v7.n9.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

PREVISÃO DE CURTO PRAZO DO CARREGAMENTO APARENTE AGREGADO EM SUBESTAÇÕES DE DISTRIBUIÇÃO: COMPARAÇÃO ENTRE HOLT-WINTERS E SARIMAX

SHORT-TERM FORECASTING OF AGGREGATED APPARENT LOAD IN DISTRIBUTION SUBSTATIONS: A COMPARISON OF HOLT-WINTERS AND SARIMAX

PREDICCIÓN A CORTO PLAZO DE LA CARGA APARENTE AGREGADA EN SUBESTACIONES DE DISTRIBUCIÓN: COMPARACIÓN ENTRE HOLT-WINTERS Y SARIMAX

Ananda Coaglia Trindade[1], Luísa Eriko Gibo Abud[2], Talisson de Souza Barbosa[3]

e799045
https://doi.org/10.47820/recima21.v7i9.9045

PUBLICADO: 09/2026

RESUMO

Este estudo compara Holt-Winters e SARIMAX na previsão de curto prazo do carregamento aparente agregado de quatro subestações de distribuição. Foram utilizadas séries reais em MVA, amostradas a cada 15 minutos entre junho de 2023 e maio de 2025. Após regularização temporal e qualificação dos dados, os métodos foram avaliados em sete origens não sobrepostas, com janela de treinamento de 15 dias e horizonte de 24 horas. As persistências sazonais diária e semanal serviram como referências de desempenho. Na comparação direta, Holt-Winters obteve menor WAPE em 19 das 28 combinações subestação–origem (67,9%) e predominou em três das quatro séries. Considerando as referências, Holt-Winters e a persistência semanal alcançaram o menor WAPE em 11 combinações cada, indicando forte regularidade semanal em parte das séries. A estabilidade temporal foi definida pelo intervalo interquartil (IQR) do WAPE entre as origens. Holt-Winters apresentou menor IQR em três séries, enquanto o SARIMAX foi mais estável na SE03. Holt-Winters também apresentou custo computacional substancialmente inferior ao do SARIMAX. Como verificação complementar, a vantagem relativa entre os dois modelos repetiu-se nos períodos de avaliação e confirmação: Holt-Winters apresentou menor WAPE agregado nas séries SE01, SE02 e SE04, enquanto o SARIMAX apresentou menor WAPE agregado na SE03. Embora nenhum método tenha sido superior em todas as condições, Holt-Winters apresentou o melhor equilíbrio entre acurácia, estabilidade temporal e custo computacional no conjunto analisado, mostrando-se uma alternativa adequada para aplicações operacionais que demandem reestimações frequentes.

PALAVRAS-CHAVE: Previsão de carga elétrica. Previsão de curto prazo. Séries temporais. Holt-Winters. SARIMAX. Subestações de distribuição.

ABSTRACT

This study compares Holt-Winters and SARIMAX for short-term forecasting of the aggregated apparent load of four distribution substations. Real-world series in MVA, sampled at 15-minute intervals from June 2023 to May 2025, were analyzed. After temporal regularization and quality control, the methods were evaluated at seven non-overlapping forecast origins, using a 15-day training window and a 24-hour horizon. Daily and weekly seasonal persistence served as performance benchmarks. In the direct comparison, Holt-Winters yielded lower WAPE in 19 of the 28 substation–origin combinations (67.9%) and outperformed SARIMAX in three of the four series. With the benchmarks included, Holt-Winters and weekly persistence achieved the lowest

[1] Mestre em Ciência da Computação pela Universidade Federal de São Carlos. Graduanda em Engenharia Elétrica pela Pontifícia Universidade Católica de Minas Gerais, *Campus* Poços de Caldas.
[2] Graduanda em Engenharia Elétrica pela Pontifícia Universidade Católica de Minas Gerais, *Campus* Poços de Caldas.
[3] Mestre e Doutorando em Engenharia Elétrica pela FEEC UNICAMP, Docente na Pontifícia Universidade Católica de Minas Gerais, *Campus* Poços de Caldas.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

WAPE in 11 combinations each, indicating strong weekly regularity in some series. Temporal stability was defined by the interquartile range (IQR) of WAPE across forecast origins. Holt-Winters had a lower IQR in three series, whereas SARIMAX was more stable for SE03. Holt-Winters also had a substantially lower computational cost than SARIMAX. As a complementary check, the relative advantage of the two models was consistent across the evaluation and confirmation periods: Holt-Winters yielded lower aggregate WAPE for SE01, SE02, and SE04, whereas SARIMAX did so for SE03. Although no method was superior under all conditions, Holt-Winters provided the best balance among accuracy, temporal stability, and computational cost, making it a suitable alternative for operational applications requiring frequent model refitting.

KEYWORDS: *Electrical load forecasting. Short-term forecasting. Time series. Holt-Winters. SARIMAX. Distribution substations.*

RESUMEN
Este estudio compara Holt-Winters y SARIMAX en la predicción a corto plazo de la carga aparente agregada de cuatro subestaciones de distribución. Se analizaron series reales en MVA, muestreadas cada 15 minutos de junio de 2023 a mayo de 2025. Tras la regularización temporal y el control de calidad, los métodos se evaluaron en siete orígenes no superpuestos, con una ventana de entrenamiento de 15 días y un horizonte de 24 horas. Las persistencias estacionales diaria y semanal sirvieron como referencias. En la comparación directa, Holt-Winters obtuvo menor WAPE en 19 de las 28 combinaciones subestación–origen (67,9 %) y superó a SARIMAX en tres de las cuatro series. Al incluir las referencias, Holt-Winters y la persistencia semanal alcanzaron el menor WAPE en 11 combinaciones cada uno, indicando fuerte regularidad semanal en parte de las series. La estabilidad temporal se definió mediante el rango intercuartílico (IQR) del WAPE entre los orígenes. Holt-Winters presentó menor IQR en tres series, mientras que SARIMAX fue más estable en la SE03. Holt-Winters también presentó un costo computacional sustancialmente menor que SARIMAX. Como verificación complementaria, la ventaja relativa entre ambos modelos se mantuvo en los períodos de evaluación y confirmación: Holt-Winters presentó menor WAPE agregado en SE01, SE02 y SE04, mientras que SARIMAX lo hizo en SE03. Aunque ningún método fue superior en todas las condiciones, Holt-Winters mostró el mejor equilibrio entre precisión, estabilidad temporal y costo computacional, por lo que resulta una alternativa adecuada para aplicaciones operativas que requieren reestimaciones frecuentes.

PALABRAS CLAVE*: Predicción de carga eléctrica. Predicción a corto plazo. Series temporales. Holt-Winters. SARIMAX. Subestaciones de distribución.*

INTRODUÇÃO

A previsão de carga elétrica apoia o planejamento e a operação dos sistemas elétricos, especialmente a programação operacional, a manutenção e o uso dos recursos disponíveis. Erros de previsão podem produzir consequências técnicas e econômicas, o que exige métodos capazes de representar adequadamente a dinâmica temporal da carga (Al-Hafid; Al-Maamary, 2012; Pinheiro; Madeira; Francisco, 2023). Nesse contexto, Pinheiro, Madeira e Francisco (2023) analisam a previsão de curto prazo desde o nível sistêmico até as subestações de distribuição e a relacionam à gestão e ao planejamento da rede.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

No curto prazo, as séries de carga apresentam padrões sazonais e alterações de comportamento ao longo do tempo, fazendo com que o desempenho preditivo dependa das características de cada série. Entre as abordagens estatísticas, Holt-Winters modela nível, tendência e sazonalidade por suavização exponencial, enquanto o SARIMAX representa dependências autorregressivas, diferenciação, médias móveis e sazonalidade, além de permitir a incorporação de variáveis exógenas (Al-Hafid; Al-Maamary, 2012; Elamin; Fukushige, 2018).

Diante disso, formula-se a seguinte questão de pesquisa: como os métodos Holt-Winters e SARIMAX se comparam na previsão de curto prazo quando submetidos às mesmas condições experimentais, considerando acurácia, estabilidade temporal do desempenho e custo computacional? A comparação se justifica porque não existe um método de previsão universalmente superior, uma vez que o desempenho depende das características das séries e da finalidade da previsão (Pinheiro; Madeira; Francisco, 2023). Além disso, avaliações baseadas em múltiplas origens temporais reduzem a dependência de um único período de teste e permitem examinar diferentes condições de previsão, preservando a ordem temporal das observações (Hyndman; Athanasopoulos, 2021).

