

# PREVISÃO DO CONSUMO DE ELETRICIDADE DA REGIÃO SUDESTE: UM ESTUDO DE CASO UTILIZANDO MODELOS UNIVARIADO E MULTIVARIADO

Aldino Normelio Brun Polo<sup>1</sup>; José Airton Azevedo dos Santos<sup>2</sup>; André Sandmann<sup>3</sup>

## Resumo

Este trabalho tem como objetivo comparar o desempenho de previsão dos modelos LSTM univariado e multivariado. Para realizar esta comparação utilizou-se uma base de dados do consumo de energia elétrica da região Sudeste do Brasil, fornecida pela Empresa de Pesquisa Energética (EPE). A base de dados apresenta uma série mensal do consumo de energia elétrica no período entre Janeiro/2004 e Novembro/2023, totalizando 239 observações. Modelos de previsão, baseados em Redes Neurais LSTM, foram implementados na linguagem Python. Resultados obtidos, dos modelos univariado e multivariado, foram comparados por meio das métricas RSME (*Root Mean Squared Error*), MAPE (*Mean Absolute Percent Error*) e MAE (*Mean Absolute Error*). Verificou-se, para um horizonte de 6 meses, que o modelo LSTM multivariado apresentou um melhor desempenho.

**Palavras-chave:** Redes neurais; energia elétrica; python.

## Abstract

This work aims to compare the prediction performance of univariate and multivariate LSTM models. To carry out this comparison, we used a database of electricity consumption in the Southeast region of Brazil, provided by the Energy Research Company (EPE). The database presents a monthly series of electricity consumption in the period between January/2004 and November/2023, totaling 239 observations. Prediction models, based on LSTM Neural Networks, were implemented in the Python language. Results obtained from the univariate and multivariate models were compared using the RSME (Root Mean Squared Error), MAPE (Mean Absolute Percent Error) and MAE (Mean Absolute Error) metrics. It was verified, for a horizon of 6 months, that the multivariate LSTM model presented better performance.

**Keywords:** Neural networks; electrical energy; python.

## 1 Introdução

A energia elétrica é considerada como um dos indicadores do nível de qualidade de vida e do desenvolvimento econômico de um país. Além de viabilizar maior conforto para as pessoas, sua utilização proporciona, nos diversos setores da economia, um aumento da capacidade de produção de bens e serviços. Entretanto, o consumo de energia elétrica, com o

---

<sup>1</sup> Mestrando em Tecnologias Computacionais para o Agronegócio pela Universidade Tecnológica Federal do Paraná-UFTPR, Câmpus Medianeira. E-mail: aldinopolo@alunos.utfpr.edu.br.

<sup>2</sup> Doutor em Engenharia Elétrica pela Universidade Federal de Santa Catarina-UFSC; professor do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio da Universidade Tecnológica Federal do Paraná-UFTPR, Câmpus Medianeira. E-mail: airton@utfpr.edu.br.

<sup>3</sup> Doutor em Engenharia Agrícola pela Universidade Federal de Campina Grande-UFCG; professor do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio da Universidade Tecnológica Federal do Paraná-UFTPR, Câmpus Medianeira. E-mail: sandmann@utfpr.edu.br.

crescimento da economia e desenvolvimento da população, tem aumentado gradualmente (Santos e Chaucoski, 2020; Kheirkhah *et al.* 2013; Stenghele *et al.* 2020; Peng *et al.* 2021).

Modelos de previsão de redes neurais artificiais, segundo Peng *et al.* (2021), podem ajudar na gestão do equilíbrio entre a demanda e a produção de energia elétrica. As redes neurais artificiais podem ser utilizadas para realizar previsões do consumo de energia elétrica ao longo do tempo. Redes neurais artificiais, segundo Santos (2022), são ferramentas de grande importância em um sistema de planejamento. São consideradas como um esquema de processamento capaz de armazenar conhecimento, por meio de um banco de dados, e disponibilizá-lo para determinada aplicação.

Dentre as ferramentas, de previsão de redes neurais artificiais, está a rede LSTM (*Long Short Term Memory*). Esta rede, introduzida inicialmente por Hochreiter e Schmidhuber (1997), funciona muito bem em uma grande variedade de problemas, sendo atualmente amplamente utilizada em análise de séries temporais (Yang *et al.* 2018).

