

Um estudo comparativo da aplicação de redes neurais artificiais na previsão de geração eólica

A comparative study of the application of artificial neural networks in wind generation prediction

Leandro de Oliveira¹, José Airton Azevedo dos Santos²

RESUMO

O presente trabalho tem como objetivo comparar modelos, de redes neurais artificiais, para previsão de geração eólica. A base de dados fornecida pelo Operador Nacional do Sistema Elétrico (ONS) apresenta uma série histórica de geração de energia, do parque eólico de Icaraizinho, no Ceará, no período entre 2010 e 2020. Modelos de previsão, baseados em redes neurais LSTM (*Bidirectional Long Short Term Memory*), GRU (*Gated Recurrent Units*), CNN (*Convolutional neural network*) e BIGRU-CNN (*Bidirectional Gated Recurrent Units - Convolutional neural network*), foram implementados na linguagem python, utilizando o *framework* Keras. Resultados obtidos, dos quatro modelos, 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 curto prazo, que o modelo híbrido BIGRU-CNN apresentou melhor desempenho.

Palavras-chave Redes híbridas; BIGRU-CNN; Keras; Python.

ABSTRACT

The present work aims to compare models of artificial neural networks for forecasting wind generation. The database provided by the National Electric System Operator (ONS) presents a historical series of energy generation, from the Icaraizinho wind farm, in Ceará, in the period between 2010 and 2020. Forecast models, based on LSTM neural networks (*Bidirectional Long Short Term Memory*), GRU (*Gated Recurrent Units*), CNN (*Convolutional neural network*) and BIGRU-CNN (*Bidirectional Gated Recurrent Units - Convolutional neural network*), were implemented in the python language, using the Keras framework. Results obtained from the four models were compared using metrics RSME (*Root Mean Squared Error*), MAPE (*Mean Absolute Percent Error*) and MAE (*Mean Absolute Error*). It was found, for a short-term horizon, that the hybrid BIGRU-CNN model performed better.

Keywords: Hybrid networks; BIGRU-CNN; Keras; Python.

¹ Discente. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA - UTFPR). E-mail: chaucoski@alunos.utfpr.edu.br

² 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

1. INTRODUÇÃO

A qualidade de vida de uma população está intimamente relacionada ao fornecimento de energia elétrica. O crescimento da demanda energética, devido ao aumento natural e melhorias no padrão de vida da população, é um dos grandes problemas da atualidade. A produção de energia elétrica, no Sistema Interligado Nacional, é obtida por um sistema hidro-termo-eólico de grande porte, com predominância de usinas hidrelétricas. Fatores ambientais, como a ocorrência de longos períodos de estiagem, afetam a geração hidroelétrica. A geração, no período de estiagem, geralmente é complementada pela utilização de usinas termoeletricas. Em 2021, devido a queda de produção das hidroelétricas, o acionamento de termoeletricas, cuja geração de energia é mais cara e poluente, foram de 16.245 MW médios, uma alta de 45%. Contudo, a utilização das fontes eólicas, na geração distribuída, pode complementar a geração hidroelétrica, em épocas de estiagem, e minimizar os impactos causados pelas termoeletricas (ONS, 2022, COELHO, 2018, SPANCERSKI; SANTOS, 2021; DALMAZ, 2007; QUIROZ, 2017, AQUILA et al., 2017; EPBR, 2022).

Segundo Spancerski & Santos (2021), a previsão da geração eólica, imprescindível para gestão do setor elétrico, pode ser realizada por meio de modelos de previsão de séries temporais. Dentre estes modelos tem-se: os sistemas especialistas; a computação evolutiva; os sistemas fuzzy; as redes neurais artificiais e os modelos híbridos (SOARES, 2021). Redes Neurais Artificiais (RNAs) têm sido utilizadas, com sucesso, em tarefas de predição e modelagem de séries temporais (SANTOS, 2021).

As RNAs são sistemas de processamento paralelo, inspirados no funcionamento do cérebro humano, capazes de lidar com problemas complexos. São capazes de apreender, por meio da modificação dos pesos sinápticos, e generalizar para dados desconhecidos (SEBASTIAN, 2016; ABRAHAM et al., 2019, BASTIANI et al., 2018; HAYKIN, 2001; PINHEIRO et al., 2020; SANTOS, 2021).

