z_t : representa a série temporal observada;

⁹ Na prática, normalmente o grau máximo de diferenciação é 2.

B : é o operador de diferença ($\nabla = (1-B)$), tal que $BZ_t = Z_{t-1}$;

d : é o número de diferenciações da série original necessárias para produzir estacionariedade;

$\phi(B) = 1 - \phi_1 B - \phi_2 B - \dots - \phi_q B^q$: é o polinômio autorregressivo (AR) de ordem q ;

$\theta(B) = 1 - \theta_1 B - \theta_2 B - \dots - \theta_q B^q$: é o polinômio de médias móveis (MA) de ordem q ;

a_t : é um processo de ruído branco, $a_t \sim WN(0, \sigma^2)$ (Zanini, 2023).

Quando bem especificados, os modelos ARIMA oferecem grande capacidade preditiva, pois integram rigor estatístico, flexibilidade estrutural e um esquema de estimação orientado tanto à dinâmica observada quanto às propriedades estocásticas da série (Zanini, 2023).

Na prática as séries encontradas no mundo real, raramente são estacionárias e muitas vezes apresentam sazonalidades. Dessa forma, os autores Box & Jenkins formularam seus modelos também para componentes sazonais, originando o modelo SARIMA, descrito na equação 18, cuja sua estrutura é denominada SARIMA(p, d, q)*(P, D, Q), onde as letras maiúsculas correspondem aos componentes sazonais (Zanini, 2023).

$$\phi(B)\Phi(B^S)\nabla^D_S\nabla^dZ_t = \theta(B)\Theta(B^S)a_t \quad (9)$$

Onde:

$\phi(B)$: operador não sazonal autorregressivo;

ϕ : parâmetros autorregressivo não-sazonais;

$\nabla^d = (1-B)^d$: operador diferença não sazonal de ordem d ;

$\Phi(B^S)$: operador sazonal autorregressivo;

Φ : parâmetros autorregressivo sazonais;

$\nabla^D_S = (1-B^S)^D$: operador diferença sazonal de ordem D ;

$\theta(B)$: operador não sazonal de médias móveis;

θ : parâmetros de médias móveis não sazonais;

$\Theta(B^S)$: operador sazonal de médias móveis;

Θ : parâmetros de médias móveis sazonais.

Tanto o modelo ARIMA quanto o SARIMA seguem um procedimento sistemático composto por três etapas que serão explicadas a seguir.

A primeira consiste na identificação das ordens dos componentes autorregressivos (AR) e de médias móveis (MA), por meio da análise das funções de autocorrelação (FAC)⁷ e autocorrelação parcial (FACP), além da inspeção visual dos correlogramas. Para um processo AR(p), a FAC tende a decrescer gradualmente enquanto a FACP apresenta um corte⁸ nítido. O *lag* onde este corte ocorre define a ordem p . No caso dos modelos sazonais, como o SARIMA, a análise deve ser estendida aos *lags* sazonais — por exemplo, 12, 24 ou 36 em séries mensais (Zanini, 2023).

Por outro lado, para um processo MA(q), observa-se o comportamento inverso: a FACP decresce gradualmente, enquanto a FAC apresenta um corte significativo. Assim como no caso autorregressivo, o *lag* do corte indica a ordem q do modelo (Zanini, 2023).

Após a identificação das ordens do modelo, procede-se à estimação dos parâmetros do modelo por máxima verossimilhança¹⁰. Em seguida, verifica-se os testes dos resíduos para assegurar que se comportem como ruído branco — isto é, sem estrutura de autocorrelação remanescente, condição essencial para a validade do modelo. Complementarmente, aplica-se o teste de sobrefixação — que consiste em estimar modelos de ordem ligeiramente superior à identificada, a fim de confirmar a pertinência e parcimônia do modelo selecionado — ou o teste de Ljung-Box e significância paramétrica¹¹ (Zanini, 2023).

3.5 COMPETIÇÃO DE MÉTODOS: ACURÁCIA E DESEMPENHO PREDITIVO

Com o intuito de selecionar o modelo mais adequado para previsão da série temporal de veículos elétricos no Brasil, será conduzida uma competição de métodos de previsão, comparando o desempenho dos modelos de Amortecimento Exponencial e do Box-Jenkins (ARIMA). A comparação baseia-se em métricas de acurácia e em testes de diagnóstico, permitindo identificar qual modelo oferece melhor ajuste e maior capacidade de previsão para a série analisada.

¹⁰ Dudewicz & Mishra, 1988.

¹¹ H_0 : os parâmetros são iguais a zero, portanto são significativos se rejeitamos esta hipótese.

Cada um destes métodos será aplicado e avaliado quanto a sua capacidade de captar padrões históricos e projetar tendências futuras com precisão. A avaliação do desempenho preditivo será conduzida a partir de duas abordagens complementares:

3.7.1 In-Sample:

A análise *in-Sample* consiste em estimar os parâmetros do modelo e gerar previsões “ajustadas” para o período histórico, comparando os valores observados (reais) e os valores estimados. Essa comparação permite avaliar o erro de previsão um passo-à-frente e fornece um indicador da qualidade do modelo dentro da amostra utilizada na estimação (ZANINI, 2023). As principais métricas consideradas serão:

i. Mape (*Mean Absolute Percentual Erro*)

O MAPE (Erro Médio Absoluto Percentual) mede a média dos erros em termos percentuais, é calculado através da média das diferenças absolutas entre os valores estimados e reais dada por:

$$MAPE = \frac{\sum_{t=1}^N \left| \frac{Y(t) - \hat{Y}(t)}{Y(t)} \right| * 100}{N} \quad (10)$$

Onde:

$Y(t)$: representa o valor real da série temporal no período t ;

$\hat{Y}(t)$: valor ajustado da série temporal para o período (t) ;

N : total de observações.

