

## **PREVISÃO DO PERFIL DE DEMANDA DE ENERGIA ELÉTRICA UTILIZANDO O MODELO SARIMA**

### ***ELECTRIC DEMAND PROFILE FORECASTING USING THE SARIMA MODEL***

Lucas Silva Plachi<sup>1</sup>  
Carlos Eduardo Alves Carvalho<sup>2</sup>  
Aldo Cesar dos Reis<sup>3</sup>  
Flávio Junio Paulino<sup>4</sup>  
Tálisson de Souza Barbosa<sup>5</sup>

**Resumo** – *A previsão de demanda de energia elétrica constitui um desafio recorrente no planejamento energético, tanto para concessionárias quanto para grandes consumidores. A correta estimativa do perfil futuro de consumo permite reduzir custos operacionais, evitar penalidades e promover maior segurança no fornecimento de energia. O presente estudo aplica o modelo estatístico SARIMA sobre dados reais de demanda, faturadas entre janeiro de 2020 e dezembro de 2023, obtendo projeções para os doze meses de 2024. Diferentemente de estudos que utilizam abordagens de aprendizado de máquina, de maior complexidade, no presente trabalho empregou-se o modelo SARIMAX. A modelagem resultou em previsões mensais acompanhadas de intervalos de confiança de 90%, permitindo avaliar não apenas a tendência central, mas também a incerteza associada às estimativas. Os resultados demonstraram que o SARIMA é capaz de capturar o padrão sazonal e a tendência de crescimento observada no histórico, revelando-se uma ferramenta eficaz de apoio à tomada de decisão no planejamento energético.*

**Palavras-chave:** *Previsão de demanda. Séries temporais. SARIMA.*

**Abstract** - *Electricity demand forecasting remains a recurring challenge in energy planning, both for utilities and large consumers. Accurate estimation of future consumption profiles helps reduce operational costs, avoid penalties, and ensure greater reliability in energy supply. This study applies the statistical SARIMA model to real demand data billed between*

<sup>1</sup> Graduando em Engenharia Elétrica (PUC Minas, campus Poços de Caldas-MG). Contato: lucasplachi7@gmail.com.

<sup>2</sup> Graduando em Engenharia Elétrica (PUC Minas, campus Poços de Caldas-MG). Contato: carlos.carvalho.1322193@sga.pucminas.br.

<sup>3</sup> Graduando em Engenharia Elétrica (PUC Minas, campus Poços de Caldas-MG). Contato: aldocesarreis@msn.com.

<sup>4</sup> Graduando em Engenharia Elétrica (PUC Minas, campus Poços de Caldas-MG). Contato: flaviojpaulino@gmail.com.

<sup>5</sup> Professor do curso de Engenharia Elétrica (PUC Minas, campus Poços de Caldas-MG). Contato: talissonbarbosa@pucpcaldas.br.

*January 2020 and December 2023, generating projections for the twelve months of 2024. Unlike studies that rely on more complex machine learning approaches, this work employs the SARIMAX model. The modeling produced monthly forecasts with 90% confidence intervals, allowing the assessment of not only the central trend but also the uncertainty associated with the estimates. The results demonstrate that SARIMA effectively captures both the seasonal pattern and the growth trend observed in the historical data, proving to be a reliable tool to support decision-making in energy planning.*

**Keywords:** demand forecasting. time series. SARIMA.

## I. INTRODUÇÃO

No setor elétrico brasileiro, a demanda é definida como a maior média de potência requisitada em 15 minutos consecutivos, servindo de referência para planejamento e tarifação, conforme estabelecido pela Resolução nº 1000 da ANEEL (2021). A análise e a previsão desse indicador constituem tarefas centrais para o setor elétrico, uma vez que variações inesperadas podem comprometer tanto o equilíbrio econômico-financeiro das distribuidoras quanto a confiabilidade do fornecimento aos usuários finais (Wood; Wollenberg, 2012).

A previsão de demanda permite antecipar comportamentos de consumo, possibilitando a adoção de estratégias preventivas. Entre tais estratégias destacam-se a adequação dos contratos de fornecimento, o dimensionamento da infraestrutura elétrica e a otimização do despacho de geração. Segundo Gellings (1985), iniciativas de gestão pelo lado da demanda (demand-side management) representam ferramentas eficazes para racionalizar o consumo, mas dependem, em grande medida, de projeções confiáveis sobre a evolução do uso de energia.