Diversos trabalhos, devido à importância do assunto, utilizaram métodos de previsão, de séries temporais, na análise de produção de energia eólica. Dentre eles podem-se citar os trabalhos de: Hiruma (2016) que utilizou Redes Neurais Artificiais e Modelos Estatísticos para previsão de geração eólica, de curtíssimo prazo, para usina eólica-elétrica de Palmas (PR). FARIA (2020) que previu, por meio de modelos de *machine learning*, a geração de energia de dois parques eólicos. Bulhões (2015) que estudou as potencialidades de utilização de modelos, baseados em redes neurais artificiais, na

previsão de geração eólica em horizontes de muito curto prazo e curto prazo. Já Coelho (2018) utilizou Redes Neurais Recorrentes para previsão de geração eólica e do preço de liquidação das diferenças, os quais são parâmetros relevantes, para diversos processos de tomada de decisão, no mercado de energia elétrica do Brasil.

Apesar da importância da produção de energia eólica, para o Brasil, muito poucos são os trabalhos que utilizam redes híbridas, como a BIGRU-CNN, na previsão da produção de energia eólica.

Neste contexto, este trabalho tem como objetivo comparar modelos, de redes neurais artificiais, para previsão de geração eólica.

2. MATERIAIS E MÉTODOS

Parque eólico de Icaraizinho:

O nordeste, em termos de geração eólica, é a região brasileira de maior destaque. Sendo o Ceará um dos estados, da região nordeste, com maior geração de energia eólica. O parque eólico de Icaraizinho fica localizado no estado do Ceará, na cidade de Amontada. O empreendimento, com 26 aerogeradores Suzlon – S88, possui uma potência instalada de 54,60 MW (MOREIRA et al., 2013).

Modelo LSTM:

Redes neurais LSTM, tipo de rede neural recorrente, são projetadas para modelar sequências de longo prazo. Sendo muito utilizadas em tarefas que envolvam séries temporais (SANTOS, 2022).

A rede LSTM, diferente das redes recorrentes convencionais, contém células de memória. A célula de memória (Figura 1) controla, por meio de portas (entrada (i_t), saída (o_t) e esquecimento (f_t)), como as informações fluem para dentro e para fora da célula. O estado da célula (C_t) representa as informações que chegaram até esse passo em instante de tempos passados (GRAVES, 2014; SANTOS; CHAUCOSKI, 2020; PASSOS, 2021).

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

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad 1$$

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad 2$$

$$\tilde{C}_t = \tanh(w_c \cdot [h_{t-1}, x_t] + b_c) \quad 3$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad 4$$

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad 5$$

$$h_t = o_t * \tanh(C_t) \quad 6$$

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, σ a função de ativação *sigmoid* e *tanh* a função de ativação tangente hiperbólica.




Figura 1. Células LSTM e GRU
 Fonte: Adaptado de Tutorial Example (2020).

Modelo BIGRU:

A rede GRU, introduzida em 2014, pode ser considerada uma variação da LSTM, porque ambas são projetadas de maneira semelhante (SHEWALKAR, 2019). Na GRU são utilizadas apenas duas portas de controle (Figura 1). Uma porta de atualização (r_t - *update gate*) que faz o papel da porta de esquecimento e de entrada e uma porta de redefinição (z_t - *reset gate*). Estas portas gerenciam o fluxo de dados da rede neural (SILVA et al., 2022).

As equações da rede GRU são definidas como (SHEWALKAR et al., 2019):

$$z_t = \sigma(w_z * [h_{t-1}, x_t] + b_z) \quad 7$$

$$r_t = \sigma(w_r * [h_{t-1}, x_t] + b_r) \quad 8$$

$$\tilde{h}_t = \tanh(w_h * [r_t \cdot h_{t-1}, x_t] + b_h) \quad 9$$

$$h_t = (1 - z) \cdot h_{t-1} + z_t \cdot \tilde{h}_t \quad 10$$

Onde σ é a função de ativação *sigmoid*, *tanh* é a função de ativação tangente hiperbólica, \tilde{h}_t é a informação da porta de atualização, w_z , w_r e w_h são os pesos e b_z , b_r e b_h são os bias.

A rede GRU só pode ler informações do passado. Contudo, várias tarefas de modelagem sequencial necessitam de informações tanto do passado quanto do presente. A rede BIGRU pode ser criada por meio de duas camadas intermediárias, considerando uma sequência *forward* (\vec{h}_t) e uma sequência *backward* (\overleftarrow{h}_t) que são transmitidas para a camada de saída (Figura 2) (YIN et al., 2021; WANG et al., 2021).




