

Um Estudo Comparativo de Modelos de Previsão para o Consumo de Eletricidade da Indústria de Cimento no Brasil

Rodrigo Felipe da Silva Mendes

Universidade Federal Rural do Rio de Janeiro
Km 07, BR-465, Seropédica - RJ, 23890-000
rodrigo16rg@gmail.com

Felipe Leite Coelho da Silva

Universidade Federal Rural do Rio de Janeiro
Km 07, BR-465, Seropédica - RJ, 23890-000
felipeleite@ufrrj.br

Kleyton Vieira Sales da Costa

Universidade Federal Rural do Rio de Janeiro
Km 07, BR-465, Seropédica - RJ, 23890-000
kleyton.vsc@gmail.com

RESUMO

O consumo de energia elétrica no setor industrial brasileiro vem sendo investigado ao longo dos últimos anos. Esse interesse está relacionado com o desenvolvimento do setor, o planejamento energético e a eficiência energética. Dessa forma, os modelos de previsão são importantes para a tomada de decisões. O objetivo deste trabalho é comparar diferentes modelos de previsão aplicados aos dados mensais do consumo de energia elétrica da indústria de cimento no Brasil. Assim, foram utilizados o método de Holt-Winters, o modelo ARIMA Sazonal, o modelo linear dinâmico e o modelo de redes neurais autorregressivas. Através das métricas de precisão consideradas, o modelo ARIMA sazonal apresentou o melhor desempenho preditivo para o período analisado.

PALAVRAS CHAVE. Indústria do cimento, previsão, energia elétrica

ABSTRACT

Electricity consumption in the Brazilian industrial sector has been investigated over the past few years. This interest is related to the development of the sector, energy planning and energy efficiency. Thus, forecasting models are important for decision making. The objective of this work is to compare different forecast models applied to monthly electricity consumption data for the cement industry in Brazil. Thus, the prediction models of Holt-Winters, Seasonal ARIMA, dynamic linear and autoregressive neural networks were used. The results showed that the seasonal ARIMA model presented the best predictive performance for the analyzed period.

KEYWORDS. Cement industry, forecasting, electricity.

1. Introdução

Nos últimos anos têm-se investigado as projeções do consumo de energia elétrica em setores da indústria no Brasil, seja a curto ou longo prazo [Silva et al., 2018]. Esse interesse está relacionado com o desenvolvimento do setor, o planejamento energético e a eficiência energética. Além disso, a energia elétrica tem uma importância econômica e social para um país ou região, fazendo com que as projeções sejam ferramentas importantes na tomada de decisão de órgãos e entidades que atuam no setor energético [Ardakani e Ardehali, 2014].

Neste contexto, vários modelos têm sido utilizados para obter as projeções de eletricidade, tais como os modelos de regressão [Taylor e Buizza, 2003; Bianco et al., 2009], os modelos de Box e Jenkins, e de amortecimento exponencial [Taylor e Mcsharry, 2007], os modelos de redes neurais [Santana et al., 2012], modelo linear dinâmico bayesiano [Sadownik e Barbosa, 1999], os modelos semi-paramétricos aditivos [Fan e Hyndman, 2012], abordagem *bottom-up* [Huang et al., 2016; Silva et al., 2018] e abordagem *bottom-up* estocástica [Silva et al., 2019].

A indústria cimenteira no Brasil apresenta grande demanda de consumo de energia, dentre elas a energia elétrica e de outros derivados para que se possa obter o seu produto final, ou seja, o cimento Portland. O Portland é um dos principais itens utilizados pelo ser humano e seu processo produtivo tem o calcário e a argila como substâncias minerais fundamentais. Tais matérias-primas são necessárias para o fornecimento dos compostos que são essenciais para a produção de cimento, uma vez que é delas que se origina o clínquer (o principal componente do cimento Portland). A partir de sua produção ele recebe uma adição do carbonato de cálcio (gesso), entre outras adições, de acordo com o tipo de cimento que se deseja produzir.

Segundo dados do Sindicato Nacional da Indústria do Cimento [2021], o cimento é um dos principais materiais utilizados na construção civil. Esse setor que já chegou a representar cerca de 6% da economia brasileira segundo dados de 2014. A indústria de cimento é importante para o desenvolvimento do Brasil uma vez que o setor é responsável por aproximadamente 70 mil empregos sendo um propulsor na geração de renda que, em cenários anteriores a pandemia do Covid-19, alcançou valores próximos aos R\$ 27 bilhões de reais ao ano e uma arrecadação líquida que se aproxima de R\$ 3 bilhões em tributos anuais.

