57º SBPO
SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
Gramado • RS
DE 5 A 9 DE OUTUBRO DE 2025

ANÁLISE DOS MODELOS DE DECOMPOSIÇÃO CLÁSSICA E DE SUAVIZAÇÃO EXPONENCIAL EM UMA ARBORDAGEM HÍBRIDA NA PREVISÃO DE CONSUMO MENSAL DE ENERGIA ELÉTRICA RESIDENCIAL

Bernardo Maceira de Melo
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca – CEFET-RJ
Engenharia de Produção
bernardomaceira@gmail.com

Anna Regina Corbo Costa
Centro Federal de Educação Tecnológica Celso Suckow da Fonseca – CEFET-RJ
Departamento de Matemática
anna.costa@cefet-rj.br

RESUMO

A previsão do consumo de energia elétrica desempenha um papel fundamental nas atividades do setor elétrico. Neste trabalho avalia-se o desempenho de modelos de previsão de séries temporais aplicados ao consumo mensal de energia elétrica residencial por consumidor no Brasil, em um horizonte de 12 meses. Foram utilizados dois modelos de previsão - decomposição clássica e suavização exponencial, os quais foram aplicados individualmente e em uma abordagem combinada (híbrida), incluindo os métodos da média aritmética, variância mínima, média geométrica ponderada, média harmônica ponderada e *Inverse Mean Square.* Dentre os modelos individuais, o modelo de suavização exponencial conseguiu captar melhor a sazonalidade da série temporal, enquanto o de decomposição clássica, apesar de apresentar a maior correlação entre a série prevista e a observada, apresentou desempenho inferior. Numa análise geral, os métodos de combinação apresentaram um ganho pouco significativo aos modelos individuais, sendo que o *Inverse Mean Square* obteve o melhor desempenho.

PALAVRAS CHAVE. Previsão de consumo de energia elétrica. Análise de séries temporais. Métodos híbridos.

EN&OG, EST&AM

ABSTRACT

Electricity consumption forecasting plays a fundamental role in the activities of the electricity sector. This work aims to evaluate the performance of time series forecasting models applied to the prediction of monthly residential electricity consumption per consumer in Brazil, over a 12-month horizon. Two time series forecasting models were used - classical decomposition and exponential smoothing. Both models were applied individually and then in a combined (hybrid) approach, using the methods of arithmetic mean, minimum variance, weighted geometric mean, weighted harmonic mean, and Inverse Mean Square. Among the individual models, the exponential smoothing model was better able to capture the seasonality of the time series, while the classical decomposition model, despite presenting the highest correlation between the predicted and observed series, showed inferior performance. In a general analysis, the combination methods showed little significant gain over the individual models, with the Inverse Mean Square method obtaining the best performance.

KEYWORDS. Electricity consumption forecasting. Time series analysis. Hybrid methods. EN&OG, EST&AM

1. Introdução

Uma atividade fundamental no planejamento da expansão e da operação de sistemas elétricos é a previsão de valores futuros do consumo de energia, insumo essencial para sinalizar as necessidades de investimentos no sistema e de montantes de energia a serem contratados [MME e EPE 2024].

Neste trabalho são avaliados o desempenho de modelos de previsão de séries temporais aplicados à previsão de consumo mensal de energia elétrica residencial, por unidade consumidora no Brasil, em um horizonte de 12 meses. Para isso, foram utilizados os modelos de decomposição clássica e de suavização exponencial [Morettin e Toloy 2006; Morettin e Singer 2022]. Estes modelos foram aplicados de forma individual e em uma abordagem combinada (híbrida), utilizando os métodos da média aritmética, da variância mínima [Martins 2014], da média geométrica ponderada, da média harmônica ponderada e *Inverse Mean Square* [Jacobs 2014].

2. Metodologia

A base de dados utilizada foi extraída do site da Empresa de Pesquisa Energética [EPE 2022], e se refere ao consumo mensal de energia elétrica por classe (regiões e subsistemas elétricos) no Brasil, em MWh, e o número de unidades consumidoras, abrangendo o período de janeiro de 2004 até dezembro de 2022 (120 meses). Os valores do consumo mensal da classe residencial foram divididos pelo número de consumidores residenciais em cada mês (KWh/Unidade consumidora).

