



De 11 a 14 - NOVEMBRO DE 2024

**Inteligência Artificial
na Gestão de Operações:
Limitações e possibilidades**



COMPARAÇÃO DE MODELOS HIERARQUICOS E DE REGRESSÃO NO CONSUMO DE ELETRICIDADE DO SETOR INDUSTRIAL BRASILEIRO

RAFAEL SANTOS DE OLIVEIRA – rafaelrso@ufrj.br
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO – UFRRJ

MARLON MESQUITA LOPES CABREIRA – marlonmlc23@gmail.com
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO - UFRRJ

FELIPE LEITE COELHO DA SILVA– felipeleite@ufrj.br
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO – UFRRJ

JOSIANE DA SILVA CORDEIRO COELHO – josicordeiro@gmail.com
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO – UFRRJ

RENAN DE SOUZA TEIXEIRA – rsteixei@ufrj.br
UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO – UFRRJ

ÁREA: 3. PESQUISA OPERACIONAL
SUBÁREA: 3.3 - PROCESSOS DECISÓRIOS

RESUMO: O setor industrial é o maior consumidor de energia elétrica no Brasil, tornando o planejamento energético fundamental para seu desenvolvimento. Os dados de consumo de energia elétrica do setor industrial brasileiro podem ser organizados em uma estrutura hierárquica composta por cada região geográfica (Sul, Sudeste, Centro-Oeste, Nordeste e Norte). Este trabalho tem como objetivo avaliar a capacidade preditiva das redes neurais autorregressivas (RNA) e perceptron multicamadas (MLP) com variável regressora e, também, acopladas as abordagens bottom-up, top-down e combinação ótima utilizadas para prever o consumo de energia elétrica no setor industrial brasileiro. Os resultados mostraram que a abordagem top-down e de combinação ótima forneceram as melhores previsões e, portanto, superando os outros métodos preditivos.

PALAVRAS-CHAVES: SÉRIES TEMPORAIS; ENERGIA ELÉTRICA; PREVISÃO;
PRODUTO INTERNO BRUTO.

1. INTRODUÇÃO

Nos últimos anos, o consumo de energia elétrica do setor industrial e o Produto Interno Bruto (PIB) industrial vem sendo investigados devido a sua 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, o conjunto de dados é tratado considerando períodos trimestrais para poder adequar-se a alguns pressupostos dos modelos de séries temporais. Primeiramente, será realizada uma análise exploratória dos dados, em seguida o ajuste e previsão dos modelos de redes neurais autorregressivas e de *perceptron* multicamadas (MLP - *Multilayer Perceptrons*) e por fim, a comparação entre eles.

A abordagem *bottom-up* vem sendo usada na análise de sistemas de energia desde 1980 (FEYNMAN; VERNON, 1963; GEROSKI, 2000). Herbst et al. (2012) avaliaram a demanda e o fornecimento de energia futura utilizando modelos de energia *bottom-up* e *top-down*. Esse estudo ressaltou que um modelo energético *bottom-up* possui maior detalhamento tecnológico dos dados quando comparado a um modelo *top-down*. Também foi ressaltado que a abordagem híbrida desses modelos vem sendo empregada para realizar o planejamento de sistemas energéticos. Fleiter et al. (2012) adotaram uma abordagem *bottom-up* determinística para analisar e prever o consumo de energia elétrica a longo prazo de indústria de papel e celulose na Alemanha.

Análises e projeções do consumo do setor industrial brasileiro vêm sendo desenvolvidas na literatura. Bastos et al. (2015), Silva et al. (2019) e Maçaira (2020) utilizaram abordagem *bottom-up* para projeções do consumo de energia elétrica no setor comercial, industrial e residencial, respectivamente. Meira et al., (2023) desenvolveram uma metodologia de reconciliação de séries temporais hierárquicas e aplicaram aos dados de consumo de energia elétrica no Brasil. Filgueira e Da silva (2023) utilizaram a abordagem *bottom-up* com o agrupamento de clusters para prever o consumo de energia elétrica da Universidade Federal Rural do Rio de Janeiro (UFRRJ). Cabreira et al. (2024) desenvolveram uma abordagem híbrida que combina abordagens *top-down* e *bottom-up* para a previsão do consumo de energia elétrica do setor industrial brasileiro.

