

Previsão do Consumo de Energia Elétrica na Região Sudeste: Um Estudo de Caso Usando SARIMA e LSTM

Forecast of Electricity Consumption in the Southeast Region: A Case of Study Using SARIMA and LSTM

José Airton Azevedo dos Santos¹, Yasmin Chaucoski²

RESUMO

O presente trabalho tem como objetivo avaliar modelos, baseados em redes neurais LSTM (*Long Short-Term Memory*) e SARIMA (*Seasonal Auto-regressive Integrated Moving Average*), para a previsão do consumo de energia elétrica da região sudeste do Brasil. A base de dados, disponibilizada pela Empresa de Pesquisa Energética (EPE), apresenta uma série histórica mensal, do consumo de energia elétrica, no período entre Janeiro de 2004 e Maio de 2020, representado 197 observações mensais. Os modelos SARIMA e LSTM foram implementados na linguagem Python. Os resultados obtidos, para um horizonte de curto prazo, mostram que os modelos fornecem estimativas confiáveis para o consumo de energia elétrica da região sudeste.

Palavras-chave: Modelos de previsão. Eletricidade. Python.

ABSTRACT

The present work aims to evaluate models, based on LSTM (*Long Short-Term Memory*) neural networks and SARIMA (*Seasonal Auto-regressive Integrated Moving Average*), for the forecast of electric energy consumption in the southeastern region of Brazil. The database, made available by the Energy Research Company (EPE), presents a monthly historical series of electricity consumption, in the period between January 2004 and May 2020, representing 197 monthly observations. The SARIMA and LSTM models were implemented in the Python language. The results obtained, for a short term horizon, show that the models provide reliable estimates for the electric energy consumption in the southeast region.

Keywords: Forecasting models. Electricity. Python.

¹ Doutor em Engenharia Elétrica. Docente do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA). Universidade Tecnológica Federal do Paraná (UTFPR). E-mail: airton@utfpr.edu.br

² Discente. Engenharia Elétrica. Universidade Tecnológica Federal do Paraná (UTFPR). E-mail: chaucoski@alunos.utfpr.edu.br

1. INTRODUÇÃO

A energia elétrica tem um papel importante na economia mundial. É considerada como um dos indicadores do nível de qualidade de vida e do desenvolvimento econômico. As pessoas dependem, direta ou indiretamente, da eletricidade e as indústrias a utilizam como um fator de produção (KHEIRKHAH et al., 2013; STENGHELE et al., 2020).

A previsão do consumo de eletricidade é um fator importante no planejamento eficiente de um sistema de geração de energia. Métodos de previsão, de séries temporais, podem ser utilizados para avaliar o consumo de energia elétrica ao longo do tempo. Uma série temporal é qualquer conjunto de observações ordenado no tempo. As observações podem ser diárias, semanais, mensais, etc (MORETTIN, 2008; JUNIOR, 2018).

Dentre os métodos de previsão, de séries temporais, têm-se os métodos quantitativos SARIMA (Autoregressivos Integrados de Médias Móveis com a Característica Sazonal da Série) e as Redes Neurais Artificiais (RNAs). Métodos quantitativos podem realizar previsões, de períodos futuros, por meio de dados históricos (TUBINO, 2009).

Os modelos ARIMA e SARIMA são muito utilizados para previsão de séries temporais. Amaro (2017) analisou a capacidade preditiva, de modelos ARIMA, para o consumo de energia elétrica no Brasil. Contreras (2003) utilizou modelos ARIMA para prever preços de eletricidade para o dia seguinte. Nepal et al. (2019) utilizaram modelos ARIMA para previsão de cargas elétricas em edifícios. Stenghele et al. (2020) utilizaram modelos SARIMA, por meio do software GRET, para previsão do consumo mensal, de energia elétrica, da região sudeste do Brasil.

