



Centro Unversitário Santo Agostinho

revistafsa

www4.fsnet.com.br/revista

Rev. FSA, Teresina, v. 21, n. 5, art. 7, p. 135-149, mai. 2024

ISSN Impresso: 1806-6356 ISSN Eletrônico: 2317-2983

http://dx.doi.org/10.12819/2024.21.5.7



Análise Comparativa de Modelos LSTM e GRU Para Previsão da Velocidade do Vento

Comparative Analysis of LSTM and GRU Models for Wind Speed Prediction

Aldino Normelio Brun Polo

Mestrando no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio

Engenheiro Químico pela Universidade Estadual do Oeste do Paraná

E-mail: aldinopolo@alunos.utfpr.edu.br

José Airton Azevedo dos Santos

Doutor em Engenharia Elétrica, Universidade Federal de Santa Catarina

Professor da Universidade Tecnológica Federal do Paraná

E-mail: airton@utfpr.edu.br

Cidmar Ortiz dos Santos

Doutor em Ensino de Ciência e Tecnologia, Universidade Tecnológica Federal do Paraná

Professor da Universidade Tecnológica Federal do Paraná

E-mail: cidmar@utfpr.edu.br

Endereço: Aldino Normelio Brun Polo

Universidade Tecnológica Federal do Paraná – Campus Medianeira - Avenida Brasil, 4232 CEP 85884-000 - Caixa Postal 271 - Medianeira - PR – Brasil.

Endereço: José Airton Azevedo dos Santos

Universidade Tecnológica Federal do Paraná – Campus Medianeira - Avenida Brasil, 4232 CEP 85884-000 - Caixa Postal 271 - Medianeira - PR – Brasil.

Endereço: Cidmar Ortiz dos Santos

Universidade Tecnológica Federal do Paraná – Campus Medianeira - Avenida Brasil, 4232 CEP 85884-000 - Caixa Postal 271 - Medianeira - PR – Brasil

Editor-Chefe: Dr. Tonny Kerley de Alencar Rodrigues

Artigo recebido em 04/02/2024. Última versão recebida em 14/03/2024. Aprovado em 15/03/2024.

Avaliado pelo sistema Triple Review: a) Desk Review pelo Editor-Chefe; e b) Double Blind Review (avaliação cega por dois avaliadores da área).

Revisão: Gramatical, Normativa e de Formatação



RESUMO

Este trabalho tem como objetivo comparar o desempenho de previsão dos modelos LSTM (*Long Short Term Memory*) e GRU (*Gated Recurrent Units*). Para realizar essa comparação, utilizou-se uma base de dados de velocidade máxima do vento, obtida do Instituto Nacional de Meteorologia (INMET). Essa base apresenta uma série histórica mensal de velocidade máxima do vento, da estação meteorológica de Palmeira dos Índios, no período entre 2008 e 2020. Os modelos de previsão LSTM e GRU foram implementados em Python, utilizando a biblioteca Pytorch. Resultados obtidos dos dois modelos foram comparados por meio das métricas RMSE (*Root Mean Squared Error*), MAPE (*Mean Absolute Percent Error*) e MAE (*Mean Absolute Error*). Verificou-se, para um horizonte de curto prazo (6 meses), que a rede neural LSTM apresentou o melhor desempenho.

Palavras-chave: Redes Neurais. Séries Temporais. Pytorch. Python.

ABSTRACT

This work aims to compare the prediction performance of the LSTM (Long Short Term Memory) and GRU (Gated Recurrent Units) models. To carry out this comparison, a database of maximum wind speed, obtained from the National Institute of Meteorology (INMET), was used. This database presents a monthly historical series of maximum wind speed, from the Palmeira dos Índios meteorological station, in the period between 2008 and 2020. The LSTM and GRU forecast models were implemented in Python using the Pytorch library. Results obtained from the two models were compared using the metrics RMSE (Root Mean Squared Error), MAPE (Mean Absolute Percent Error) and MAE (Mean Absolute Error). It was verified, for a short-term horizon (6 months), that the LSTM neural network presented the best performance.