A finalidade deste trabalho é comparar diferentes abordagens de modelos de previsão de séries temporais (clássica, bayesiana e de redes neurais) aplicados ao consumo de energia elétrica na indústria de cimento no Brasil. Para abordagem clássica foram considerados para análise o método de Holt-Winters aditivo [Granger e Newbold, 1977; Winters, 1960] e o modelo ARIMA Sazonal (ou SARIMA) [Box et al., 2015]. Em seguida foi utilizado o modelo de redes neurais autorregressivas [Adya e Collopy, 1998; Hyndman e Athanasopoulos, 2018]. Por último foi aplicado o modelo linear dinâmico [West e Harrison, 1997] que nos permite analisar estruturas de séries temporais flexíveis, tais como um crescimento linear ou sazonalidade, que se aplicam a série temporal deste estudo, entre outras.

O trabalho está organizado da seguinte forma: na seção 2 se apresenta uma breve descrição teórica dos modelos e métodos de previsão utilizados. Na seção 3 são apresentados os resultados obtidos. E na seção 4 são expostas as principais conclusões obtidas no trabalho.

2. Metodologia

Os dados de consumo de energia elétrica foram obtidos no sítio eletrônico da Empresa de Pesquisa Energética (EPE) e no Sindicato Nacional da Indústria do Cimento (SINC). Neste trabalho, foram utilizados os dados mensais do consumo de energia elétrica de janeiro de 2001 até dezembro de 2019 da indústria de cimento no Brasil. O conjunto de treino foi estabelecido entre janeiro de

2001 e dezembro de 2017. E o conjunto de teste entre janeiro de 2018 e dezembro de 2019 para avaliar a qualidade da previsão 24 passos à frente.

O desempenho dos modelos foi medido através das métricas de precisão raiz do erro quadrático médio (RMSE), erro médio absoluto (MAE) e o erro médio absoluto percentual (MAPE).

As análises estatísticas foram realizadas através do programa R 4.0.5 (The R foundation for Statistical Computing, Vienna, Austria; <http://www.r-project.org>).

2.1. Método de Holt-Winters

O método de Holt-Winters é utilizado por se ajustar a uma grande quantidade de séries temporais, sendo esse método adequado para séries de comportamento mais geral, tendo em vista que na prática uma grande parte das séries encontradas possuem componentes de sazonalidade [Hyndman e Athanasopoulos, 2018]. Existem dois métodos distintos de análise proposta pelo modelo: o aditivo e o multiplicativo. Ambos os modelos foram aplicados a série analisada; assim como foram calculados os seus respectivos erros, e constatou-se que o sazonal aditivo é o mais adequado para série, isto é para cada $t = 1, \dots, T$,

$$Y_t = a_1 + b_1 t + \gamma_t + \epsilon_t \quad (1)$$

Em que ϵ_t é o ruído e, a_1 , b_1 e γ_t são, respectivamente, considerados os parâmetros de suavização para o nível, tendência e sazonalidade.

2.2. Modelo SARIMA

Os modelos de Box e Jenkins determinam o processo estocástico adequado para representar uma determinada série temporal por meio da passagem de um ruído branco por um filtro linear [Box et al., 2015]. O modelo utilizado foi o ARIMA sazonal (SARIMA) para incorporar a componente de sazonalidade presente na série temporal deste estudo.

A estrutura do modelo SARIMA de ordem segue os componentes simples (p, d, q) e sazonais $(P, D, Q)_s$, pode ser definido como:

$$\phi(B)\Phi(B^s)\nabla^s\nabla_s^D Y_t = \theta(B)\Theta(B^s)a_t, \quad (2)$$

em que $\phi(B)$ é denominado operador auto-regressivo de ordem p ; $\theta(B)$ será considerado o operador de médias móveis de ordem q ; $\Phi(B^s)$ será o operador auto-regressivo sazonal de ordem P ; $\Theta(B^s)$ será o operador de médias móveis sazonais de ordem Q ; ∇^d é o operador da diferença simples e; ∇_s^D será o operador da diferença sazonal; a_t é um ruído branco.