Redes Neurais Artificiais têm, também, sido utilizadas com sucesso em tarefas de predição e modelagem de séries temporais (HAYKIN, 2001). Khamis (2011) utilizou redes neurais artificiais para previsão de demanda de energia elétrica em sistemas de potência de pequena escala. Tian (2018) aplicou redes neurais recorrentes na previsão de carga num horizonte de curto prazo. Já Zengh (2017) utilizou redes neurais recorrentes para previsão de cargas elétricas em redes inteligentes.

Dentro deste contexto, este trabalho tem como objetivo avaliar modelos, baseados em redes neurais LSTM (*Long Short-Term Memory*) e SARIMA (*Seasonal Auto-regressive Integrated Moving Average*), para a previsão do consumo de energia elétrica da região sudeste do Brasil.

Este trabalho está organizado da seguinte maneira. Na Seção 2 são descritas as metodologias empregadas na previsão do consumo de energia elétrica da região sudeste. Na Seção 3 são apresentados os resultados obtidos da aplicação dos modelos, SARIMA e LSTM, em observações mensais do consumo de energia elétrica da região sudeste. Comentários finais e conclusões finalizam o trabalho.

2. MATERIAIS E MÉTODOS

Nesta seção aborda-se a metodologia utilizada para realizar essa pesquisa, detalhando os métodos propostos para realização dos experimentos, bem como as técnicas utilizadas.

Base de dados:

Os dados utilizados, neste trabalho, foram obtidos do relatório mensal do consumo de energia, fornecido pela Empresa de Pesquisa Energética – EPE. A EPE é uma empresa pública, instituída nos termos da Lei nº 10.847, de 15 de março de 2004, e do Decreto nº 5.184, de 16 de agosto de 2004 (EPE, 2019; STENGHELE et al., 2020).

Os dados obtidos, da base de dados da EPE, já estavam limpos e sem a presença de *outliers*. Os dez primeiros registros do conjunto de dados são apresentados na Tabela 1.

Tabela 1. Dez primeiros registros do conjunto de dados.

Safra	Consumo (GWh)
2004/1	14,93
2004/2	14,71
2004/3	14,9
2004/4	15,5
2004/5	14,91
2004/6	14,9
2004/7	15,09
2004/8	15,19
2004/9	15,59
2004/10	15,84

Fonte: EPE (2019).

A série temporal (*Observed*) e sua decomposição (*Trend*, *Seasonal* e *Residual*) são apresentados na Figura 1. A série é composta por 197 observações (Janeiro de 2004 a Maio de 2020).

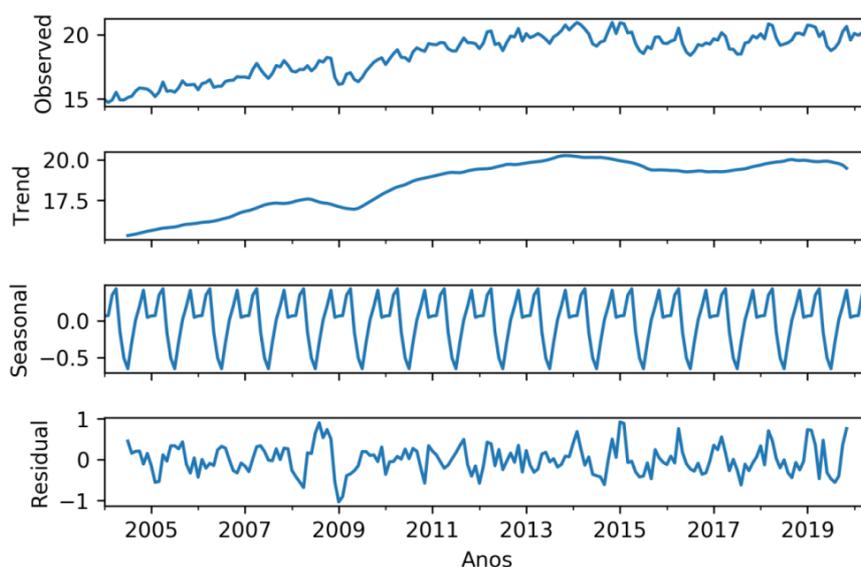


Figura 1. Decomposição da série do consumo da região sudeste

Observa-se da decomposição da série, apresentada na Figura 1, uma tendência (*Trend*) do aumento do consumo ao longo dos anos. Observa-se também que a série possui sazonalidade (*Seasonal*), padrões que se repetem em período fixo de tempo.

