

Previsão Hierárquica do Consumo de Energia Elétrica do Rio Grande do Sul

Rafael S. de Oliveira ¹

FIOCRUZ, Rio de Janeiro, RJ

Marlon M. L. Cabreira²

CEFET, Rio de Janeiro, RJ

Felipe L. C. da Silva,³ Josiane da S. C. Coelho,⁴ Duilio T. da Conceição Junior⁵

UFRRJ, Seropédica, RJ

Resumo. O estado do Rio Grande do Sul é um dos maiores consumidores de energia elétrica no Brasil. Dessa forma, como em outros estados, o planejamento energético torna-se importante para o desenvolvimento econômico, social e segurança ambiental. Os dados de consumo de energia elétrica deste estado podem ser organizados em uma estrutura hierárquica composta pelos setores (comercial, industrial, residencial e outros). Este trabalho tem como objetivo avaliar a capacidade preditiva das abordagens *bottom-up*, *top-down* e combinação ótima para previsão do consumo de energia elétrica do estado Rio Grande do Sul. Essas abordagens foram integradas aos métodos preditivos de suavização exponencial, de Box e Jenkins e de redes neurais. Os resultados mostraram que o método de suavização exponencial acoplado as abordagens de combinação ótima e *top-down* forneceram as melhores previsões e, portanto, superando as outras abordagens de previsão hierárquica.

Palavras-chave. Séries Temporais Hierárquicas, Energia Elétrica, Previsão

1 Introdução

O planejamento do fornecimento de energia elétrica tem uma importância para o desenvolvimento econômico, social e ambiental de uma região, estado ou país. Desta forma, análise e previsão do consumo de energia elétrica é importante para as empresas responsáveis pela matriz energética. Neste trabalho, propõe-se um estudo sobre o consumo de energia elétrica do Estado do Rio Grande do Sul (ERS). O ERS é um dos maiores consumidores de energia elétrica no Brasil, ocupando em 2023 a quinta posição entre os estados brasileiros [5]. Além disso, o ERS tem sido afetado pelos eventos climáticos extremos resultando na perda de diversas lavouras e, consequentemente, gerando prejuízos à economia local e do país [6].

Os dados de consumo de energia elétrica do Rio Grande do Sul podem ser organizados em estrutura hierárquica. Nesta estrutura hierárquica, o topo (nível 0) sendo o consumo total do estado, no nível intermediário (nível 1), estão as séries históricas de cada um dos setores da economia (comercial, industrial, residencial e outros).

Atualmente, as abordagens *bottom-up* e *top-down* têm sido utilizadas para a previsão de séries temporais hierárquicas [3, 10]. Na abordagem *bottom-up*, primeiramente são geradas as previsões

¹rafaelrso@ufrj.br

²marlonmlc23@gmail.com

³felipeleite@ufrj.br

⁴josicordeiro@gmail.com

⁵duiliotadeu@gmail.com

independentes para cada série no nível mais baixo da hierarquia e, em seguida, elas são agregadas para produzir a previsão dos níveis superiores da hierarquia. Por outro lado, a abordagem *top-down* gera as previsões da série temporal agregada e, em algumas situações, desagrega tais previsões para os níveis exigidos em proporções históricas. Herbst et al. [7] desenvolveram um estudo com as abordagens *bottom-up* e *top-down* com dados de energia. Neste estudo salientaram que um modelo *bottom-up* possui maior detalhamento dos dados quando comparado a um modelo *top-down*.

Nos últimos anos tem sido desenvolvidos estudos relacionados a previsão hierárquica do consumo de energia elétrica no Brasil. Silva et al. [11] apresentaram um estudo comparativo usando os modelos de redes neurais artificiais para previsão do consumo de eletricidade do setor industrial brasileiro. Cabreira et al. [4] apresentaram uma metodologia de previsão hierárquica aplicada aos dados de consumo de energia elétrica da indústria brasileira. Silva et al. [12, 13] apresentaram uma metodologia abordagem *bottom-up* para previsão do consumo de energia elétrica do setor industrial no Brasil. Maçaira et al. [9] apresentaram uma abordagem *bottom-up* para previsão do consumo de energia elétrica do setor residencial.

O objetivo deste trabalho é comparar as abordagens *bottom-up*, *top-down* e de combinação ótima na obtenção das projeções mensais do consumo de energia elétrica do estado do Rio Grande do Sul. Essas abordagens foram acopladas aos modelos de suavização exponencial, de Box-Jenkins e de redes neurais autorregressivas e de perceptron multicamadas (*MLP - Multilayer Perceptrons*). A capacidade preditiva das abordagens foi avaliada pelas métricas do erro médio absoluto percentual (MAPE) e da raiz do erro quadrático médio (RMSE).