O presente estudo parte de um problema concreto: como prever a demanda futura de um consumidor de médio porte, de forma a apoiar o planejamento energético do mesmo, utilizando-se os dados de demandas faturadas de quatro anos (2020–2023)? Para responder a essa questão, adota-se o modelo estatístico SARIMA, amplamente discutido na literatura de séries temporais (Box; Jenkins, 1970; Hyndman; Athanasopoulos, 2018). Esse modelo distingue-se por combinar componentes autorregressivos, médias móveis e diferenciações, além de incorporar estruturas sazonais, adequando-se, portanto, a séries que apresentam padrões recorrentes ao longo do tempo.

Assim, este trabalho busca demonstrar a aplicação prática do SARIMA na previsão do perfil de demanda elétrica de um consumidor de médio porte, detalhando desde a fundamentação teórica até a obtenção de resultados gráficos e tabulares. A pesquisa insere-se em um contexto de crescente necessidade de ferramentas quantitativas de apoio ao planejamento energético, reforçando a relevância de métodos estatísticos transparentes, interpretáveis e de fácil implementação computacional.

## II. FUNDAMENTAÇÃO TEÓRICA

A previsão de demanda é um desafio recorrente no setor elétrico, especialmente em ambientes industriais, onde variações no consumo impactam diretamente os custos de energia e a eficiência operacional. Métodos tradicionais de projeção, como médias móveis ou extrapolações lineares, muitas vezes não capturam adequadamente a sazonalidade, as tendências e os fatores externos que influenciam a carga (Silva et al., 2021). Esse problema leva a estimativas menos precisas e decisões de contratação de energia que podem resultar em perdas financeiras ou riscos de sobrecarga.

A presente proposta busca superar essa limitação por meio da aplicação de modelos estatísticos robustos, com ênfase na utilização do método SARIMA, o qual se mostra adequado para capturar padrões de variabilidade e autocorrelação característicos de séries temporais. Um diferencial essencial do estudo é o uso de dados reais provindos de uma empresa de médio porte do setor de iluminação automotiva, localizada no sul de Minas Gerais, o que garante maior aderência do modelo às condições reais de consumo. Essa abordagem não apenas aumenta a precisão das previsões, mas também oferece suporte para um planejamento energético mais confiável e economicamente eficiente (Carvalho & Souza, 2022).

A literatura apresenta diferentes abordagens para estimar o perfil de demanda elétrica, cada uma com vantagens específicas conforme a natureza dos dados e o horizonte de previsão. Entre os métodos mais empregados estão:

### *2.1 – Métodos Clássicos de Previsão de Demanda*

Entre os métodos mais empregados para previsão de demanda destacam-se:

- Modelos de Regressão: buscam relacionar a variável dependente (demanda) a variáveis independentes, como temperatura, atividade econômica ou número de consumidores. Embora úteis em análises de causalidade, apresentam limitações quando a série exibe forte autocorrelação (Gujarati; Porter, 2009);
- Redes Neurais e Aprendizado de Máquina: têm sido aplicadas principalmente em horizontes de curto prazo, sendo capazes de capturar padrões não lineares (Hippert; Pedreira; Souza, 2001). No entanto, tais métodos demandam grande volume de dados e podem apresentar menor transparência interpretativa;
- Método de Monte Carlo: consiste em simulações estocásticas que geram cenários de demanda baseados em distribuições de probabilidade. É útil para avaliação de riscos e incertezas (Metropolis; Ulam, 1949; Kroese et al., 2014), mas não produz previsões pontuais tão precisas quanto modelos estatísticos ajustados à série histórica;
- Modelos de Séries Temporais: exploram diretamente a estrutura dos dados no tempo, considerando tendência, sazonalidade e ruído. Entre eles, destacam-se os modelos ARIMA e suas extensões sazonais, como o SARIMA (Box; Jenkins, 1970; Shumway; Stoffer, 2017).