SARIMA:

O modelo ARIMA, proposto Box-Jenkins na década de 1970, é um modelo estatístico muito utilizado em análise de séries temporais. Segundo Walter et al. (2013), este modelo tem origem nos modelos autorregressivos (AR), médias móveis (MA) e de combinação de modelos AR e MA (ARMA). Neste estudo, utiliza-se o modelo ARIMA Sazonal, denominado SARIMA, para realizar as previsões do consumo de energia de elétrica da região sudeste (MONTGOMERY et al., 2008, BOX; JENKINS, 1976).

O modelo SARIMA é definido como SARIMA(p,d,q)(P,D,Q), onde D é o termo de diferenciação sazonal do modelo. A definição do modelo é dada por (STENGHELE et al., 2020):

$$\phi(B)\phi(B^S)\Delta^d\Delta_S^D X_t = \theta(B)\theta(B^S)\varepsilon_t \quad 1$$

Onde:

$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$ é o operador autorregressivo estacionário de ordem p ;

$\theta(B) = 1 - \theta_1 B - \dots - \theta_q B^q$ - é o operador de médias móveis invertível de ordem q ;

$\phi(B^S) = 1 - \phi_1 B^S - \dots - \phi_p B^{Sp}$ - é o operador autorregressivo sazonal de ordem P ;

$\theta(B^s) = 1 - \theta_1 B^s - \dots - \theta_q B^{sq}$ – é o operador de médias móveis sazonal de ordem Q , invertível;

$\Delta^d = (1 - B)^d$ – d indicando o número de diferenças;

$\Delta_s = (1 - B^s)^s$ – é o operador diferença sazonal;

$\Delta_s^D = (1 - B^s)^D$ – D indicando o número de diferenças sazonais;

ε_t – representa o ruído branco com média zero.

LSTM:

As redes recorrentes LSTMs contém unidades especiais chamados de blocos de memória. Estes blocos contém células de memória. Uma célula de memória (Figura 2) é composta por três portas: uma porta de entrada (*input gate*), uma porta de esquecimento (*forget gate*) e uma porta de saída (*output gate*). As portas servem para modular as interações entre a própria célula de memória e seu ambiente. A porta de entrada pode permitir que o sinal recebido altere o estado da célula de memória ou bloqueie-o. Por outro lado, a porta de saída pode permitir que o estado da célula de memória tenha efeito sobre outros neurônios ou evite-os. Finalmente, a porta de esquecimento pode modular a conexão auto-recorrente da célula de memória, permitindo que a célula se lembre ou esqueça seu estado anterior, conforme necessário (CARRIER, 2020).

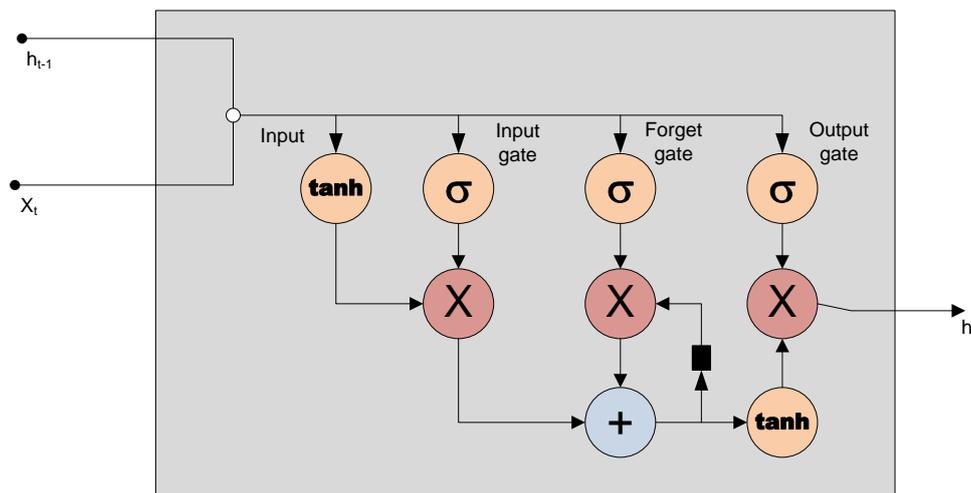


Figura 2. Célula de memória
Fonte: Adaptado de Thomas (2020).