Os dados de consumo de energia elétrica industrial do Brasil podem ser organizados em estrutura hierárquica. Nesta estrutura hierárquica, o consumo total do país está no topo (nível 0) e no nível intermediário (nível 1) estão as séries históricas de cada uma das regiões do Brasil

(Norte, Nordeste, Sudeste, Centro-Oeste e Sul).

O objetivo deste trabalho é comparar as previsões das abordagens *bottom-up*, *top-down* e de combinação ótima sem variável regressora (forma simples) e considerando o Produto Interno Bruto (PIB) industrial como variável regressora para obtenção das projeções trimestrais do consumo de energia elétrica industrial do Brasil. Essas abordagens foram acopladas aos modelos de redes neurais autorregressivas e de *perceptron* multicamadas (MLP - *Multilayer Perceptron*). 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 do PIB (em reais) e do consumo de energia elétrica (em GWh) do setor industrial brasileiro, considerando o período de janeiro de 1996 até dezembro de 2023. Esses dados estão disponíveis no sítio eletrônico do Instituto de Pesquisa Econômica e Aplicada (IPEA, 2024) e da Empresa de Pesquisa Energética (EPE, 2024). A partir dessa estrutura hierárquica, as abordagens *bottom-up*, *top-down* e de combinação ótima incorporaram as previsões do consumo de energia obtidas pelo método de redes neurais. As abordagens foram comparadas com previsões utilizando a variável regressora PIB industrial somente para a série de topo. As séries de consumo de energia elétrica foram submetidas a uma diferença simples e o PIB, a uma transformação logarítmica.


Para testar o poder de ajuste e das previsões, os dados foram divididos em dois conjuntos: o conjunto de treino, com intuito de exploração dos dados, ajustes e validação dos modelos e o conjunto de teste para avaliar a capacidade preditiva. Além disso, foram considerados 4 cenários distintos de particionamento dos dados. Os conjuntos das séries temporais do consumo de energia e do PIB foram divididos em duas partes: as primeiras 96, 100, 104 e 108 observações trimestrais de cada série foram utilizadas como conjunto de treinamento, correspondendo aos anos de 1996 até 2019, 1996 até 2020, 1996 até 2021 e 1996 até 2022, respectivamente, para estimar os parâmetros; e, as próximas 4 observações constituindo o conjunto de teste, ou seja, para obter como previsão 2020, 2021, 2022 e 2023.

Em seguida, foram ajustados os modelos de redes neurais com a abordagem hierárquica sem variável regressora e modelos com a variável regressora somente para a série de topo para serem comparados. Finalmente, foram obtidas as previsões para cada uma das séries temporais considerando 4 passos à frente. Para selecionar o modelo mais adequado foram utilizadas as métricas de acuracidade do erro médio absoluto percentual (MAPE) e a da raiz do erro quadrático médio (RMSE).

2.1 Notação de Séries Temporais Hierárquicas

Os dados de consumo de energia elétrica da indústria brasileira podem ser desagregados em cinco grupos (regiões do Brasil), apresentando uma estrutura hierárquica, onde a base da estrutura é formada por cinco séries temporais (Norte, Nordeste, Centro-Oeste, Sudeste e Sul) e no topo da hierarquia se encontra a série totalmente agregada que representa os dados do Brasil. Como apresentado na figura 1:

Figura 1: Esquema da estrutura hierárquica de um nível para o consumo de energia elétrica do setor industrial brasileiro.