ii. Coeficiente de Explicação Ajustado (R^2 ajustado)

O R ajustado tem uma interpretação similar ao R , cujo índice indica o quanto da variação total dos dados é explicada pelo modelo. Entretanto, faz-se uma correção tendo em vista a quantidade de parâmetros no modelo como demonstrado na equação a seguir (ZANINI, 2023).

$$R^2_{\text{ajust}} = \left(1 - \frac{\sum_{t=1}^N \frac{(Y(t) - \hat{Y}(t))^2}{N - k}}{\sum_{t=1}^N \frac{(Y(t) - \bar{Y})^2}{N - 1}} \right) * 100 \quad (11)$$

Onde:

$Y(t)$ = valor da série temporal no período (t);

$\hat{Y}(t)$ = previsão da série temporal para o período (t);

\bar{Y} = média das observações (média da série temporal) ;

N = total de dados utilizados (total de observações);

k = número de parâmetros do modelo.

iii. GMRAE (*Geometric Mean Relative Absolute Error*):

O GMRAE (Erro Absoluto Relativo Médio Geométrico): é a média geométrica da razão (quociente) entre o erro absoluto (portanto, em módulo) do modelo estimado e o erro absoluto do método ingênuo. Portanto, é desejável que o GMRAE seja igual ou menor do que 1 (ZANINI, 2023).

$$GMRAE = \sqrt[N]{\prod_{t=1}^N \left(\frac{|Y(t) - \hat{Y}(t)|}{|Y(t) - Y(t-1)|} \right)} \quad (12)$$

Onde:

$Y(t)$: é o valor real da série no período (t);

$\hat{Y}(t)$: é a previsão gerada pelo modelo para o período (t);

$Y(t-1)$: é o valor da série temporal no período (t-1);

N : é o número de observações.

3.7.2 Out-of-sample e rolling evaluation

A avaliação *out-of-sample* envolve testar o modelo em um conjunto de dados que não foram utilizados na etapa de estimação, validando assim sua capacidade preditiva para períodos futuros.

Pode-se empregar ainda o procedimento de *out-of-sample rolling evaluation*, no qual a origem da previsão é deslocada ao longo da janela de teste, fazendo previsões para cada passo, com os mesmos parâmetros estimados. Como Zanini (2023, p. 11) exemplifica:

“Caso sejam retirados os 12 últimos dados¹², isto significa que serão feitas no período out-of-sample um total de 78 previsões (12 previsões para um passo (mês) à frente, 11 previsões para 2 passos à frente, 10 previsões para 3 passos à frente e assim sucessivamente). Pode-se definir como critério, por exemplo, que o método vencedor a ser selecionado será aquele que minimizar o MAD (Mean Absolute Deviation) acumulado ou erro médio absoluto acumulado fora da amostra. Para entender melhor o procedimento de rolling evaluation observar a figura 2 a seguir” (Zanini, 2023, p.11).

¹² Obviamente retirar os últimos dados é apenas um procedimento de análise para seleção de modelos. Para se obter as previsões desejadas, depois de feita análise *in-sample* e *out-of-sample*, os dados retirados são novamente incorporados e os parâmetros atualizados. Foi dado como exemplo a retirada dos últimos 12 dados o que geraria um total de 78 previsões fora da amostra. Entretanto, este “período de corte” pode ser definido de acordo com cada problema.

Figura 2 - Procedimento de *out-of-sample rolling evaluation*

		HORIZONTE											
		jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
ORIGEM	dez	A	A	A	A	A	A	A	A	A	A	A	A
	Jan	F	F	F	F	F	F	F	F	F	F	F	F
	Fev	A	A	F	F	F	F	F	F	F	F	F	F
	mar	A	A	A	F	F	F	F	F	F	F	F	F
	abr	A	A	A	A	F	F	F	F	F	F	F	F
	mai	A	A	A	A	A	F	F	F	F	F	F	F
	Jun	A	A	A	A	A	A	F	F	F	F	F	F
	Jul	A	A	A	A	A	A	A	F	F	F	F	F
	ago	A	A	A	A	A	A	A	A	F	F	F	F
	set	A	A	A	A	A	A	A	A	A	F	F	F
	out	A	A	A	A	A	A	A	A	A	A	F	F
	nov	A	A	A	A	A	A	A	A	A	A	A	F

Fonte: Zanini (2023). Nota: F = *Forecast* (previsão); A = *Actual* (atual).

No presente estudo, após a estimação e a análise das previsões de cada método utilizando a série completa, realiza-se a avaliação do desempenho preditivo por meio da aplicação dos modelos aos últimos doze meses da série temporal mensal, com o objetivo de mensurar a acurácia tanto dentro da amostra (in-sample) quanto fora da amostra (out-of-sample).

Com base na avaliação in-sample e out-of-sample, o modelo que apresentar os menores valores das métricas MAPE, MAD ou GMRAE será indicado como o mais adequado para a previsão da série de vendas de veículos elétricos, conforme Zanini (2023).

A partir da seleção do modelo de melhor desempenho, procede-se à análise detalhada de suas previsões, com ênfase na interpretação dos resultados e na avaliação das variações anuais projetadas, de modo a subsidiar conclusões sobre a dinâmica recente e a tendência de curto prazo do mercado de veículos elétricos no Brasil.

4 ANÁLISE DE DADOS E RESULTADOS

Nesta seção são apresentados a análise do banco de dados, a interpretação dos resultados obtidos e as previsões geradas pelos dois métodos considerados. Adicionalmente, realiza-se a comparação entre os modelos por meio de métricas de acurácia, com o objetivo de avaliar qual deles apresenta o melhor desempenho preditivo.

4.1 BASE DE DADOS

Os dados foram obtidos no site oficial da Associação Brasileira do Veículo Elétrico (ABVE), que reúne e disponibiliza informações consolidadas sobre o mercado de veículos eletrificados no Brasil.