Métricas:

Neste trabalho, os modelos obtidos foram avaliados por (CANKURT; SUBASI, 2015):

- MSE (*Mean Squared Error*): É uma forma de avaliar a diferença entre um estimador e o verdadeiro valor da quantidade estimada.
- RSME (*Root Mean Squared Error*): Penaliza mais os erros maiores, permite avaliar a qualidade de um previsor em relação aos dados.
- MAPE (*Mean Absolute Percent Error*): O MAPE mede o tamanho do erro em termos percentuais.

Na Tabela 2 apresentam-se as equações das métricas MSE, RMSE e MAPE.

Tabela 2. Equações – MSE, RMSE e MAPE.

Sigla	Equação
MSE	$\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)$
RMSE	$\sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)}$
MAPE	$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)/y_i \times 100$

Fonte: Cankurt e Subasi (2015).

Onde: y_i é o valor real do período i , \hat{y}_i é a previsão para o período i e n é o número de observações.

3. RESULTADOS E DISCUSSÃO

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Tabela 3).

Tabela 3. Análise descritiva.

Parâmetro analisado	Sudeste
Média (GWh)	18,42
Mediana (GWh)	18,91
Mínimo (GWh)	14,710
Máximo (GWh)	20,970
Desvio Padrão (GWh)	1,677
Coeficiente de Variação (%)	9,1%

Pode-se observar, dos dados apresentados na Tabela 3, que o consumo ficou, para o período em estudo, em média de 18,42 GWh. Apresentando, neste período, consumos mínimo e máximo de 14.710 GWh e 20,970 GWh, respectivamente. Observa-se também um baixo coeficiente de variação dos dados (9,1%).

SARIMA:

Inicialmente, identificou-se o modelo SARIMA(7,1,7)(0,1,0)₁₂, que obteve, dos modelos testados, o menor valor do critério de AKAIKE (AIC). Na sequência, verificou-se a normalidade e a autocorrelação dos resíduos (Figura 3). Obteve-se, do teste de normalidade (*Jarque-Bera normality test*), um p-valor de 0,353, o que revela a não rejeição da hipótese nula de normalidade dos resíduos. Observa-se do correlograma que os resíduos não são autocorrelacionados, pois os coeficientes de autocorrelação dos resíduos são estatisticamente iguais a zero, isto é, não ultrapassam os limites de confiança.