Diversos trabalhos utilizaram redes neurais artificiais para previsão do consumo de energia elétrica. Dentre eles pode-se citar: Santos e Chaucoski (2020) que realizaram a previsão do consumo de energia elétrica na região Sudeste, utilizando SARIMA (*Seasonal Autoregressive Integrated Moving Average*) e LSTM univariado. Antonioli (2021) que comparou resultados de modelos, de redes neurais artificiais LSTM e CNN-LSTM, na previsão do consumo de energia elétrica de uma agroindústria localizada no estado do Paraná. Marcos e Júnior (2021) que utilizaram as ferramentas SARIMA, MLP (*Multilayer perceptron*), CNN (*Convolutional Neural Network*) e LSTM para previsão do consumo de energia da região nordeste do Brasil. Já Da Silva *et al.* (2023) aplicaram a rede híbrida BiLSTM-CNN na previsão do consumo de energia elétrica de uma agroindústria do estado de Goiás.

Neste contexto, este trabalho tem como objetivo comparar o desempenho de previsão dos modelos LSTM univariado e multivariado. De maneira a verificar, na previsão do consumo de energia elétrica da região Sudeste do Brasil, qual modelo apresenta melhor desempenho.

O artigo está organizado da seguinte maneira. Na Seção 2 é apresentada a metodologia utilizada na previsão do consumo de energia da região Sudeste. Na Seção 3 são apresentados os resultados obtidos da aplicação dos modelos LSTM univariado e multivariado. Comentários finais, na Seção 4, finalizam o artigo.


## 2 Materiais e Métodos

Aborda-se, nesta seção, a metodologia utilizada neste trabalho, apresentando as etapas do trabalho, a rede LSTM para previsão do consumo de energia, a base de dados, bem como as métricas utilizadas.

### 2.1 Rede LSTM

A rede LSTM é capaz de capturar relações complexas entre indicadores em sequências de tempo, por isso é muito utilizada em tarefas que envolvam entradas sequenciais. Sendo capaz de apreender sequências de curto e longo prazo. A célula de memória (Figura 1) é o elemento base da topologia de uma rede LSTM (Sun *et al.* 2018; Santos *et al.* 2023, Santos *et al.* 2022).

**Figura 1** - Célula de memória



Fonte: Sun *et al.* (2018).

O fluxo de informações, para dentro e para fora da célula de memória, é controlado por meio de portas (Graves *et al.* 2013; Santos e Chaucoski, 2020; Passos, 2021; Silva, 2023):

- ✓ Porta de Esquecimento ( $f_t$ ): Esta porta determina se a quantidade de informação, que vêm da célula anterior ( $h_{t-1}$ ), deve ser mantida ou esquecida. Esse valor e o valor de entrada ( $x_t$ ) alimentam a função sigmoide ( $\sigma$ ). A função sigmoide retorna um valor entre 0 e 1. A informação será esquecida com valores próximos de 0 e mantida com valores próximos de 1.
- ✓ Porta de Entrada ( $i_t$ ): Esta porta determina a quantidade de informação a ser adicionada pelo estado interno da célula ( $C_t$ ). Esta porta recebe informações da célula anterior ( $x_t$  e  $h_{t-1}$ ).

- ✓ Porta de Saída ( $O_t$ ): A porta de saída controla a saída das informações para próxima célula.

As equações da rede LSTM são definidas como (SHEWALKAR *et al.* 2019):

$$\begin{aligned}
 f_t &= \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) & 1 \\
 i_t &= \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) & 2 \\
 \tilde{C}_t &= \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) & 3 \\
 C_t &= f_t * C_{t-1} + i_t * \tilde{C}_t & 4 \\
 o_t &= \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) & 5 \\
 h_t &= o_t * \tanh(C_t) & 6
 \end{aligned}$$

Onde  $x_t$  e  $h_t$  são os vetores de entrada e saída,  $w_f$ ,  $w_i$ ,  $w_c$  e  $w_o$  são os pesos,  $b_f$ ,  $b_i$ ,  $b_c$  e  $b_o$  os bias,  $\sigma$  a função de ativação sigmoid e  $\tanh$  a função de ativação tangente hiperbólica.