Fonte: Elaboração dos autores. (2024)

Seja y_t o consumo de energia elétrica observado no mês t , para $t = 1, \dots, T$, com T representando a quantidade de observações na série temporal. De acordo com Hyndman et al. (2018), uma série temporal hierárquica pode ser representada através de uma equação matricial representada na equação (1):

$$Y_t = S b_t \quad (1)$$

em que S é uma matriz soma de ordem $n \times m$, em que n é a quantidade de séries em toda hierarquia e m é a quantidade de séries na base da hierarquia (quantidade de regiões, em particular), b_t é o vetor de observações na base da hierarquia de dimensão m no tempo t . Em particular, a equação matricial utilizada neste trabalho está apresentada na equação (2):

$$\begin{pmatrix} y_{B,t} \\ y_{BN,t} \\ y_{BR,t} \\ y_{BC,t} \\ y_{BD,t} \\ y_{BS,t} \end{pmatrix} = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} y_{BN,t} \\ y_{BR,t} \\ y_{BC,t} \\ y_{BD,t} \\ y_{BS,t} \end{pmatrix} \quad (2)$$

em que $n = 6$ é o total de séries temporais na hierarquia, $m = 5$ é o total de séries temporais no nível inferior da hierarquia, e $y_{B,t}, y_{BN,t}, y_{BR,t}, y_{BC,t}, y_{BD,t}$ e $y_{BS,t}$ representam as séries temporais do consumo de energia elétrica para o Brasil e para as regiões Norte, Nordeste, Centro-Oeste, Sudeste e Sul, respectivamente. Previsões utilizando uma estrutura de série temporal hierárquica podem ser calculadas através da equação (3):

$$\tilde{Y}_h = SG\hat{Y}_h \quad (3)$$

em que $\tilde{Y}_h$ representa um conjunto de previsões combinadas h passos à frente, $\hat{Y}_h$ são as previsões de base (ou seja, é o nível inferior da estrutura hierárquica), 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.

2.2 Abordagem Bottom-Up

Esta abordagem consiste em utilizar modelos preditivos em cada série no nível inferior e da hierarquia, em seguida, agregá-las para produzir previsões para toda estrutura hierárquica. Uma vantagem dessa abordagem é que prevendo nos níveis inferiores, nenhuma informação perdida devido a agregação, ou seja, a abordagem é capaz de captar características particulares das séries inferiores, assim, podendo contribuir para a capacidade preditiva. Pode-se representar a abordagem *bottom-up* utilizando a equação (4):

$$\begin{pmatrix} \tilde{y}_{B,T,h} \\ \tilde{y}_{BN,h} \\ \tilde{y}_{BR,h} \\ \tilde{y}_{BC,h} \\ \tilde{y}_{BD,h} \\ \tilde{y}_{BS,h} \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}}_S \cdot \underbrace{\begin{pmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}}_G \cdot \begin{pmatrix} \hat{y}_{B,T,h} \\ \hat{y}_{BN,h} \\ \hat{y}_{BR,h} \\ \hat{y}_{BC,h} \\ \hat{y}_{BD,h} \\ \hat{y}_{BS,h} \end{pmatrix} \quad (4)$$

Onde $G = [0_{m \times (n-m)} | I_m]$ é uma matriz de zeros de ordem $m \times (n - m)$ acoplada a uma matriz identidade de ordem m .

2.3 Abordagem Top-Down

A abordagem *top-down* envolve, primeiramente, previsões para a série no topo da hierarquia $y_{B,t}$ em seguida, desagregando-as para níveis inferiores utilizando um conjunto de proporções $p_1, p_2, \dots, p_m$, onde m é a quantidade de séries na base da hierarquia. Estas proporções ditam como a previsão deve ser distribuída nas séries inferiores. Uma vantagem desta abordagem é a simplicidade, já que prevendo somente com uma série podemos ter

previsões para toda a hierarquia. Pode-se representar a abordagem *top-down* utilizando a equação (5):

$$\begin{pmatrix} \tilde{Y}_{B,T,h} \\ \tilde{Y}_{BN,h} \\ \tilde{Y}_{BR,h} \\ \tilde{Y}_{BC,h} \\ \tilde{Y}_{BD,h} \\ \tilde{Y}_{BS,h} \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 1 & 1 & 1 & 1 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}}_S \cdot \underbrace{\begin{pmatrix} p_1 & 0 & 0 & 0 & 0 \\ p_2 & 0 & 0 & 0 & 0 \\ p_3 & 0 & 0 & 0 & 0 \\ p_4 & 0 & 0 & 0 & 0 \\ p_5 & 0 & 0 & 0 & 0 \end{pmatrix}}_G \cdot \begin{pmatrix} \hat{Y}_{B,T,h} \\ \hat{Y}_{BN,h} \\ \hat{Y}_{BR,h} \\ \hat{Y}_{BC,h} \\ \hat{Y}_{BD,h} \\ \hat{Y}_{BS,h} \end{pmatrix} \quad (5)$$