A ABVE é uma entidade civil de direito privado, sem fins lucrativos, que atua junto a órgãos governamentais e instituições empresariais do setor automotivo. A associação é amplamente reconhecida como fonte de referência por publicar regularmente dados de mercado, relatórios analíticos e indicadores do setor elétrico automotivo, garantindo confiabilidade e transparência às informações utilizadas.

A base foi estruturada considerando o volume total de vendas das tecnologias BEV, PHEV, HEV e HEV FLEX, de forma a garantir maior continuidade histórica da série. Optou-se por excluir os veículos MHEV na análise, uma vez que esse segmento passou a ser reportado apenas recentemente e com consolidação anual, o que implicaria descontinuidade temporal e possível distorção na modelagem da série.


O período da base de dados inclui dados de janeiro de 2012 a novembro de 2025, toda via, para realizar as previsões de ambos os métodos e refletir resultados mais próximos da realidade, será feito um recorte de janeiro de 2020 a novembro de 2025, onde começa a ascensão e tendência da série, dado pelo avanço da tecnologia e popularização da venda de veículos elétricos no Brasil.

A implementação dos modelos foi realizada no software FPW, e a avaliação do desempenho preditivo seguiu os critérios metodológicos e métricas estatísticas descritos nas seções subsequentes.

4.2 ANÁLISE EXPLORATÓRIA DOS DADOS

A análise exploratória tem como objetivo identificar os padrões estruturais presentes na série temporal de vendas de veículos eletrificados no Brasil. A figura 3 apresenta a evolução mensal do volume comercializado entre janeiro de 2012 e novembro de 2025. Observa-se que, na primeira metade do período (2012 a 2019), as vendas mantiveram-se em níveis relativamente baixos e estáveis, indicando um estágio ainda embrionário do mercado nacional de veículos elétricos.

Figura 3 - Evolução Mensal das Vendas de Veículos Eletrificados no Brasil (2012–2025)



Fonte: Elaboração própria.

Durante e após o período pandêmico, a partir de 2020, verifica-se uma elevação gradual do volume vendido, seguida por um crescimento acentuado até 2025. Esse comportamento revela uma tendência de crescimento, associada a fatores como maior oferta de modelos, redução relativa de custos, incentivos fiscais e maior aceitação do consumidor.

Além da tendência de longo prazo, a série apresenta sazonalidade, percebida pela repetição de oscilações em intervalos regulares. Essas variações podem estar relacionadas ao

calendário fiscal, ciclos de produção e vendas, estratégias de lançamento pelas montadoras e condições macroeconômicas que influenciam decisões de compra ao longo do ano.

A presença simultânea de tendência e sazonalidade indica que a série possui componentes estruturais sistemáticos que devem ser explicitamente tratados no processo de modelagem. Consequentemente, torna-se necessário utilizar métodos de previsão capazes de incorporar essas variações temporais, evitando estimativas enviesadas e garantindo maior precisão nas projeções.

4.3 PREVISÃO E ANÁLISE DO MÉTODO DE AMORTECIMENTO EXPONENCIAL

No presente estudo, o modelo selecionado, apresentou sazonalidade multiplicativa e presença do componente de tendência. Nesse caso, as previsões são obtidas multiplicando o nível suavizado pelo índice sazonal correspondente a cada período, refletindo o fato de que os efeitos sazonais variam proporcionalmente ao nível da série.

A partir da aplicação do Método de Amortecimento Exponencial (MAE), foram obtidos os parâmetros estimados para o nível, tendência e sazonalidade, bem como seus respectivos pesos de suavização. Esses resultados, que sintetizam o comportamento estrutural da série, estão apresentados na tabela 1 a seguir:

Tabela 1 - Parâmetros e Hiperparâmetros do Método MAE

Componente	Parâmetros (Valor estimado)	Hiperparâmetros (Peso)
Nível	20.620	0,54342
Tendência	316,56	0,02512
Sazonalidade	*	0,22013

Fonte: Elaboração própria. Nota: * Fatores sazonais são apresentados na tabela 2.

O nível suavizado estimado para a demanda de veículos elétricos no Brasil no último período observado, é de 20.620 unidades, o que indica a ordem de magnitude da demanda ao final da amostra. O peso de suavização do nível ($\alpha = 0,54342$) indica que o modelo atribui 54,3% de peso ao valor mais recente e 45,7% ao histórico acumulado, fazendo com que o nível responda rapidamente às variações mais atuais da série, o da tendência, exprime um peso maior para o passado, cerca de 97,5% ao o passado e apenas 2,5% ao presente. Por fim, o peso sazonal

indica que o modelo utiliza apenas 22% da informação recente para atualizar os fatores sazonais, preservando 78% do padrão histórico. Dessa forma, a sazonalidade é ajustada gradualmente, com pouca sensibilidade a variações de curto prazo.

A tabela 2 apresenta, mês a mês, os incrementos sazonais associados ao horizonte de previsão.

Tabela 2 - Parâmetros Sazonais	
Mês	Fatores Sazonais
	$\rho(T+\tau)$
Janeiro	0,88456
Fevereiro	0,94094
Março	1,07804
Abril	0,90001
Maio	0,91110
Junho	0,97768
Julho	0,99963
Agosto	1,05927
Setembro	1,02596
Outubro	1,00415
Novembro	1,05115
Dezembro	1,21234

Fonte: Elaboração própria.

Com base nos fatores sazonais estimados, observa-se que, no primeiro semestre, a maior parte dos meses apresentou valores inferiores a 1, refletindo reduções sazonais entre aproximadamente 1% e 12%, com janeiro se destacando como o período de menor demanda relativa. Em contraste, o segundo semestre — especialmente de agosto a dezembro — registrou fatores superiores a 1, indicando incrementos sazonais que variam de cerca de 0,4% a 21%, sendo dezembro o mês de maior acréscimo. Convém destacar que março, embora pertencente ao primeiro semestre, constitui uma exceção ao padrão, ao apresentar um aumento de 7,8%. Ademais, julho, ainda que faça parte do segundo semestre, apresenta uma leve redução sazonal de 0,01%, destoando dos demais meses desse período.