2 Metodologia

Neste trabalho, foram utilizados os dados de janeiro de 2004 até dezembro de 2023 do consumo mensal de energia elétrica do Rio Grande do Sul, em *GWh*, disponível no sítio eletrônico da Empresa de Pesquisa Energética (EPE). Doravante, organizou-se os dados considerando a estrutura hierárquica do consumo de energia para o estado e setores da economia. A partir dessa estrutura hierárquica, as abordagens *bottom-up*, *top-down* e de combinação ótima incorporaram as previsões do consumo energia obtidas pelos métodos de suavização exponencial, de Box e Jenkins e de redes neurais (Autorregressivas (RNA) e de Perceptron Multicamadas (MLP))

Para testar a capacidade de ajuste e previsões, os dados foram divididos em dois conjuntos: o conjunto de treino, com intuito de ajuste aos dados e validação dos modelos e o conjunto de teste para avaliar o poder preditivo. Foram propostos três conjuntos de treino e teste. No primeiro conjunto de treino, foi considerado os dados de janeiro de 2004 até dezembro de 2020 e o conjunto teste, sempre com doze observações à frente do conjunto de treino, logo, de janeiro de 2021 até dezembro de 2021. E assim por diante, até o último conjunto que contém os dados de janeiro de 2004 até dezembro de 2022 para o conjunto de treino e janeiro de 2023 até dezembro de 2023 para o conjunto de teste. Com isso, foi calculado a média das métricas MAPE, RMSE e RelRMSE de cada conjunto considerado com o intuito de comparar as abordagens *bottom-up*, *top-down* e o método de combinação ótima.

2.1 Notação de Séries Temporais Hierárquicas

As séries temporais que são organizadas em uma estrutura hierárquicas e que podem ser agregadas em diferentes níveis da hierarquia são denominadas de séries temporais hierárquicas. O consumo de energia elétrica do Rio Grande do Sul pode ser organizado em uma estrutura hierárquica considerando os setores industrial, residencial, comercial e outros.

Seja y_t o consumo de energia elétrica observada no mês t , para $t = 1, \dots, T$, com T representando a quantidade de meses da série. De acordo com Athanasopoulos et al. [2] e Hyndman et al. [8],

uma série temporal hierárquica pode ser apresentada usando a equação matricial:

$$\tilde{Y}_h = SG\hat{Y}_h \quad (1)$$

em que \tilde{Y}_h representa um conjunto de previsões combinadas h passos á frente, \hat{Y}_h são as previsões de base (ou seja, para todos os níveis da hierarquia), que são previsões independentes de todas as séries na hierarquia e G é uma matriz referente ao tipo de abordagem de previsão hierárquica que será utilizada e SG realiza a reconciliação.

2.2 Abordagem *Bottom-Up*

Esta abordagem consiste em utilizar modelos preditivos em cada série na base da hierarquia e, em seguida, agregá-las para gerar previsões para toda estrutura hierárquica. Uma vantagem dessa abordagem é que prevendo nos níveis inferiores, nenhuma informação é perdida devido a agregação, ou seja, no caso do consumo de energia elétrica do ERS, a abordagem é capaz de capturar as características de tendência e sazonalidade em níveis de cada setor da economia (comercial, industrial, residencial e outros). Pode-se representar a abordagem *bottom-up* utilizando a matriz G construída na forma:

$$G = [0_{m \times (n-m)} | I_m], \quad (2)$$

em que I_m é a matriz identidade de ordem m e $0_{m \times (n-m)}$ é a matriz nula de ordem $m \times (n - m)$.

2.3 Abordagem *Top-Down*

Nesta abordagem, primeiramente obtém-se a previsão para a série temporal do nível superior da hierarquia e, em seguida, desagrega-se para os níveis inferiores utilizando um conjunto de proporções p_1, p_2, \dots, p_m , em que m é a quantidade de séries na base da hierarquia. Estas proporções ditam como a previsão deve ser distribuída nas séries inferiores. Em geral, para um conjunto fixo de proporções, as abordagens *top-down* podem ser representadas como $\tilde{Y}_{T+h} = SG\hat{y}_{T+h}$, onde a matriz G é construída na forma:

$$G = [\mathbf{p} | 0_{m \times (n-1)}], \quad (3)$$

em que $\mathbf{p} = [p_1, p_2, \dots, p_m]^t$. A primeira coluna inclui o conjunto de proporções que distribuem as previsões básicas do nível superior para o nível inferior. O restante das colunas zera as previsões básicas abaixo do nível mais alto de agregação. Como o interesse deste trabalho é em previsões para série totalmente agregada não será realizado a etapa de desagregação das previsões, somente a previsão da série univariada que ocupa o topo da hierarquia.