Onde $G = [p|0_{m \times (n-1)}]$ é uma matriz com um vetor coluna de proporções p acoplado a uma matriz de zeros de ordem $m \times (n-1)$. Como este trabalho tem o interesse em comparar previsões para a série de topo, não será desagregada as previsões para níveis inferiores, assim não sendo necessário o cálculo de proporções.

2.4 Abordagem de Combinação Ótima

Cada abordagem possui uma matriz G particular, portanto, há interesse em uma matriz G ótima, ou seja, uma matriz que minimize o erro de previsão do conjunto de previsões combinadas. A abordagem de combinação ótima tem esse objetivo (HYNDMAN et al., 2011). Se as previsões de base são imparciais, então as previsões para o restante da hierarquia serão imparciais desde que $SGS = S$, com isso, temos uma restrição para a matriz G .

De acordo com Hydman et al. (2011), pode-se calcular as variâncias das previsões revisadas. Suponha que a matriz de covariância das previsões de base $\hat{Y}_h$ é dado é dado por W_h , então $Var[\tilde{Y}_h]$ é:

$$Var[\tilde{Y}_h] = SGW_hG^tS^t \quad (6)$$

A variância dos erros de previsão está na diagonal de W_h , logo suponha V_h o traço de W_h , de acordo com Wickramasuriya et al. (2019), a matriz G que minimiza V_h tal que $SGS = S$ é dado por:

$$G = (S^tW_h^{-1}S)^{-1}S^tW_h^{-1} \quad (7)$$

Portanto as previsões revisadas são dadas por:

$$\tilde{Y}_h = S(S^tW_h^{-1}S)^{-1}S^tW_h^{-1}\hat{Y}_h \quad (8)$$

Para encontrar G , é necessário estimar W_h e na prática existem algumas formas, a usada neste trabalho foi o método de mínimos quadrados ordinários (OLS - *ordinary least squares*), em que $W_h = k_h I$ (I é a matriz identidade) implicando em $G = (S^tS)^{-1}S^t$.

2.5 Redes Neurais

As redes neurais artificiais foram apresentadas pela primeira vez por McCulloch e Pitts (1943). Desde então, observam-se aplicações de redes neurais nas diversas áreas da ciência, inclusive em séries temporais. Toda a rede neural artificial tem uma camada de entrada e outra de saída. Também pode haver camadas intermediárias contendo neurônios ocultos, a qual chama-se de camada oculta. As camadas contêm uma quantidade de neurônios artificiais, em que são conectados entre si formando uma rede.

A camada de entrada é responsável por receber informações oriundas de um meio externo, no caso de uma série temporal, em geral, são observações passadas. Já a camada oculta, tem a tarefa de aplicar pesos as observações passadas e utilizam funções, que são chamadas de funções de ativação, para introduzir a não linearidade nas saídas das camadas ocultas. A camada de saída, em geral, entrega o valor da previsão no tempo futuro subsequente.

Neste trabalho foram utilizados dois tipos de redes neurais: a autorregressiva (RNA) e a perceptron multicamadas (MLP - Multilayer Perceptrons).

2.5.1 REDE NEURAL AUTORREGRESSIVA – RNA (*Neural network auto regression model-NNAR*)

Com os dados da série temporal, os valores defasados da série temporal podem ser usados como entradas para uma rede neural, assim como usamos os valores defasados em um modelo de autorregressão linear. Chamamos isso de rede neural autorregressiva ou modelo NNAR.

Neste estudo será considerado apenas a rede unidirecional (feedforward) com uma camada oculta e representada pela notação $NNAR(p, P, k)_m$, p número de defasagens não sazonais usadas como entradas ($p = 4$, são as 4 últimas observações), P representa o número de defasagens sazonais usadas como entradas e k é o número de nós (neurônios) na camada oculta, (Hyndman e Athanasopoulos, 2013).