A equação de previsão do modelo Holt-Winters com tendência, nível e fatores sazonais multiplicativos é dada pela seguinte equação:

$$\hat{Z}_{T(t)} = (20.620 + 316,56(\tau))\rho_{(T+\tau)} \quad (13)$$

Na tabela 3 são apresentadas as principais estatísticas do modelo. O poder de explicação do modelo estimado é de 94,77%, e ele erra em média 19,85% ao realizar previsões para o mês seguinte.

O p-valor do teste de Ljung-Box foi de 0,4627. Assim, ao nível de significância de 5%, não se rejeita a hipótese nula de ausência de autocorrelação nos resíduos, indicando que o modelo captura adequadamente a dependência temporal da série. Podemos observar isso no comportamento dos resíduos na figura 4.


Tabela 3 – Estatísticas do Desempenho Preditivo do MAE

R ² ajustado (%)	94,77
MAPE (%)	19,85
P-valor do Teste de Ljung-Box*	0,4627

Fonte: Elaboração própria.

Nota: *No software do FPW, rejeita-se a hipótese nula quando o p-valor é \geq ao nível de confiança.


Figura 4 – Correlograma da Função de Autocorrelação dos Erros gerado pelo MAE



Fonte: Elaboração própria.

A figura 5 abaixo apresenta a evolução da série temporal das vendas de veículos elétricos ao longo do período analisado o ajustamento e a previsão até o final do ano de 2026, marcada por leves oscilações sazonais.

Figura 5 – Previsão das vendas de veículos elétricos através do MAE



Fonte: Elaboração própria. Nota: ____ Valor real ____ Valor ajustado/previsões ____ Intervalo de Confiança de 95%.

Na tabela 4 abaixo, estão expostas as previsões para o período de dezembro de 2025 até dezembro de 2026 gerados pelo Método de Amortecimento Exponencial.

Vale destacar uma das vantagens de trabalhar com modelos matemático-estatísticos para geração de previsões: eles não fornecem apenas um único número, mas sim uma previsão probabilística, expressa por meio de um intervalo de confiança. Esse intervalo indica a faixa dentro da qual o valor futuro tem determinada probabilidade de ocorrer.

No caso do presente modelo, por exemplo, para dezembro de 2025, há 95% de chance de que a demanda prevista esteja entre 11.048 e 37.412 unidades, sendo que o valor pontual estimado para esse mês é de 25.382 unidades.

Tabela 4 – Projeção de vendas de veículos elétricos obtida pelo método MAE

Data	Limite inferior	Valor Previsto	Limite Superior
12-2025	11.048	25.382	37.412
01-2026	5.641	18.800	29.842
02-2026	5.414	20.296	32.785
03-2026	6.315	23.594	38.095
04-2026	2.669	19.983	34.513
05-2026	2,140	20.517	35.940
06-2026	2.545	22.326	38.927
07-2026	2.195	23.144	40.724
08-2026	2,514	24.860	43.613
09-2026	1.201	24.403	43.874
10-2026	165	24.202	44.375
11-2026	468	25.667	46.816
12-2026	2.895	29.987	52.724

Fonte: Elaboração própria. Nota: Intervalo de Confiança de 95%.

4.4 PREVISÃO E ANÁLISE DO MÉTODO BOX-JENKINS

O modelo Box–Jenkins estimado para a série de vendas de veículos elétricos no Brasil foi o SARIMA (0,1,1)(1,0,1), estimado após a aplicação de uma transformação de raiz quadrada. A estrutura do modelo — composta por uma diferenciação não sazonal de primeira ordem, um termo de média móvel não sazonal e, na parte sazonal, um termo autorregressivo e um termo de média móvel — mostrou-se adequada para capturar a dinâmica estocástica da série após a remoção da tendência determinística via diferenciação. A escolha da estrutura do modelo foi feita por um critério automático de minimização do BIC (*Bayesian Information Criterion*)¹³. A equação 14, apresenta os coeficientes do modelo SARIMA estimados:

$$(1 - 0,9791 B^{12}) (1-B) \sqrt{(Z_t)} = (1 - 0,3293 B) (1 - 0,8675 B^{12}) a_t \quad (14)$$

Conforme estatísticas de desempenho preditivo presentes na tabela 5, o coeficiente de explicação ajustado (R^2 ajustado) indica que o modelo explica 95,8% das vendas, e uma taxa de erro de quase 20% nas previsões. O *p-valor* do teste de Ljung–Box de 0,3917, sugere ausência de autocorrelação nos resíduos, ou seja, não rejeita a hipótese nula¹⁴ de que os erros se comportam como ruído branco. Além desses diagnósticos confirma-se que o modelo está bem especificado e que sua estrutura capta satisfatoriamente a dependência serial da série pela análise do correlograma dos erros na figura 6 adiante.

Tabela 5 – Estatísticas do Desempenho Preditivo do MBJ

R^2 ajustado (%)	95,80
MAPE (%)	19,27
P-valor do Teste de Ljung-Box*	0,3917

Fonte: Elaboração própria. Nota: *no software do fpw, rejeita-se a hipótese nula quando o *p-valor* é \geq ao nível de confiança.

¹³ Ver Goodrich (1999) e Goodrich (1989).

¹⁴ Hipótese nula do teste de Ljung–Box: os resíduos não apresentam autocorrelação, isto é, comportam-se como ruído branco.


Figura 6 - Correlograma do erro gerado pelo MAE



Fonte: Elaboração própria.