2.3. Redes Neurais Autorregressivas

O modelo de redes neurais artificiais busca modelar a relação entre um conjunto de sinais de entrada e um sinal de saída. Uma rede neural *feedforward* pode ser representada através de uma camada oculta e uma camada de entradas defasadas, sendo uma abordagem útil para a previsão de séries temporais univariadas. Ao utilizar-se os valores defasados da série temporal como entradas para uma rede neural *feedforward*, esse processo é chamado de autorregressão de redes neurais ou modelo NNAR [Hyndman e Athanasopoulos, 2018].

Neste trabalho foi utilizado um modelo NNAR que considera sazonalidade. Para o modelo NNAR $(p, P, k)_m$, a camada de entrada é escrita como $(y_{t-1}, y_{t-2}, \dots, y_{tp}, y_{tm}, y_{t-2m}, y_{t-Pm})$ com uma camada oculta que possui k nós.

2.4. Modelo Linear Dinâmico

Os modelos lineares dinâmicos fazem parte da classe de modelos de espaço de estados, sendo uma formulação elegante e robusta tanto para o ajuste como para a previsão de séries temporais [West e Harrison, 1997]. O modelo linear dinâmico utilizado neste estudo considera crescimento linear e sazonalidade sendo definido por:

$$\begin{aligned} Y_t &= \mu_t + \gamma_t + \epsilon_t, & \epsilon_t &\sim \mathcal{N}(0, V_\epsilon), \\ \mu_t &= \mu_{t-1} + \beta_{t-1} + \delta_{\mu t}, & \delta_{\mu t} &\sim \mathcal{N}(0, V_\mu), \\ \beta_t &= \beta_{t-1} + \delta_{\beta t}, & \delta_{\beta t} &\sim \mathcal{N}(0, V_\beta), \\ \gamma_t &= -\sum_{i=1}^{11} \gamma_{t-i} + \delta_{\gamma t}, & \delta_{\gamma t} &\sim \mathcal{N}(0, V_\gamma), \end{aligned} \quad (3)$$

em que μ_t é o nível, β_t é a inclinação, γ_t é o fator sazonal, V_e é a variância observacional, V_μ , V_β e V_γ são as variâncias dos estados do sistema, e os erros ϵ_t , $\delta_{\mu t}$, $\delta_{\beta t}$ e $\delta_{\gamma t}$ são internamente e mutuamente independentes.

3. Resultados e Discussão

Nesta seção serão apresentados os resultados encontrados através do método de Holt-Winters, modelo ARIMA sazonal (SARIMA), modelo de redes neurais autorregressivas e o modelo linear dinâmico. Assim os principais resultados serão apresentados e interpretados através da representação gráfica e também das métricas de precisão utilizadas para comparar os conjuntos de treino e teste.

3.1. Método de Holt-Winters

Na Figura 1 observa-se os resultados de ajuste e previsão do método aditivo de Holt-Winters aplicado ao consumo de energia elétrica da indústria do cimento no Brasil. Os resultados mostram que o modelo foi capaz de se ajustar de maneira razoável aos dados do conjunto de treino. E as previsões geradas pelo modelo também se mostram razoáveis, não sendo capazes de prever completamente o comportamento sazonal observado na série.

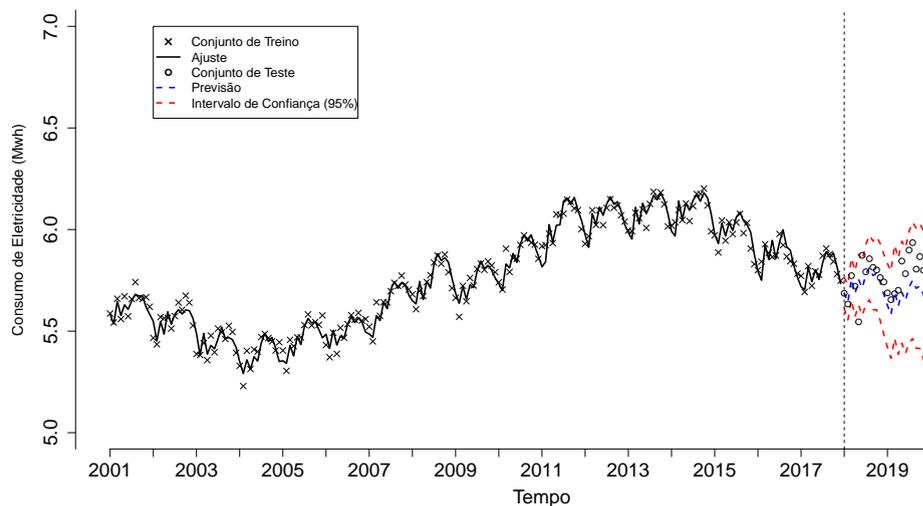


Figura 1: Resultados de Ajuste e Previsão para o método de Holt-Winters.