O estudo foi realizado na linguagem R [R Project 2024]. As principais bibliotecas utilizadas foram a zoo, xts, forecast e lmtest, além da ggplot2 e dplyr.

2.1 Análise da Série Temporal

Uma série temporal é um conjunto de observações sobre uma variável, ordenadas no tempo, que apresentam dependência entre instantes de tempo e que são registradas em períodos regulares. A maneira tradicional de analisá-la é através da sua decomposição nas componentes de tendência, ciclo, sazonalidade e variações aleatórias. O objetivo da análise desses componentes é identificar padrões não aleatórios na série, permitindo realizar as previsões.

2.2 Escolha de Modelos de Previsão

A série temporal estuda apresentada sazonalidade. Logo, neste trabalho, foram adotados modelos que usassem diferentes métodos para calcular a tendência da série temporal, uma vez que a sazonalidade seria introduzida da mesma maneira para ambos os modelos. Assim, foi escolhido o modelo de Decomposição Clássica, que calcula a tendência através de um modelo de regressão, e o modelo de Suavização Exponencial, que calcula a tendência através de um ajuste exponencial [Morettin e Toloy 2006] [Morettin e Singer 2022]:

Modelo de Decomposição Clássica

$X_t = T_t + S_t + E_t$

T_t - tendência

S_t – sazonalidade; E_t - resíduo

X_t - valor ajustado

Modelo de Suavização Exponencial

$X_t = \alpha \times Y_t + (1 - \alpha) \times X_{t-1} + E_t$

α – coeficiente de ajuste (0,05)

Y_t – valor da série temporal

X_t - valor exponencialmente ajustado

2.3 Escolha dos Modelos de Combinação

Visando melhorar a acurácia das previsões, foi adotada uma abordagem híbrida, ou seja, além de aplicar os dois métodos descritos de forma individual, as suas previsões também foram combinadas [Jacobs 2014]. Para todos os métodos de combinação selecionados e apresentados a seguir, vale ressaltar que *w* é o peso atribuído aos valores das previsões individuais, X_{1t} e X_{2t} são os valores das previsões individuais, no mês t, a serem combinadas, Z_t é a previsão resultante dessa combinação, ρ é o valor da correlação linear entre os erros das duas previsões e σ_1^2 e σ_2^2 correspondem à variância dos erros de previsão de X_{1t} e X_{2t}, respectivamente. Os métodos são apresentados a seguir, sendo que, no método Inverse Mean Square, o valor de t varia entre 109 e 120, pois foi calculado exclusivamente para o ano de 2021. Nos demais, t varia entre 1 e 120.

Método da Média Aritmética

$$Z_t = 0.5\,X_{1t} + 0.5\,X_{2t}$$

Método da Variância Mínima

$$Z_t = w\,X_{1t} + (1 - w)X_{2t}$$

$$w = \frac{\sigma_2^2 - \rho\sigma_1\sigma_2}{\sigma_1^2 + \sigma_2^2 - 2\rho\sigma_1\sigma_2}$$

Métodos da Média Geométrica Ponderada e da Média Harmônica Ponderada

$Z_t = X_{1t}^{w}\ X_{2t}^{1-w}$ média geométrica ponderada

$Z_t = \frac{X_{1t}\ X_{2t}}{(1-w)X_{1t}+wX_{2t}}$ média harmônica ponderada

Os pesos entre os dois métodos visam minimizar o erro médio quadrático (EQM)

$$EQM = \frac{1}{n}\sum_{i=1}^{n}(Y_i - Z_i)^2$$

Método *Iverse Mean Square*

$$Z_t = w_t X_{1t} + (1 - w_t)X_{2t}$$

Os pesos são adaptativos para cada horizonte de previsão, resultando em 12 pesos diferentes, um para cada mês da previsão, calculados através da média móvel de três períodos visando minimizar o EQM

$$w_i = \frac{\frac{1}{3}\sum_{j=i}^{3}\left(Y_{108+i-j} - x_{108+i-j}^{(2)}\right)^2}{\frac{1}{3}\sum_{j=i}^{3}\left(Y_{108+i-j} - x_{108+i-j}^{(1)}\right)^2 + \frac{1}{3}\sum_{j=i}^{3}\left(Y_{108+i-j} - x_{108+i-j}^{(2)}\right)^2}$$