2.4 Abordagem de Combinação Ótima

Este método tem como objetivo encontrar uma matriz G que minimiza o erro de previsão do conjunto de previsões combinadas [8]. Se as previsões na base da hierarquia são imparciais, então as previsões para o restante da hierarquia serão imparciais desde que $SGS = S$, com isso, temos uma restrição para a construção da matriz G .

De acordo com Hyndman et al. [8], pode-se calcular a variância das previsões revisadas. Suponha que a variância das previsões de base $\hat{Y}_n(h)$ é dado por Σ_h . Assim, a $Var[\tilde{Y}_n(h)]$ é obtida por

$$Var[\tilde{Y}_n(h)] = SG\Sigma_h G^t S^t \quad (4)$$

Dado uma abordagem e uma hierarquia, obtém-se S e G , logo, obtendo Σ_h , calcula-se a variância e os intervalos de previsão revisado.

Wickramasuriya et al. [14] propuseram uma abordagem que reescreve a previsão de base como uma equação de regressão, conhecida como combinação ótima (Eq. 5).

$$\hat{Y}_n(h) = S\beta_n(h) + \epsilon_h \quad (5)$$

em que ϵ_n representa o erro da regressão e não deve ser confundido com o erro de previsão e $\beta_n(h) = E[Y_{K,n+h}|Y_1, \dots, Y_n]$, que representa a esperança da previsão das séries de base. Além disso, ϵ_n tem média zero e variância Σ_h .

Wickramasuriya et al. [14] utilizaram o método dos mínimos quadrados generalizados para estimar β_n . Assim, umas das formas de escrever a equação 5 é dada por

$$\tilde{Y}_n(h) = S(S^t S)^{-1} S^t \hat{Y}_n(h) \quad (6)$$

Note que a matriz $G = (S^t S)^{-1} S^t$, ou seja, no método de combinação ótima, a matriz G depende exclusivamente da forma da estrutura hierárquica.

2.5 Capacidade Preditiva

Para avaliar a capacidade preditiva de cada método preditivo utilizou-se as métricas de modelo do erro médio absoluto percentual (MAPE), a raiz do erro quadrático médio (RMSE) e o RMSE relativo. Considerando-se que N é quantidade de valores previstos, \hat{y}_i é o valor previsto, y_i é o valor observado ambos para o instante i e $RMSE_I$ é a métrica calculada no método de previsão Ingênuo [1]. Seguem as equações:

$$MAPE = 100 \times \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right|, \quad RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2}, \quad RelRMSE = \frac{RMSE}{RMSE_I} \quad (7)$$

3 Resultados

Nesta seção serão apresentadas as séries temporais do consumo de energia elétrica do Rio Grande do Sul e de cada setor da economia considerado. Além disso, serão mostrados os resultados de capacidade preditiva das abordagens.

3.1 Descrição dos Dados

A figura 1 mostra o consumo de energia elétrica do Rio Grande do Sul comparando os setores da economia. O comportamento da série temporal do consumo total de energia elétrica apresenta uma tendência amortecida e com sazonalidade. O comportamento da série temporal do setor industrial mostra-se mais ruidosa devido aos vales abruptos presentes em alguns anos. O comportamento da série temporal do consumo de eletricidade do setor residencial vem crescendo ao longo dos anos e com tendência de ultrapassar o consumo do setor industrial. As séries temporais do setor comercial e outros também apresentam sazonalidade.

3.2 Comparação das Abordagens

As tabelas 1, 2, 3 e 4 mostram os resultados das métricas MAPE, RMSE e a média RelRMSE para as abordagens consideradas com os métodos preditivos de Suavização Exponencial, Box e Jenkins, RNA e MLP. Na tabela 1, pode-se verificar que os valores do MAPE médio são menores que 2,5% e iguais entre as abordagens de previsão hierárquica adotadas neste trabalho, considerando o modelo de suavização exponencial. A abordagem *Top-Down* via método de suavização exponencial




Figura 1: Consumo de energia elétrica dos setores do estado do Rio Grande do Sul. Fonte: Autores

apresentou o menor valor para a média do RMSE, logo, obteve a melhor capacidade preditiva em comparação com as outras abordagens. Na tabela 2 foi utilizado o método de Box e Jenkins. Pode-se observar que os valores do MAPE médio são inferiores a 3%, ademais a abordagem *bottom-up* se destacou em ambas as métricas, apresentando um valor de RMSE médio de 93,09. Na tabela 3, para o método de redes neurais autorregressivas, os resultados apresentam MAPE médios menores de 4,6%. A abordagem de combinação ótima se destacou em ambas as métricas seguido pela abordagem *top-down*.