Keywords: Neural Networks. Time Series. Pytorch. Python.

1 INTRODUÇÃO

Os ventos, caracterizados como resultados de diferentes gradientes horizontais de pressão, são originados do aquecimento diferencial de porções do ar pela radiação solar. O conhecimento da velocidade do vento contribui para o planejamento de instalação de distritos industriais, construção de estábulos, dimensionamento de torres de geração de energia eólica etc. A velocidade do vento, além de estar diretamente relacionada com o fenômeno da polinização, influencia também a distribuição das culturas no campo (JÚNIOR *et al.*, 2019; LISKA, 2013).

Portanto, a implementação de ferramentas de previsão capazes de predizerem os valores da velocidade do vento em uma região, a partir de dados históricos, faz-se necessária para processos de tomada de decisão. Segundo Pinto (2023), ferramentas de previsão de séries temporais podem ser utilizadas para realizar previsões mensais da velocidade do vento em uma determinada região.

Séries temporais podem ser definidas como uma coleção de dados de um determinado fenômeno, coletados ao longo de um período de tempo, geralmente em intervalos iguais (MALETZKE, 2009). Segundo Cunha (2019), é possível, por meio de modelagem matemática, extrair informações desses dados, supondo a continuidade do comportamento apresentado anteriormente.

Dentre as técnicas utilizadas para previsão de séries temporais, estão as redes neurais recorrentes. As redes recorrentes são redes muito utilizadas para analisar padrões que variam com o tempo. As redes LSTM e GRU são redes neurais recorrentes que operam com boa precisão em uma grande variedade de problemas, graças à capacidade dessas redes em apreenderem sequências de curto e longo prazo (GRAVES, 2013; NELSON *et al.*, 2017).

Vários trabalhos, na última década, utilizaram técnicas de análise de séries temporais para prever a velocidade do vento. Camelo *et al.* (2017) utilizaram modelos Arima, Holt-Winters e de redes neurais artificiais para previsão mensal da velocidade do vento na região nordeste do Brasil. Sen e Ozcan (2021) utilizaram redes neurais artificiais para previsão da velocidade máxima do vento na província de Konya, situada na Turquia. Lim *et al.* (2022) utilizaram, para controle do tráfego, uma rede LSTM para previsão de ventos fortes, de curta duração, em uma ponte. Chandrabha *et al.* (2020) compararam modelos LSTM e de regressão linear na previsão da velocidade do vento na Índia. Xu *et al.* (2019) propuseram um modelo GRU para previsão da velocidade do vento na China. Já Silva *et al.* (2022) utilizaram

a rede neural recorrente LSTM multivariada para previsão da velocidade do vento no distrito federal.

Nesse contexto, este trabalho tem como objetivo comparar o desempenho de previsão dos modelos LSTM (*Long Short Term Memory*) e GRU (*Gated Recurrent Units*), de modo a verificar qual dos dois modelos apresenta melhor desempenho na previsão mensal da velocidade máxima do vento.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção apresentam-se, de maneira sintetizada, os conceitos teóricos que embasam este trabalho.

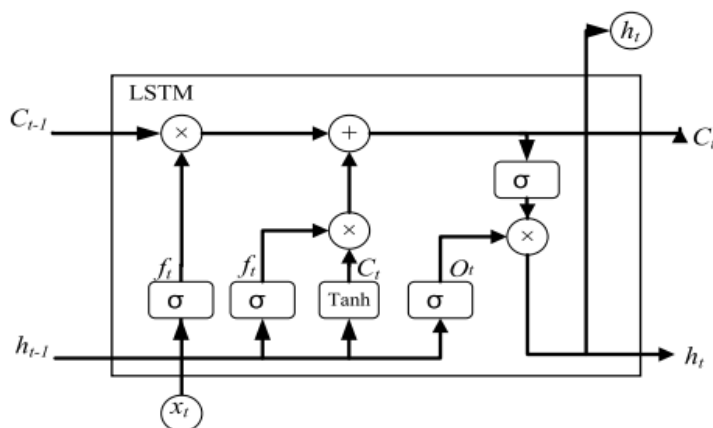
2.1 Rede LSTM

A rede neural recorrente LSTM foi projetada com maior precisão que as redes neurais recorrentes convencionais, para modelar sequências temporais e suas dependências de longo prazo (OLIVEIRA; SANTOS, 2023).

