

CONSUMO DE ENERGIA ELÉTRICA NO BRASIL: UMA ABORDAGEM COMBINANDO AS MODELAGENS LOESS E SARIMA

Data de aceite: 02/05/2024

Cleber Bisognin

Departamento de Estatística – UFSM
Santa Maria – RS
<https://orcid.org/0000-0002-0714-3739>

Caroline Lopes Gonçalves

Departamento de Estatística – UFSM
Santa Maria- RS
<https://orcid.org/009-0000-6339-069X>

Luciane Flores Jacobi

Departamento de Estatística – UFSM
Santa Maria – RS
<https://orcid.org/0000-0003-4622-9292>

aplicar o Modelo Loess com um parâmetro de suavização, com o intuito de remover a tendência. Posteriormente, foi realizada a modelagem usando a abordagem de Box e Jenkins. O modelo SARIMA demonstrou ser o mais adequado, resultando na combinação dos dois modelos para produzir as previsões. As previsões geradas pelo modelo escolhido estiveram em grande proximidade com os dados reais, demonstrando a eficácia do modelo.

PALAVRAS-CHAVE: Consumo; Previsão; Loess; Sarima.

ELECTRICITY CONSUMPTION IN BRAZIL: AN APPROACH COMBINING LOESS AND SARIMA MODELLING

ABSTRACT: The purpose of this study is to apply a combined approach of Loess and SARIMA models to model a time series, aiming to compare the forecasts of electricity consumption in Brazil with the actual values observed during the period. The data used were extracted from the IPEA database and consist of monthly records of electricity consumption in Gigawatt-hours in Brazil, covering the period from January 1976 to April 2023. All analyses and procedures were conducted using the R software. The time series in question is non-stationary and exhibits seasonal patterns. Therefore, the

RESUMO: O propósito deste estudo é aplicar uma abordagem combinada de modelos Loess e SARIMA para modelar uma série temporal, visando comparar as previsões de consumo de energia elétrica no Brasil com os valores reais observados durante o período. Os dados utilizados foram extraídos do banco de dados do IPEA e consistem nos registros mensais de consumo de energia elétrica em Gigawatt-hora no Brasil, abrangendo o período de janeiro de 1976 a abril de 2023. Todas as análises e procedimentos foram conduzidos utilizando o software R. A série temporal em questão é não estacionária e exibe padrões sazonais. Portanto, o primeiro passo foi

first step was to apply the Loess Model with a smoothing parameter , with the aim of removing the trend. Subsequently, modeling was performed using the Box and Jenkins approach. The SARIMA model proved to be the most suitable, resulting in the combination of the two models to produce the forecasts. The forecasts generated by the chosen model were in close proximity to the actual data, demonstrating the effectiveness of the model.

KEYWORDS: Consumption; Forecast; Loess; Sarima.

INTRODUÇÃO

A importância da eletricidade tem sido objeto de estudo no campo da estatística, uma vez que seu uso é crucial na sociedade contemporânea. Com o avanço das tecnologias essenciais para sua operação, a sociedade tem se tornado cada vez mais dependente da eletricidade.

No Brasil, segundo Gomes e Vieira (2009) o uso da energia elétrica iniciou no ano de 1880 com sua utilização limitada a alguns serviços públicos e à atividade fabril. Na atualidade, o seu uso é ilimitado, sendo consumido por toda população.

De acordo com Tavares (2023), a matriz energética do Brasil é responsável por suprir a demanda de energia elétrica no país, sendo, aproximadamente 78% do total, composta por fontes de energia renovável. A energia hidráulica ainda é amplamente utilizada no Brasil, respondendo por aproximadamente 57% do consumo de eletricidade, conforme relatado por Energética (2023). Entretanto essa dependência gera desafios em períodos de pouca chuva e longas secas, o que requer a utilização de outros meios de geração de energia, podendo impactar tanto o meio ambiente quanto o custo repassado ao consumidor.