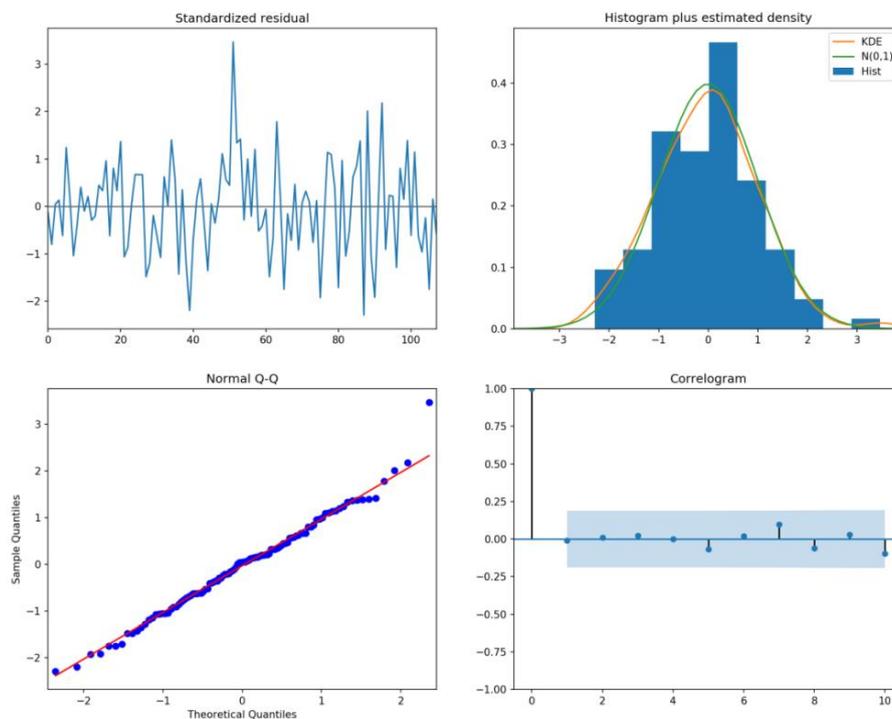


Figura 3. Gráficos do modelo Sarima

Os teste estatísticos realizados, bem como o diagnóstico dos resíduos validaram o modelo SARIMA(7,1,7)(0,1,0)₁₂.

LSTM:

Neste trabalho implementou-se os modelos LSTMs por meio da biblioteca Keras, rodando como *frontend* em TensorFlow. As redes neurais foram treinadas com 129 amostras (67%) e testadas com 63 amostras (33%). O melhor modelo, encontrado por meio das métricas, utilizou o algoritmo de otimização Adam com os seguintes hiperparâmetros: *cells* = 4, *batch* = 1, *learning rate* = 0.0005 e *activate* = relu. Os resultados das métricas, para este modelo, foram MSE=0.32, RMSE=0,56 e MAPE=2,32%.

Como critério de parada utilizou-se o método conhecido como Método de Parada Antecipada (*Earling Stopping*). Segundo Silva (2010), este método ajuda a projetar uma rede neural com bom poder de generalização. Neste contexto, definiu-se neste trabalho, como critério de parada do treinamento, a função *EarlyStopping()* com o parâmetro *patience*=50. O parâmetro *patience* indica o número de épocas, após a qual nenhuma melhoria foi observada.

Na Figura 4, apresenta-se a curva de aprendizagem para a energia consumida na região sudeste. Pode-se observar, por meio da figura, a estabilidade na convergência da curva de treino e teste.

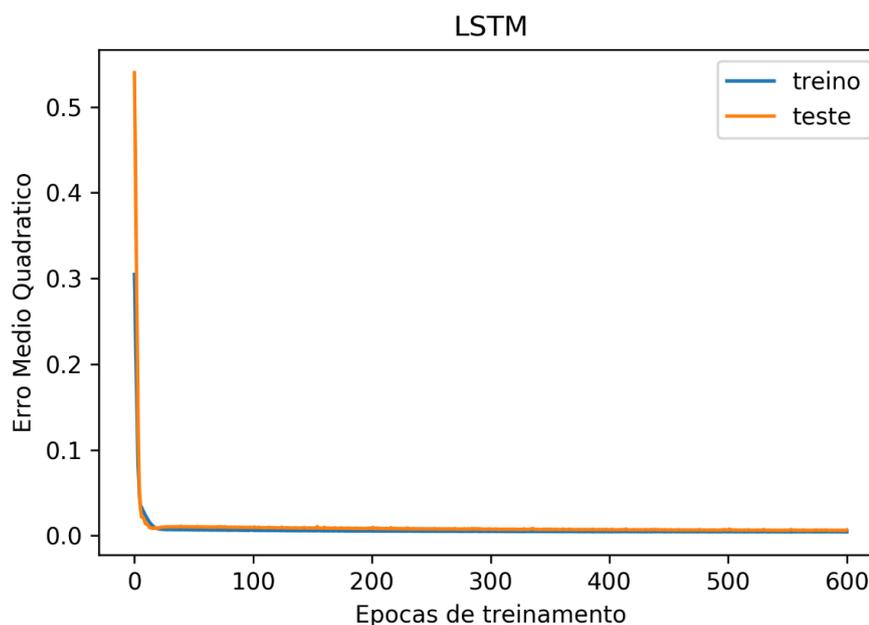


Figura 4. Curva de aprendizagem – Treino e Teste

Na Figura 5 apresentam-se as previsões para os conjuntos de treinamento e teste do modelo LSTM.