### *2.2 – Modelos de aprendizado de máquina*

Nas últimas décadas, técnicas de inteligência artificial, como redes neurais artificiais (RNA) e modelos baseados em aprendizado profundo, têm sido aplicadas à previsão de carga. Trabalhos clássicos destacam que redes neurais são capazes de aprender relações complexas entre variáveis explicativas e resposta (Hippert et al., 2001). Mais recentemente, avanços com arquiteturas como LSTM (Long Short-Term Memory) têm ampliado a acurácia em séries de alta frequência, particularmente em mercados de energia (Lago et al., 2018). Apesar disso, esses métodos frequentemente requerem grandes volumes de dados para treinamentos eficazes, além de apresentarem menor interpretabilidade devido à complexidade de sua arquitetura e opacidade no processo decisório (Zhang et al., 2020)

### *2.3 – Modelo ARIMA*

O modelo ARIMA (Autoregressive Integrated Moving Average) é construído a partir de três componentes principais:

Parte Autorregressiva (AR): a demanda em determinado período é explicada por valores passados da própria série conforme a equação (1).

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t \quad (1)$$

onde  $\phi_i$  são parâmetros autorregressivos,  $\varepsilon_t$  é o erro aleatório e  $Y_t$  é o valor da série temporal no instante t.

Parte de Médias Móveis (MA): a demanda atual depende de erros passados.

$$Y_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2)$$

Diferenciação (I): aplicada para tornar a série estacionária, removendo tendência. O operador de diferenciação é representado por  $\nabla^d Y_t$ , onde  $d$  é o número de diferenças aplicadas.

O modelo geral ARIMA(p,d,q) em que:

p: ordem da parte autorregressiva (defasagens de  $Y_t$ );

d: ordem de diferenciação aplicada à série para torná-la estacionária;

q: ordem de médias móveis (defasagens dos erros incluídos);

que pode ser expresso conforme Equação (3):

$$\Phi(B)(1 - B)^d Y_t = \Theta(B)\varepsilon_t \quad (3)$$

Onde B é o operador de defasagem ( $BY_t = Y_{t-1}$ ),  $\Phi(B)$  é o polinômio autorregressivo e  $\Theta(B)$  o polinômio de médias móveis.

#### 2.4 – Modelo SARIMA

O modelo SARIMA (Seasonal ARIMA) estende o ARIMA ao incorporar efeitos sazonais, representados por um conjunto adicional de parâmetros sazonais (P,D,Q,s), em que:

P: ordem autorregressiva sazonal;

D: ordem de diferenciação sazonal;

Q: ordem de médias móveis sazonais;

s: período da sazonalidade (12 para dados mensais).

A formulação geral do SARIMA é:

$$\Phi_p(B)\Phi_P(B^s)(1 - B)^d(1 - B^s)^D Y_t = \Theta_q(B)\Theta_Q(B^s)\varepsilon_t \quad (4)$$

Essa estrutura permite capturar tantas relações de curto prazo (autorregressivas e médias móveis não sazonais) quanto padrões cíclicos de longo prazo (componentes sazonais).

## 2.5 – Relevância do SARIMA na Previsão de Energia

Estudos aplicados demonstram que o SARIMA é capaz de reproduzir o comportamento cíclico do consumo elétrico, especialmente em séries com periodicidade anual ou mensal (Chatfield, 2003; Hyndman; Athanasopoulos, 2018). Além disso, por fornecer intervalos de confiança, o método oferece informações adicionais sobre a incerteza associada às estimativas, aspecto essencial no planejamento energético (Armstrong, 2001).

Assim, o SARIMA consolida-se como ferramenta robusta, transparente e amplamente aceita na literatura para previsão de séries temporais em energia elétrica.

## III. METODOLOGIA

A metodologia adotada neste estudo seguiu a abordagem clássica de análise de séries temporais, proposta por Box e Jenkins (1970), estruturada em três etapas principais: identificação do modelo, estimação dos parâmetros e verificação da adequação. Além disso, a implementação prática foi conduzida em linguagem Python.

### 3.1 – Coleta e organização dos dados

Foram utilizados dados reais de demanda medida durante 5 anos de determinado consumidor do subgrupo A4, do ramo de lanternas automotivas, localizado no Sul de Minas Gerais. Foi utilizada os dados de 2020 a 2023 e organizada em frequência mensal regular resultando em 48 observações.

Figura 1 – Dados obtidos.