Para que as empresas do setor e os gestores antecipem as demandas futuras e otimizem o fornecimento de energia de forma eficiente, o ajuste de séries temporais desempenha um papel crucial na previsão do consumo de energia elétrica. Uma metodologia bastante utilizada na análise de séries temporais são os modelos de Box e Jenkins (1976). Tal metodologia consiste em ajustar modelos auto regressivos integrados de médias móveis, ARIMA (p, d, q) a um conjunto de dados, onde p representa a parte autorregressiva, d representa o número de diferenças dados na série para estacionalizá-la e q representa a parte de médias móveis (Pedroso et al., 2007). No caso da série apresentar sazonalidade o modelo é denotado por SARIMA (p,d,q) × (P,D,Q)_s, onde D é o grau de diferenciação sazonal (Bisognin et al., 2023).

Com a finalidade de estimar o consumo de energia elétrica para o Brasil, com a série do IPEA, no período de 1976 a 2015, Amaro et al. (2017) demonstrou que o modelo referente ao processo ARIMA (2,1,1) teve a melhor capacidade preditiva. Além disso, para modelar a série temporal de consumo residencial mensal de energia elétrica de uma concessionária do Rio de Janeiro, Cassiano et al. (2015) utilizou os modelos auto regressivos integrados de médias móveis (ARIMA) combinados com a técnica não-paramétrica *Singular Spectrum Analysis* (SSA).

Diante de cenários de crise torna-se necessário um controle e monitoramento no consumo de energia elétrica, para que sejamos capazes de prever e assim minimizar os impactos gerados durante esses períodos. Para isso, uma das ferramentas que pode ser utilizada é a modelagem de séries temporais. Dessa forma, o objetivo deste estudo é prever o consumo de energia elétrica no Brasil combinando o método de regressão polinomial local (Loess) com os modelos ARIMA com comportamento de sazonalidade (SARIMA).

METODOLOGIA

A modelagem de séries temporais consiste em fazer uma análise e previsão sobre dados temporais verificando padrões ao longo da série temporal. Com esses padrões somos capazes de identificar ciclos, tendências e sazonalidades. Serão combinadas as modelagens Loess, desenvolvido por Cleveland (1979), e SARIMA (BOX e JENKINS, 1976; BOX et al., 2015) para encontrar um modelo capaz de realizar previsões mais precisas sobre a série temporal do consumo de energia elétrica no Brasil.

Os dados, em Gigawatt-hora (GWh), da série analisada foram coletados na base de dados do Instituto de Pesquisa Econômica Aplicada (IPEA), compreendendo o período de janeiro de 1976 a abril de 2023. A série temporal será dividida em dois conjuntos: treino, durante o período de janeiro 1976 a abril 2021, e teste, durante o período de maio 2021 a abril de 2023. Será utilizado o conjunto treino para modelagem.

O Método de Regressão Polinomial Local (*Local Polynomial Regression - Loess*), desenvolvido por Cleveland (1979), é um modelo onde a variável dependente, y , e a independente, x , são relacionadas de acordo com a equação (1):

$$Y_t = f(x_t) + \varepsilon_t \quad (1)$$

onde $f(x_t)$ é não conhecida e $\{\varepsilon_t\}_{t=1}^n$ denota o termo de erro independente e identicamente distribuído com média zero e variância constante.

Para cada valor de x_t , é estimado o valor correspondente de $f(x_t)$ usando os valores amostrados próximos e determinando, dessa forma, a suavidade da estimativa resultante. A função $f(x_t)$ não é globalmente suposta, mas se assume que ela pode ser bem aproximada localmente por uma função constante ou linear. Portanto, a função é estimada localmente pelo algoritmo do Loess. Para cada valor de x_t , o valor de $f(x_t)$ é estimado usando os valores amostrados próximos conhecidos, ajustando a suavidade da estimativa resultante.