A fim de facilitar a visualização do desempenho deste modelo, a figura 7 apresenta o ajustamento e as projeções, evidenciando a proximidade entre valores previstos e observados e ilustrando a capacidade do SARIMA (0,1,1)(1,0,1) de reproduzir a trajetória das vendas de veículos elétricos.

Figura 7 – Previsão das vendas de veículos elétricos através do MBJ



Fonte: Elaboração própria. Nota: ____ Valor real ____ Valor ajustado/previsões ____ Intervalo de Confiança de 95%.

Na tabela 6 abaixo, estão expostas as previsões para o período de dezembro de 2025 até dezembro de 2026 gerados pelo Modelo Box & Jenkins.

O intervalo deste modelo para o mês de dezembro de 2025, por exemplo, há 95% de chance de que a demanda prevista esteja entre 20.181 e 28.266 unidades, sendo que o valor pontual estimado para esse mês é de 24.408 unidades.

Tabela 6 - Projeção de vendas de veículos elétricos obtida pelo método MBJ

Data	Limite inferior	Valor Previsto	Limite Superior
12-2025	20.181	24.408	28.266
01-2026	14.710	19.141	23.309
02-2026	14.346	19.407	24.243
03-2026	15.070	20.875	26.476
04-2026	14.294	20.527	26.625
05-2026	14.702	21.550	28.304
06-2026	14.546	21.864	29.151
07-2026	15.331	23.313	31.298
08-2026	15.833	24.405	33.025
09-2026	15.629	24.604	33.702
10-2026	15.497	24.874	34.449
11-2026	15.649	25.491	35.595
12-2026	17.685	28.657	39.899

Fonte: Elaboração própria. Nota: Intervalo de Confiança de 95%.

4.5 COMPETIÇÃO DE MÉTODOS

De acordo com a tabela 7, apresentam-se os resultados de desempenho preditivo dos modelos, considerando tanto os dados da análise *in-sample* quanto *out-of-sample*. Recapitulando, para o ajuste dentro da amostra, foram avaliadas as métricas R^2 ajustado e MAPE. Já para a análise fora da amostra, calculou-se o MAPE (%) para o horizonte de 1 passo à frente ($H = 1$, $N = 12$) e o MAPE (%) acumulado para as 78 previsões avaliadas. Adicionalmente, foi utilizado o Erro Absoluto Relativo Médio Geométrico (GMRAE), que compara o desempenho de cada método em relação ao modelo *naive* (ingênuo).

Com base nessas métricas, procedeu-se à análise recursiva de desempenho, englobando os resultados *in-sample* (análise dentro da amostra) e *out-of-sample* (análise recursiva fora da amostra).

Tabela 7 - Análise *In-Sample* e *Out-of-sample*

Método	<i>In-sample</i>		<i>Out-of-sample</i>			
	R ² ajustado (%)	MAPE (%)	MAPE (%) (H =1, N =12)	MAPE (%) acumulado	GMRAE (H =1, N =12)	GMRAE acumulado
MAE	94,8	19,8	13,3	15,5	2,0	0,8
MBJ	95,8	19,3	13,1	21,5	1,0	1,0

Fonte: Elaboração própria.

Primeiramente analisando-se o poder de generalização dos modelos (análise em linha da tabela 7), vê-se que tanto o MAE quanto o MBJ possuem um bom poder de generalização gerando um erro de previsão fora da amostra menor do que o erro dentro da amostra. O MAE, por exemplo, apresenta um MAPE de 19,8% dentro da amostra e de 13,3% fora da amostra para as previsões um passo à frente (mês seguinte) e no acumulado, 15,5%. Já o MBJ apresenta um MAPE de 19,3% dentro da amostra e 13,1% fora da amostra para as previsões um passo à frente e 21,5% no acumulado. É possível observar também que, no MAE, os erros acumulados e um passo à frente, fora da amostra, são próximos. Os erros do MBJ não são tão próximos quanto os erros do MAE. No MAE, por exemplo, tem um erro de 13,3% para as previsões um passo à frente e 15,5% no acumulado. Já no MBJ tem-se um erro de quase 13,1% para as previsões um passo à frente e 21,5% no acumulado. Na comparação com o método ingênuo, observa-se que ambos os métodos apresentam GMRAE igual ou superior a 1 no horizonte de um passo à frente. No acumulado, o GMRAE do MAE é de 0,8 e o do MBJ é de 1%. Isso significa que, no caso do MAE, o erro é menor do que aquele que seria obtido caso se utilizasse o método ingênuo, que toma o último dado observado como previsor. Já para o MBJ, a previsão apresenta desempenho equivalente ao do modelo ingênuo.

Num segundo momento, realiza-se a comparação entre os modelos (análise entre as linhas da tabela). Dentro da amostra, o modelo Box–Jenkins apresentou maior poder de

explicação (95,8%) em relação ao método de Amortecimento Exponencial (94,8%). Além disso, o MBJ exibiu um MAPE inferior ao do MAE. Em síntese, na análise *in-sample*, o modelo Box–Jenkins mostra maior capacidade explicativa e menor erro médio preditivo. Contudo, fora da amostra, exceto no MAPE um passo à frente (mas com um desempenho muito próximo ao MBJ), o método de Amortecimento Exponencial apresenta melhor desempenho em praticamente todas as métricas avaliadas. Assim, de acordo com o critério definido neste trabalho, o método que demonstra maior capacidade de previsão *out-of-sample* é o MAE, sendo, portanto, considerado o modelo vencedor. Diante disso, as previsões para final de 2025 e o ano de 2026 das vendas de veículos elétricos no Brasil foram calculadas pelo MAE e serão apresentadas a seguir.