O elemento base da topologia LSTM é a célula de memória (Figura 1). A célula LSTM possui uma entrada x_t e três portas (GRAVES et al., 2013; PASSOS, 2021).

- ✓ Porta de Esquecimento (f_t): Essa porta permite eliminar elementos da memória;
- ✓ Porta de Saída (O_t): Nessa porta o estado oculto é atualizado, com base na entrada e na memória da célula;
- ✓ Porta de Entrada (i_t): Permite adicionar novo
- ✓ s elementos à memória.

Figura 1 – Célula de memória - LSTM



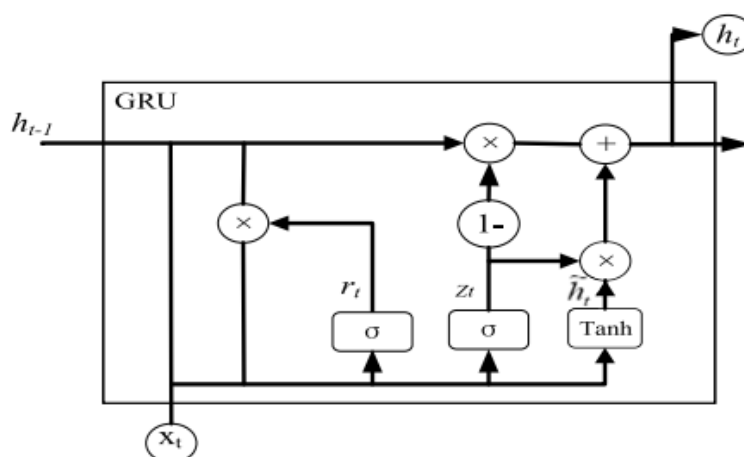
Fonte: Jia e Wang (2020).

Cada uma das três portas utiliza unidades de ativação para serem acionadas. Isso faz com que as informações fluam através da célula. O parâmetro C_t , estado da célula, se comporta como uma correia transportadora na qual se pode adicionar ou remover dados da memória da célula (SANTOS; CHAUCOSKI, 2020; SILVA, 2023).

2.2 Rede GRU

A rede recorrente GRU, uma variação da rede LSTM, possui uma estrutura mais simples e requer menos tempo de treinamento. Nessa rede são utilizadas somente duas portas de controle. A porta de atualização r_t , que faz o papel da porta de entrada e esquecimento, e a porta de redefinição z_t . A rede GRU é mais rápida de treinar e precisa de menos dados para generalizar (SANTOS; SPANCERSKI, 2021). A topologia de uma célula GRU é apresentada na Figura 2.

Figura 2 – Célula de memória - GRU



Fonte: Jia e Wang (2020).

2.3 MÉTRICAS

Para avaliar o desempenho de previsão dos modelos LSTM e GRU, foram utilizados três indicadores: Raiz Quadrada do Erro Quadrático Médio (RMSE), Erro Médio Absoluto (MAE) e Erro Percentual Absoluto Médio (MAPE). Quanto mais próximo de zero forem os valores das métricas MAE, RSME e MAPE, melhor será a previsão do modelo (PINHEIRO *et al.*, 2020; BASTIANI *et al.*, 2018; CANKURT; SUBASI, 2015).

As equações das métricas, MAPE, RMSE e MAE, são apresentadas na Tabela 1.

Tabela 1 – Métricas MAE, RMSE e MAPE

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

Fonte: Antonioli (2021).

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

3 MATERIAIS E MÉTODOS

Nesta seção serão abordados os procedimentos adotados para realização do trabalho.