Contudo, ao estimar uma função constante localmente, surgem limitações, tais como viés nas regiões de fronteira e no interior, especialmente quando a variável independente não é uniforme ou quando a função de regressão apresenta curvatura. Uma abordagem para lidar com essa questão é empregar a regressão local linear ponderada, uma técnica inicialmente proposta por Cleveland (1979) e Stone (1977).

Ao estimar uma função polinomial localmente em vez de uma constante, conseguimos superar o problema de viés de primeira ordem. Assim, a regressão local linear resolve um problema de mínimos quadrados ponderados para cada ponto de interesse x_0 . Em relação a séries temporais univariadas, x_t representa o instante em que os dados estão discriminados. O tamanho da vizinhança utilizado na regressão pode ser ajustado com o parâmetro α (*espan*), que varia de 0 a 1 e controla o nível de suavização.

Para o modelo SARIMA é fundamental considerar o processo estocástico $\{X_t\}_{t \in \mathbb{Z}}$ satisfazendo a Equação (2):

$$\phi(B^s)\phi(B)(1 - B^s)^D(1 - B)^d(X_t - \mu) = \theta(B)\theta(B^s)\varepsilon_t, \quad (2)$$

em que μ é a média do processo, $\{\varepsilon_t\}_{t \in \mathbb{Z}}$ é o processo ruído branco, $s \in \mathbb{N}$ é a sazonalidade, B é o operador defasagem ou de retardo, isto é, $B^j(X_t) = X_{t-j}$ e $B^{sj}(X_t) = X_{t-sj}$ para $j \in \mathbb{N}$, $\phi(\cdot)$, $\theta(\cdot)$, $\Phi(\cdot)$, e $\Theta(\cdot)$ são os polinômios de ordem p , q , P e Q , respectivamente, definidos pelas Equações (3) e (4).

$$\phi(z) = \sum_{l=1}^p (-\phi_l)z^l, \theta(z) = \sum_{m=1}^q (-\theta_m)z^m, \quad (3)$$

$$\Phi(z) = \sum_{r=1}^P (-\phi_r)z^r, \Theta(z) = \sum_{l=1}^Q (-\theta_l)z^l, \quad (4)$$

com $\phi_l, 1 \leq l \leq p$, $\theta_m, 1 \leq m \leq q$, $\phi_r, 1 \leq r \leq P$ e $\theta_l, 1 \leq l \leq Q$, constantes reais e $\phi_0 = \Phi_0 = -1 = \theta_0 = \Theta_0$. Então $\{X_t\}_{t \in \mathbb{Z}}$ é um processo sazonal autorregressivo integrado de média móvel de ordem $(p, d, q) \times (P, D, Q)_s$ com sazonalidade s , denotado por $\text{SARIMA}(p, d, q) \times (P, D, Q)_s$, onde d e D são, respectivamente, o grau de diferenciação e o grau de diferenciação sazonal.

A equação (5) a seguir apresenta a previsão de um processo $\text{SARIMA}(p, d, q) \times (P, D, Q)_s$ invertível,

$$\hat{X}_t(h) = \sum_{j \geq 1} \pi_j \hat{X}_t(j - h), \quad (5)$$

onde $h \geq 1$ e $\{\pi_j\}_{j \geq 0}$, são os coeficientes da representação auto regressiva infinita do processo. Pode-se perceber que $\hat{X}_t(h)$ pode ser expressa com uma soma ponderada das observações presentes e passadas $\{X_t\}_{t \leq n}$, com n é o tamanho da série temporal.

De acordo com Werner et. al. (2017), para selecionarmos a melhor técnica de previsão para obtermos as melhores medidas (qualidade do ajuste), recorreremos às medidas de acurácia. Uma das medidas de precisão mais comumente utilizadas é a média dos erros percentuais absolutos (MAPE), conforme Kim (2016), essa medida é a mais utilizada devido às vantagens de interpretação e independência na escala. Essa medida é apresentada na equação (6).