Tabela 1: Desempenho de previsão das abordagens para os dados de consumo de eletricidade do Rio Grande do Sul usando o modelo de suavização exponencial.

Teste	2021		2022		2023		Média		RelRMSE
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	
Bottom-up	2,10%	65,33	2,82%	88,93	2,35%	104,30	2,42%	86,19	0,41
Top-Down	2,09%	67,60	2,93%	92,37	2,24%	95,97	2,42%	85,31	0,41
Optimal*	2,09%	67,03	2,91%	91,60	2,26%	97,50	2,42%	85,38	0,41

*Abordagem de combinação ótima.

Tabela 2: Desempenho de previsão das abordagens para os dados de consumo de eletricidade do Rio Grande do Sul usando o modelo de Box e Jenkins.

Teste	2021		2022		2023		Média		RelRMSE
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	
Bottom-up	2,59%	78,10	2,65%	76,97	3,13%	124,20	2,79%	93,09	0,45
Top-Down	3,16%	97,91	2,88%	79,53	2,68%	114,29	2,91%	97,24	0,48
Optimal*	2,98%	91,18	2,84%	78,35	2,74%	115,79	2,85%	95,11	0,46

*Abordagem de combinação ótima.

Tabela 3: Desempenho de previsão das abordagens para os dados de consumo de eletricidade do Rio Grande do Sul usando o modelo de Redes Neurais Autorregressivas (RNA).

Teste	2021		2022		2023		Média		
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	RelRMSE
Bottom-up	3,61%	104,95	3,56%	109,81	6,37%	194,59	4,51%	136,45	0,65
Top-Down	4,43%	130,32	3,41%	109,44	3,93%	159,52	3,92%	133,09	0,65
Optimal*	4,49%	127,60	3,24%	101,88	3,51%	142,93	3,75%	124,14	0,61

*Abordagem de combinação ótima.

Tabela 4: Desempenho de previsão das abordagens para os dados de consumo de eletricidade do Rio Grande do Sul usando o modelo de Redes Neurais Perceptron Multicamadas (MLP).

Teste	2021		2022		2023		Média		
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	RelRMSE
Bottom-up	2,03%	79,22	2,72%	83,05	3,20%	111,44	2,65%	91,24	0,44
Top-Down	2,36%	77,26	2,65%	77,71	3,91%	117,61	2,98%	90,86	0,44
Optimal*	2,71%	85,82	3,10%	90,36	2,49%	120,06	2,77%	98,75	0,48

*Abordagem de combinação ótima.

4 Considerações Finais

Neste trabalho considerou-se que o consumo de energia elétrica do estado do Rio Grande do Sul pode ser organizado em uma estrutura hierárquica, onde o consumo pode ser desagregado pelos setores da economia. A partir desta estrutura hierárquica considerada foram utilizadas as abordagens *bottom-up*, *top-down* e de combinação ótima integradas aos modelos preditivos de suavização exponencial, de Box e Jenkins, e de redes neurais autorregressivas e redes MLP, com o intuito de obter a previsão do consumo de energia elétrica do ERS.

As abordagens utilizadas neste trabalho apresentaram um MAPE médio inferior a 3,93%. O método preditivo de suavização exponencial apresentou as melhores métricas, o MAPE médio em todas as abordagem foram aproximadamente de 2,42%, todavia os melhores RMSE médios foram obtidos pelas abordagens *top-down* e de combinação ótima. As métricas de RMSE relativas tiveram destaque, também, no método de suavização exponencial, evidenciando que os modelos são melhores do que o método ingênuo. Portanto, os resultados mostraram que estas abordagens podem contribuir para obtenção de projeções do consumo de energia elétrica no horizonte de curto prazo.

Para pesquisas futuras seria interessante observar o impacto das enchentes no estado do Rio Grande do Sul associadas ao abastecimento e consumo de energia elétrica. Outro trabalho interessante, seria investigar o consumo de energia elétrica do setor agropecuário. Esse setor não foi analisado neste trabalho pois os dados mensais não estavam disponíveis.