## 2.2 Base de dados

Utilizou-se, para previsão do consumo de energia da região Sudeste, uma base de dados com 239 observações (Jan/2004 – Nov/2023) (EPE, 2023). Cada instância da base de dados apresenta as variáveis: Sudeste, Residencial, Comercial e Industrial (Figura 2). A variável Sudeste corresponde ao consumo de energia elétrica da região Sudeste do Brasil. As outras variáveis correspondem ao consumo de energia Residencial, Comercial e Industrial da região Sudeste.

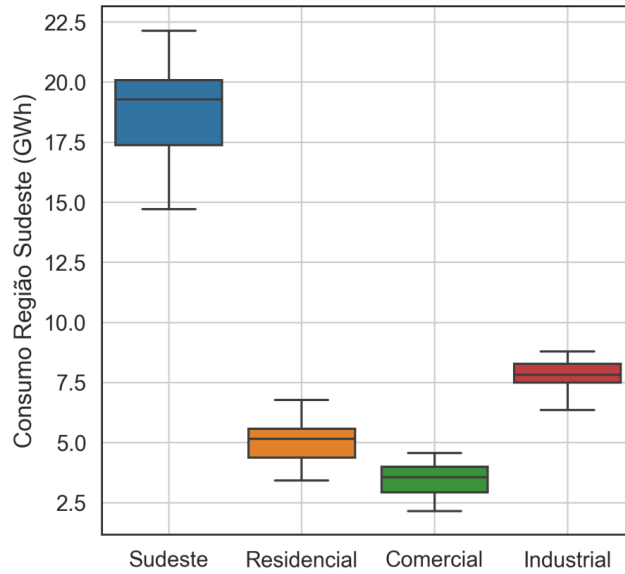
Figura 2 - Cinco primeiros registros do conjunto de dados

	Sudeste	Residencial	Comercial	Industrial
<b>Date</b>				
<b>2004-01-01</b>	14.92	3.69	2.45	6.970
<b>2004-02-01</b>	14.71	3.51	2.39	7.080
<b>2004-03-01</b>	14.90	3.62	2.40	7.087
<b>2004-04-01</b>	15.50	3.73	2.58	7.380
<b>2004-05-01</b>	14.90	3.53	2.34	7.250

Fonte: Elaborado pelos autores (2023).

O *Boxplot* dos dados é apresentado na Figura 3.

**Figura 3 - Boxplot dos dados do consumo de energia elétrica**



Fonte: Elaborado pelos autores (2023).

Observa-se que, neste trabalho, os dados foram normalizados. A função *Minmax* foi utilizada para normalizar os dados. A Equação 7 é uma representação matemática da função *Minmax* (Arunkumar *et al.* 2022).

$$x_n = \frac{x - x_{min}}{x_{max} - x_{min}} \quad 7$$

Onde  $x$  são dados da série original,  $x_{min}$  é valor mínimo da série temporal e  $x_{max}$  o valor máximo.

### 2.3 Recursos

Neste trabalho, para implementação do algoritmo LSTM, utilizou-se da ferramenta Jupyter Notebook. O Jupyter Notebook é uma ferramenta, de código aberto, que permite a escrita e a execução de códigos de computador. Foram também utilizados, em conjunto com a linguagem de programação Python, as bibliotecas de aprendizado de máquina Pandas, Matplotlib e Keras. Pandas fornece ferramentas de análise de dados e estrutura de dados de alta performance. Matplotlib é uma biblioteca de visualização de dados e Keras é uma biblioteca, para redes neurais de alto nível, que roda como *frontend* em TensorFlow (Santos e Spancerski, 2021).

Em relação ao *hardware* utilizou-se, em conjunto com o sistema operacional *Windows*, um *notebook* com processador AMD Ryzen 5 com 16 GB de memória RAM.

## 2.4 Métricas

Os modelos, implementados neste trabalho, foram avaliados pelos parâmetros: Raiz Quadrada do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE) e Erro Percentual Absoluto Médio (MAPE). Quanto menor o valor das métricas (MAE, RMSE e MAPE) melhor será a previsão do modelo (Pinheiro *et al.* 2020; Bastiani *et al.* 2018; Cankurt e Subasi, 2015; Camelo *et al.* 2018).