3.2. Modelo SARIMA

Para que se possa identificar o modelo SARIMA mais adequado é necessário verificar o comportamento da série temporal, da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP).

A série temporal do consumo de eletricidade é claramente não estacionária (Figura 2(a)) com alguma sazonalidade, portanto, primeiramente será necessário uma diferença sazonal. Pode-se observar que os dados sazonalmente diferenciados também não são estacionários (Figura 2(b)). Assim será necessário uma primeira diferença adicional (Figura 2(c)).

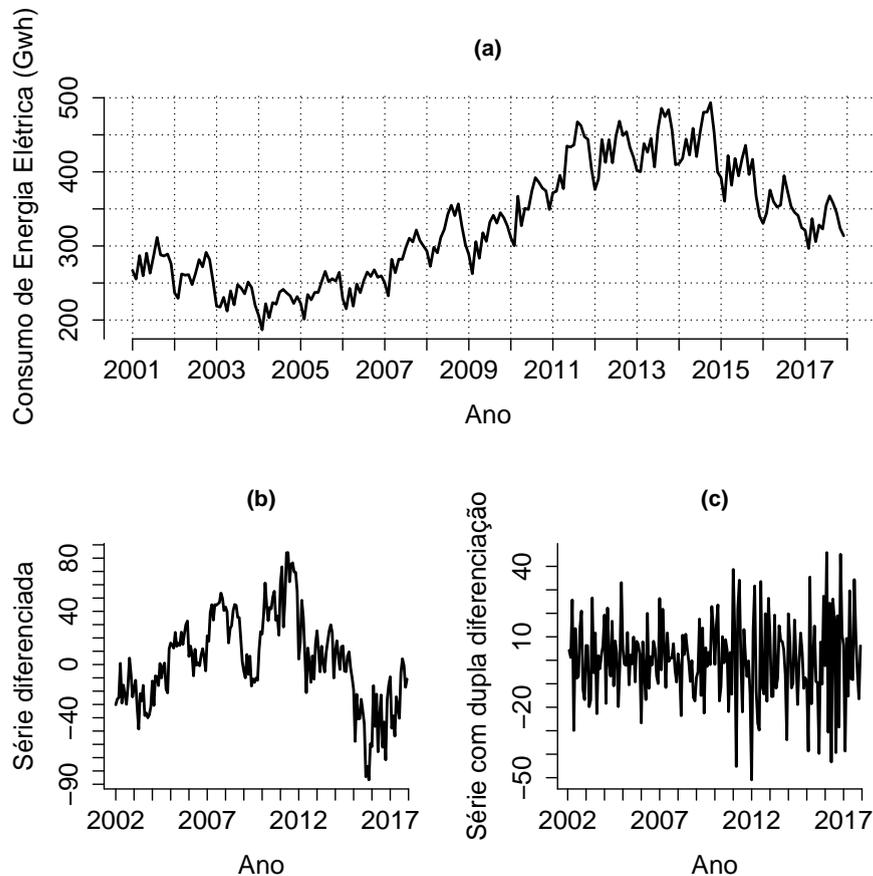


Figura 2: Série temporal (a), série temporal com diferença sazonal (b) e série temporal com dupla diferenciação (c).

Na figura 3(a) a FAC mostra um pico significativo na defasagem 1 sugerindo uma componente de médias móveis (MA(1)) não sazonal, e o aumento significativo na defasagem 12 que sugere uma componente de médias móveis sazonal. Pela FACP pode-se observar um pico significativo na defasagem 3 sugerindo uma componente autorregressiva (AR(3)) não sazonal e um pico acentuado no atraso 12 sugerindo uma componente autorregressiva sazonal. Consequentemente será considerado inicialmente com base nas funções de autocorrelação um modelo SARIMA(3, 1, 1) \times (1, 1, 1)₁₂. Através do teste de sobre-fixação para verificar a possibilidade da existência de um modelo de ordem mais elevada, foi encontrado o modelo SARIMA(3, 1, 2) \times (1, 1, 1)₁₂.