2.4 Avaliação do Desempenho das Previsões

Para a avaliação do desempenho das previsões obtidas pelos modelos individuais e de combinação, tanto para o período usado como base nos cálculos e tanto para o ano destinado à previsão, foram consideradas as seguintes métricas [Morettin e Singer 2022]:

Erro Médio Absoluto (MAE)

$$MAE = \frac{1}{n}\sum_{i=1}^{n}|Y_i - X_i|$$

Erro Percentual Médio Absoluto (MAPE)

$$MAPE = \frac{1}{n}\sum_{i=i}^{n}\left|\frac{Y_i - X_i}{Yi}\right| \times 100$$

Correlação entre as séries observada e prevista (cor.test R)

$$\rho_{X,Y} = \frac{\frac{1}{n}\sum_{t=i}^{n}(Y_t - \mu_Y)\quad (X_t - \mu_X)}{\sigma_X\ \sigma_Y}$$

3. Resultados

Da base de dados carregada no software R, os valores mensais de 2012 a 2020 foram utilizados para construir os modelos de previsão e o ano de 2021 foi utilizado para medir a assertividade desses modelos.

As Figuras 1 a 4 apresentam a série temporal observada e as previsões (KWh/Unidade consumidora) obtidas com os modelos individuais e de forma combinada, para o ano de 2021. Já as Tabelas 1 e 2 apresentam as métricas de avaliação, MAE (KWh/Unidade consumidora) e MAPE, para cada um dos modelos estudados.

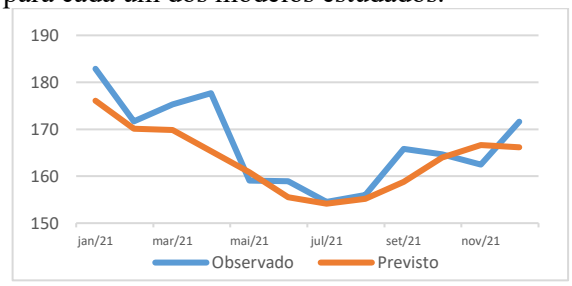


Figura 1 – Previsão - Decomposição Clássica

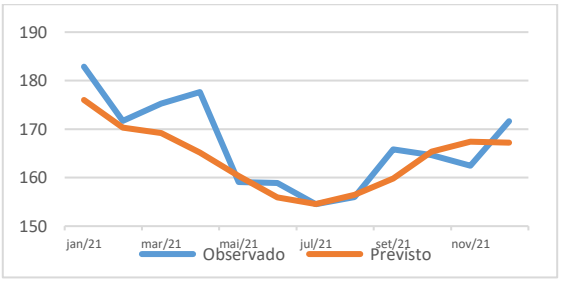


Figura 2 – Previsão – Suavização Exponencial

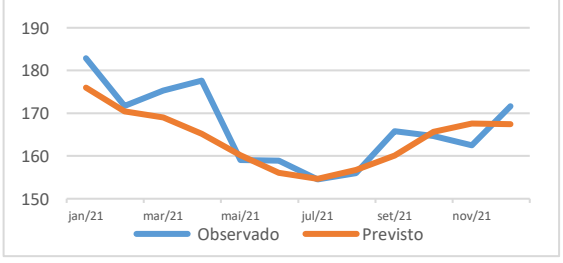


Figura 3 – Previsão – Variância Mínima

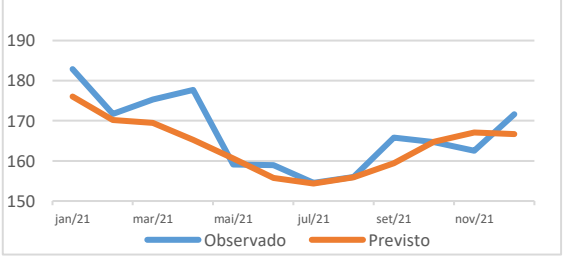


Figura 4 – Previsão – Inverse Mean Square

Tabela 1 – Métricas de avaliação para os anos utilizados na base de dados dos modelos