MAE (GWh) – Erro Médio Absoluto: O MAE mede o valor médio do erro entre os valores observados e preditos pelo modelo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)| \text{ (GWh)} \quad 8$$

RSME – Raiz Quadrada do Erro Quadrático Médio: O RMSE é a raiz do erro médio quadrático da diferença entre a previsão e o valor observado.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)} \text{ (GWh)} \quad 9$$

MAPE – Erro Percentual Absoluto Médio: O MAPE mede o erro em termos percentuais.

$$MAPE = \frac{1}{n} \sum_{i=1}^n |(y_i - \hat{y}_i)/y_i| \times 100 \text{ (\%)} \quad 10$$

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.

## 2.5 Etapas do trabalho

Na primeira etapa, Coleta e Análise dos Dados, realizaram-se a coleta e a análise exploratória dos dados, com o objetivo de obter informações importantes sobre os mesmos. Na sequência, nas etapas de Treinamento e Validação, selecionaram-se, por meio das métricas MAE, RMSE e MAPE, os melhores modelos LSTM univariado e multivariado. Por último, na Etapa de Teste, os modelos foram testados para dados que não participaram das etapas de Treinamento e Validação (Junho, Julho, Agosto, Setembro, Outubro e Novembro de 2023).

## 3 Resultados e Discussão

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Figura 4).

**Figura 4 - Análise descritiva dos dados**


	Sudeste	Residencial	Comercial	Industrial
<b>count</b>	233.000000	233.000000	233.000000	233.000000
<b>mean</b>	18.746309	5.019386	3.460661	7.855210
<b>std</b>	1.750144	0.804252	0.623841	0.500381
<b>min</b>	14.710000	3.430000	2.150000	6.350000
<b>25%</b>	17.370000	4.380000	2.920000	7.500000
<b>50%</b>	19.290000	5.150000	3.550000	7.830000
<b>75%</b>	20.080000	5.580000	3.990000	8.270000
<b>max</b>	22.140000	6.770000	4.570000	8.790000

Fonte: Elaborado pelos autores (2023).

Pode-se observar, dos dados apresentados na Figura 4, que o consumo para região Sudeste ficou, para o período em estudo, em média de 18,746 GWh. Apresentando, neste período, consumos mínimo e máximo de 14,710 e 22,140 GWh, respectivamente. Observou-se também, por meio dos dados, um coeficiente de variação de 9,33%.

A série histórica, do consumo de energia da região Sudeste, é apresentada na Figura 5.


**Figura 5 - Série histórica do consumo de energia elétrica**



Fonte: Elaborado pelos autores (2023).

A média mensal do consumo de energia da região Sudeste, durante o período estudado, é apresentada na Figura 6. Pode-se notar, por meio desta figura, que os meses, com maior consumo, ocorrem entre outubro e dezembro. Observou-se também um consumo médio mínimo de 17,649 GWh no mês de julho e um consumo médio máximo de 18,98 GWh para o mês de novembro.

**Figura 6** - Média mensal do consumo de energia - Sudeste



Fonte: Elaborado pelos autores (2023).

### 3.1 Treinamento e validação

Vários modelos LSTM, univariado e multivariado, foram implementados neste trabalho, com o objetivo de obter os melhores modelos. Portanto, exploraram-se camadas de arquiteturas e ajustes dos hiperparâmetros. As redes neurais foram treinadas com 174 amostras (75%) e validadas com 59 amostras (25%).

Os parâmetros das redes LSTM são apresentados na Tabela 2.

**Tabela 2** - Parâmetros das redes LSTM

Parâmetros	
<i>Optimizer</i>	Adam
<i>Time step</i>	11
<i>Learning rate</i>	0,0001
<i>Epochs</i>	600
<i>Batch</i>	15
<i>Numbers of hidden units in BiLSTM layer</i>	32
<i>Activation function</i>	relu
<i>Dense units</i>	1

Fonte: Elaborado pelos autores (2023).

Na Tabela 3 apresentam-se os resultados das métricas MAE, RMSE e MAPE para o conjunto de validação.