3.1 TIPO DE PESQUISA

Os procedimentos metodológicos desenvolvidos nesta pesquisa são apresentados no fluxograma da Figura 3 (GIL, 2010; PINTO, 2023).

Figura 3 – Procedimentos Metodológicos

Fonte: Pinto (2023).

Onde:

- ✓ Pesquisa Quantitativa: caracteriza-se pelo uso de dados numéricos históricos. Nesta abordagem aplicam-se também técnicas estatísticas como a média, desvio padrão, coeficiente de variação etc;
- ✓ Pesquisa Básica: é uma pesquisa científica que tem como propósito analisar conhecimentos úteis para o avanço da ciência e da tecnologia;
- ✓ Pesquisa Descritiva: pode ser definida como aquela que descreve uma realidade, como, por exemplo, as características de uma população;
- ✓ Pesquisa Operacional: busca solução para um determinado problema por meio de modelos matemáticos ou estatísticos.

3.2 ETAPAS DO TRABALHO

Três etapas foram realizadas neste trabalho, para comparar os modelos LSTM e GRU:

- ✓ Análise de dados: Inicialmente, na primeira etapa, realizou-se um pré-processamento dos dados obtidos do INMET visando adequá-los aos algoritmos. Na sequência, realizou-se uma análise exploratória desses dados;
- ✓ Treinamento e Validação: Na segunda etapa, treinamento e validação, foram selecionados, por meio de métricas, os melhores modelos LSTM e GRU;
- ✓ Teste: Na última etapa, etapa de teste, os modelos foram testados para dados que não participaram da etapa de treinamento e validação.

3.3 BASE DE DADOS

Inicialmente, obteve-se da estação meteorológica A327 (Figura 4), localizada no município de Palmeira dos Índios, no estado do Alagoas, uma base de dados com 156 instâncias da velocidade máxima do vento (Jan/2008 - Dez/2020) (INMET, 2022).


Figura 4 – Estação Meteorológica de Palmeira dos Índios



Fonte: Pereira *et al.* (2017).

A estação de Palmeira dos Índios possui uma torre com 3 anemômetros situados nas alturas de 30, 70 e 100m e sensores de direção da velocidade do vento em 30 e 70m (PINTO, 2023).

A série histórica da velocidade máxima do vento é apresentada na Figura 5.

Figura 5 – Série histórica da velocidade máxima do vento

Fonte: Os autores.

3.4 RECURSOS

Neste trabalho, para implementação dos algoritmos LSTM e GRU, utilizou-se o ambiente de desenvolvimento Jupyter Notebook. Foram utilizadas, em conjunto com a linguagem de programação Python, as bibliotecas de visualização e análise dos dados Matplotlib e Pandas. Pytorch é uma biblioteca desenvolvida pelo laboratório de inteligência artificial do Facebook, para utilização em projetos de aprendizado de máquina (OLIVEIRA; SANTOS, 2021).

Em relação ao *hardware*, utilizou-se, em conjunto com o sistema operacional Ubuntu, um *notebook* com processador core i7, com 16 GB de memória RAM.

4 RESULTADOS E DISCUSSÕES

Inicialmente, realizou-se uma análise descritiva dos dados (Figura 6).


Figura 6 – Análise descritiva dos dados

	Number
count	156.000000
mean	6.627564
std	0.909862
min	4.900000
25%	5.900000
50%	6.600000
75%	7.325000
max	8.700000

Fonte: Os autores.

Pode-se observar, pelos dados apresentados na Figura 6, que a velocidade ficou para o período em estudo em média de 6,627 m/s, apresentando, neste período, velocidade mínima e máxima de 4,9 m/s e 8,7 m/s. Calculou-se, por meio dos dados apresentados na Figura 6, um coeficiente de variação dos dados de 13,7%. Quanto maior o coeficiente de variação maior a variação nos dados.