4.6 PREVISÃO DE VEÍCULOS ELÉTRICOS NO BRASIL

Feitas estas considerações, ou seja, definido o método vencedor, os dados que anteriormente foram retirados para se promover a competição de métodos são novamente incorporados à amostra e os parâmetros do modelo são atualizados chegando-se na equação 13 que será utilizada para se calcular as previsões. As previsões de vendas de veículos elétricos para o final de 2025 e para o ano de 2026 foram calculadas pelo Modelo de Amortecimento Exponencial e podem ser vistas no figura 5 e na tabela 4.

A Tabela 8 a seguir, apresenta as vendas anuais de veículos elétricos de 2012 a 2026, evidenciando o comportamento de crescimento do setor ao longo dos anos. Nota-se uma expansão significativa especialmente a partir de 2019, quando as vendas crescem de forma mais acelerada. Para 2025 e 2026, as previsões indicam continuidade desse processo, com crescimentos de 21,45% e 28,97%, respectivamente.

Além disso, observa-se que 2015 apresenta a única variação negativa da série, o que poderia ser explicado, por exemplo, pelo contexto macroeconômico adverso enfrentado pelo país naquele período.

Tabela 8 - Valores Anualizados

Ano	Unidades de Veículos Vendidos	Variação anual (%)
2012	117	-
2013	491	319,7
2014	855	74,1
2015	846	-1,1
2016	1.091	28,9
2017	3.296	202
2018	3.970	20,5
2019	11.858	198,5
2020	19.745	66,5
2021	34.990	77,2
2022	49.245	40,7
2023	93.927	90,7
2024	177.358	88,9
2025*	215.389	21,5
2026*	277.778	29,9

Fonte: Elaboração própria. Nota * Valores estimados pelo MAE.

Observa-se que, apesar das oscilações, as projeções indicam uma tendência consistente de expansão do mercado de veículos elétricos. Esse movimento reflete tanto a crescente adaptação tecnológica dos consumidores às alternativas sustentáveis de mobilidade quanto a contínua ampliação da infraestrutura de recarga no Brasil.

5 CONCLUSÃO

Este estudo teve como objetivo avaliar o desempenho dos métodos Box-Jenkins (SARIMA) e Amortecimento Exponencial na previsão das vendas de veículos elétricos no Brasil, considerando a crescente relevância deste segmento no mercado automotivo nacional. A comparação entre os modelos permitiu identificar diferenças importantes na capacidade de ajustamento e previsão, revelando que os métodos estudados oferecem resultados satisfatórios, embora com níveis distintos de precisão, robustez estatística e aderência ao comportamento da série.

De maneira geral, verificou-se uma trajetória ascendente nas vendas de veículos elétricos no país. O método de Amortecimento Exponencial, ao atribuir maior peso às observações mais recentes e suavizar flutuações aleatórias, proporcionou previsões mais estáveis e consistentes. A identificação desses amortecimentos decrescentes é fundamental para orientar decisões estratégicas relacionadas ao planejamento da produção, à expansão da infraestrutura de recarga, à definição de metas comerciais e à formulação de políticas públicas de incentivo — que, conforme destaca a literatura, constituem fatores decisivos para o avanço desse mercado.

Os resultados reforçam a importância do uso de métodos estatísticos formais para apoiar decisões em um mercado em constante transformação. O uso de critérios objetivos, baseado em métricas de acurácia e testes de diagnóstico, permitiu não apenas fornecer uma previsão pontual, mas também construir intervalos de confiança que permitem a construção de cenários distintos: o limite inferior pode ser interpretado como um cenário conservador, o limite superior como um cenário otimista e o valor central como um cenário esperado. Essa abordagem probabilística oferece maior segurança e capacidade de planejamento para empresas, formuladores de políticas e investidores que precisam lidar com incertezas inerentes ao setor.

Além disso, o trabalho destaca como técnicas de previsão são relevantes para setores emergentes, como o de veículos elétricos, cuja dinâmica é fortemente influenciada por fatores tecnológicos, regulatórios e macroeconômicos. O uso adequado desses métodos contribui para uma maior eficiência operacional, para um planejamento financeiro mais consistente e para uma maior capacidade de adaptação diante das rápidas transformações tecnológicas e econômicas que caracterizam esse mercado.

Para pesquisas futuras, recomenda-se a ampliação da base histórica, bem como a incorporação de variáveis exógenas — como PIB, taxa de juros, demanda de energia, emissões de CO₂, incentivos fiscais e consumo energético de postos de recarga —, de forma a enriquecer a modelagem e explorar tanto por metodologias clássicas, como uma regressão dinâmica, quanto abordagens mais avançadas, como técnicas de aprendizado de máquina ou redes neurais. A ampliação metodológica pode aprofundar o entendimento dos fatores que impulsionam a adoção de veículos elétricos e aumentar a precisão das projeções.

Assim, espera-se que este estudo contribua para a compreensão da dinâmica do mercado brasileiro de veículos elétricos e para o aprimoramento das práticas de previsão no contexto econômico nacional, oferecendo subsídios úteis para pesquisadores, empresas e agentes públicos que buscam decisões mais informadas em um setor que tende a ganhar protagonismo nos próximos anos.