**Tabela 3** - Métricas – Conjunto de Validação

Modelo	MAE (GWh)	RMSE (GWh)	MAPE (%)
<i>LSTM Multivariate</i>	0,71	0,86	3,45
<i>LSTM Univariate</i>	0,55	0,74	2,78

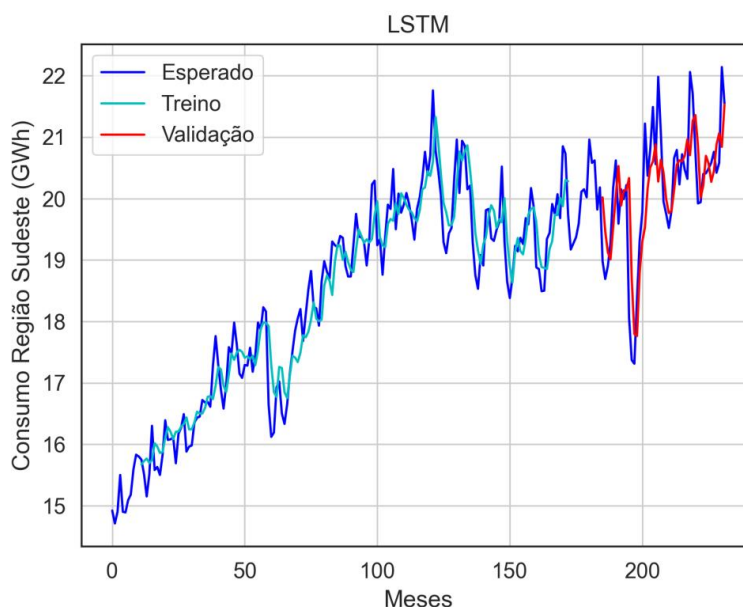
Fonte: Elaborado pelos autores (2023).



Observa-se, da Tabela 3, que o modelo LSTM univariado obteve, para o conjunto de validação, erros menores que o modelo multivariado.

Na Figura 7 apresentam-se, como exemplo, os resultados da predição, de treino e validação, do modelo LSTM univariado.

**Figura 7 - Modelo LSTM univariado – Treino e Validação**



Fonte: Elaborado pelos autores (2023).

### 3.2 Teste

Na Tabela 4 apresentam-se os dados, observados (reais) e preditos pelos modelos de previsão, para os 6 meses que não participaram da etapa de treino e validação (Conjunto de Teste).


**Tabela 4 - Resultados das previsões - Conjunto de Teste (GWh)**

Mês	Observado	LSTM Univariado	LSTM Multivariado
jun/23	20,38	20,7	20,16
jul/23	20,04	20,47	19,95
ago/23	20,72	20,75	20,31
set/23	21,13	21,02	21,01
out/23	22,05	20,89	21,82
nov/23	22,24	20,73	22,54

Fonte: Elaborado pelos autores (2023).

Na Figura 8 apresentam-se, na forma gráfica, os resultados das previsões para o Conjunto de Teste.

**Figura 8 - Previsões – Conjunto de Teste**



Fonte: Elaborado pelos autores (2023).

Na Tabela 5 apresentam-se, para o Conjunto de Teste, os resultados das métricas MAE, RSME e MAPE.

**Tabela 5 - Métricas – Conjunto de Teste**

Modelo	MAE (GWh)	RMSE (GWh)	MAPE (%)
<i>LSTM Multivariate</i>	<b>0,22</b>	<b>0,25</b>	<b>1,06</b>
<i>LSTM Univariate</i>	0,59	0,81	2,74

Fonte: Elaborado pelos autores (2023).

Observa-se, dos resultados apresentados na Tabela 5, que o modelo LSTM Multivariado obteve o melhor resultado. Este modelo, comparado com o modelo LSTM Univariado, apresentou erros menores (MAE, RSME e MAPE). Por exemplo, o MAPE do modelo LSTM multivariado, com relação ao univariado, reduziu 1,68%, passando de 2,74% para 1,06%. Da Figura 8 também pode-se observar que a curva do modelo Multivariado se ajustou melhor a curva dos dados Observados (reais).

#### 4 CONSIDERAÇÕES FINAIS

Neste trabalho abordou-se a aplicação de modelos LSTM, univariado e multivariado, na previsão do consumo de energia elétrica da região Sudeste do Brasil. Os modelos LSTMs passaram pelas Etapas de Treinamento, Validação e Teste.

Inicialmente, realizaram-se as Etapas de Treinamento e Validação dos modelos implementados neste trabalho. Na sequência, observou-se, na Etapa de Teste (Junho, Julho, Agosto, Setembro, Outubro e Novembro de 2023), a boa capacidade de generalização do

modelo LSTM multivariado, demonstrado pela proximidade dos valores previstos com os obtidos da Empresa de Pesquisa Energética (EPE). Destaca-se também, a boa capacidade do modelo LSTM multivariado, para realizar previsões do consumo de energia elétrica da região Sudeste, mesmo com um conjunto de dados com apenas 239 instâncias.