O objetivo geral deste trabalho é comparar Holt-Winters e SARIMAX na previsão de curto prazo do carregamento aparente agregado de quatro subestações de distribuição. Os objetivos específicos consistem em qualificar e organizar as séries históricas; identificar seus principais padrões temporais e sazonais; implementar e parametrizar os modelos sob condições experimentais equivalentes; produzir previsões com horizonte de 24 horas em múltiplas origens temporais; utilizar persistências sazonais diária e semanal como métodos de referência; e comparar as abordagens quanto à acurácia, à estabilidade temporal do desempenho e ao custo computacional.

A contribuição científica consiste em fornecer evidências empíricas, baseadas em dados reais de subestações, sobre a adequação de métodos com diferentes níveis de complexidade à previsão do carregamento em sistemas de distribuição. Os resultados subsidiam a escolha da abordagem conforme o comportamento da série e as exigências da aplicação, sem pressupor que modelos mais complexos sejam necessariamente superiores. Operacionalmente, previsões mais consistentes podem apoiar a antecipação de picos e restrições, a programação da operação e da manutenção, o gerenciamento da demanda e o uso eficiente dos ativos da rede. O estudo, portanto, fornece subsídios, baseados na acurácia, na estabilidade temporal e no custo computacional, para a seleção de métodos de previsão e para o planejamento operacional das subestações, contribuindo para o uso eficiente dos ativos da rede e para o desenvolvimento de sistemas de distribuição mais inteligentes, resilientes e sustentáveis.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

1. REFERENCIAL TEÓRICO

1.1. Previsão de carga elétrica de curto prazo

O horizonte de previsão determina o tipo de decisão apoiada pelos modelos de previsão de carga. Enquanto horizontes de médio e longo prazo atendem ao planejamento energético, a previsão de curto prazo abrange, em geral, algumas horas a poucos dias e subsidia atividades como programação operacional, gerenciamento da demanda, planejamento da manutenção e avaliação das condições da rede, incluindo a previsão para o dia seguinte (Nti et al., 2020; Pinheiro; Madeira; Francisco, 2023).

O desempenho da previsão de curto prazo depende dos padrões temporais da carga, relacionados ao horário do dia, aos dias da semana, ao calendário e às características dos consumidores. Em níveis menos agregados da rede, a variabilidade tende a aumentar, tornando a previsão particularmente relevante para os sistemas de distribuição (Haben; Voss; Holderbaum, 2023; Pinheiro; Madeira; Francisco, 2023). Em uma aplicação de larga escala, Pinheiro, Madeira e Francisco (2023) empregaram modelos desde o nível sistêmico até aproximadamente 100 mil subestações secundárias, demonstrando seu uso na antecipação de picos e restrições da rede.

A resolução temporal também condiciona a formulação do problema. Estudos recentes utilizaram dados em intervalos de 15 minutos tanto em avaliações por janelas móveis quanto em previsões para sistemas de distribuição, evidenciando a relevância da modelagem em resolução sub-horária para aplicações operacionais (Austnes et al., 2025; Misiurek; Olkuski; Zyśk, 2026).

1.2. Modelos estatísticos aplicados à previsão de carga

Entre os métodos estatísticos empregados na previsão de séries temporais estão os modelos de suavização exponencial e os modelos autorregressivos da família ARIMA (Hyndman; Athanasopoulos, 2021; Haben; Voss; Holderbaum, 2023).

O método de Holt-Winters é uma extensão da suavização exponencial que representa os componentes de nível, tendência e sazonalidade. Esses componentes são atualizados recursivamente a partir das observações da série.

A sazonalidade pode ser formulada de maneira aditiva, quando sua amplitude permanece aproximadamente constante, ou multiplicativa, quando varia proporcionalmente ao nível da série (Al-Hafid; Al-Maamary, 2012; Hyndman; Athanasopoulos, 2021). Estudos comparativos também apontam custo computacional inferior ao de modelos sazonais da família ARIMA em determinadas aplicações de previsão de carga (BaniMustafa et al., 2026).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

A ocorrência simultânea de padrões diários e semanais, além de efeitos associados ao calendário, pode representar uma limitação para formulações com uma única sazonalidade. Trull, García-Díaz e Troncoso (2021), por exemplo, empregaram uma extensão de Holt-Winters com múltiplas sazonalidades e componentes específicas para eventos especiais, obtendo redução do erro em períodos de feriados.

Já os modelos ARIMA representam a dependência temporal por meio de componentes autorregressivas, diferenciação e médias móveis. A extensão sazonal SARIMA acrescenta termos associados a um período sazonal específico, enquanto o SARIMAX permite ainda incorporar variáveis exógenas potencialmente relacionadas à variável prevista (Box et al., 2015; Hyndman; Athanasopoulos, 2021). Elamin e Fukushige (2018), ao empregarem SARIMAX na previsão de demanda elétrica horária, incorporaram temperatura, umidade, calendário e interações entre variáveis e verificaram redução dos erros com a inclusão desses efeitos.

Holt-Winters e SARIMAX representam, portanto, estratégias distintas para a previsão de carga. Enquanto o primeiro atualiza diretamente os componentes estruturais da série por suavização exponencial, o segundo representa sua dependência temporal por uma estrutura autorregressiva e pode incorporar informações externas. Essas diferenças justificam a comparação empírica dos dois métodos, pois o desempenho de cada abordagem depende das características da série e das condições de previsão.

2. METODOLOGIA

A pesquisa caracteriza-se como quantitativa e aplicada, desenvolvida a partir de dados históricos reais de uma empresa de distribuição de energia elétrica localizada em Minas Gerais. Foram analisadas quatro séries de carregamento aparente agregado de subestações de distribuição, com registros em intervalos de 15 minutos entre 1º de junho de 2023 e 31 de maio de 2025.

O processamento e a modelagem foram realizados em *Python*, abrangendo o tratamento dos dados, a modelagem preditiva e a avaliação de desempenho. Compararam-se Holt-Winters e SARIMAX às persistências sazonais diária e semanal, utilizando-se o WAPE como métrica principal e MAE e RMSE como métricas complementares.

O tratamento dos dados, o cálculo das métricas e a consolidação dos resultados utilizaram *NumPy* e *pandas*. WAPE, MAE e RMSE foram calculados diretamente com *NumPy*, enquanto os agrupamentos foram realizados com *pandas*. O modelo Holt-Winters foi ajustado com a classe *ExponentialSmoothing*, e o SARIMAX, com a classe *SARIMAX*, ambas do pacote

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

statsmodels. As ordens do SARIMAX foram selecionadas pela função *auto_arima*, do pacote *pmdarima*. As figuras foram produzidas com *Matplotlib*.

Os experimentos foram executados localmente em um computador Dell Inspiron 15 3530, equipado com processador Intel Core i7-1355U de 13ª geração, com 10 núcleos físicos e 12 processadores lógicos, 15,69 GB de memória RAM e sistema operacional Windows 11, versão 25H2, compilação 26200.9445, de 64 bits. O ambiente de software foi composto por *Python* 3.14.3, *NumPy* 2.4.4, *pandas* 3.0.2, *statsmodels* 0.14.6, *pmdarima* 2.1.1 e *Matplotlib* 3.10.8. As execuções foram realizadas exclusivamente em CPU, sem aceleração por GPU. O mesmo ambiente computacional foi utilizado nos 28 ajustes de cada modelo, permitindo comparar seus tempos de processamento sob condições equivalentes.

2.1. Tratamento e estruturação dos dados

As quatro séries analisadas correspondem ao carregamento aparente agregado de subestações pertencentes a uma concessionária de distribuição de energia elétrica de Minas Gerais. Para preservar a confidencialidade da fonte e das informações operacionais, a concessionária não é identificada e as subestações são denominadas SE01, SE02, SE03 e SE04.

Cada série contém 70.176 posições esperadas na grade temporal regular de 15 minutos. A Tabela 1 apresenta a caracterização descritiva das observações classificadas como válidas, isto é, valores finitos, positivos, alinhados à grade temporal e associados à topologia normal de operação. As estatísticas foram calculadas sem imputação de valores ausentes e sem remoção de valores extremos.