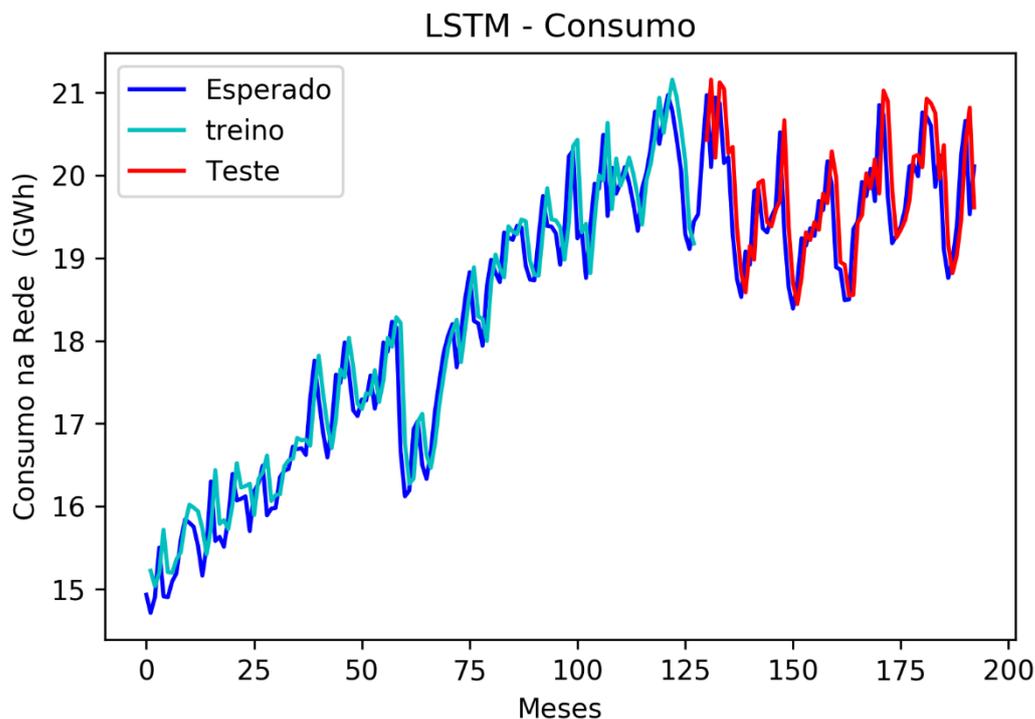


Figura 5. Previsão do consumo na rede – Conjuntos de treino e teste

Previsões:

Na sequência, depois de validar os modelos, realizaram-se previsões do consumo de energia, para os meses que não participaram do processo de treinamento e teste (Janeiro, Fevereiro, Março, Abril e Maio de 2020) (Tabela 4).

Tabela 4. Resultados das previsões para Jan/Fev/Mar/Abr/Mai de 2020 - (GWh).

Mês	EPE	LSTM	SARIMA
Jan/20	20,11	19,43	19,43
Fev/20	19,96	19,27	19,96
Mar/20	20,17	19,12	20,7
Abr/20	18,01	18,99	20,14
Mai/20	17,43	18,82	20,85

Os resultados das previsões, em termos gráficos, são apresentados na Figura 6.