Meses	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
<b>2020</b>												
Demanda contratada (kW)	200	200	200	200	200	200	200	200	200	200	200	200
Demanda medida (kW)	159	154	153	160	150	162	150	155	157	159	153	154
<b>2021</b>												
Demanda contratada (kW)	200	200	200	200	200	200	200	200	200	200	200	200
Demanda verificada (kW)	179	172	174	189	170	183	170	169	167	178	177	209
<b>2022</b>												
Demanda contratada (kW)	200	200	200	200	200	200	200	200	200	300	300	300
Demanda verificada (kW)	207	213	224	241	267	274	269	271	281	279	281	276
<b>2023</b>												
Demanda contratada (kW)	300	300	300	300	300	300	300	300	300	300	300	300
Demanda verificada (kW)	273	285	278	268	280	292	292	297	299	290	303	303
<b>2024</b>												
Demanda contratada (kW)	400	400	400	400	400	400	400	400	400	400	400	400
Demanda verificada (kW)	312	326	341	333	338	344	330	345	369	389	396	390

Fonte: Autores, 2025.

### 3.2 – Pré-processamento da Série Temporal

O pré-processamento incluiu a verificação de valores ausentes, padronização da frequência temporal e análise exploratória inicial. Essa etapa permitiu identificar tendências e variações sazonais, que foram posteriormente incorporadas ao modelo SARIMA.

### 3.3 – Ajuste do modelo SARIMA

O ajuste do modelo foi realizado por meio do algoritmo `auto_arima`, que implementa estratégias de busca de parâmetros otimizados de acordo com critérios estatísticos como AIC (Akaike Information Criterion) e BIC (Bayesian Information Criterion). Foram considerados modelos com período de 12 meses, de modo a capturar a variação anual típica de séries de demanda de energia.

$(p,d,q)(P,D,Q)s=(1,1,1)(1,1,1)12$

onde:

$p=1$ :um termo autorregressivo não sazonal;

$d=1$ :primeira diferença não sazonal;

$q=1$ :um termo de média móvel não sazonal;

$P=1$ :um termo autorregressivo sazonal;

$D=1$ :primeira diferença sazonal;

$Q=1$ :um termo de média móvel sazonal;

$s=12$ :periodicidade anual, para dados mensais.

Esse modelo foi escolhido por capturar adequadamente tanto a dependência temporal de curto prazo quanto os padrões sazonais observados.

### 3.4 – Estimação dos Parâmetros

A estimação dos parâmetros do modelo foi realizada via máxima verossimilhança, conforme implementado no `statsmodels`. O ajuste produziu coeficientes estatisticamente significativos para os termos AR e MA, tanto na parte sazonal quanto na não sazonal, corroborando a adequação da especificação escolhida.

### 3.5 – Previsão e Intervalos de Confiança

Após o ajuste, foram realizadas previsões para o horizonte de 12 meses, abrangendo o período de janeiro a dezembro de 2024. Além da estimativa pontual, foram calculados intervalos de confiança de 90% para cada mês. O intervalo de confiança é definido como:

$$IC_{90\%} = \hat{Y}_t \pm z_{\alpha/2} \cdot \hat{\sigma}_t \quad (5)$$

em que  $\hat{Y}_t$  é a previsão pontual para o período  $t$ ,  $\hat{\sigma}_t$  é o erro padrão da previsão e  $z$  é o quantil da distribuição normal correspondente ao nível de confiança (para 90%,  $z \approx 1,64$  ).


A escolha do intervalo de 90% deve-se ao equilíbrio entre precisão e abrangência: um intervalo mais estreito poderia não captar adequadamente a incerteza, enquanto um mais amplo reduziria a utilidade prática da previsão.

## V. RESULTADOS

Seguindo a metodologia apresentada, foi criado um código usando a linguagem de programação Python com o intuito de que esse recurso pudesse automatizar os passos estatísticos do Método SARIMA e assim modelar o respectivo caso de previsão de demanda.

O gráfico que demonstra o levantamento e a tendência da demanda real em kW utilizados de base, demonstrado na Figura 2.


Figura 2 – Levantamento de tendência.



Fonte: Autores, 2025.

Para a obtenção dos parâmetros  $d$  e  $D$  calculou-se a diferenciação entre os meses ( $d=1$ ) para remover a tendência. A figura 3 apresenta o gráfico com os resultados dessa diferenciação:


Figura 3 – Resultados após a primeira diferenciação.