A média mensal da velocidade máxima do vento durante o período estudado é apresentada na Figura 7. Pode-se notar, por meio dessa figura, que os meses com menor velocidade são maio e junho (5,65 m/s). Observou-se também uma velocidade máxima para o mês de novembro (7,54 m/s).

Figura 7 – Média mensal máxima da velocidade do vento

Fonte: Os autores.

4.1 TREINAMENTO E VALIDAÇÃO

Vários modelos dos dois algoritmos foram treinados utilizando-se a biblioteca Pytorch. Os melhores parâmetros encontrados para os modelos LSTM e GRU são apresentados na Tabela 2. Os modelos foram configurados para utilizarem 70% das amostras em treinamento e os 30% restantes para validação.

Tabela 2 – Parâmetros das redes

Parâmetro	
Activation function of the hidden layer	relu
Window	9
Epochs	2850
Dropout	0,15
Hidden layer dimension	7
Number de network layers	2
Activantion function of the output layer	tanh
Learning rate	0,015
Optimizer	Adam

Fonte: Os autores.

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

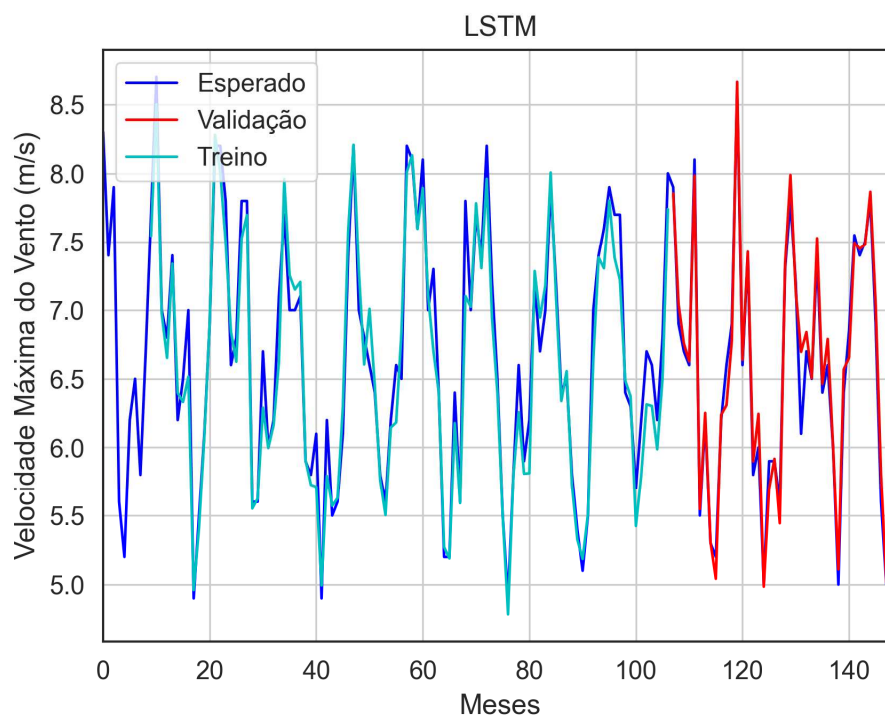
Tabela 3 – Métricas – Conjunto de Validação

Modelo	MAE (m/s)	RMSE (m/s)	MAPE (%)
LSTM	0,10	0,14	1,61
GRU	0,14	0,19	2,32

Fonte: Os autores.

Observa-se, nos dados registrados na Tabela 3, que o modelo LSTM apresentou, para o conjunto de validação, erros menores que o modelo GRU.

Na Figura 8, apresentam-se os resultados da predição de treino e validação do modelo LSTM.

Figura 8 – Modelo LSTM – Treino e Validação

4.2 TESTE


Na Tabela 4, apresentam-se, para o Conjunto de Teste (6 meses), os dados observados (reais) e preditos pelos modelos de previsão LSTM e GRU.

Tabela 4 – Previsões - Conjunto de Teste (m/s)

Meses	Observado	LSTM	GRU
jul/20	5,9	5,68	8,24
ago/20	5,4	5,35	8,23
set/20	6,4	6,73	6,07
out/20	7,3	6,77	7,9
nov/20	6,8	6,77	7,75
dez/20	7,1	6,77	6,4

Fonte: Os autores.