REFERÊNCIAS

- AL-DAL'AIN, R.; CELEBI, D. Planning a mixed fleet of electric and conventional vehicles for urban freight transport with routing and replacement considerations. **Sustainable Cities and Society**, [S. l.], v. 73, art. 103105, 2021. DOI: 10.1016/j.scs.2021.103105.
- ASSOCIAÇÃO BRASILEIRA DO VEÍCULO ELÉTRICO (ABVE). **ABVE Data**: BI Geral. Disponível em: <https://abve.org.br/abve-data/bi-geral/>. Acesso em: 19 out. 2025.
- ASSOCIAÇÃO BRASILEIRA DO VEÍCULO ELÉTRICO (ABVE). **Mercado já optou pelo veículo sustentável**. [S. l.], 2022. Disponível em: <https://abve.org.br/mercado-ja-optou-pelo-veiculo-sustentavel/>. Acesso em: 19 out. 2025.
- ASSOCIAÇÃO BRASILEIRA DO VEÍCULO ELÉTRICO (ABVE). **Presidente da ABVE destaca crescimento de 20% do setor de eletrificação em 2025**. [S. l.], 2025. Disponível em: <https://abve.org.br/presidente-da-abve-destaca-crescimento-de-20-do-setor-de-eletrificacao-em-2025/>. Acesso em: 19 out. 2025.
- BAC, Ugur; ERDEM, Mehmet. Optimization of electric vehicle charging schedule and routing problem with time windows and partial recharging: A comparative study for an urban logistics fleet. **Sustainable Cities and Society**, [S. l.], v. 70, art. 102883, 2021. DOI: 10.1016/j.scs.2021.102883.
- BASSO, Rafael; KULCSÁR, Balázs; SANCHEZ-DIAZ, Ivan. Electric vehicle routing problem with machine learning for energy prediction. **Transportation Research Part B: Methodological**, [S. l.], v. 144, p. 203–228, 2021. DOI: 10.1016/j.trb.2020.12.007.
- BRASIL. Ministério do Desenvolvimento, Indústria, Comércio e Serviços. Secretaria de Desenvolvimento Industrial, Inovação, Comércio e Serviços. **Programa MOVER**. Brasília, DF, 2024. Disponível em: <https://www.gov.br/mdic/pt-br/assuntos/sdic/setor-automotivo/programa-mover>. Acesso em: 14 dez. 2025.
- CHAKRABORTY, N.; MONDAL, A.; MONDAL, S. Intelligent charging scheduling and eco-routing mechanism for electric vehicles: a multi-objective meta-heuristic approach. **Sustainable Cities and Society**, [S. l.], v. 69, art. 102820, 2021. DOI: 10.1016/j.scs.2021.102820.
- CHATTERJEE, S.; BYUN, Y.-C. Time series data generation using generative adversarial networks for mobility demand forecasting. **CMC – Computers, Materials & Continua**, [S. l.], v. 74, n. 3, p. 5507–5525, 2023. DOI: <https://doi.org/10.32604/cmc.2023.032843>.
- DUDEWICZ, E. J.; MISHRA, S. N. **Modern Mathematical Statistics**. New York: Wiley, 1988.

EMPRESA BRASIL DE COMUNICAÇÃO (EBC). **Voz do Brasil**. [S. l.], 9 out. 2025. Podcast. Disponível

em: <https://open.spotify.com/episode/2xit9Coa3YW022ZhTVIJPl?si=SxGnprg2RnSyJNyvQCbADg>. Acesso em: 24 out. 2025.

FERNANDES, C.; FRÍAS, P.; LATORRE, J. M. Impact of vehicle-to-grid on power system operation costs: the Spanish case study. **Applied Energy**, [S. l.], v. 96, p. 194-202, 2012. DOI: 10.1016/j.apenergy.2011.11.058.

GIAMBIAGI, F.; CASTRO, L. B.; VILLELA, A.; HERMANN, J. (org.). **Economia Brasileira Contemporânea: 1945–2015**. 10. ed. Rio de Janeiro: Elsevier, 2017.

GOODRICH, R. L. **Applied Statistical Forecasting**. Belmont: Business Forecast Systems, 1989.

GOODRICH, R. L.; STELLWAGEN, E. A. **Forecast Pro for Windows**. Belmont: Business Forecast Systems, 1999.

GULZAR, Yonis; DUTTA, Monica; GUPTA, Dipali; JUNEJA, Sapna; SOOMRO, Arjumand Bano; MIR, Mohammad Shuaib. Revolutionizing mobility: a comprehensive review of electric vehicle charging stations in India. **Frontiers in Sustainable Cities**, [S. l.], v. 6, art. 1346731, 1 fev. 2024. DOI: <https://doi.org/10.3389/frsc.2024.1346731>.

HIERMANN, G.; PUCHINGER, J.; ROPKE, S.; HARTL, R. F. The electric fleet size and mix vehicle routing problem with time windows and recharging stations. **European Journal of Operational Research**, [S. l.], v. 252, n. 3, p. 995–1018, 2016. DOI: 10.1016/j.ejor.2016.01.038.

HUANG, Y.; SURAWSKI, N. C.; ORGAN, B.; ZHOU, J. L.; TANG, O. H. H.; CHAN, E. F. C. Fuel consumption and emission performance under real driving conditions: Comparison between hybrid and conventional vehicles. **Science of the Total Environment**, [S. l.], v. 659, p. 275–282, 2019. DOI: <https://doi.org/10.1016/j.scitotenv.2018.12.354>.

KENNEDY, C. A.; IBRAHIM, N.; HOORNWEG, D. Low-carbon infrastructure strategies for cities. **Nature Climate Change**, [S. l.], v. 4, n. 5, p. 343–346, 2014.

KESKIN, M.; LAPORTE, G.; ÇATAY, B. Electric vehicle routing problem with time-dependent waiting times at recharging stations. **Computers & Operations Research**, [S. l.], v. 107, p. 77–94, 2019. DOI: 10.1016/j.cor.2019.01.006.

KESSLER, S.; BOGENBERGER, K. Dynamic traffic information for electric vehicles as basis for energy efficient routing. **Transportation Research Procedia**, [S. l.], v. 37, p. 457–464, 2019. DOI: 10.1016/j.trpro.2018.12.215.

KHARDENAVIS, A.; HEWAGE, K.; PERERA, P.; SHOTORBANI, A. M.; SADIQ, R. Mobile energy hubs planning for complex urban grids: A robust optimization approach. **Energy**, [S. l.], v. 235, p. 121424, 2021. DOI: 10.1016/j.energy.2021.121424.