Finalmente, pode-se concluir que o modelo LSTM multivariado pode auxiliar no planejamento de geração de energia elétrica para região Sudeste.

Para trabalhos futuros sugere-se a aplicação do modelo LSTM multivariado, para previsão do consumo de energia em outras regiões do país, se possível com um maior conjunto de dados.

## Referências

ANTONIOLLI, E. A. **Previsão do consumo de energia elétrica em um frigorífico: um estudo de caso utilizando regressão linear, redes neurais e máquinas de vetores de suporte**. 2021. 67 f. Dissertação (Mestrado em Tecnologias Computacionais para o Agronegócio) - Universidade Tecnológica Federal do Paraná, Medianeira, 2021. Disponível em: <https://repositorio.utfpr.edu.br/jspui/handle/1/28877>. Acesso em: 22 jul. 2024.

ARUNKUMAR, K. E *et al.* Comparative analysis of Gated Recurrent Units (GRU), long Short-Term memory (LSTM) cells, autoregressive Integrated moving average (ARIMA), seasonal autoregressive Integrated moving average (SARIMA) for forecasting COVID-19 trends. **Alexandria Engineering Journal**, v. 61, n. 1, 2022. Disponível em: <https://doi.org/10.1016/j.aej.2022.01.011>. Acesso em: 22 jul. 2024.

BASTIANI, M. *et al.* Application of data mining algorithms in the management of the broiler production. **Geintec**, v. 8, n. 1, 2018.

CAMELO, H. *et al.* C. Proposta para previsão de velocidade do vento através de modelagem híbrida elaborada a partir dos modelos ARIMAX e RNA. **Revista Brasileira de Meteorologia**, v. 33, n. 1, 2018. Disponível em: <https://doi.org/10.1590/0102-7786331005>. Acesso em: 22 jul. 2024.

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

DA SILVA, G, B.; OLIVEIRA, L.; SANTOS, J. A. A. BiLSTM-CNN network applied to the forecast of electricity consumption in agroindustry of the southwest of Goiás. **Revista Cereus**, v. 15, n. 3, p. 93-108, 2023. Disponível em: <http://www.ojs.unirg.edu.br/index.php/1/article/view/4264/2106>. Acesso em: 22 jul. 2027.

EPE - Empresa de Pesquisa Energética. **Anuário estatístico de energia elétrica**. Disponível em <http://epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica>. Acesso em: 12 dez. 2023.

GRAVES, A.; JAITLY, N.; MOHAMED, R. **Hybrid speech recognition with deep bidirectional lstm**. In. **2013 IEEE Workshop on Automatic Speech Recognition and**

nderstanding, Olomouc-Czech Republic, p. 273-278, 2013. Disponível em: <https://doi.org/10.1109/ASRU.2013.6707742>. Acesso em: 22 jul. 2024.

KHEIRKHAH, A. *et al.* Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis. **Computers & Industrial Engineering**, v. 64, n. 1, p. 425-441, 2013. Disponível em <https://doi.org/10.1016/j.cie.2012.09.017>. Acesso em: 22 jul. 2024.

MARCOS, I. P.; JÚNIOR, A. P. P. Previsão do consumo de energia elétrica na região nordeste do Brasil. **Revista de Engenharia e Pesquisa Aplicada**, v. 6, n. 3, 2021. Disponível em: <https://doi.org/10.25286/repa.v6i3.1684>. Acesso em: 22 jul. 2024.

PASSOS, B. T. Long short term: redes neurais artificiais que são capazes de ler, ouvir e ler. **Blog Ateliware**. Curitiba, 9 nov. 2021. Disponível em: <https://blog.ateliware.com/long-short-term-memory/>. Acesso em: 22 jul. 2024.

PENG, L. *et al.* Effective energy consumption forecasting using empirical wavelet transform and long short-term memory. **Energy**, v. 238, n. 1, 2022. Disponível em: <https://doi.org/10.1016/j.energy.2021.121756>. Acesso em: 22 jul. 2024.