Fonte: Autores, 2025.

Com a primeira diferenciação pronta, aplicou-se a diferenciação com  $\text{lag}12(m=12)$ .  $D=1$  no objetivo de remover a sazonalidade. O gráfico com esse resultado pode ser encontrado na Figura 4:

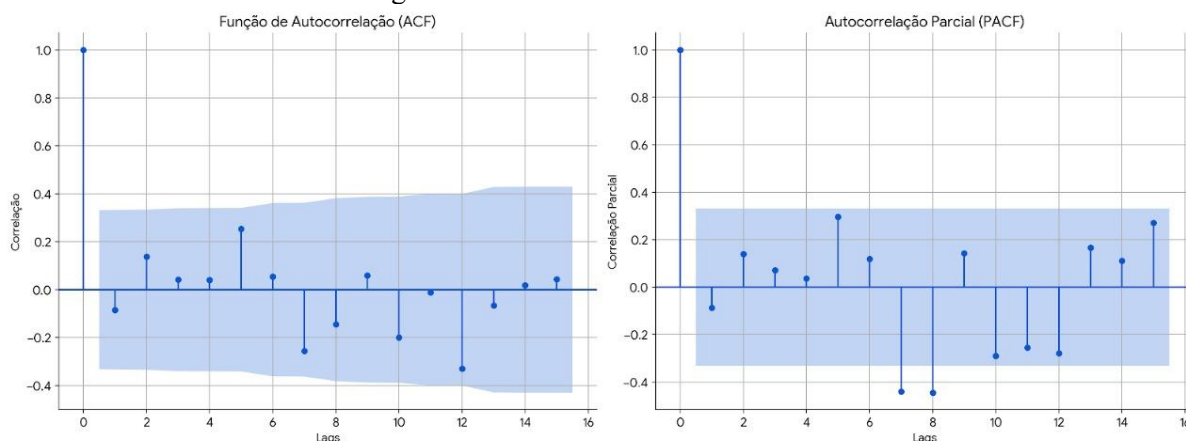
Figura 4 – Resultados após diferenciação completa.



Fonte: Autores, 2025.

Com as diferenciações realizadas foram gerados os gráficos ACF e PACF para a série final estacionária, no objetivo da obtenção dos parâmetros  $p$ ,  $q$ ,  $P$  e  $Q$ . Os dois gráficos estão apresentados na Figura 5 de maneira respectiva:

Figura 5 – Gráficos ACF e PACF.




Fonte: Autores, 2025.

Já com todos esses dados gráficos em mãos, agora é possível fazer a estimação dos parâmetros. Esta etapa é puramente computacional. Uma vez que se fornece as ordens do modelo SARIMA  $(1,1,1)(1,1,1,12)$ , o *software* desenvolvido utiliza algoritmos de otimização, como a Estimação de Máxima Verossimilhança, para encontrar os coeficientes que melhor ajustam o modelo aos dados históricos.

Após essa etapa é necessário fazer o diagnóstico e validação dos dados obtidos para verificar se o modelo ajustado é bom e confiável. O *software* analisa os resíduos do modelo ajustado. O principal teste é olhar o gráfico ACF dos resíduos, no qual pode ser visto abaixo:



Figura 6 – Gráficos ACF dos resíduos do modelo



Fonte: Autores, 2025.

Por fim, já com o modelo validado, é possível realizar a previsão mensal para o ano de 2024 junto com seu intervalo de confiança (IC) que foi utilizado no valor de 90%. Por exemplo, para prever janeiro de 2024, o modelo utiliza os valores observados de dezembro de 2023 (para o componente  $p=1$ ) e de janeiro de 2023 (para o componente  $P=1$ ), os erros de previsão calculados para dezembro de 2023 ( $q=1$ ) e janeiro de 2023 ( $Q=1$ ) e os coeficientes estimados na Etapa 3 e assim repetindo o processo para todos os meses.