KIM, Gitae. Electric vehicle routing problem considering charging station states. **Sustainability**, [S. l.], v. 16, n. 8, art. 3439, 19 abr. 2024. DOI: <https://doi.org/10.3390/su16083439>.

LUO, Q.; YE, Z.; JIA, H. A charging planning method for shared electric vehicles with collaboration of mobile and fixed facilities. **Sustainability**, [S. l.], v. 15, p. 16107, 2023.

LYU, P.; WANG, P.; LIU, Y.; WANG, Y. Review of the studies on emission evaluation approaches for operating vehicles. **Journal of Traffic and Transportation Engineering (English Edition)**, [S. l.], v. 8, n. 4, p. 493–509, 2021. DOI: <https://doi.org/10.1016/j.jtte.2021.07.004>.

MA, B.; HU, D.; CHEN, X.; WANG, Y.; WU, X. The vehicle routing problem with speed optimization for shared autonomous electric vehicle service. **Computers & Industrial Engineering**, [S. l.], v. 161, art. 107614, 2021. DOI: 10.1016/j.cie.2021.107614.

MENES, M. Two decades of hybrid electric vehicle market. **Journal of Civil Engineering and Transportation**, [S. l.], v. 3, p. 29–37, 2021.

MONTGOMERY, D. C.; JOHNSON, L. A. **Forecasting and Time Series Analysis**. New York: McGraw-Hill Book Co., 1990.

MONTOYA, A.; GUÉRET, C.; MENDOZA, J. E.; VILLEGAS, J. G. The electric vehicle routing problem with nonlinear charging function. **Transportation Research Part B: Methodological**, [S. l.], v. 103, p. 87–110, 2017. DOI: 10.1016/j.trb.2017.03.007.

NIELSEN, Aileen. **Análise prática de séries temporais: predição com estatística e aprendizado de máquina**. 1. ed. Rio de Janeiro: Alta Books, 2021.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS BRASIL (ONU). **Veículos elétricos podem dobrar empregos no Brasil até 2050**. [S. l.], [20--?]. Disponível em: <https://brasil.un.org/pt-br/297624-ve%C3%ADculos-el%C3%A9tricos-podem-dobrar-empregos-no-brasil-at%C3%A9-2050>. Acesso em: 22 out. 2025.

PELLETIER, S.; JABALI, O.; LAPORTE, G. The electric vehicle routing problem with energy consumption uncertainty. **Transportation Research Part B: Methodological**, [S. l.], v. 126, p. 225–255, 2019. DOI: 10.1016/j.trb.2019.06.006.

PINDYCK, R. S.; RUBINFELD, D. L. **Econometria: Modelos & Previsões**. Rio de Janeiro: Campus, 2004.

RÁDIO GOV. **E-Notícia**: Luciano Seixas fala sobre investimentos da Hyundai no Brasil. [S. l.]: EBC, 22 fev. 2024. Podcast. Disponível em: <https://radiogov.ebc.com.br/programas/e-noticia/22-02-24-e-noticia-luciano-seixas-investimentos-hyundai.mp3>. Acesso em: 22 out. 2025.

RASOOL, Y.; ZAIDI, S. A. H.; ZAFAR, M. W. Determinants of carbon emissions in Pakistan's transport sector. **Environmental Science and Pollution Research**, [S. l.], v. 26, p. 22907–22921, 2019. DOI: <https://doi.org/10.1007/s11356-019-05600-9>.

SOLAYMANI, S. CO2 emissions and the transport sector in Malaysia. **Frontiers in Environmental Science**, [S. l.], v. 9, art. 774164, 2022. DOI: <https://doi.org/10.3389/fenvs.2021.774164>.

SOUZA, R. C.; CAMARGO, M. E. **Análise e Previsão de Séries Temporais**: Os Modelos ARIMA. [S. l.]: SEDIGRAF, 1996.

TARROJA, B.; HITTINGER, E. The value of consumer acceptance of controlled electric vehicle charging in a decarbonizing grid: The case of California. **Energy**, [S. l.], v. 229, e120691, 2021. DOI: 10.1016/j.energy.2021.120691.

WEIS, A.; JARAMILLO, P.; MICHALEK, J. Consequential life cycle air emissions externalities for plug-in electric vehicles in the PJM interconnection. **Environmental Research Letters**, [S. l.], v. 11, n. 2, e024009, 2016. DOI: 10.1088/1748-9326/11/2/024009.

XU, N.; KONG, Y.; CHU, L.; JU, H.; YANG, Z.; XU, Z. Towards a smarter energy management system for hybrid vehicles: A comprehensive review of control strategies. **Applied Sciences**, [S. l.], v. 9, p. 2026, 2019. DOI: <https://doi.org/10.3390/app9102026>.

YUAN, X.; CAI, Y. Forecasting the development trend of low emission vehicle technologies: Based on patent data. **Technological Forecasting and Social Change**, [S. l.], v. 166, p. 120651, 2021. DOI: <https://doi.org/10.1016/j.techfore.2021.120651>.

ZANINI, Alexandre. **Modelos de previsão para séries temporais**: Material Didático. Juiz de Fora: Universidade Federal de Juiz de Fora, Faculdade de Economia, 2023.

ZHANG, S. Q.; WEI, Y. P.; GUO, X. Q.; LI, Z.; SONG, X. F.; BLAABJERG, F. Overview of U.S. patents for energy management in hydrogen renewable energy systems. **International Journal of Hydrogen Energy**, [S. l.], v. 48, n. 26, p. 9574–9591, 2023. DOI: 10.1016/j.ijhydene.2022.12.091.

ZHU, Yan; WU, Jie; GAIDAI, Oleg. The technology innovation of hybrid electric vehicles: a patent-based study. **World Electric Vehicle Journal**, [S. l.], v. 15, n. 8, art. 329, 24 jul. 2024. DOI: <https://doi.org/10.3390/wevj15080329>.