PINHEIRO, T. C.; SANTOS, J. A. A.; PASA, L. A. Gestão da produção de frangos de corte por meio de redes neurais artificiais. **Revista Holos**, v. 2, n. 1, p. 1-15, 2020. Disponível em: <https://doi.org/10.15628/holos.2020.9043>. Acesso em: 22 jul. 2024.

SANTOS, J. A. A. Previsão do preço do café arábica: uma aplicação de redes neurais CNN-BLSTM. **Research, Society and Development**, v. 11, n. 1, p. e351132610, 2022. Disponível em: <https://doi.org/10.33448/rsd-v11i3.2610>. Acesso em: 22 jul. 2024.

e. Previsão do consumo de energia elétrica em uma agroindústria: um estudo de caso usando redes LSTM e CNN-LSTM. **Revista Cereus**, v. 14, n. 1, p. 63-76, 2022. Disponível em: <http://www.ojs.unirg.edu.br/index.php/1/article/view/3636>. Acesso em: 22 jul. 2024.

SANTOS, J. A. A.; CHAUCOSKI, Y. Previsão do Consumo de Energia Elétrica na Região Sudeste: Um Estudo de Caso Usando SARIMA e LSTM. **Revista Cereus**, v. 12, n. 4, p. 93-104, 2020. Disponível em: <http://ojs.unirg.edu.br/index.php/1/article/view/3255>. Acesso em: 22 jul. 2024.

SANTOS, J. A. *et al.* Previsão do preço do milho: uma comparação entre os modelos SARIMA e LSTM. **Peer Review**, v. 5, n. 18, p. 538-549, 2023. Disponível em: <https://doi.org/10.53660/952.prw2533>. Acesso em: 22 jul. 2024.

SANTOS, J. A. A.; & SPANCERSKI, J. S. Redes neurais aplicadas na predição do preço da soja no estado do Paraná. **Revista Exatas & Engenharias**, v. 11, n. 1, p. 19-32, 2021. Disponível em: <https://doi.org/10.25242/885X113220212282>. Acesso em: 22 jul. 2024.

SHEWALKAR, A.; NYAVANANDI, D.; LUDWIG, S. A. Performance evaluation of deep neural networks applied to speech recognition; RNN, LSTM and GRU. **Journal of Artificial Intelligence and Soft Computing Research**, v. 9, n. 4, p. 235-245, 2019. Disponível em <https://intapi.sciendo.com/pdf/10.2478/jaiscr-2019-0006>. Acesso em: 22 jul. 2024.

SILVA, A. F. L. **Redes Neurais LSTM em Python: Previsão do S&P500**. 2021, 26 f. Dissertação (Mestrado em Matemática Financeira) - Universidade de Lisboa, Lisboa, Portugal, 2023. Disponível em: [https://repositorio.ul.pt/bitstream/10451/61679/1/TM\\_Andr%c3%a9\\_Silva.pdf](https://repositorio.ul.pt/bitstream/10451/61679/1/TM_Andr%c3%a9_Silva.pdf). Acesso em: 22 jul. 2024.

STENGHELE, G. *et al.* Previsão do consumo de energia elétrica na região sudeste: um estudo de caso usando SARIMA. **Rev. FSA**, v. 17, n. 1, p. 169-183, 2020. Disponível em: <http://www4.unifsa.com.br/revista/index.php/fsa/article/download/1956/491492137>. Acesso em: 22 jul. 2024.

SUN, Q. *et al.* Predicting Blood Glucose with an LSTM and Bi-LSTM Based Deep Neural Network. In: **14th Symposium on Neural Networks and Applications (NEUREL)**, Belgrado (Sérvia), 2018, p. 1-5. Disponível em: <https://ieeexplore.ieee.org/abstract/document/8586990/metrics#metrics>. Acesso em: 22 jul. 2024.

YANG, R.; HUANG, M.; LU, Q.; ZHONG, M. Rotating Machinery Fault Diagnosis Using Long-short-term Memory Recurrent Neural Network. **IFAC-PapersOnLine**, v. 51, n. 1, 2018.

YANG, R. *et al.* Rotating machinery fault diagnosis using long-short-term memory recurrent neural network. **IFAC-PapersOnLine**, v. 51, n. 24, p. 228-232, 2018. Disponível em: <https://doi.org/10.1016/j.ifacol.2018.09.582>. Acesso em 22 jul. 2024.