Tabela 1. Caracterização descritiva das quatro séries de carregamento aparente agregado

Série	Observações válidas, n (%)	Média (MVA)	Desvio-padrão (MVA)	CV (%)	Mediana (MVA)	Mín.–máx. (MVA)
SE01	67.334 (95,95%)	9,45	2,13	22,51	9,41	2,69 – 16,05
SE02	64.441 (91,83%)	12,50	2,18	17,46	12,52	3,34 – 19,50
SE03	68.129 (97,08%)	23,00	4,00	17,40	22,44	10,31 – 36,30
SE04	67.075 (95,58%)	15,69	3,15	20,09	15,58	6,98 – 26,46

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

O coeficiente de variação (CV) foi calculado somente com as observações classificadas como válidas e o desvio-padrão apresentado é amostral.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

As séries apresentam escalas e níveis de variabilidade distintos. A SE03 possui o maior carregamento médio (23,00 MVA) e o maior desvio-padrão absoluto (4,00 MVA), enquanto a SE01 apresenta o menor carregamento médio (9,45 MVA) e a maior variabilidade relativa, expressa pelo coeficiente de variação de 22,51%. As médias e medianas são próximas nas quatro séries. Quanto à disponibilidade de dados válidos, a cobertura variou entre 91,83% na SE02 e 97,08% na SE03. Essas diferenças de escala e variabilidade reforçam a utilização de uma métrica relativa, o WAPE, para comparar o desempenho preditivo entre as subestações.

Para cada circuito associado às subestações, o carregamento aparente é calculado pela magnitude apresentada na Equação (1).

$$|S_i| = \sqrt{P_i^2 + Q_i^2} \quad (1)$$

onde P_i e Q_i representam, respectivamente, as potências ativa e reativa. O carregamento utilizado neste estudo corresponde à soma das magnitudes dos circuitos associados a cada subestação, conforme a Equação (2), e é expresso em MVA.

$$S_{agg} = \sum_i |S_i| \quad (2)$$

Inicialmente, as séries foram regularizadas em uma grade temporal de 15 minutos. Os registros originalmente não alinhados à grade foram associados à posição temporal disponível que minimizava o deslocamento absoluto, com tolerância máxima de 10 minutos e sem permitir mais de uma medição na mesma posição. Os instantes original e ajustado foram preservados para fins de rastreabilidade.

Em seguida, as observações foram classificadas segundo critérios de qualidade. Valores finitos e positivos foram considerados válidos, enquanto valores ausentes, negativos, iguais a zero ou associados a condições classificadas como inadequadas foram considerados inelegíveis para os experimentos.

Optou-se por não realizar o preenchimento prévio de toda a série temporal nem a remoção de valores extremos por interpolação global. Essa estratégia evita que longos períodos sem observações reais sejam artificialmente reconstruídos e incorporados ao treinamento ou à avaliação dos modelos. Consequentemente, o arquivo processado preserva as medições originais, incorporando apenas os indicadores de qualidade que determinam a elegibilidade de cada registro para os experimentos.

2.2. Protocolo experimental

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Após o tratamento e a classificação dos dados, foram considerados, para cada origem de previsão, os 15 dias anteriores como janela de treinamento, correspondentes a 1.440 observações, e um horizonte de 24 horas, equivalente a 96 observações. Todas as origens foram definidas para as 00:00, de modo que somente informações anteriores ao início do dia previsto estivessem disponíveis para os modelos.

Uma janela de treinamento foi considerada elegível quando apresentava pelo menos 95% de observações válidas e não continha mais de oito pontos inválidos consecutivos, equivalentes a duas horas. Os valores inválidos foram tratados somente após a seleção da janela, utilizando-se exclusivamente informações do período de treinamento. Essa condição evita que períodos extensos sem medições reais sejam artificialmente reconstruídos e utilizados no ajuste dos modelos.

As lacunas internas foram preenchidas por interpolação linear temporal. Nas extremidades, utilizou-se a mediana dos valores válidos correspondentes ao mesmo quarto de hora e, quando esse valor não estava disponível, a mediana global da janela. Nenhuma informação posterior à origem foi empregada, evitando o uso de dados futuros no ajuste dos modelos.

Para o horizonte de previsão, adotou-se um critério mais restritivo: somente dias com as 96 observações classificadas como válidas foram utilizados na avaliação. Dessa forma, nenhum valor do período de teste foi interpolado ou imputado. Os dados foram divididos cronologicamente em três períodos: desenvolvimento, de 01/06/2023 a 31/08/2024; avaliação, de 01/09/2024 a 21/03/2025; e confirmação, de 22/03/2025 a 31/05/2025. As configurações dos modelos foram definidas exclusivamente no período de desenvolvimento e mantidas durante as etapas posteriores.

Após a aplicação dos critérios de elegibilidade, foram identificadas 39 origens comuns às quatro séries no período de avaliação e oito no período de confirmação. Para evitar a reutilização das mesmas observações em janelas temporalmente próximas, aplicou-se, separadamente em cada período, um procedimento sequencial cronológico. Selecionou-se a primeira origem comum elegível e, em seguida, a próxima situada pelo menos 16 dias depois. Esse intervalo corresponde aos 15 dias da janela de treinamento acrescidos do horizonte de previsão de 24 horas, assegurando que os blocos completos de treinamento e previsão não se sobrepusessem. A aplicação automática desse critério resultou em cinco origens no período de avaliação e duas no período de confirmação.

As cinco origens selecionadas no período de avaliação foram 14/09/2024, 30/09/2024, 20/10/2024, 05/11/2024 e 01/01/2025, enquanto as duas origens do período de confirmação

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

foram 22/03/2025 e 23/05/2025. As mesmas sete origens foram utilizadas para todas as subestações e todos os métodos, garantindo comparações pareadas sob condições temporais equivalentes e totalizando 28 combinações subestação–origem.

Como referências de desempenho, foram utilizadas persistências sazonais diária e semanal, descritas na Seção 2.4.4.

2.3. Modelagem preditiva

2.3.1. Holt-Winters

A suavização exponencial sazonal de Holt-Winters (HW) é uma extensão dos métodos de suavização exponencial destinada à modelagem de séries temporais com componentes de nível, tendência e sazonalidade. Na formulação completa, o método utiliza equações recursivas para atualizar essas componentes e uma equação para obter as previsões. A sazonalidade pode ser modelada de forma aditiva ou multiplicativa (Barros; Mattos; Oliveira, 2017; Hyndman; Athanasopoulos, 2021; Tayebi; Lahaghi; Zaker, 2025).

O modelo com sazonalidade aditiva é descrito pelas Equações (3) a (6):

$$l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1}) \quad (3)$$

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1} \quad (4)$$

$$s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-m} \quad (5)$$

$$\hat{y}_{t+h|t} = l_t + hb_t + s_{t+h-m(k+1)} \quad (6)$$

em que α, β e γ são as constantes de suavização; t representa o instante de tempo; y_t é o valor observado; m é o comprimento do ciclo sazonal; l_t, b_t e s_t representam, respectivamente, as componentes de nível, tendência e sazonalidade; e $\hat{y}_{t+h|t}$ é a previsão para h períodos à frente. Na Equação (3), o nível combina a observação ajustada sazonalmente e a previsão não sazonal para o instante t. Na Equação (6), k é um índice inteiro utilizado para localizar, dentro do ciclo sazonal de comprimento m, o fator correspondente ao horizonte h. A Equação (5) atualiza a componente sazonal pela combinação do índice atual com o índice da mesma estação m períodos atrás (Hyndman; Athanasopoulos, 2021).

Na formulação aditiva, a componente sazonal é incorporada como uma variação absoluta em torno do nível da série, sendo mais adequada quando a amplitude sazonal permanece aproximadamente constante ao longo do tempo (Hyndman; Athanasopoulos, 2021).

O modelo com sazonalidade multiplicativa é descrito pelas Equações (7) a (10):

$$l_t = \alpha\frac{y_t}{s_{t-m}} + (1-\alpha)(l_{t-1} + b_{t-1}) \quad (7)$$

$$b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1} \quad (8)$$

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

$$s_t = \gamma \frac{y_t}{l_{t-1} + b_{t-1}} + (1-\gamma) s_{t-m} \quad (9)$$

$$\hat{y}_{t+h|t} = (l_t + hb_t) s_{t+h-m(k+1)} \quad (10)$$

Na formulação multiplicativa, as variáveis e os parâmetros mantêm os significados definidos anteriormente, mas a componente sazonal passa a atuar proporcionalmente ao nível da série. Assim, a amplitude das variações sazonais aumenta ou diminui conforme o carregamento observado (Al-Hafid; Al-Maamary, 2012).

As Equações (3) a (10) apresentam as formulações clássicas com tendência. Durante o desenvolvimento, também foram avaliadas variantes sem tendência e com tendência aditiva amortecida (Hyndman; Athanasopoulos, 2021).