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} * 100\% \quad (6)$$

De acordo com Shcherbakov et al. (2013), quando as previsões de séries temporais apresentam a mesma escala, as medidas sugeridas são a raiz quadrada da média dos erros quadráticos (RMSE) e o erro absoluto médio (MAE). Essas medidas são apresentadas nas equações (7) e (8), respectivamente.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (7)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (8)$$

Para verificar a estacionariedade da série temporal, é utilizado o teste de Dickey-Fuller Aumentado (ADF) (Dickey e Fuller, 1981), cuja hipótese nula pressupõe a presença de uma raiz unitária na série temporal. Para examinar a existência de uma tendência determinística na série, recorre-se ao teste de Cox-Stuart (Cox e Stuart, 1955), onde a hipótese nula indica a ausência de tal tendência. Os testes de Kruskal-Wallis e Friedman (Siegel e Castellan, 2006) são aplicados para determinar se a série temporal exibe sazonalidade, com a hipótese nula desses testes sugerindo a falta de sazonalidade. Já para avaliar a autocorrelação dos resíduos de um modelo de séries temporais, emprega-se o teste de Box-Pierce (Box e Pierce, 1970), onde a hipótese nula é a independência dos resíduos.

RESULTADOS E DISCUSSÃO

Para identificação do modelo, inicialmente foi gerado o gráfico da série temporal original estudada. O gráfico da série temporal (Figura 1(a)) e a função de autocorrelação amostral (Figura 1(b)) indicam que se trata de uma série não estacionária.




FIGURA 1: Consumo Mensal de Energia Elétrica do Brasil, de jan/1976 a abr/2023: (a) gráfico da série temporal; (b) função de autocorrelação amostral. Fonte Os Autores (2024).

Para testar a estacionariedade da série, foi aplicado o teste Dickey-Fuller (ADF) [valor- $p=0,2099$], indicando que a série temporal possui raiz unitária, sendo, portanto, não estacionária. Realizou-se a análise de tendência determinística nos dados, por meio do teste de Cox-Stuart [valor- $p<0.001$], indicando haver tendência determinística. Para análise da sazonalidade da série temporal, foram aplicados os testes de Kruskal Wallis e Friedman [valor- $p<0.001$], que indicaram que a série é sazonal.

Esses resultados estão alinhados a outros estudados com séries de energia elétrica. O consumo de energia elétrica (MWh) nas indústrias do Rio Grande do Sul, por mesorregiões e microrregiões, entre 1991 e 2010 foi analisado por Furtado et al. (2018) que verificou tendência crescente significativa do consumo de energia elétrica pelas indústrias na maioria das microrregiões do Rio Grande do Sul.

Avaliando a série do Consumo de Energia Elétrica Mensal no Brasil no período de janeiro de 1976 a abril de 2022, Bisognin et al. (2023) determinou que a série era não estacionária, com tendência determinística e sazonal. Analisando a série geração de eletricidade das fontes biomassa, hidráulica e eólica nos primeiros meses da pandemia da COVID-19 no Brasil, Reichert et al. (2022) constatou que os modelos SARIMA são capazes de identificar os efeitos sazonais causados por instabilidades climáticas, como períodos de estiagem.

Assim, será utilizado a Regressão Polinomial Local - *Loess* para retirada da tendência determinística e após será ajustado um modelo SARIMA $(p,d,q) \times (P,D,Q)_s$. A seguir serão geradas as predições utilizando a combinação de ambos os modelos, e calculadas as medidas de acurácia.

Considerando a tendência determinística, foi ajustado o modelo *Loess* com o parâmetro $\alpha = 0,2$ que controla o grau de suavização, apenas para a retirada da tendência (Figura 2(a)). Na Figura 2(b) e (c) são apresentadas, respectivamente, a série temporal sem tendência, verificada pelos testes anteriormente mencionados, e sua respectiva função de autocorrelação amostral.