Modelo	MAE	Mape	Correlação
Decomposição Clássica	3,81363	2,3118%	0,80313
Suavização Exponencial	3,50887	2,1288%	0,84107
Variância Mínima	3,50859	2,1292%	0,84227
Média Aritimética	3,60526	2,1859%	0,82900
Média Geométrica Ponderada	3,51012	2,1294%	0,84046
Média Harmônica Ponderada	3,51010	2,1294%	0,84046

Tabela 2 – Métricas de avaliação para o ano de 2021

Modelo	Mae	Mape	Correlação
Decomposição Clássica	4,155466	2,4255%	87,873%
Suavização Exponencial	3,961359	2,3047%	86,794%
Variância Mínima	3,988733	2,3222%	86,425%
Média Aritimética	3,956779	2,3019%	87,444%
Média Geométrica Ponderada	3,955237	2,3008%	86,869%
Média Harmônica Ponderada	3,955213	2,3007%	86,870%
Inverse Mean Square	3,952629	2,2991%	87,336%

4. Discussão

Nesse trabalho, foram avaliados os modelos de decomposição clássica e suavização exponencial, além dos métodos de combinação (híbridos) da variância mínima, da média aritmética, da média geométrica ponderada, da média harmônica ponderada e *Inverse Mean Square*; aplicados à previsão de consumo mensal de energia elétrica residencial, por consumidor, no Brasil.

Como é possível observar pelos gráficos ilustrados nas Figuras 1 a 4, e pelas Tabelas 1 e 2, as previsões individuais se aproximaram bastante da série original, principalmente para os anos utilizados na base de dados dos modelos, como era esperado.

Dentre os modelos individuais, o modelo de suavização exponencial conseguiu captar melhor a sazonalidade da série temporal, uma vez que foi considerada uma tendência estacionária no modelo de decomposição clássica. Isso garantiu à previsão do modelo de suavização exponencial uma maior assertividade em relação às métricas de erro analisadas, a média dos erros, MAPE e MAE. O modelo de decomposição clássica foi o que apresentou desempenho inferior em relação às métricas de erro, apesar de apresentar a maior correlação entre a série prevista e a observada, para o ano de 2021.

Os métodos de combinação apresentarem resultados muito próximos, sendo que o *Inverse Mean Square* obteve o menor MAE e MAPE. Numa análise geral, os métodos de combinação apresentaram um ganho pouco significativo aos modelos individuais, principalmente ao modelo de suavização exponencial.

Para trabalhos futuros, propõe-se verificar o desempenho dos métodos empregados à para outras classes de consumo, como a comercial e a industrial. Também seria interessante avaliar o desempenho de outros métodos de previsão, como o modelo exponencial sazonal *Holt Winters* e o modelo SARIMA [Morettin e Toloi 2006], assim como métodos de aprendizado de máquina.

Agradecimentos

Os autores agradecem ao programa PIBIC do CEFET-RJ pela bolsa concedida.

Referências

Jacobs, W. (2014). Combinação das Previsões dos Modelos de Box-Jenkins e MLP/RNA para a Previsão de Demanda no Planejamento da Produção, Universidade Federal de Santa Maria.

Martins, V. (2014). Comparação de Previsões Individuais e suas Combinações: um Estudo com Séries Industriais. Production, v.24, n. 3, p. 618-627.

Ministério de Minas e Energia - MME, Empresa de Pesquisa Energética – EPE (2024). Plano Decenal de Expansão de Energia 2034.

Morettin, P., Toloi, C. (2006). Análise de Séries Temporais, ISBN 9788521203896, 2ª Ed. Editora Blucher.

Morettin, P., Singer, J.M. (2022), Estatística e Ciência de Dados, ISBN 9788521638162, Editora LTC.

R Project, The R Project for Statistical Computing. Disponível em: https://www.r-project.org/. Acessado: 2024, Set.