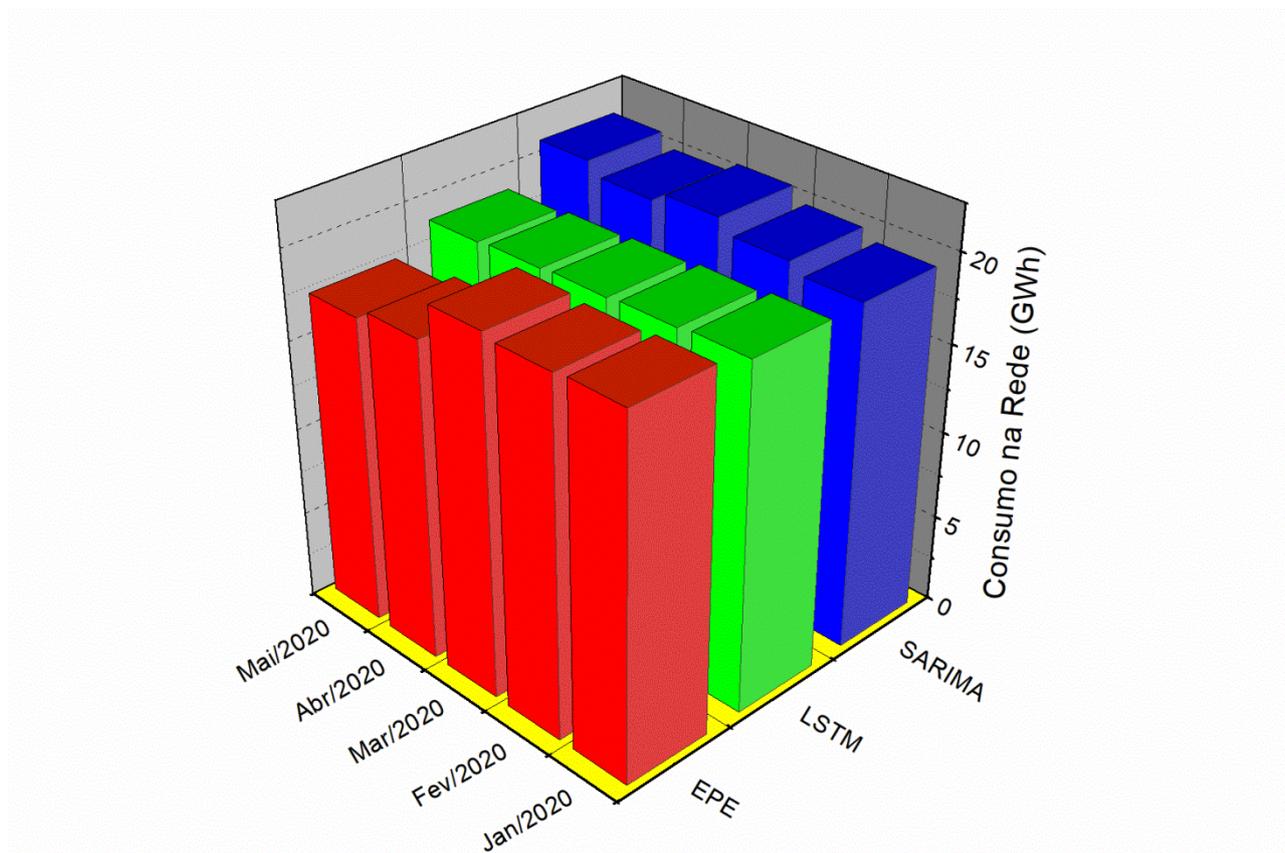


Figura 6. Previsão do consumo na rede (Jan/Fev/Mar/Abr/Mai de 2020)

Observa-se dos resultados apresentados, na Tabela 4 e na Figura 6, que os modelos, LSTM e SARIMA, apresentam resultados muito próximos, aos fornecidos pela Empresa de Pesquisa Energética - EPE, para os meses de Janeiro, Fevereiro, Março, Abril e Maio de 2020.

4. CONSIDERAÇÕES FINAIS

Neste trabalho apresentou-se uma aplicação, de modelos de séries temporais, para previsão do consumo de energia elétrica, da região sudeste do Brasil, utilizando os modelos SARIMA (*Seasonal Auto-regressive Integrated Moving Average*) e LSTM (*Long Short-Term Memory*). Buscou-se, por meio deste estudo, determinar o comportamento

futuro, do consumo de energia elétrica, a partir da dinâmica do passado. Os modelos foram construídos baseados nos dados disponibilizados pela Empresa de Pesquisa Energética – EPE.