FIGURA 2: Consumo Mensal de Energia Elétrica do Brasil, de jan/1976 a abr/2021 após retirada da tendência determinística: (a) ajuste de tendência determinística utilizando o modelo *LOESS* com parâmetro $\alpha = 0,2$; (b) gráfico da série temporal; (c) função de autocorrelação amostral. Fonte Os Autores (2024).

A necessidade de realizar previsões acuradas, tem estimulado a aplicação e comparação de diferentes técnicas de modelagem, assim como de métodos de combinação (Martins e Werner, 2014). Para monitorar o preço das ações do Banco Bradesco Pedroso et al. (2007) combinou os modelos ARIMA com gráficos de controle. Com o intuito de obter previsões mais precisas Rosa et al. (2024), combinaram as previsões obtidas nos métodos SARIMA, de Suavização Exponencial e Holt-Winters. A seguir, foram ajustados modelos SARIMA que se encontram na Tabela 1.

Modelo	RMSE	MAE	MAPE
SARIMA	834,3111	557,575	132,3313
SARIMA	834,7468	558,5429	138,2285
SARIMA	834,6222	558,4318	135,4191

TABELA 1 - Resultado das medidas de acurácia dos modelos da série temporal Consumo Mensal de Energia Elétrica do Brasil, de jan/1976 a abr/2021.

Fonte: Os Autores (2024).

De acordo com os dados da Tabela 1, observa-se que o modelo SARIMA (2,0,3) x (0,0,1)₁₂ exibe as menores medidas de acurácia. Isso sugere que este modelo pode proporcionar um desempenho superior em termos de precisão e uma menor porcentagem de erro em relação aos valores reais. Analisando séries sazonais da matriz energética brasileira, Reichert et al. (2022) identificaram o SARIMA como o melhor modelo, enquanto Bisognin et al. (2023) destacaram o modelo de Holt-Winters com efeitos sazonais multiplicativos com amortecimento (HW-MA) como o mais preciso.

A seguir, é apresentado o modelo SARIMA (2,0,3) x (0,0,1)₁₂, cujos coeficientes encontram-se na Tabela 2. Pelo Teste de Box-Pierce [p-valor=0,3952], os resíduos do modelo são não correlacionados, sendo assim, o modelo proposto é adequado aos dados.

Parâmetros	Estimativa	Erro Padrão	Estat. Z	P(> z)
ϕ_1	-0,2298	0,1367	-1,6800	0,092
ϕ_2	0,4052	0,1277	3,1734	<0,01
θ_1	0,9826	0,1365	7,1979	<0,01
θ_2	0,4018	0,1056	3,8046	<0,01
θ_3	0,2549	0,0590	4,3172	<0,01
θ_1	0,2956	0,0465	6,3499	<0,01

Log Verossimilhança: -4221,42; AIC = 8456,83
 Teste Resíduos (Box-Pierce): df=10 - p-valor= 0,3952

TABELA 2 - Resultado do ajuste do modelo SARIMA (2,0,3) x (0,0,1)₁₂, ao Consumo Mensal de Energia Elétrica do Brasil, de jan/1976 a abr/2021 após retirada da tendência determinística.

Fonte: Os Autores (2024).

Após o ajuste do modelo, estimado os seus parâmetros foram calculadas as previsões e previsões. A Tabela 2 apresenta as previsões para a série temporal do Consumo Mensal de Energia Elétrica do Brasil, de maio de 2021 a abril de 2023, calculada utilizando o modelo com melhor acurácia.

Período	Mai/21	Jun/21	Jul/21	Ago/21	Set/21	Out/21	Nov/21	Dez/21
Previsão	41651,8	41334,3	41359,5	41625,7	41764,7	42318,6	41840,7	42275,2
V.real	40351	40179	39941	40629	41985	42622	41932	42916
Período	Jan/22	Fev/22	Mar/22	Abr/22	Mai/22	Jun/22	Jul/22	Ago/22
Previsão	42508,9	42267,8	42949,0	43045,4	43022,7	43015,9	42929,3	42987,5
V.real	42591	41977	44677	43216	42055	40944	41238	42177
Período	Set/22	Out/22	Nov/22	Dez/22	Jan/23	Fev/23	Mar/23	Abr/23
Previsão	43038,8	43152,0	43249,8	43377,7	43493,9	43626,6	43752,3	43887,9
V.real	42282	42491	42791	43235	42813	42897	45712	44693

TABELA 3 - Previsões do Consumo Médio Mensal de Energia Elétrica (GWh) do Brasil no período de mai/2022 a abr/2023 do modelo com melhor acurácia.