2.5.2 PERCEPTRON MULTICAMADAS (*Multilayer perceptron - MLP*)


A arquitetura de rede é exibida na Figura 1, incluindo pelo menos três camadas. Este modelo consiste em entradas, pesos, vieses e uma função ativação que produz a saída (PARHIZKARI, L.; NAJAFI, A.; GOLSHAN, M., 2020). Cada entrada x_i para um neurônio, j é multiplicado por um coeficiente adaptativo w_{ij} , chamado peso, e depois por uma função de ativação não linear (φ), como sigmoide, tangente hiperbólica etc. Calcula-se a soma ponderada

das entradas conforme mostrado a seguir na Equação 9 abaixo:

$$o_i = \varphi \left(\sum_{j=1}^d (x_j w_{ij} + b_j) \right) \quad (9)$$

A arquitetura da rede MLP é exibida na Figura 1, incluindo pelo menos três camadas. Este modelo consiste em entradas, pesos, vieses e uma função ativação que produz a saída. Uma função de ativação permite que a rede mapeie uma entrada para saída, e a rede aprende a representar dados complexos. Em outras palavras, do ponto de vista estatístico, os MLPs funcionam de forma não linear autorregressiva (KAUSHIK et al., 2020).

FIGURA1: A estrutura da rede MLP



Fonte: Talkhi et al.

Na saída o_i de um neurônio da rede MLP, d é o número de as entradas x_j , b_j e w_{ij} são as tendências e os pesos associados a cada x_j . Na fase de treinamento do modelo, os coeficientes ou pesos da rede são ajustados com base no cálculo da função de erro nas próximas etapas, os pesos são atualizados com base na taxa de aprendizagem e no erro em cada iteração. Na etapa final, todos os passos são repetidos até atingir o número de épocas (PARHIZKARI, L.; NAJAFI, A.; GOLSHAN, M., 2020).

2.6 Capacidade Preditiva

Para avaliar a capacidade preditiva de cada método preditivo utilizou-se as métricas do erro médio absoluto percentual (MAPE) e a raiz do erro quadrático médio (RMSE), considerando-se que N é quantidade de valores previstos, $\hat{y}_t$ é o valor previsto e y_t é o valor observado ambos para o instante t . Seguem as equações das métricas:

$$MAPE = 100 \times \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right|, RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2} \quad (10)$$

3. RESULTADOS E DISCUSSÕES

Nesta seção, primeiramente é feita uma análise exploratória para as séries temporais do consumo de energia elétrica industrial do Brasil e PIB industrial brasileiro. Em seguida, serão apresentados os resultados obtidos através dos modelos de redes neurais NNAR e MLP utilizando as diferentes abordagens *bottom-up*, *top-down*, combinação ótima e com a inserção de uma variável regressora.


3.1 Análise Exploratória

As séries temporais do consumo de energia elétrica do Brasil e do PIB do setor industrial brasileiro são apresentadas na Figura 2. Pode-se observar nesta figura que ambas as séries temporais possuem tendência e sazonalidade.

Na Figura 2, a série temporal do consumo de energia elétrica industrial possui bastante mudança de nível e aumento expressivo no ano de 2002 até 2005, com vales mais significativos em 2002, 2008 e 2020. Em 2008 houve a crise econômica mundial, em 2020 a COVID-19, que refletiram expressivamente no comportamento da série temporal. No PIB também houve uma queda, porém menos acentuada. Nota-se também que após a pandemia da COVID-19, há uma tendência acentuada em ambas as séries temporais.


Na Figura 3 é apresentado os gráficos dos consumos de eletricidade do setor industrial das cinco regiões brasileiras. A região Sudeste é a que mais consome energia elétrica, devido ao alto nível de industrialização nesta região, enquanto que a região Sul possui uma tendência de crescimento ao longo dos trimestres e, atualmente, é a segunda região que mais consome energia elétrica. A região Nordeste experimentou uma queda no consumo de eletricidade por parte de suas indústrias a partir do ano de 2010. Por outro lado, as regiões Norte e Centro-Oeste são as que menos consomem energia elétrica, mas possuem uma tendência de crescimento ao longo dos trimestres.