Os resultados das previsões para o Conjunto de Teste são apresentados na Figura 9.

Figura 9 – Previsões – Conjunto de Teste

Fonte: Os autores.

Apresentam-se também, na Tabela 5, os resultados das métricas (MAE, RSME e MAPE) para o conjunto de teste.

Tabela 5 – Métricas – Conjunto de Teste

Modelo	MAE (m/s)	RMSE (m/s)	MAPE (%)
LSTM	0,24	0,30	3,67
GRU	1,29	1,60	21,7

Fonte: Os autores.

Nota-se, por meio das curvas apresentadas na Figura 9, que a curva dos dados previstos pelo modelo LSTM teve um melhor ajuste com a curva dos dados observados (reais). Observa-se também, dos resultados apresentados na Tabela 5, que o modelo LSTM, com relação ao modelo GRU, apresentou erros menores (MAE, RSME e MAPE).

5 CONSIDERAÇÕES FINAIS

Neste trabalho, compararam-se, na previsão da velocidade mensal máxima do vento, os resultados dos modelos *deep learning* LSTM e GRU. Os dados de velocidade do vento da estação de Palmeira dos Índios foram fornecidos pelo Instituto Nacional de Meteorologia (INMET). Os modelos LSTM e GRU, implementados neste trabalho, passaram pelas etapas de treinamento, validação e teste.

Inicialmente, na etapa de treinamento e validação, selecionaram-se, por meio das métricas MAE, RSME e MAPE, os melhores modelos LSTM e GRU. Na sequência, na etapa de teste,

observou-se que o modelo LSTM apresentou melhores previsões que o modelo GRU (MAPE_LSTM=3,67% e MAPE_GRU=21,7%). Um MAPE=3,67% indica a boa capacidade de generalização da rede neural LSTM. Portanto, conclui-se que o modelo LSTM pode ajudar nos processos de tomada de decisão em áreas que tenham interesse em previsões de vento. Embora o algoritmo LSTM tenha apresentado bons resultados na previsão da velocidade máxima do vento, sugere-se, para trabalhos futuros, uma comparação com redes neurais híbridas CNN-LSTM e BiLSTM-CNN.

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.** Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná.
- BASTIANI, M *et al.* Application of data mining algorithms in the management of the broiler production. **Geintec**, v. 8, 2018.
- CAMELO, H. N *et al.* Métodos de previsão de séries temporais e modelagem híbrida ambos aplicados em médias mensais da velocidade do vento para regiões do nordeste do Brasil. **Revista Brasileira de Meteorologia**. v. 32, 2017.
- CANKURT, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, 2015.
- CHANDRAPRABHA; DINESH, C.; IBRAHIM, A. M.; SARAVNAN, G. LSTM model based Wind speed forecasting. **International Journal of Future Generation Communication and Networking**, v. 13, 2020.
- CUNHA, M. M. **Previsão de séries temporais por meio de métodos estatísticos e neurais: aplicação a uma indústria de bebidas.** Trabalho de Conclusão de Curso. Universidade Tecnológica Federal do Paraná, Medianeira, 2019.
- GIL, A. C. **Como Elaborar Projetos de Pesquisa.** São Paulo: Atlas, 2010.
- GRAVES, A.; JAITLY, N.; MOHAMEDA. R. Hybrid speech recognition with deep bidirectional lstm. In: Proceedings of the Automatic speech recognition and understanding, 2013.
- INMET. **Estação: Palmeira dos Índios A327.** Disponível em: <<https://tempo.inmet.gov.br/TabelaEstacoes/A327>>. Acesso em: 20 mai. 2022.
- JIA, P.; LIU, H.; WANG, P. Research on a Mine Gas Concentration Forecasting Model Based on a GRU Network. **IEEE Access**, 2020.
- JÚNIOR, G. N. A.; QUEIROA, M. G. Caracterização da direção predominante, velocidade máxima e média do vento do município de Petrolina-PE. **Pensar acadêmico**, v. 17, 2019.