Figura 2. Estrutura da BIGRU
 Fonte: Adaptado de Wang et al. (2021)

As sequências \vec{h}_t e \overleftarrow{h}_t são combinadas para encontrar a sequência de saída h_t :

$$\vec{h}_t = f(x_t, \vec{h}_{t-1}) \quad 11$$

$$\overleftarrow{h}_t = f(x_t, \overleftarrow{h}_{t-1}) \quad 12$$

$$h_t = w_{t1} \vec{h}_t + w_{t2} \overleftarrow{h}_t + b_t \quad 13$$

Onde w_{t1} e w_{t2} são os pesos e b_t o bias.

Modelo BIGRU-CNN

As redes CNN (*Convolutional neural network*), variação das redes MLP (*Multilayer perceptron*), foram inspiradas no processo biológico de processamento de dados visuais

(VARGAS, 2022). A versão 1D, da rede *feedforward* CNN, é utilizada para tratar sequência de dados, tais como séries temporais, gravação de áudio, etc (LAWAL, 2021).

As redes CNNs, capazes de codificar informações importantes contidas nos dados de entrada, são compostas, além da camada de entrada, por três camadas principais: camada convolucional, camada de *pooling* e uma camada totalmente conectada.

O modelo BIGRU-CNN extrai inicialmente as dependências de longo prazo da série temporal através da BIGRU. Na sequência, usa a rede CNN para extrair, por meio das camadas de convolução e *pooling*, os relacionamentos locais significativos (Figura 3) (SOARES, 2022).

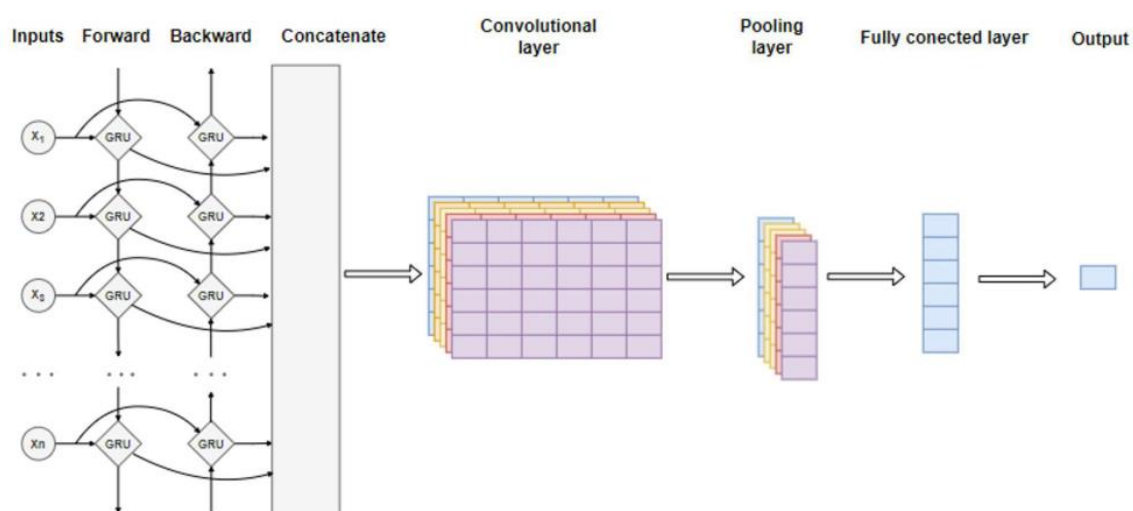


Figura 3. Modelo BIGRU-CNN
Fonte: Soares et al. (2022).

Base de dados:

Inicialmente, para previsão da energia eólica, em MW médio (MWmed) da Usina de Icaraizinho, obteve-se, do Operador Nacional do Sistema Elétrico (ONS), uma base de dados com 140 instâncias (Jan/2010 - Ago/2021) (ONS, 2022). Na sequência, o conjunto de dados foi expandido usando interpolação. Inicialmente, os dados possuíam 140 instâncias, após a interpolação esse número passou para 557 instâncias. A série histórica é apresentada na Figura 4.




Figura 4. Série: Geração eólica (Icaraizinho)

Os dados de geração de energia eólica, da Usina de Icaraizinho, foram divididos em três conjuntos. O primeiro conjunto, o conjunto de treinamento, foi formado pelos primeiros 436 dados. O segundo conjunto, o conjunto de validação, foi constituído pelos seguintes 109 dados. Finalmente, o conjunto de teste foi formado pelos 12 dados restantes.

Os dados, para evitar que o desempenho dos algoritmos fossem afetados, foram normalizados. A normalização, para o intervalo de $[0,1]$, foi realizada por meio da função `MinMaxScaler()` da biblioteca `Scikit-learn`.