Durante o período de desenvolvimento, foram avaliadas 12 configurações de Holt-Winters, obtidas pela combinação das periodicidades sazonais diária para $m = 96$ e semanal para $m = 672$, das sazonalidades aditiva e multiplicativa e de três estruturas de tendência: ausente, aditiva e aditiva amortecida. Utilizaram-se inicialização heurística, estimação otimizada dos parâmetros de suavização e correção de viés.

A configuração de cada série foi selecionada exclusivamente no período de desenvolvimento, com o WAPE como critério principal e o MAE como critério secundário. As configurações escolhidas e mantidas nas etapas de avaliação e confirmação são apresentadas na Tabela 2.

Tabela 2. Configurações de Holt-Winters selecionadas para cada subestação.

Subestação	Tendência	Sazonalidade	Período sazonal	Correção de viés
SE01	Ausente	Multiplicativa	672 (semanal)	Sim
SE02	Aditiva	Multiplicativa	96 (diária)	Sim
SE03	Aditiva amortecida	Aditiva	672 (semanal)	Sim
SE04	Aditiva amortecida	Aditiva	672 (semanal)	Sim

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

2.3.2. SARIMAX

Os modelos ARIMA (*Autoregressive Integrated Moving Average*) representam a dependência temporal de uma série por meio de componentes autorregressivos, de médias móveis e de diferenciação. A componente autorregressiva relaciona o valor atual aos valores passados, enquanto a componente de médias móveis incorpora os efeitos de choques aleatórios, ou inovações, atuais e passados. A diferenciação transforma séries não estacionárias para obter processos aproximadamente estacionários (Box et al., 2015).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Para séries com comportamento sazonal, o ARIMA pode ser estendido ao modelo SARIMA, representado por $(p,d,q)(P,D,Q)_m$, em que p, d e q são as ordens não sazonais, P, D e Q são as ordens sazonais e m corresponde ao período sazonal. A inclusão de regressoras externas origina o SARIMAX, que combina a dinâmica temporal e sazonal da série com os efeitos de variáveis exógenas (Hyndman; Athanasopoulos, 2021).

O modelo SARIMAX é descrito pelas Equações (11) e (12). A Equação (11) representa a regressão dinâmica com erros ARIMA, conforme Hyndman e Athanasopoulos (2021), enquanto a Equação (12) apresenta a estrutura ARIMA sazonal multiplicativa, conforme Box et al. (2015), na notação $(p,d,q)(P,D,Q)_{\mathrm{m}}$.

$$Y_t = \sum_{i=1}^{k} \beta_i X_{i,t} + \eta_t \tag{11}$$

$$\phi_p(B)\Phi_P(B^m)(1-B)^d(1-B^m)^D\eta_t = \theta_q(B)\Theta_Q(B^m)\varepsilon_t \tag{12}$$

em que Y_t é o valor observado no instante t; $X_{i,t}$ representa a i-ésima variável exógena, com coeficiente β_i; η_t é o erro de regressão, modelado por um processo SARIMA; B é o operador de defasagem; m é o período sazonal; $\phi_p(B)$ e $\Phi_P(B^m)$ são os polinômios autorregressivos não sazonal e sazonal; $\theta_q(B)$ e $\Theta_Q(B^m)$ são os polinômios de médias móveis não sazonal e sazonal; e ε_t é o ruído branco. As ordens não sazonais são representadas por p, d e q, e as sazonais, por P, D e Q.

Neste estudo, o SARIMAX foi especificado como $\mathrm{SARIMAX}(p,d,q)(P,D,Q)_m$, com periodicidade sazonal $m = 96$, correspondente ao ciclo diário das séries amostradas em intervalos de 15 minutos. Adotaram-se diferenciação não sazonal $d = 0$, diferenciação sazonal $D = 1$ e ausência de tendência determinística. Como variável exógena, utilizou-se um indicador binário de fim de semana, conhecido antecipadamente no instante da previsão.

A seleção das ordens foi realizada separadamente para cada série e exclusivamente no período de desenvolvimento, por meio da função *auto_arima*, do pacote *pmdarima*. Empregou-se busca sequencial com minimização do Critério de Informação de Akaike (AIC), considerando $p, q \; e \; P \in \{0,1,2\}$, $Q \in \{0,1\}$, $d = 0$, $D = 1$ e $m = 96$.

Para reduzir o custo computacional da seleção, foram utilizadas as 672 observações mais recentes da janela de desenvolvimento de cada série. As configurações selecionadas foram: SE01, $SARIMAX(0,0,1)(0,1,1)_{96}$; SE02, $SARIMAX(0,0,0)(2,1,0)_{96}$; SE03, $SARIMAX(0,0,1)(1,1,0)_{96}$; e SE04, $SARIMAX(0,0,0)(0,1,1)_{96}$.

As ordens selecionadas foram mantidas fixas durante as etapas de avaliação e confirmação. Os ajustes finais foram realizados com a classe SARIMAX, do módulo

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

statsmodels.tsa.statespace.sarimax, com *enforce_stationarity* = *False* e *enforce_invertibility* = *False*. Os parâmetros foram estimados por máxima verossimilhança, utilizando o otimizador L-BFGS limitado a 200 iterações. Em cada origem temporal, o modelo foi reestimado com as 1.440 observações dos 15 dias anteriores e produziu diretamente as 96 previsões correspondentes às 24 horas seguintes.

A representação sazonal não foi imposta de forma idêntica aos dois modelos, pois suas estruturas e seus custos de estimação são distintos. No Holt-Winters, as periodicidades diária com $m = 96$ e semanal com $m = 672$ foram avaliadas no período de desenvolvimento, e a configuração foi selecionada conforme o desempenho preditivo fora da amostra. Por sua formulação recursiva e parcimoniosa, o método permitiu representar diretamente o ciclo semanal com baixo custo computacional.

No SARIMAX, a avaliação direta de modelos sazonais com $m = 672$ implicaria componentes autorregressivos ou de médias móveis com elevada defasagem, aumentando substancialmente a dimensão da representação em espaço de estados e o custo de otimização. Além disso, a janela de treinamento de 1.440 observações conteria pouco mais de dois ciclos semanais completos, quantidade limitada para estimar essa estrutura. Por essa razão, adotou-se $m = 96$, correspondente a 15 ciclos diários completos na mesma janela, associado ao indicador de fim de semana. Essa variável permite distinguir dias úteis de fins de semana sem aumentar excessivamente a complexidade do modelo.

O indicador de fim de semana, entretanto, não reproduz integralmente um perfil sazonal semanal. Assim, a comparação realizada não pressupõe equivalência entre as representações sazonais, mas avalia configurações práticas e parcimoniosas de cada método sob o mesmo protocolo experimental: mesmas séries, janelas de treinamento, origens temporais, horizonte de previsão e métricas. Essa diferença estrutural foi considerada na interpretação dos resultados.

2.4. Métricas de desempenho e métodos de referência

2.4.1. WAPE

O erro percentual absoluto ponderado (WAPE - *Weighted Absolute Percentage Error*) expressa a soma dos erros absolutos em relação à magnitude total dos valores observados. Empregado em aplicações de previsão de demanda de energia, fornece uma medida relativa de interpretação direta, na qual menores valores indicam maior acurácia preditiva (Lara-Benítez et al., 2020).

O WAPE é definido pela Equação (13):

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

$$WAPE = \frac{\sum_{i=1}^{N}|y_i - \hat{y}_i|}{\sum_{i=1}^{N}|y_i|} x100 \quad (13)$$

em que N representa o número de observações consideradas na avaliação, y_i corresponde ao valor observado e $\hat{y}_i$ ao valor previsto para a i-ésima observação.

Neste estudo, o WAPE foi adotado como métrica principal para comparar os métodos, pois expressa o erro absoluto agregado como porcentagem do carregamento observado.

2.4.2. MAE

O erro absoluto médio (MAE - *Mean Absolute Error*) corresponde à média dos módulos dos erros de previsão e quantifica a diferença média entre os valores observados e previstos, independentemente do sinal. Menores valores indicam previsões mais próximas das observações (Hyndman; Athanasopoulos, 2021).

O MAE é definido pela Equação (14):

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|y_i - \hat{y}_i| \quad (14)$$

em que N representa o número de observações avaliadas, y_i representa o carregamento observado e $\hat{y}_i$ o carregamento previsto.

Como as séries são expressas em MVA, o MAE também é apresentado nessa unidade, permitindo interpretar diretamente a magnitude média dos erros de cada método.

2.4.3. RMSE

O RMSE (*Root Mean Square Error*), ou raiz do erro quadrático médio, atribui maior peso aos erros de maior magnitude e é expresso na mesma unidade da série prevista. Menores valores indicam melhor desempenho preditivo (Hyndman; Athanasopoulos, 2021; Hyndman; Koehler, 2006; Haben; Voss; Holderbaum, 2023).