Referências

- [1] J. S. Armstrong e F. Collopy. "Error measures for generalizing about forecasting methods: Empirical comparisons". Em: **International Journal of Forecasting** 8.1 (1992), pp. 69–80. ISSN: 0169-2070. DOI: [https://doi.org/10.1016/0169-2070\(92\)90008-W](https://doi.org/10.1016/0169-2070(92)90008-W). URL: <https://www.sciencedirect.com/science/article/pii/016920709290008W>.

- [2] G. Athanasopoulos, R. A. Ahmed e R. J. Hyndman. “Hierarchical forecasts for Australian domestic tourism”. Em: **International Journal of Forecasting** 25.1 (2009), pp. 146–166. ISSN: 0169-2070. DOI: <https://doi.org/10.1016/j.ijforecast.2008.07.004>.
- [3] M. L. Cabreira, F. L. C. Silva, J. S. Cordeiro, J. M. U. Tolentino, N. Carbo-Bustanza, P. C. Rodrigues e J. L. López-Gonzales. “Comparison Between Hierarchical Time Series Forecasting Approaches for the Electricity Consumption in the Brazilian Industrial Sector”. Em: **Applied Stochastic Models in Business and Industry** (2024). DOI: 10.1002/asmb.2907.
- [4] M. M. L. Cabreira, F. L. C. Silva, J. S. Cordeiro, R. M. S. Hernández, P. Canas R. e J. L. López-Gonzales. “A Hybrid Approach for Hierarchical Forecasting of Industrial Electricity Consumption in Brazil”. Em: **Energies** 17.13 (2024). ISSN: 1996-1073. DOI: 10.3390/en17133200.
- [5] EPE. **Consumo de Energia Elétrica**. Online. Acessado em 2024, <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/consumo-de-energia-eletrica>.
- [6] EPE. **Mudanças climáticas e Transição energética**. Online. Acessado em 2025, <https://www.epe.gov.br/pt/abcedenergia/clima-e-energia>.
- [7] A. Herbst, F. Toro e F. Reitze. “Introduction to Energy Systems Modelling”. Em: **Swiss J Econ Stat** 148 (abr. de 2012), pp. 111–135. DOI: 10.1007/BF03399363.
- [8] R. J. Hyndman, R. A. Ahmed, G. Athanasopoulos e H. L. Shang. “Optimal combination forecasts for hierarchical time series”. Em: **Computational Statistics & Data Analysis** 55.9 (2011), pp. 2579–2589. ISSN: 0167-9473. DOI: <https://doi.org/10.1016/j.csda.2011.03.006>.
- [9] P. Maçaira, R. Elsland e F. C. Oliveira. “Forecasting residential electricity consumption: a bottom-up approach for Brazil by region”. Em: **Energy Efficiency** 13 (2020), pp. 911–934. DOI: <https://doi.org/10.1007/s12053-020-09860-w>. URL: <https://link.springer.com/article/10.1007/s12053-020-09860-w#citeas>.
- [10] C. F. S. Netto, V. A. Brei e R. J. Hyndman. “Forecasting system’s accuracy: A framework for the comparison of different structures”. Em: **Applied Stochastic Models in Business and Industry** 40.2 (2024), pp. 462–482. DOI: <https://doi.org/10.1002/asmb.2823>. eprint: <https://onlinelibrary.wiley.com/doi/pdf/10.1002/asmb.2823>. URL: <https://onlinelibrary.wiley.com/doi/abs/10.1002/asmb.2823>.
- [11] F. L. C. Silva, K. da Costa, P. Rodrigues, R. Salas e J. Linkolk. “Statistical and Artificial Neural Networks Models for Electricity Consumption Forecasting in the Brazilian Industrial Sector”. Em: **Energies** 15 (jan. de 2022), p. 588. DOI: 10.3390/en15020588.
- [12] F. L. C. Silva, F. L. C. Oliveira e R. C. Souza. “A bottom-up bayesian extension for long term electricity consumption forecasting”. Em: **Energy** 167 (2019), pp. 198–210. ISSN: 0360-5442. DOI: <https://doi.org/10.1016/j.energy.2018.10.201>.
- [13] F. L. C. Silva, R. C. Souza, F. L. C. Oliveira, P. M. Lourenco e R. F. Calili. “A bottom-up methodology for long term electricity consumption forecasting of an industrial sector - Application to pulp and paper sector in Brazil”. Em: **Energy** 144 (2018), pp. 1107–1118. ISSN: 0360-5442. DOI: <https://doi.org/10.1016/j.energy.2017.12.078>.
- [14] S. L. Wickramasuriya, G. Athanasopoulos e R. J. Hyndman. “Optimal forecast reconciliation for hierarchical and grouped time series through trace minimization”. Em: **Journal of the American Statistical Association** 114.526 (2019), pp. 804–819.