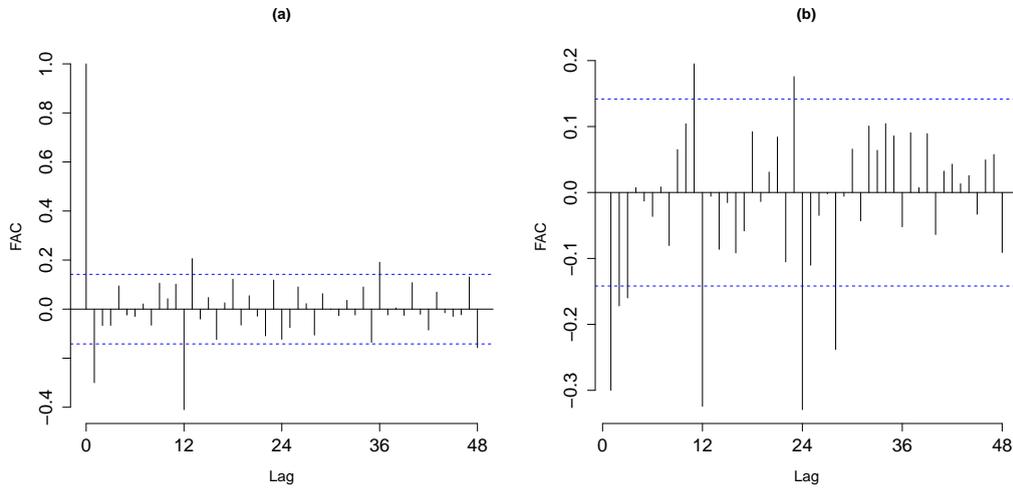


Figura 3: Função de autocorrelação (a) e autocorrelação parcial (b).

A figura 4(a) mostra os resíduos gerados a partir do ajuste do modelo $SARIMA(3, 1, 2) \times (1, 1, 1)_{12}$. Pode-se observar que todos os picos estão dentro dos limites de significância da FAC (Figura 4(b)), então o processo gerou um ruído branco. Além disso pelo teste de Jarque-Bera o valor do p-valor obtido foi igual a 0.2941, o que nos leva a aceitar a hipótese de normalidade dos resíduos ao nível de significância de 5%.

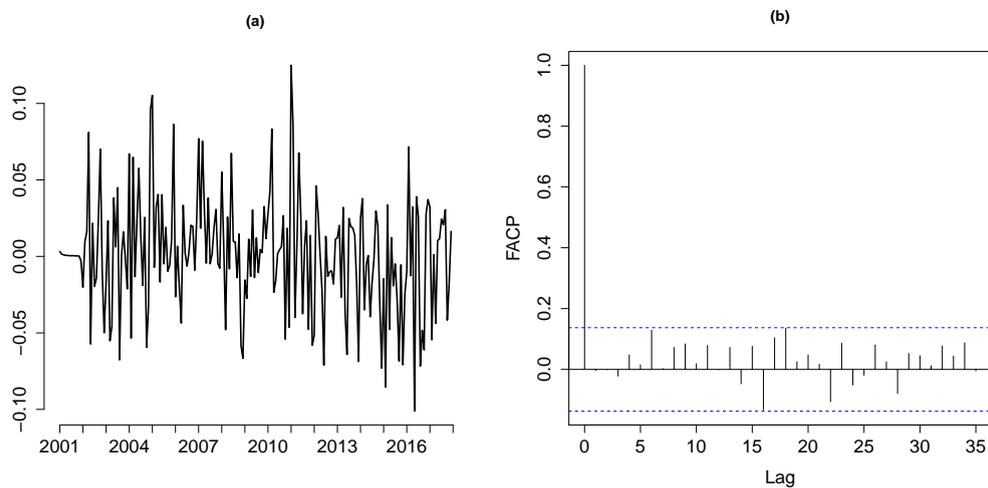


Figura 4: Série residual do ajuste do modelo $SARIMA(3, 1, 2) \times (1, 1, 1)_{12}$ (a) e a função de autocorrelação do resíduo (b).