O RMSE é definido pela Equação (15):

$$RMSE = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y_i - \hat{y}_i)^2} \quad (15)$$

em que N, y_i e $\hat{y}_i$ possuem as mesmas definições apresentadas para o MAE.

Na avaliação conjunta, o WAPE representa o erro relativo agregado, o MAE quantifica a magnitude média dos desvios e o RMSE atribui maior peso aos erros mais acentuados.

2.4.4. Métodos de referência por persistência sazonal

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

A avaliação dos modelos foi complementada por dois métodos de referência baseados em persistência sazonal, correspondentes aos padrões diário e semanal recorrentes nas séries de carga (Haben; Voss; Holderbaum, 2023).

Para uma origem de previsão t e horizonte $h = 1,\ldots,96$, as previsões por persistência diária e semanal foram definidas, respectivamente, pelas Equações (16) e (17):

$$\hat{y}_{t+h|t}{}^{(D)} = y_{t+h-96} \quad (16)$$

$$\hat{y}_{t+h|t}{}^{(S)} = y_{t+h-672} \quad (17)$$

em que 96 e 672 correspondem, respectivamente, ao número de observações de 15 minutos em um dia e em uma semana.

Esses métodos não envolvem estimação de parâmetros e foram avaliados nas mesmas origens, horizontes e métricas utilizados para Holt-Winters e SARIMAX. Sua inclusão permite verificar se a maior complexidade dos modelos estatísticos resulta em ganho de desempenho em relação à repetição dos padrões sazonais anteriores.

2.4.5. Estabilidade do desempenho entre origens de previsão

Como o WAPE foi adotado como métrica principal, definiu-se a estabilidade do desempenho como a regularidade dos erros de um modelo ao longo das sete origens de previsão. Para cada modelo e subestação, a mediana representou o desempenho típico, e o intervalo interquartil (IQR), a dispersão dos 50% centrais dos valores de WAPE. O IQR foi calculado pela Equação (18):

$$IQR_{m,s} = Q_3\left(WAPE_{m,s}\right) - Q_1\left(WAPE_{m,s}\right) \quad (18)$$

em que m identifica o modelo, s identifica a subestação e $Q1$ e $Q3$ correspondem, respectivamente, ao primeiro e ao terceiro quartis dos sete valores de WAPE, calculados por interpolação linear. Como o WAPE é expresso em porcentagem, o IQR é apresentado em pontos percentuais. A medida assume valores iguais ou superiores a zero e não possui limite superior fixo. Menores valores indicam menor oscilação do erro entre as origens e, portanto, maior estabilidade relativa. A comparação foi realizada entre os modelos em cada subestação.

O IQR foi preferido ao desvio-padrão por ser menos sensível a valores extremos isolados, que podem ocorrer em origens com perfis de carga atípicos. Todos os valores de WAPE foram mantidos. Como foram utilizadas apenas sete origens por subestação, a análise possui caráter descritivo e não estabelece um limite absoluto para classificar um modelo como estável ou instável.

3. RESULTADOS E DISCUSSÃO

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Os resultados abrangem sete origens não sobrepostas comuns às quatro subestações: cinco do período de avaliação e duas do período reservado para confirmação, totalizando 28 combinações subestação–origem. Essa estrutura permite analisar tanto a magnitude dos erros quanto a variação do desempenho dos métodos entre as origens.

3.1. Desempenho dos métodos por origem de previsão

A Figura 1 apresenta o WAPE dos modelos Holt-Winters e SARIMAX e das referências de persistência sazonal diária e semanal nas sete origens avaliadas. Os valores correspondentes constam na Tabela 3, na qual o menor erro de cada combinação subestação–origem está destacado em negrito.

Considerando os dois modelos e as duas referências, Holt-Winters e a persistência semanal apresentaram o menor WAPE em 11 das 28 combinações cada; SARIMAX e a persistência diária, em três cada. As ocorrências favoráveis à persistência semanal distribuíram-se em três origens da SE01, quatro da SE02, três da SE03 e uma da SE04, mostrando que sua competitividade variou entre as séries.

A persistência semanal reproduz o carregamento observado no mesmo quarto de hora da semana anterior. Seu desempenho indica a recorrência de padrões semanais, sobretudo nas séries SE01, SE02 e SE03, e estabelece uma referência exigente para os modelos estatísticos: a maior complexidade somente representa ganho efetivo quando reduz o erro em relação à repetição do ciclo semanal.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 1. WAPE dos métodos para as sete origens de previsão nas quatro subestações.

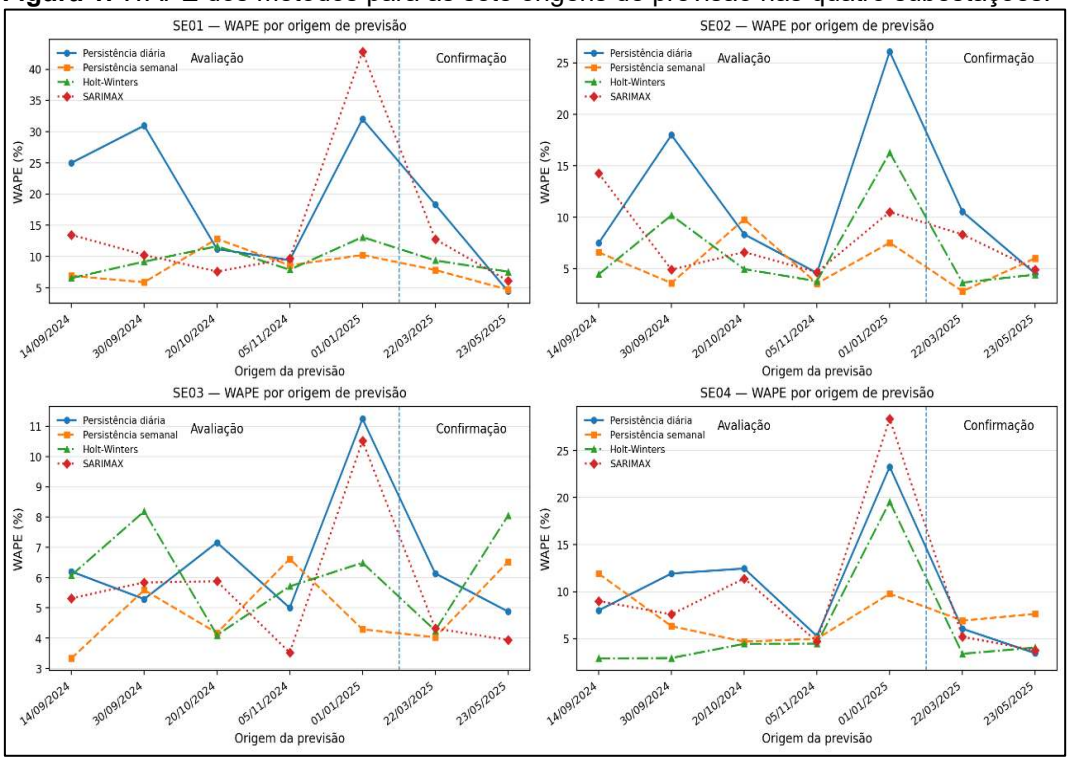

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

A origem de 01/01/2025 concentrou alguns dos maiores erros observados no estudo. Para Holt-Winters, essa data apresentou o maior WAPE entre as sete origens nas séries SE01, SE02 e SE04; para SARIMAX, o maior valor ocorreu nessa origem nas séries SE01, SE03 e SE04. A persistência semanal, entretanto, apresentou o menor WAPE entre as quatro abordagens em todas as subestações: 10,24% na SE01, 7,53% na SE02, 4,29% na SE03 e 9,76% na SE04.

Como a persistência semanal reproduz o perfil de 25/12/2024, também feriado, seu desempenho sugere a existência de semelhanças entre os perfis de carga dos dois dias especiais. SARIMAX utilizou apenas um indicador de fim de semana. Como 01/01/2025 ocorreu em uma quarta-feira, essa variável não diferenciou a data dos demais dias úteis, o que pode ter limitado a representação de seu comportamento específico.