Inicialmente, validaram-se os modelos SARIMA e LSTM. Na sequência, estimaram-se os valores referentes aos meses de janeiro, fevereiro, março, abril e maio de 2020, que não participaram do processo de validação. Observou-se, dos dados previstos, que os modelos apresentaram resultados próximos ao da Empresa de Pesquisa Energética – EPE. Portanto, a proximidade entre valores preditos e reais demonstram a boa capacidade de generalização, para um horizonte de curto prazo, dos modelos implementados neste trabalho.

Finalmente, observa-se que as previsões do comportamento, do consumo de energia na região sudeste, podem auxiliar no planejamento do sistema de geração de energia elétrica.

REFERÊNCIAS

AMARO, R. S. Comparação da capacidade preditiva de modelos ARIMA para o consumo de energia elétrica no Brasil. **Revista Unmeet de Contabilidade**, vol. 16, 2017.

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

CANKURT, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, 2015.

CARRIER, P. C. **LSTM network for sentiment analysis**. Disponível em: <<http://deeplearning.net/tutorial/lstm.html>>. Acesso em: 19 mar. 2020.

CONTRERAS, J. ARIMA models to predict next-day electricity. **IEEE Transactions on Power Systems**, vol. 18, 2003.

EPE - Empresa de Pesquisa Energética. **Anuário estatístico de energia elétrica de 2018**. Disponível em: <<http://epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>>. Acesso em: 30 abr. 2019.

HAYKIN, S. **Neural networks: a comprehensive foundation**. New Delhi: Pearson Prentice Hall, 2001.

JUNIOR, L. M. C.; MELQUIADES, T. F.; MARTINS, K. L. C.; JUNIOR, E. P. S. FREITAS, G. P. Previsão de consumo de eletricidade no nordeste brasileiro. **Engevista**, vol. 20, n. 3, 2018.

KHAMIS, M. F. I. **Electricity forecasting for small scale power system using neural network**. In: 5th IEEE Conference, Najing: China, 2011.

KHEIRKHAH, A.; AZADEH, A.; SABERI, M.; AZARON, A.; SHAKOURI, H. Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis. **Computers & Industrial Engineering**, vol. 64, n. 1, 2013.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. New Jersey: John Wiley& Sons, 2008.

MORETTIN, P. A. **Econometria Financeira: Um curso em séries temporais financeiras**. São Paulo: Ed: Blucher, 2008.

NEPAL, B. Electricity load forecasting using clustering and ARIMA model for energy management in buildings. **IEEE Transactions on Computational Social Systems**, 2019.

SILVA, M. P. **Aplicação de redes neurais artificiais no diagnóstico de falha de turbina a gás**. Dissertação (Mestrado) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2010.

STENGHELE, G.; SANTOS, J. A. A.; MIURA, F. S.; PASA, L. A.; SCHMIDT, C. A. P. Previsão do consumo de energia elétrica na região sudeste: um estudo de caso usando SARIMA. **FSA**, vol. 17, 2020.

THOMAS, A. **Adventures in machine learning**. Disponível em: <https://adventuresinmachinelearning.com/category/deep-learning/lstms/>. Acesso em: 12 mar. 2020.

TIAN, C. A deep neural network model short-term load forecast based o long short-term memory network and convolutional neural network. **Energies**, 2018.

TIDRE, P. V.; BIASE, N. G.; SILVA, M. I. Utilização dos modelos de séries temporais na previsão do consumo mensal de energia elétrica na região norte do Brasil. **Matemática e Estatística em Foco**, v. 1, 2013.

TUBINO, D. F. **Planejamento e controle da produção - Teoria e Prática**. São Paulo: Atlas, 2009.

WALTER, O. M. F. C.; HENNING, E.; MORO, G., SAMOBYL, R. W. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta – EP**. v. 11, 2013.

ZHENG, J. **Electric load forecasting in smart grids using long-short-term-memory based recurrent neural network**. In: Conference on Information Sciences and Systems (CISS), Baltimore, USA, 2017.