Com isso é possível obter os valores da previsão mostrados na Tabela 1.:

Tabela 1 – Previsão da demanda mensal em kW para 2024.					
Mês	Demanda Prevista (kW)	IC90% Inferior	IC90% Superior	Valor Real	JUN
JAN	290,25	270,48	310,02	312	99,37%
FEV	308,63	281,97	335,29	326	97,23%
MAR	303,92	271,98	335,87	341	98,50%
ABR	293,34	257,04	329,64	333	98,99%
MAI	310,98	270,94	351,02	338	96,29%
JUN	324,73	281,40	368,06	344	93,46%
JUL	327,29	281,01	373,57	330	88,34%
AGO	335,06	286,10	384,02	345	89,84%
SET	338,83	287,40	390,27	369	94,55%
OUT	327,50	273,76	381,23	389	98,00%
NOV	341,13	285,24	397,03	396	99,74%
DEZ	331,61	273,66	389,55	390	99,88%

Em que a assertividade é a precisão do valor real registrado em relação com o valor máximo da previsão (IC90% Superior).

O gráfico mostrado na Figura 7, demonstra a relação entre todos esses valores:

Figura 7 – Demanda prevista e valor real



Fonte: Autores, 2025.

## V. ANÁLISE DOS RESULTADOS

O A previsão realizada por meio do modelo SARIMA apresentou resultados consistentes, capazes de capturar tanto a tendência de crescimento quanto os efeitos sazonais da demanda elétrica. Essa capacidade se deve ao fato de que o modelo incorpora explicitamente componentes autorregressivos, de médias móveis e de diferenciação, ajustando-se à estrutura temporal observada nos dados históricos.

A principal vantagem dessa abordagem está na geração de previsões determinísticas acompanhadas de intervalos de confiança. Isso significa que, para cada período futuro, é fornecida uma estimativa central (previsão pontual) e um intervalo de incerteza estatisticamente fundamentado. Essa característica é de grande relevância prática, pois permite ao planejador energético não apenas visualizar a evolução esperada da demanda, mas também avaliar cenários de risco de ultrapassagem de limites contratuais.

Em contraste, métodos probabilísticos, como simulações de Monte Carlo, embora extremamente úteis para explorar incertezas e gerar cenários diversos, não fornecem de forma direta uma previsão estruturada da trajetória futura da série. O Monte Carlo depende da definição de distribuições de probabilidade, a priori, muitas vezes escolhidas com base em hipóteses simplificadas ou em conhecimento externo. O SARIMA, por sua vez, utiliza a própria informação contida nos dados históricos para estimar os parâmetros e projetar a evolução futura, garantindo maior aderência ao comportamento real observado.

Outro ponto a destacar é a interpretação mais transparente do SARIMA. Por meio das funções de autocorrelação e autocorrelação parcial, é possível justificar a escolha do modelo e verificar sua adequação. Isso confere maior rigor estatístico ao processo e facilita a validação do método em contextos acadêmicos e corporativos. Métodos probabilísticos, embora poderosos em termos de simulação, tendem a ser menos interpretáveis e mais dependentes de premissas de modelagem.

Por fim, observa-se que os resultados obtidos alinham-se ao esperado para séries temporais de consumo de energia: tendência de crescimento gradual e manutenção de

sazonalidade anual. A coerência entre histórico e previsão reforça a confiabilidade do modelo, tornando-o uma ferramenta útil para apoio ao planejamento energético, sobretudo em horizontes de curto prazo (até 12 meses), nos quais a acurácia do SARIMA é maximizada.

## V. CONCLUSÃO

O objetivo central do presente trabalho foi aplicar o modelo SARIMA à previsão da demanda mensal de energia elétrica, utilizando dados históricos de 2020 a 2023 e projetando valores para 2024. A metodologia de Box-Jenkins mostrou-se adequada, uma vez que a série analisada apresentou características típicas de séries temporais com tendência e sazonalidade, exigindo diferenciações regular e sazonal.

Os resultados demonstraram que o modelo SARIMA (1,1,1)(1,1,1)<sub>12</sub> conseguiu reproduzir satisfatoriamente o comportamento da série, capturando tanto a tendência de crescimento gradual quanto a sazonalidade anual. A previsão para 2024 apresentou valores crescentes mês a mês, em conformidade com o padrão observado no histórico. Além disso, os intervalos de confiança de 90% forneceram uma visão clara da incerteza associada às projeções, permitindo que o processo de tomada de decisão seja realizado de forma mais segura e fundamentada.