Essa interpretação é compatível com estudos que identificam alterações do perfil de carga em feriados e eventos especiais (Trull; García-Díaz; Troncoso, 2021). Entretanto, a presença de uma única origem correspondente a feriado não permite isolar causalmente esse efeito nem o generalizar para outras datas especiais.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Tabela 3. WAPE (%) dos métodos por subestação e origem de previsão

SE	Origem	Persist. diária	Persist. semanal	Holt-Winters	SARIMAX
SE01	14/09/2024	25,00	6,90	**6,54**	13,46
SE01	30/09/2024	30,96	**5,88**	9,18	10,26
SE01	20/10/2024	11,19	12,83	11,64	**7,59**
SE01	05/11/2024	9,42	8,59	**7,88**	9,71
SE01	01/01/2025	32,01	**10,24**	13,11	42,81
SE01	22/03/2025	18,33	**7,84**	9,37	12,76
SE01	23/05/2025	**4,43**	4,69	7,57	6,11
SE02	14/09/2024	7,50	6,60	**4,46**	14,26
SE02	30/09/2024	17,98	**3,62**	10,19	4,92
SE02	20/10/2024	8,35	9,80	**4,97**	6,62
SE02	05/11/2024	4,60	**3,58**	3,80	4,67
SE02	01/01/2025	26,07	**7,53**	16,28	10,52
SE02	22/03/2025	10,54	**2,82**	3,66	8,33
SE02	23/05/2025	4,54	6,03	**4,44**	4,93
SE03	14/09/2024	6,20	**3,33**	6,08	5,32
SE03	30/09/2024	**5,29**	5,59	8,19	5,84
SE03	20/10/2024	7,16	4,17	**4,10**	5,88
SE03	05/11/2024	5,00	6,62	5,71	**3,52**
SE03	01/01/2025	11,25	**4,29**	6,49	10,52
SE03	22/03/2025	6,14	**4,03**	4,25	4,32
SE03	23/05/2025	4,88	6,52	8,05	**3,94**
SE04	14/09/2024	8,00	11,90	**2,89**	8,99
SE04	30/09/2024	11,92	6,32	**2,93**	7,58
SE04	20/10/2024	12,45	4,67	**4,44**	11,39
SE04	05/11/2024	5,26	4,98	**4,46**	4,68
SE04	01/01/2025	23,27	**9,76**	19,55	28,38
SE04	22/03/2025	6,04	6,90	**3,38**	5,19
SE04	23/05/2025	**3,44**	7,63	4,04	3,74

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

3.2. Comparação entre Holt-Winters e SARIMAX

Na comparação direta, Holt-Winters apresentou menor WAPE que SARIMAX em 19 das 28 combinações subestação–origem, o que representa 67,9%. Isso ocorreu em cinco das sete origens da SE01, cinco da SE02 e seis da SE04. Na SE03, SARIMAX obteve menor WAPE em quatro das sete origens. Assim, embora Holt-Winters tenha predominado globalmente, seu desempenho não foi superior de forma uniforme em todas as séries.

A Figura 2 compara o WAPE agregado de Holt-Winters e SARIMAX nos períodos de avaliação e confirmação. No primeiro período, Holt-Winters apresentou menor WAPE nas séries SE01, SE02 e SE04, enquanto SARIMAX apresentou pequena vantagem na SE03. O mesmo ordenamento relativo foi observado no período de confirmação. Essa concordância nas quatro subestações indica consistência entre os períodos, mas não estabilidade da magnitude dos erros.

Figura 2. Comparação do WAPE agregado de Holt-Winters e SARIMAX nos períodos de avaliação e confirmação

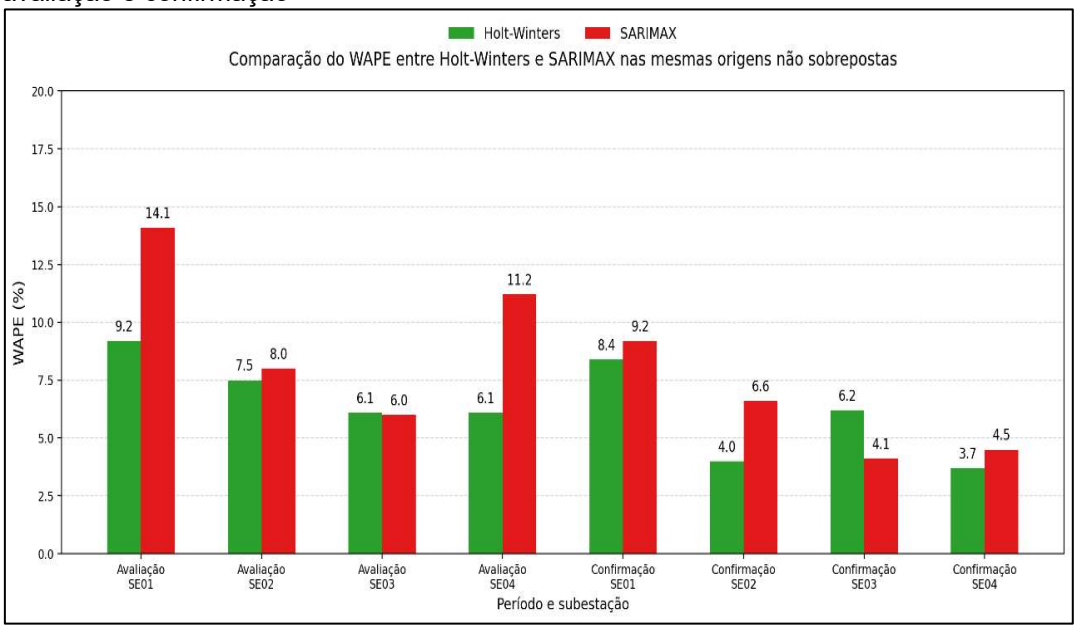

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

Para avaliar a estabilidade do desempenho entre as origens, examinou-se a dispersão dos sete valores de WAPE obtidos por cada modelo em cada subestação. A Figura 3 apresenta os respectivos diagramas de caixa e mantém visíveis os resultados individuais de todas as origens.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Figura 3. Distribuição do WAPE de Holt-Winters e SARIMAX nas sete origens de previsão, por subestação

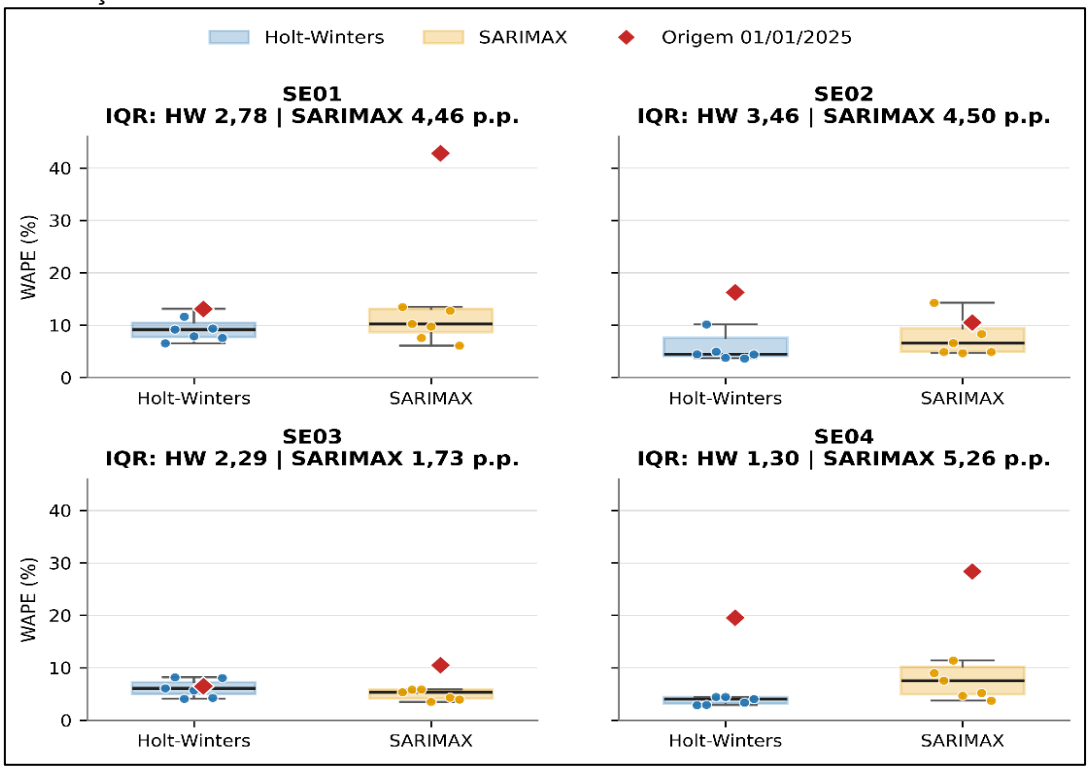

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

As caixas delimitam o primeiro e o terceiro quartis; a linha central representa a mediana; os bigodes alcançam os valores mais extremos situados até 1,5 vez o IQR; e os pontos representam as origens individuais. Os losangos vermelhos identificam a origem de 01/01/2025.