FIGURA 2 – (a) Série Temporal do Consumo de energia elétrica industrial do Brasil e (b) Série Temporal do PIB industrial brasileiro.



Fonte: Elaboração dos autores. (2024)

FIGURA 3 – Séries Temporais do Consumo de energia elétrica industrial das regiões brasileiras.



Fonte: Elaboração dos autores. (2024)

Na Tabela 1, pode-se observar as medidas estatísticas para os dados de consumo de energia elétrica da indústria brasileira e para o PIB industrial brasileiro para o período de 2014 a 2023.

A correlação calculada entre os dados de consumo de energia elétrica da indústria do Brasil e do PIB industrial foi de 0,76, apontando que o uso da série do PIB como variável explicativa pode fornecer melhor capacidade de ajuste e de previsão do consumo.

TABELA 1 - Tabela de medidas estatísticas anuais do consumo de energia da indústria e do PIB de 2014 a 2023.

Variáveis	Média	Desvio Padrão	Mínimo	Máximo	Coef. De Variação
Consumo (GWh)	43335,97	2369,48	36943	47486	5,47
PIB (R\$)	389664,86	121335,67	262129,37	637046,60	31,14

Fonte: Elaboração dos autores. (2024)

3.2 Modelo NNAR

Nesta seção serão apresentados os resultados obtidos pelas abordagens *bottom-up*, *top-down*, de combinação ótima e com a variável do PIB como regressora para prever o comportamento da série temporal do consumo de energia elétrica industrial utilizando o modelo NNAR. Na Tabela 2, são mostrados os resultados das métricas MAPE e RMSE para as abordagens estudadas via o método preditivo de redes neurais NNAR.

TABELA 2 - Desempenho de previsão das abordagens para os dados de consumo de eletricidade industrial do Brasil usando o modelo de Redes Neurais Autorregressivas (NNAR).

Teste	2020		2021		2022		2023		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
<i>Bottom-Up</i>	6,45	3505,56	3,26	1655,06	2,10	1065,20	0,88	534,97	3,17	1690,20
<i>Top-Down</i>	6,46	3434,51	2,89	1451,60	3,25	1675,70	0,54	291,75	3,28	1713,39
Ótima	6,52	3478,69	3,32	1750,79	2,49	1285,74	0,56	267,99	3,22	1695,80
Regressor	6,40	3516,71	3,24	1683,52	1,95	1048,87	0,69	329,90	3,07	1644,75

Fonte: Elaboração dos autores. (2024)

3.3 Modelo MLP

Nesta seção serão apresentados os resultados obtidos pelas abordagens *bottom-up*, *top-down*, de combinação ótima e com a variável do PIB industrial como regressora para prever o comportamento da série temporal do consumo de energia elétrica industrial utilizando o modelo MLP. Na Tabela 3 apresentam-se os resultados das métricas MAPE e RMSE para as abordagens estudadas aplicando-se o método preditivo de redes neurais MLP.

TABELA 3 - Desempenho de previsão das abordagens para os dados de consumo de eletricidade industrial do Brasil usando o modelo de Redes Neurais Multicamadas *Perceptron* (MLP).


Teste	2020		2021		2022		2023		Média	
	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE
<i>Bottom-Up</i>	7,55	3914,04	4,21	2343,55	0,97	526,29	2,08	1143,19	3,70	1981,77
<i>Top-Down</i>	6,83	3827,18	1,82	914,61	2,12	1289,37	1,03	568,87	2,95	1650,01
Ótima	6,49	3469,10	2,86	1468,06	2,59	1328,81	0,42	1328,81	3,09	1616,73
Regressor	7,75	4093,97	1,35	819,06	1,67	986,57	1,75	1162,29	3,13	2206,84

Fonte: Elaboração dos autores. (2024)

3.4 Comparação entre os modelos RNA e MLP


As Figuras 5 e 6 apresentam as previsões através dos modelos RNA e MLP, respectivamente, utilizando as diferentes abordagens adotadas neste trabalho e, para cada um dos quatro conjuntos de teste escolhidos. Sob ambas as redes, no ano de 2020 houve baixa capacidade preditiva no vale provocado pela pandemia de COVID-19 (painel superior esquerdo). As previsões obtidas pela rede MLP, nos anos subsequentes acompanharam os comportamentos dos conjuntos de teste, sendo que para o ano de 2023 houve a melhor performance. A rede RNA também se destacou no ano de 2023, todavia, para o ano de 2022, as diferentes propostas não conseguiram capturar o crescimento da demanda energética no terceiro trimestre.