Fonte: Os Autores (2024).

Na Figura 3 é apresentada a predição da série temporal do Consumo Mensal de Energia Elétrica do Brasil, de janeiro de 1976 a abril de 2021 e a previsão da mesma série temporal para o período de maio de 2021 a abril de 2023, utilizando a Regressão *Loess* para retirada da tendência determinística e após foi ajustado um modelo SARIMA $(p,d,q) \times (P,D,Q)_s$.

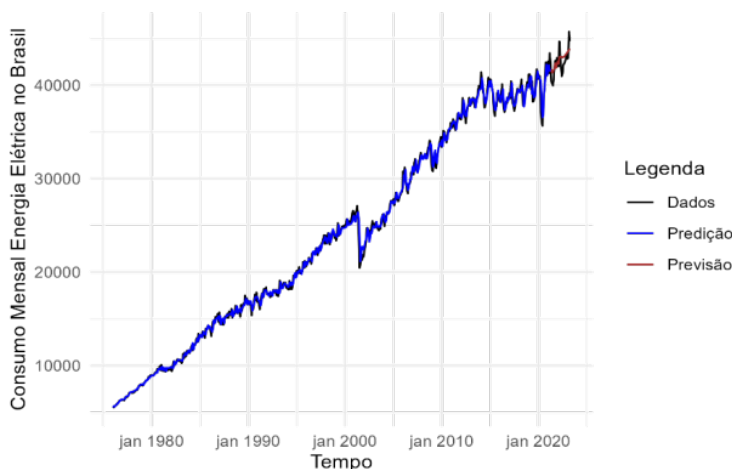


FIGURA 3 – Previsão e Previsão do Consumo Mensal de Energia Elétrica do Brasil, de jan/1976 a abr/2023. Fonte: Os autores (2024).

CONSIDERAÇÕES FINAIS

Verificou-se que a modelagem pelo modelo de Regressão Polinomial Local (**Loess**) com o parâmetro $\alpha=0,2$ foi eficaz para a retirada da tendência determinística. Após foi verificado que o modelo SARIMA (2,0,3) X (0,0,1)₁₂ foi o que melhor se ajustou aos dados. Estes resultados mostram que o modelo Loess foi eficiente para tornar a série estacionária antes de sua modelagem apresentando um ganho significativo nas previsões.

REFERÊNCIAS

AMARO, R. S. et al. *Comparação da capacidade preditiva de modelos ARIMA para o consumo de energia elétrica no Brasil*. **Revista Unemat de Contabilidade**, v. 6, n. 11, 2017. Disponível em: <<https://periodicos.unemat.br/index.php/ruc/article/view/1848>>. Acesso em: 24 set. 2023.

BISOGNIN, C. et al. *Análise e previsão do consumo de energia elétrica mensal do Brasil*. São Paulo: Editora Científica Digital, 2023. E-book. 1941p. DOI10.37885/230111738. Disponível em : <<https://www.editoracientifica.com.br/articles/code/230111738>>

BOX, G. E. P. ; JENKINS, G. M. *Time series analysis forecasting and control*. San Francisco: Holden - Day, 1976.

BOX, G. E. P. ; PIERCE, D. A. *Distribution of residual autocorrelation in autoregressive integrated moving average time series models*. **Journal of the American Statistical Association**, v. 65, n. 332, p. 1509-1526, 1970.