Holt-Winters apresentou menor IQR do WAPE na SE01 (2,78 p.p., ante 4,46 p.p. do SARIMAX), na SE02 (3,46 p.p., ante 4,50 p.p.) e na SE04 (1,30 p.p., ante 5,26 p.p.). Na SE03, SARIMAX apresentou menor IQR (1,73 p.p., ante 2,29 p.p. do Holt-Winters). Portanto, Holt-Winters apresentou maior estabilidade relativa em três das quatro séries, enquanto SARIMAX foi mais estável na SE03.

Esse resultado se refere à dispersão dos erros e não deve ser confundido com acurácia: menor IQR indica maior regularidade entre as origens, enquanto menor WAPE indica maior proximidade entre os valores previstos e observados.

As métricas MAE e RMSE, apresentadas na Tabela 4, complementam a análise de acurácia. No período de avaliação, Holt-Winters apresentou menor MAE em SE01, SE02 e SE04 e menor RMSE nas quatro séries. Na SE03, SARIMAX apresentou menor WAPE e MAE, mas RMSE superior ao do Holt-Winters, indicando maior influência de erros pontuais de magnitude

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

elevada. No período de confirmação, as três métricas favoreceram Holt-Winters em SE01, SE02 e SE04 e SARIMAX em SE03.

Tabela 4. MAE e RMSE agregados dos modelos nos períodos de avaliação e confirmação.

Período	Série	MAE HW (MVA)	MAE SARIMAX (MVA)	RMSE HW (MVA)	RMSE SARIMAX (MVA)
Avaliação	SE01	**0,76**	1,16	**0,99**	1,46
Avaliação	SE02	**0,86**	0,92	**1,13**	1,17
Avaliação	SE03	1,40	**1,37**	**1,66**	1,74
Avaliação	SE04	**0,91**	1,66	**1,30**	2,11
Confirmação	SE01	**0,91**	0,99	**1,18**	1,30
Confirmação	SE02	**0,50**	0,83	**0,66**	1,06
Confirmação	SE03	1,38	**0,92**	1,86	**1,14**
Confirmação	SE04	**0,58**	0,69	**0,82**	0,89

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

Os resultados foram agregados por subestação sobre 480 observações no período de avaliação, correspondentes a cinco origens de 96 observações, e 192 observações no período de confirmação, correspondentes a duas origens de 96 observações. Os menores valores de cada métrica em cada linha estão destacados em negrito.

O comportamento da SE03 difere do padrão observado nas demais subestações. Nessa série, SARIMAX apresentou menor WAPE em quatro das sete origens. No período de avaliação, sua vantagem agregada foi pequena, com WAPE de 5,99% contra 6,11% do Holt-Winters. No período de confirmação, a diferença aumentou para 4,12% contra 6,22%, e, considerando as sete origens, SARIMAX também apresentou menor mediana do WAPE, 5,32% contra 6,08%, e menor IQR, 1,73 p.p. contra 2,29 p.p.

A SE03 possui o maior carregamento médio entre as séries, 23,00 MVA, e a menor variabilidade relativa, com coeficiente de variação de 17,40%. Do ponto de vista operacional, essa subestação atende parcela expressiva da carga do sistema e reúne perfis distintos de consumo, incluindo cargas urbanas e industriais.

Esse maior nível de agregação pode contribuir para a menor variabilidade relativa e para o desempenho do SARIMAX nessa série. Entretanto, como a composição das cargas não foi utilizada como variável explicativa, essa relação deve ser interpretada como hipótese, e não

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

como efeito causal demonstrado. Os resultados reforçam que a seleção do modelo deve considerar o comportamento específico de cada subestação.

A Figura 4 ilustra as previsões obtidas pelos dois modelos para a origem de 23/05/2025. Seu propósito é mostrar o acompanhamento do perfil intradiário, enquanto as conclusões quantitativas se baseiam no conjunto completo das origens.

Figura 4. Valores observados e previsões de Holt-Winters e SARIMAX para a origem de 23/05/2025

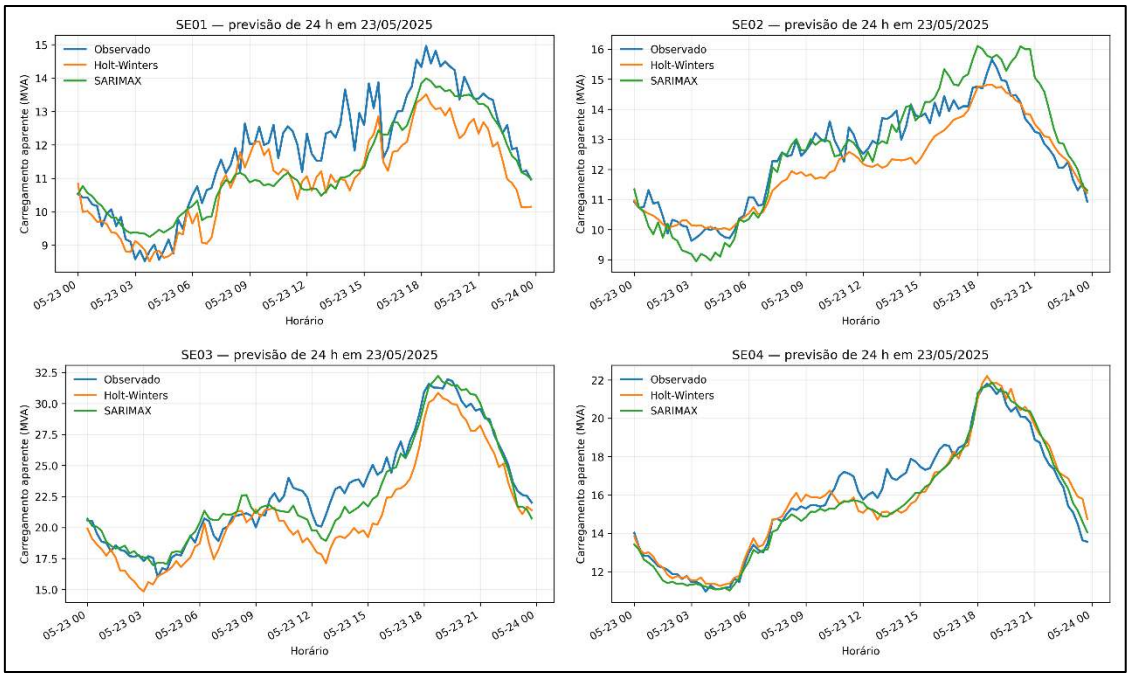

Fonte: elaboração dos autores com base nos dados da pesquisa (2026).

Ambos os modelos reproduzem as principais variações do perfil diário, embora apresentem diferenças nas regiões de maior alteração do carregamento. O padrão visual é compatível com os resultados quantitativos, segundo os quais a maior complexidade estrutural não produziu ganho sistemático de acurácia.

3.3. Custo computacional

Os tempos de ajuste evidenciaram diferença expressiva entre os métodos. Nas mesmas 28 combinações subestação–origem utilizadas na avaliação final, Holt-Winters apresentou tempo mediano de 0,022 s por ajuste, enquanto SARIMAX apresentou 103,62 s. Os tempos totais foram

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

de 0,85 s e 3.558,44 s, respectivamente, sendo este último equivalente a 59,3 minutos, conforme apresentado na Tabela 5.

Embora os valores absolutos dependam do ambiente computacional e das implementações utilizadas, as medições foram realizadas sob o mesmo protocolo e no mesmo ambiente, permitindo comparar o custo relativo dos métodos. Os valores foram extraídos diretamente dos registros de diagnóstico do procedimento experimental.

Tabela 5. Tempo computacional registrado no ajuste dos modelos

Método	Mediana por ajuste (s)	Média por ajuste (s)	Intervalo observado (s)	Tempo total – 28 ajustes (s)
Holt-Winters	0,022	0,03	0,007 – 0,253	0,85
SARIMAX	103,62	127,09	42,97 – 265,91	3.558,44

Fonte: elaboração dos autores com base nos registros dos experimentos (2026).

Esse resultado é compatível com BaniMustafa et al. (2026), que também observaram menor custo computacional para Holt-Winters em comparação com modelos sazonais da família ARIMA na previsão de carga elétrica. Entretanto, valores absolutos obtidos em diferentes estudos não devem ser comparados diretamente, devido às diferenças entre bases de dados, implementações, configurações dos modelos e ambientes computacionais.