A Figura 5 apresenta os resultados obtidos através do modelo SARIMA aplicado aos dados de consumo energia elétrica da indústria de cimento no Brasil. Gráficamente, observa-se que o modelo foi capaz de se ajustar aos conjunto de treino de forma satisfatória, adaptando-se a estrutura e aos componentes observados de tendência e sazonalidade. O mesmo desempenho satisfatório é observado com relação à previsão gerada pelo modelo.

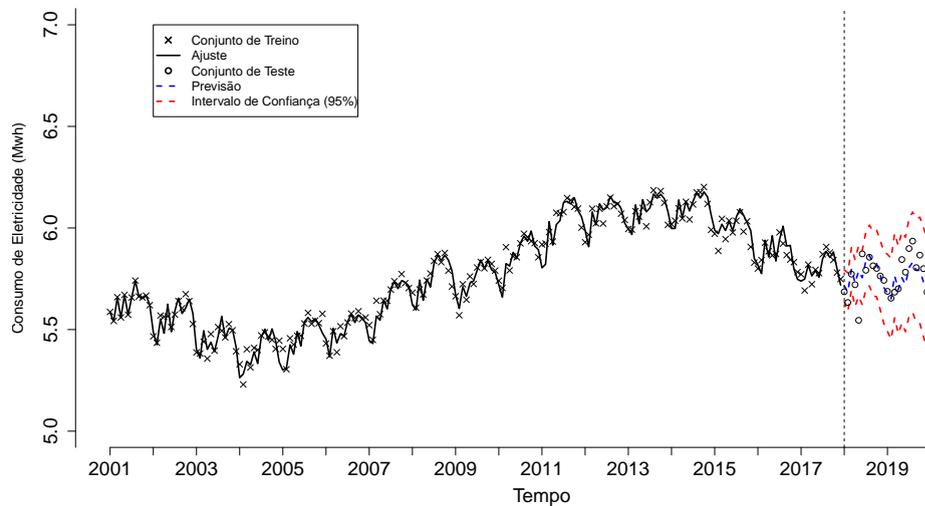


Figura 5: Resultados de ajuste e previsão para o modelo SARIMA.

3.3. Redes Neurais Autorregressivas

A Figura 6 apresenta os resultados obtidos através do modelo de redes neurais autorregressivas para os dados de consumo de energia elétrica para a indústria do cimento. Observa-se que o modelo foi capaz de se ajustar ao conjunto de treino de maneira satisfatória, capturando os componentes de tendência e sazonalidade observados na série. Gráficamente a capacidade preditiva do modelo não pode ser considerada satisfatória, o que deverá ser validado através das métricas de precisão.

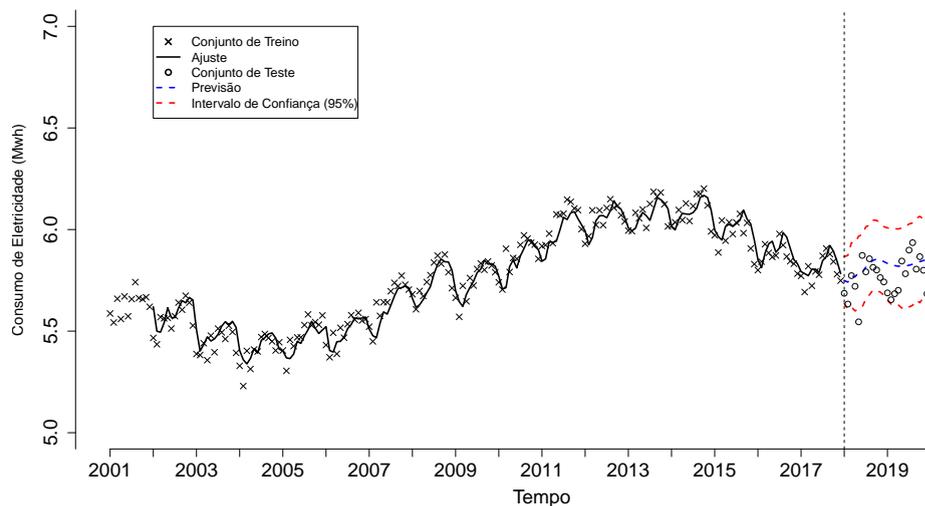


Figura 6: Resultados de ajuste e previsão para o modelo de redes neurais autorregressivas.

3.4. Modelo Linear Dinâmico

Na Figura 7 observa-se os resultados obtidos através do modelo linear dinâmico para os dados de consumo de energia elétrica na indústria de cimento no Brasil.