Em comparação a métodos puramente probabilísticos, como as simulações de Monte Carlo, a abordagem SARIMA mostrou vantagens em termos de previsão pontual estruturada, transparência estatística e interpretabilidade. Embora métodos probabilísticos sejam úteis para explorar cenários de risco, a modelagem baseada em séries temporais ajusta-se de maneira mais direta aos dados históricos, oferecendo previsões quantitativas alinhadas com a realidade observada.

Entre as limitações do estudo, destaca-se a extensão relativamente curta da base de dados, composta por apenas quatro anos. Um horizonte temporal maior poderia permitir a detecção de ciclos de mais longo prazo e aprimorar a robustez do modelo. Ademais, fatores externos, como variações econômicas, mudanças climáticas ou políticas energéticas, não foram incorporados à modelagem, mas podem influenciar significativamente a demanda.

Como perspectivas futuras, sugere-se a integração do SARIMA com técnicas híbridas, combinando previsões estatísticas com métodos de simulação probabilística, como Monte Carlo, de modo a enriquecer a análise de risco. Além disso, a inclusão de variáveis explicativas externas em modelos SARIMAX pode ampliar a capacidade de previsão, permitindo avaliar impactos de fatores climáticos e macroeconômicos.

Conclui-se, portanto, que o modelo SARIMA é uma ferramenta robusta e confiável para previsão de curto prazo da demanda de energia elétrica, contribuindo de forma efetiva para o planejamento e a gestão no setor.

## VI. REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA (Brasil). Resolução Normativa nº 1.000, de 7 de dezembro de 2021. Estabelece as regras de prestação do serviço público de distribuição de energia elétrica. Diário Oficial da União: seção 1, Brasília, DF, n. 232, p.150-165, 9 dez. 2021. Disponível em: <https://www2.aneel.gov.br/cedoc/ren20211000.pdf>. Acesso em: 22 ago, 2025.

ARMSTRONG, J. S. (org.). Principles of forecasting: a handbook for researchers and practitioners. Boston: Kluwer Academic Publishers, 2001.

BOX, G. E. P.; JENKINS, G. M. Time series analysis: forecasting and control. San Francisco: Holden-Day, 1970.

CHATFIELD, C. The analysis of time series: an introduction. 6. ed. Boca Raton: Chapman & Hall/CRC, 2004.

GELLINGS, C. W. The concept of demand-side management for electric utilities. Proceedings of the IEEE, v. 73, n. 10, p. 1468-1470, Oct. 1985. DOI:10.1109/PROC.1985.13318.

GUJARATI, D. N.; PORTER, D. C. Econometria básica. 5. ed. Porto Alegre: AMGH, 2009.

HYNDMAN, R. J.; ATHANASOPOULOS, G. Forecasting: principles and practice. 2. ed. Melbourne: OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 22 ago. 2025.

KROESE, D. P.; BRERETON, T.; TAIMRE, T.; BOTEV, Z. I. Why the Monte Carlo method is so important today. Wiley Interdisciplinary Reviews: Computational Statistics, v. 6, n. 6, p. 386-392, 2014. DOI: 10.1002/wics.1314.

METROPOLIS, N.; ULAM, S. The Monte Carlo method. Journal of the American Statistical Association, v.44, n.247, p.335-341, 1949. DOI:10.1080/01621459.1949.10483310.

MORETTIN, P. A.; TOLOI, C. M. C. Análise de séries temporais. 2. ed. São Paulo: Blucher, 2006.

SHUMWAY, R. H.; STOFFER, D. S. Time series analysis and its applications: with R examples. 4. ed. Cham: Springer, 2017.

WOOD, A. J.; WOLLENBERG, B. F. Power generation, operation, and control. 3. ed. Hoboken: John Wiley & Sons, 2012.

ZHANG, Yu; TINO, Peter; LEONARDIS, Aleš; TANG, Ke. A Survey on Neural Network Interpretability. IEEE Transactions on Emerging Topics in Computational Intelligence, v. 5, n. 5, p. 726-742, 2021.

## VII. AGRADECIMENTOS

Os autores agradecem sobretudo o curso de Engenharia Elétrica da PUC Minas – Campus Poços de Caldas-MG pelo apoio e incentivo à produção de conhecimento.

## VIII. COPYRIGHT

Direitos autorais: Os autores são os únicos responsáveis pelo material incluído no artigo