FIGURA 5 – Previsão para o consumo de energia elétrica industrial brasileiro dos quatro conjuntos de teste (diferentes painéis) utilizando as diferentes abordagens sob o modelo de rede neural autorregressiva (RNA).



Fonte: Elaboração dos autores. (2024)

FIGURA 6 – Previsão para o consumo de energia elétrica industrial brasileiro dos quatro conjuntos de teste (diferentes painéis) utilizando as diferentes abordagens sob o modelo de rede neural de múltiplas camadas ocultas (MLP).



Fonte: Elaboração dos autores. (2024)

4. CONCLUSÃO

Neste contexto, foram aplicadas as abordagens *bottom-up*, *top-down* e combinação ótima. Como modelos preditivos acoplados a estas abordagens, foram utilizados redes neurais autorregressivas (RNA) e redes neurais multicamadas perceptron (MLP) com o PIB industrial como variável regressora.

As abordagens consideradas neste trabalho apresentaram um MAPE médio inferior a 3,85%. A abordagem *top-down* apresentou a melhor capacidade preditiva média através do modelo MLP sem variável regressora. Os métodos se destacaram no ano de 2023 com MAPE inferiores a 2,32%. Para o modelo de redes neurais autorregressiva a melhor abordagem foi utilizando a variável regressora com MAPE igual a 3,07%. Segundo a métrica RMSE, a abordagem com melhor performance foi a combinação ótima acoplada a rede MLP, com uma média de 1616,73.

Portanto, os resultados mostram que a rede neural MLP pode contribuir para a obtenção de projeções de consumo de energia elétrica no horizonte de curto prazo, tanto acoplado a uma abordagem de combinação ótima quanto na *top-down*.

Agradecimentos

Ao CNPq (407972/2021-8) e a CAPES pelo suporte financeiro.

REFERÊNCIAS

- ABOLGHASEMI, M., HYNDMAN, R., SPILIOTIS, E., e BERGMEIR, C. (2022). **Model selection in reconciling hierarchical time series**. Machine Learning, 111:1–51.
- BASTOS, B. Q.; SOUZA, R. C.; Cyrino Oliveira, F. L. **Bottom-up long-term forecasting of brazilian commercial class electricity consumption: First results**. Procedia Computer Science, v. 55, p. 388–394, 2015. ISSN 1877-0509. 3rd International Conference on Information Technology and Quantitative Management, ITQM 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S187705091501563X>>.
- CABREIRA, M. M. L.; da SILVA, F. L. C.; da Silva CORDEIRO, J.; Serrano HERNÁNDEZ, R.M.; Canas RODRIGUES, P.; LÓPEZ-GONZALES, J.L. **A Hybrid Approach for Hierarchical Forecasting of Industrial Electricity Consumption in Brazil**. *Energies* **2024**, 17, 3200. <https://doi.org/10.3390/en17133200>
- EPE. Anuário Estatístico de Energia Elétrica. 2024. Disponível em: <<https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>>.
- FEYNMAN, R.; VERNON, F. **The theory of a general quantum system interacting with a linear dissipative system**. Annals of Physics, v. 24, p. 118–173, 1963. ISSN 0003-4916. Disponível em: <<https://www.sciencedirect.com/science/article/pii/000349166390068X>>.
- FILGUEIRAS, D.B., DA SILVA, F.L.C.: A study on the prediction of electricity consumption considering the energy efficiency measures—applied in case of the brazilian public sector. Energy Efficiency 16, 94 (2023). <https://doi.org/10.1007/s12053-023-10160-2>
- FLEITER, T. et al. Energy efficiency in the german pulp and paper industry – a model-based assessment of saving potentials. Energy, v. 40, n. 1, p. 84–99, 2012. ISSN 0360-5442. Disponível em: < <https://doi.org/10.1016/j.energy.2012.02.025> >
- GEROSKI, P. **Models of technology diffusion**. Research Policy, v. 29, n. 4, p. 603–625, 2000. ISSN0048-7333. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S004873339900092X>>.
- HERBST, A.; TORO, F.; REITZE, F. **Introduction to energy systems modelling**. Swiss J Econ Stat, v. 148, p. 111–135, 04 2012.
- HYNDMAN, R. J., AHMED, R. A., ATHANASOPOULOS, G., e SHANG, H. L. (2011). **Optimal combination forecasts for hierarchical time series**. Computational Statistics & Data Analysis, 55(9):2579–2589. ISSN 0167-9473.
- HYNDMAN, R. J. e KHANDAKAR, Y. (2008). **Automatic time series forecasting: the forecast package for r**. Journal of statistical software, 27:1–22.
- HYNDMAN, R. J., LEE, A. J., e WANG, E. (2016). **Fast computation of reconciled forecasts for hierarchical and grouped time series**. Computational Statistics & Data Analysis, 97:16–