Os resultados apresentados indicam um ajuste razoável após um período de adaptação do modelo aos dados entre os anos de 2001 e 2002. Graficamente nota-se que a capacidade preditiva do modelo foi limitada, não prevendo de forma completa o comportamento sazonal dos dados observados.

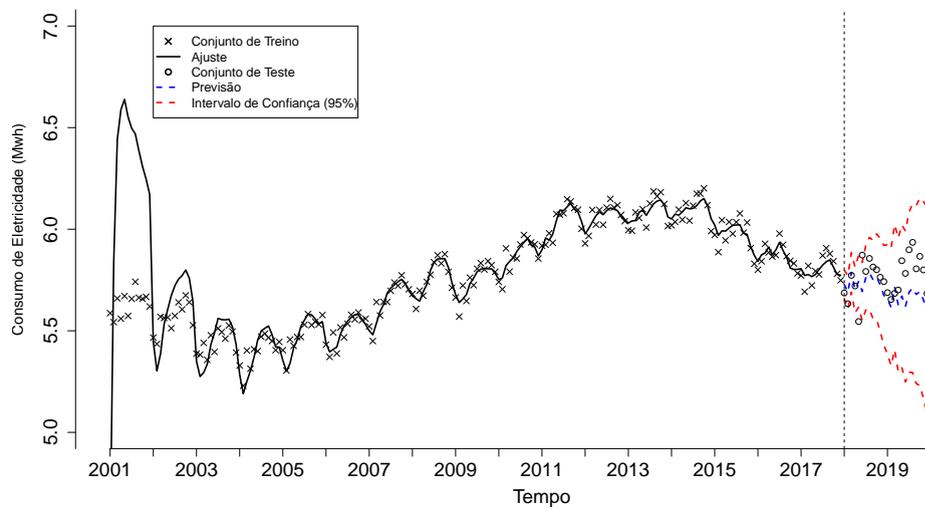


Figura 7: Resultados de ajuste e previsão para o modelo linear dinâmico.

3.5. Comparação entre os modelos Holt-Winters, SARIMA, Redes Neurais, linear dinâmico.

3.5.1. Métricas de Ajuste

Analisando os valores apresentados pelas métricas na Tabela 2 verificou-se que o modelo SARIMA possui os menores valores em duas das três métricas consideradas. Assim conclui-se que dentre os modelos considerados, o modelo SARIMA foi o que obteve a melhor capacidade de ajuste aos dados de consumo de energia elétrica para a indústria de cimento no Brasil.

Tabela 1: Métricas de ajuste.

Modelo	RMSE	MAE	MAPE
Holt-Winters aditivo	0.0376	0.0293	0.5117
SARIMA $(3, 1, 2) \times (1, 1, 1)_{12}$	0.0387	0.0292	0.5089
NNAR	0.0584	0.0468	0.8157
Linear dinâmico	0.2010	0.0815	1.4389

3.5.2. Métricas de Previsão

Considerando a capacidade preditiva dos modelos em relação ao conjunto de teste, observa-se que o modelo SARIMA foi o que obteve os menores valores para as três métricas de precisão consideradas. Com isso, pode-se concluir que o modelo SARIMA gerou as melhores previsões para

o conjunto de teste, sendo aquele com a melhor capacidade preditiva para os dados de consumo de energia elétrica para a indústria do cimento no Brasil.

Tabela 2: Métricas de previsão.

Modelo	RMSE	MAE	MAPE
Holt-Winters aditivo	0.1024	0.0804	1.3903
SARIMA $(3, 1, 2) \times (1, 1, 1)_{12}$	0.0734	0.0505	0.8790
NNAR	0.0984	0.0800	1.3996
Linear dinâmico	0.1171	0.0815	1.6486

4. Conclusão

Este trabalho apresentou a aplicação dos modelos de Holt-Winters aditivo, Arima sazonal (SARIMA), redes neurais autorregressivas e linear dinâmico com o intuito de prever o consumo de energia elétrica da indústria de cimento no Brasil. Os dados em análise compreendem o período entre janeiro de 2001 e dezembro de 2017, obtidos através do Sindicato Nacional da Indústria do Cimento [2021] e Empresa de Pesquisa Energética [2021].