BOX, G. E. P. ; REINSEL, G. C. ; JENKINS, G. M. *Time Series Analysis: Forecasting and Control*. **John Wiley & Sons**, 2015.

CASSIANO, K. M. et al. *Filtragem de séries temporais de consumo de energia via singular spectrum analysis antes de sua modelagem*. In: XLVII Simpósio Brasileiro de Pesquisa Operacional. **Anais [...]**. Porto de Galinhas, 2015. Disponível em: <<http://www.din.uem.br/sbpo/sbpo2015/pdf/140250.pdf>>. Acesso em: 24 set. 2023.

CLEVELAND, W. S. *Robust locally weighted regression and smoothing scatterplots*. **Journal of the American Statistical Association**, v. 74, n. 368, p. 829-836, 1979.

COX, D. R. ; STUART, A. *Some quick tests for trend in location and dispersion*. **Biometrika**, London, v. 42, p. 80-95, 1955.

DICKEY, D. A. ; FULLER, W. A. *Likelihood ratio statistics for autoregressive time series with a unit root*. **Econometrica**, v. 49, n. 4, p. 1057-1072, 1981. DOI10.2307/1912517.

ENERGÉTICA, E. E. D. P. *Balanco energético nacional 2022: ano base 2021*. 2022. Disponível em: <www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2022>, Acesso em: 6 set.2023.

FURTADO, J. H. et al. *Evolução do consumo de energia elétrica em indústrias do Rio Grande do Sul - Brasil, entre 1991 e 2010*. Capítulo XVII. Alinhamento dinâmico da engenharia de produção [recurso eletrônico] / Rudy de Barros Ahrens. – Ponta Grossa (PR): Atena Editora, 2018.

GOMES, J. P. P. ; VIEIRA, M. M. F. *O campo da energia elétrica no brasil de 1880 a 2002*. **Revista de Administração Pública, RAP**, v. 43, n. 2, p. 295–321, 2009.

KIM, H. *A new metric of absolute percentage error for intermittent demand forecasts*. **International Journal of Forecasting**, v. 32, n. 3, p. 669-679, July–September, 2016.

MARTINS, V. L. M. ; WERNER, L. *Comparação de previsões individuais e suas combinações: um estudo com séries industriais*. **Production**, v. 24, n. 3, p. 618-627, 2014. DOI 10.1590/S0103-65132013005000066.

PEDROSO, T. R. et al. *Previsão e monitoramento do preço das ações do Bradesco*. **Ciência e Natura, UFSM**, v. 29, n. 2, p. 53-68, 2007.

REICHERT, B. et al. *Forecasting electricity generation from renewable sources during a pandemic*. **Gestão & Produção**, 29, 2022. DOI 10.1590/1806-9649-2022v29e024

ROSA, G. J. F. et al. *Análise do índice de preços ao consumidor amplo (IPCA) por meio de combinações de previsões*. Capítulo 2. Estudios teórico-metodológicos en ciencias exactas, tecnológicas y de la tierra. **Editora Atena**, 2024.

SHCHERBAKOV, M. V. et al. *A Survey of Forecast Error Measures*. **World Applied Sciences Journal (Information Technologies in Modern Industry, Education & Society)**, v. 24, n. 24, p. 171-176, 2013.

SIEGEL, S. ; CASTELLAN, J. *Estatística não - paramétrica para as ciências do comportamento*, 2. Ed. São Paulo: Artmed Bookman, 2006.

STONE, C. J. *Consistent nonparametric regression*. **The Annals of Statistic**, v. 5, n. 4, p. 595-620, 1977.

TAVARES, L. A. *Matriz elétrica brasileira e as tendências futuras*. **Revista Científica Multidisciplinar, RECIMA21**, v.4, n. 5, 2023.

WERNER et. al. *Previsão da umidade relativa do ar diária de porto alegre*. **Cadernos do IME-Série Estatística**, v. 43, p. 39-59, 2017. DOI 10.12957/cadest.2017.31211.