32. ISSN 0167-9473.

HYNDMAN, R. e ATHANASOPOULOS, G. (2018). **Forecasting: Principles and Practice**. OTexts, Australia, 2nd edition.

INSTITUTO DE PESQUISA E ESTATÍSTICA APLICADA. IPEA DATA. 2024. Disponível em: <<http://ipeadata.gov.br/Default.aspx>>.

MANCUSO, P., PICCIALLI, V., e SUDOSO, A. M. (2021). **A machine learning approach for forecasting hierarchical time series**. Expert Systems with Applications, 182:115102. ISSN 0957-4174. URL: <https://www.sciencedirect.com/science/article/pii/S0957417421005431>.

KAUSHIK, S. et al., **AI in healthcare: time-series forecasting using statistical**, Neural, Ensemble Archit. 3 (4) (2020)

MACAIRA, P. et al. **Forecasting residential electricity consumption: a bottom-up approach for brazil by region**. Energy Efficiency, v. 13, p. 911–934, 2020. ISSN 1570-6478. 3rd International Conference on Information Technology and Quantitative Management, ITQM 2015. Disponível em: <<https://link.springer.com/article/10.1007/s12053-020-09860-w#citeas>>.

MCCULLOCH, W. S.; PITTS, W. **A logical calculus of the ideas immanent in nervous activity**. [S.l.]: Bulletin of Mathematical Biophysics, 1943.

MEIRA, E.; LILA, M. F.; Cyrino Oliveira, F. L. **A novel reconciliation approach for hierarchical electricity consumption forecasting based on resistant regression**. Energy, v. 269, p. 126794, 2023. ISSN0360-5442. Disponível em:<<https://www.sciencedirect.com/science/article/pii/S0360544223001883>>.

PARHIZKARI, L.; NAJAFI, A.; GOLSHAN, M. **Medium term electricity price forecasting using extreme learning machine**, J. Energy Manage. Technol. 4 (2) (2020) 20–27.

SILVA, F. L.; OLIVEIRA, F. L. C.; SOUZA, R. C. **A bottom-up bayesian extension for long term electricity consumption forecasting**. Energy, v. 167, p. 198–210, 2019. ISSN 0360-5442. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0360544218321984>>.

SILVA, F. L. et al. **Forecast of long-term electricity consumption of the industrial sub-sector of pulp and paper in brazil using a bottom-up approach**. Procedia Computer Science, v. 55, p. 514–522, 2015. ISSN 1877-0509. 3rd International Conference on Information Technology and Quantitative Management, ITQM 2015. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1877050915015033>>.

SILVA, F. L. et al. **A bottom-up methodology for long term electricity consumption forecasting of an industrial sector - application to pulp and paper sector in brazil**. Energy, v. 144, p. 1107–1118, 2018. ISSN 0360-5442. Disponível em: <<https://doi.org/10.1016/j.energy.2017.12.078>>.

SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais: para engenharia e ciências aplicadas**. [S.l.]: 2 ed. São Paulo: Artliber, 2016.