LIM, J. Y.; KIM, S.; KIM, H. Long short-term memory (LSTM) based Wind speed prediction during typhoon for bridge traffic control. **Journal Wind Engineering & Industrial Aerodynamics**, 2022.

LISKA, G. R *et al.* Estimativa de velocidade máxima do vento em Piracicaba-SP via séries temporais e teoria de valores extremos. **Rev. Bras. Biom.**, v. 31, 2013.

MALETZKE, A. G. **Uma metodologia para extração de conhecimento em séries temporais por meio de identificação de motivos e da extração de características.** 2009. Disponível em: <https://www.teses.usp.br/teses/disponiveis/55/55134/tde-04062009-201445/publico/dissertacao_maletzke_09.pdf>. Acesso em: 20 mai. 2023.

OLIVEIRA, E.; SANTOS J. A. A. Um estudo comparativo da aplicação de redes neurais artificiais na previsão de geração eólica. **Revista Cereus**, v.15, 2023.

PASSOS, B. T. **Long short term:** redes neurais artificiais que são capazes de ler, ouvir e ler. 2021, Disponível em: < <https://ateliware.com/blog/long-short-term-memory>>. Acesso em: 11 mar. 2022.

PEREIRA, L. T.; PERCEUS, M.; PEREIRA, E. T. Modelagem matemática e previsão de velocidade do vento em Palmeira dos Índios/AL com a utilização dos modelos Box & Jenkins. **Revista de Extensão da UNEAL**, v. 2, 2017.

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**, vol. 2, 2020.

PINTO, B. R. **Análise comparativa da eficiência de três modelos de previsão de séries temporais do software WEKA.** 2023. Disponível em: < <https://repositorio.utfpr.edu.br/jspui/bitstream/1/32763/1/analisecomparativaeficienciaprevisao.pdf>>. Acesso em: 20 jan. 2024.

NELSON, M. Q.; PEREIRA, A. C. M.; OLIVEIRA, R. A. Stock market's price prediction with LSTM neural networks. *In: International Joint Conference of Neural Networks (IJCNN). Proceedings [...].* Anchorage: IJCNN, 2017.

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. 4, 2020.

SANTOS, J. A. A.; SPANCERSKI, J. S. Aplicação de redes neurais recorrentes na previsão de geração eólica. **Revista Cereus**, v.13, 2021.

SEN, M.; OZCAN, M. Maximum wind speed forecasting using historical data and artificial neural networks modeling. **International Journal of Energy Applications and Technologies**, v. 8, 2021.

SILVA, R. N *et al.* Previsão da velocidade do vento com série temporal multivariada usando rede neural recorrente. *In: Congresso Brasileiro de Energia Solar, Anais...* Florianópolis: CEBENS, 2022.

SPANCERSKI, J.; SANTOS, J. A. A. Previsão da produtividade de arroz: uma aplicação de redes neurais recorrentes LSTM. **Revista Cereus**, v.13, 2021.

XU, A *et al.* Short-term wind speed prediction based on GRU. In: 2019 IEEE Sustainable Power and Energy Conference. **Anais...** Beijing: ISPEC, 2019.

Como Referenciar este Artigo, conforme ABNT:

POLO, A. N. B; SANTOS, J. A. A; SANTOS, C. O. Análise Comparativa de Modelos LSTM e GRU Para Previsão da Velocidade do Vento. **Rev. FSA**, Teresina, v. 21, n. 5, art. 7, p. 135-149, mai. 2024.

Contribuição dos Autores	A. N. B. Polo	J. A. A. Santos	C. O. Santos
1) concepção e planejamento.	X	X	X
2) análise e interpretação dos dados.	X	X	X
3) elaboração do rascunho ou na revisão crítica do conteúdo.	X	X	X
4) participação na aprovação da versão final do manuscrito.	X	X	X