A diferença de custo é compatível com as estruturas dos métodos. Holt-Winters realiza atualizações recursivas dos componentes de nível, tendência e sazonalidade. A estimação do SARIMAX, por sua vez, envolve otimização numérica por máxima verossimilhança e representação em espaço de estados, na qual procedimentos de filtragem são empregados na avaliação e na previsão (Durbin; Koopman, 2012).

No conjunto analisado, o maior custo computacional do SARIMAX não foi acompanhado por ganho sistemático de acurácia, pois Holt-Winters apresentou menor WAPE em 19 das 28 comparações diretas. O custo computacional constitui, portanto, um aspecto relevante para a escolha do método, especialmente em aplicações que demandem reestimações frequentes.

4. CONSIDERAÇÕES FINAIS

Este trabalho comparou Holt-Winters e SARIMAX na previsão de curto prazo do carregamento aparente agregado de quatro subestações de distribuição, utilizando séries reais com resolução de 15 minutos e horizonte de 24 horas. A avaliação em múltiplas origens, associada às referências de persistência sazonal diária e semanal, permitiu analisar o

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

desempenho dos modelos em diferentes períodos e verificar se sua maior complexidade produziu ganhos efetivos.

Os resultados mostraram que nenhum método foi superior em todas as condições. Considerando os dois modelos e as duas referências, Holt-Winters e a persistência semanal apresentaram o menor WAPE em 11 das 28 combinações subestação–origem cada, enquanto o SARIMAX e a persistência diária, em três cada. Na comparação direta, Holt-Winters apresentou menor WAPE em 19 das 28 combinações (67,9%), com predominância nas séries SE01, SE02 e SE04. A SE03 apresentou comportamento distinto, com maior frequência de resultados favoráveis ao SARIMAX. A competitividade da persistência semanal indica forte recorrência semanal em parte das séries e mostra que referências simples podem ser difíceis de superar.

Além da acurácia, observou-se diferença expressiva no custo computacional. Holt-Winters apresentou tempo de ajuste substancialmente inferior ao SARIMAX. Quanto à estabilidade do desempenho, Holt-Winters apresentou menor IQR do WAPE nas séries SE01, SE02 e SE04, enquanto SARIMAX apresentou menor IQR na SE03. Nos períodos de avaliação e confirmação, Holt-Winters manteve menor WAPE agregado em SE01, SE02 e SE04, enquanto SARIMAX manteve vantagem na SE03.

No conjunto analisado, Holt-Winters apresentou o melhor equilíbrio entre acurácia, estabilidade do desempenho e custo computacional. Esse resultado não estabelece sua superioridade geral sobre o SARIMAX, pois o desempenho depende das características de cada série e das condições de previsão.

Em termos aplicados, esses achados oferecem suporte à seleção de métodos compatíveis com as características de cada subestação e com as exigências operacionais da rede, favorecendo decisões voltadas ao uso eficiente e resiliente da infraestrutura elétrica.

Embora as quatro séries correspondam à totalidade das subestações do sistema municipal analisado, os resultados permanecem restritos a esse sistema elétrico, ao horizonte de 24 horas e às origens definidas no estudo. A sazonalidade também foi representada de forma distinta: Holt-Winters permitiu a seleção entre periodicidades diária e semanal, enquanto SARIMAX utilizou sazonalidade diária associada a um indicador de fim de semana. Mesmo submetidos ao mesmo protocolo de avaliação, os modelos preservam essa diferença estrutural, que deve ser considerada na interpretação dos resultados.

Estudos futuros poderão ampliar o número de origens à medida que novas observações forem incorporadas às séries. Também poderão incluir variáveis específicas para feriados e outros eventos especiais, investigar diferentes representações da sazonalidade semanal no SARIMAX e avaliar abordagens adicionais sob o mesmo protocolo experimental.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Pontifícia Universidade Católica de Minas Gerais pelo apoio ao desenvolvimento desta pesquisa.

REFERÊNCIAS

AL-HAFID, Majed Saleh; AL-MAAMARY, Ghazi Hussein. Short term electrical load forecasting using Holt-Winters method. *Al-Rafidain Engineering Journal*, v. 20, n. 6, p. 15-22, 2012. DOI: 10.33899/rengj.2012.63377.

AUSTNES, Pål Forr; GARCÍA-PAREJA, Celia; NOBILE, Fabio; PAOLONE, Mario. Probabilistic load forecasting of distribution power systems based on empirical copulas. *Sustainable Energy, Grids and Networks*, v. 42, art. 101708, 2025. DOI: 10.1016/j.segan.2025.101708.

BANIMUSTAFA, Ahmed; AL-OMARI, Zakaria; KHLAIFAT, Nour; HADDAD, Mike. Mode-dependent performance of ARIMA, SARIMA, Holt-Winters, and Prophet in electricity load forecasting: a held-out comparison in Jordan. *Energies*, v. 19, n. 14, art. 3257, 2026. DOI: 10.3390/en19143257.

BARROS, Anna Carolina; MATTOS, Daiane Marcolino de; OLIVEIRA, Ingrid Christyne Luquett de. *Análise de séries temporais em R: curso introdutório*. São Paulo: Atlas, 2017. E-book. Disponível em: https://app.minhabiblioteca.com.br/books/9788595154902. Acesso em: 15 ago. 2026.

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C.; LJUNG, Greta M. *Time series analysis: forecasting and control*. 5. ed. Hoboken: John Wiley & Sons, 2015.

DURBIN, James; KOOPMAN, Siem Jan. *Time series analysis by state space methods*. 2. ed. Oxford: Oxford University Press, 2012. DOI: 10.1093/acprof:oso/9780199641178.001.0001.

ELAMIN, Niematallah; FUKUSHIGE, Mototsugu. Modeling and forecasting hourly electricity demand by SARIMAX with interactions. *Energy*, v. 165, parte B, p. 257-268, 2018. DOI: 10.1016/j.energy.2018.09.157.

HABEN, Stephen; VOSS, Marcus; HOLDERBAUM, William. *Core concepts and methods in load forecasting: with applications in distribution networks*. Cham: Springer, 2023. DOI: 10.1007/978-3-031-27852-5.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. *Forecasting: principles and practice*. 3. ed. Melbourne: OTexts, 2021. Disponível em: https://otexts.com/fpp3/. Acesso em: 28 ago. 2026.

HYNDMAN, Rob J.; KOEHLER, Anne B. Another look at measures of forecast accuracy. *International Journal of Forecasting*, v. 22, n. 4, p. 679-688, 2006. DOI: 10.1016/j.ijforecast.2006.03.001.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

LARA-BENÍTEZ, Pedro; CARRANZA-GARCÍA, Manuel; LUNA-ROMERA, José M.; RIQUELME, José C. Temporal convolutional networks applied to energy-related time series forecasting. *Applied Sciences*, v. 10, n. 7, art. 2322, 2020. DOI: 10.3390/app10072322.

MISIUREK, Kamil; OLKUSKI, Tadeusz; ZYŚK, Janusz. Short-term electrical load forecasting at a 15-minute resolution: a benchmarking study using a rolling-window training approach against official TSO forecasts. *Energies*, v. 19, n. 13, art. 3211, 2026. DOI: 10.3390/en19133211.

NTI, Isaac Kofi; TEIMEH, Moses; NYARKO-BOATENG, Owusu; ADEKOYA, Adebayo Felix. Electricity load forecasting: a systematic review. *Journal of Electrical Systems and Information Technology*, v. 7, n. 1, art. 13, 2020. DOI: 10.1186/s43067-020-00021-8.

PINHEIRO, Marco G.; MADEIRA, Sara C.; FRANCISCO, Alexandre P. Short-term electricity load forecasting—A systematic approach from system level to secondary substations. *Applied Energy*, v. 332, art. 120493, 2023. DOI: 10.1016/j.apenergy.2022.120493.

TAYEBI, Arshya; LAHAGHI, Seyed Amir Mohammad; ZAKER, Behrooz. Frequency prediction of electricity grids using Holt-Winters algorithm. In: SMART GRID CONFERENCE (SGC), 15., 2025, Shiraz. *Proceedings [...]*. [S. l.]: IEEE, 2025. p. 1-5. DOI: 10.1109/SGC69320.2025.11372316.

TRULL, Oscar; GARCÍA-DÍAZ, J. Carlos; TRONCOSO, Alicia. One-day-ahead electricity demand forecasting in holidays using discrete-interval moving seasonalities. *Energy*, v. 231, art. 120966, 2021. DOI: 10.1016/j.energy.2021.120966.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.