Os resultados encontrados através das métricas de precisão consideradas neste estudo (RMSE, MAE e MAPE) mostram que o modelo SARIMA foi aquele com a melhor capacidade preditiva entre os modelos em análise. O desempenho do modelo foi o melhor tanto para o ajuste em relação ao conjunto de treino como para a previsão em relação ao conjunto de teste.

A indústria do cimento mensura a capacidade produtiva de uma determinada região ou país através da avaliação de questões como por exemplo o nível de crescimento da construção civil. Dessa maneira a previsão do consumo de energia elétrica desta indústria atua como um instrumento de apoio à decisão relevante para legisladores e agentes econômicos. Assim estudos futuros podem considerar outros modelos de redes neurais artificiais e modelos de espaço de estado que incorporem componentes dinâmicas.

Referências

- Adya, M. e Collopy, F. (1998). How effective are neural networks at forecasting and prediction? a review and evaluation. *Journal of Forecasting*, 17:481–495.
- Ardakani, F. J. e Ardehali, M. M. (2014). Novel effects of demand side management data on accuracy of electrical energy consumption modeling and long-term forecasting. *Energy Conversion and Management*, 78:745–752.
- Bianco, V., Manca, O., e Nardini, S. (2009). Electricity consumption forecasting in Italy using linear regression models. *Energy*, 34(9):1413–1421. ISSN 0360-5442. URL <https://www.sciencedirect.com/science/article/pii/S0360544209002539>.
- Box, G. E. P., Jenkins, G. M., e Reinsel, G. C. (2015). *Time Series Analysis: Forecasting and Control*. Prentice-Hall.
- Empresa de Pesquisa Energética (2021). Séries estudos de energia, anuário estatístico de energia elétrica. URL <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>.

- Fan, S. e Hyndman, R. J. (2012). Short-term load forecasting based on a semi-parametric additive model. *IEEE Transactions on Power Systems*, 27:134–141.
- Granger, C. W. J. e Newbold, P. (1977). *Forecasting Economic Time Series*. Academic Press, New York.
- Huang, Y.-H., Chang, Y.-L., e Fleiter, T. (2016). A critical analysis of energy efficiency improvement potentials in taiwan's cement industry. *Energy Policy*, 96:14–26. URL <https://www.journals.elsevier.com/energy-policy>.
- Hyndman, R. J. e Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
- Sadownik, R. e Barbosa, E. P. (1999). Short-term forecasting of industrial electricity consumption in brazil. *Journal of Forecasting*, 18:215–224.
- Santana, A. L., Conde, G. B., Rego, L. P., Rocha, C. A., Cardoso, D. L., Costa, J. C., Bezerra, U. H., e Fransc, C. R. (2012). Predict decision support system for load forecasting and inference: A new undertaking for brazilian power suppliers. *Electrical Power and Energy Systems*, 38:33–45.
- Silva, F. L. C., Souza, R. C., Oliveira, F. L. C., Lourenco, P. M., e Calili, R. F. (2018). A bottom-up methodology for long term electricity consumption forecasting of an industrial sector - Application to pulp and paper sector in Brazil. *Energy*, 144:1107 – 1118. ISSN 0360-5442. URL <http://www.sciencedirect.com/science/article/pii/S0360544217321217>.
- Silva, F. L., Cyrino Oliveira, F. L., e Souza, R. C. (2019). A bottom-up bayesian extension for long term electricity consumption forecasting. *Energy*, 167:198–210. ISSN 0360-5442. URL <https://www.sciencedirect.com/science/article/pii/S0360544218321984>.
- Sindicato Nacional da Indústria do Cimento (2021). Relatórios anuais de 2001 a 2020. URL <http://snic.org.br/numeros-relatorio-anual.php>.
- Taylor, J. W. e Buizza, R. (2003). Using weather ensemble predictions in electricity demand forecasting. *International Journal of Forecasting*, 19:57–70.
- Taylor, J. e Mcsharry, P. (2007). Short-term load forecasting methods: An evaluation based on european data. *Power Systems, IEEE Transactions on*, 22:2213 – 2219.
- West, M. e Harrison, J. (1997). *Bayesian forecasting and dynamic models*. Springer, New York.
- Winters, P. R. (1960). Forecasting sales by exponentially weighted moving averages. *Management Science*, 6(3):324–342. URL <https://EconPapers.repec.org/RePEc:inm:ormnsc:v:6:y:1960:i:3:p:324-342>.