Métricas:

Neste trabalho, os modelos obtidos foram avaliados pelas métricas *RSME* (*Root Mean Squared Error*), *MAPE* (*Mean Absolute Percent Error*) e *MAE* (*Mean Absolute Error*). Estas métricas são amplamente empregadas em problemas de previsão de séries temporais. O *RMSE* permite avaliar a qualidade de um preditor em relação aos dados, o *MAE* representa o desvio médio entre o valor observado e o predito e o *MAPE* mede o tamanho do erro em termos percentuais (CANKURT; SUBASI, 2015; SANTOS, 2021; SANTOS, 2022).

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

Tabela 1. Equações: *RMSE*, *MAE* e *MAPE*.

Métrica	RSME	MAE	MAPE
---------	------	-----	------

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

Fonte: Santos, 2021.

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.

Etapas do trabalho:

Inicialmente, neste trabalho, realizou-se a análise exploratória dos dados, obtidos do Operador Nacional do Sistema Elétrico (ONS), com a intenção de obter informações importantes sobre os mesmos. Em seguida, realizou-se a etapa de modelagem. Nesta etapa, por meio dos conjuntos de treinamento e validação, foram desenvolvidos os modelos BIGRU-CNN, LSTM, GRU e CNN. Finalmente, na última etapa, analisou-se a precisão dos modelos, por meio das métricas MAE, RSME e MAPE, no conjunto de teste.

3. RESULTADOS E DISCUSSÃO

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados (Tabela 2).

Tabela 2. Análise descritiva.

Parâmetro analisado	Resultado
Média (MWmed)	23,22
Mínimo (MWmed)	2,7
Máximo (MWmed)	41,9
Desvio Padrão (MWmed)	11,27
Coeficiente de Variação (%)	48,5

Pode-se observar, dos dados apresentados na Tabela 2, que a geração ficou, para o período em estudo, em média 23,22 MWmed. Apresentando, neste período, geração mínima e máxima de 2,7 MWmed e 41,9 MWmed, respectivamente. Observa-se também um alto coeficiente de variação (48,5%), o que indica variabilidade dos dados.

Na Figura 5 apresenta-se a geração anual de energia, do parque eólico de Icaraizinho, para os anos de 2010 à 2020. Observa-se, desta figura, que o parque eólico teve geração máxima e mínima de 362,49 MWmed (2012) e 221,8 MWmed (2018 e 2020),

respectivamente. Observa-se também, desta figura, uma queda de geração anual de energia, do parque eólico, a partir de 2012.




Figura 5. Geração eólica de 2010 à 2020

Na Figura 6 apresentam-se as médias mensais de geração eólica. Pode-se notar, por meio desta figura, que o maior potencial eólico concentra-se na primavera e no inverno. Diminuindo até a chegada do verão, onde há menor incidência de ventos (COELHO, 2021; SPANCERSKI; SANTOS, 2021).




Figura 6. Média mensal de geração eólica

Treinamento e validação:

Neste trabalho implementou-se os modelos de redes neurais por meio da biblioteca Keras, rodando como *frontend* em TensorFlow. As redes neurais foram treinadas com 436 amostras e validadas com 109 amostras. A construção dos modelos explorou, com o objetivo de obter a melhor modelagem possível da geração de energia eólica, a combinação de diferentes hiperparâmetros. A melhor combinação utilizou o algoritmo de otimização Adam com os seguintes parâmetros: *look_back* = 14, *cells* = 32, *learning rate* = 0.001, *dropout* = 0,15 e *activate* = relu. Para a rede CNN utilizou-se *filters* = 16 e *kernel* = 6. Todas as redes foram treinadas com 73 épocas e um batch = 30. Os resultados das métricas, para os três modelos, são apresentados na Tabela 3.

Tabela 3. Métricas – Conjunto de validação

Métrica	Modelo			
	BIGRU-CNN	LSTM	GRU	CNN
MAE (MWmed)	1,62	1,53	1,71	2,36
RMSE (MWmed)	1,97	1,95	2,22	2,76
MAPE (%)	15,7	15,3	20,17	24,85

Nota-se, para o conjunto de validação, que os melhores resultados foram obtidos pelas redes LSTM e BIGRU-CNN. Destacando que os resultados das redes LSTM e BIGRU-CNN estão muito próximos.

Na Figura 7 apresentam-se, como exemplo, os resultados da predição, de treino e validação, para o modelo BIGRU-CNN.

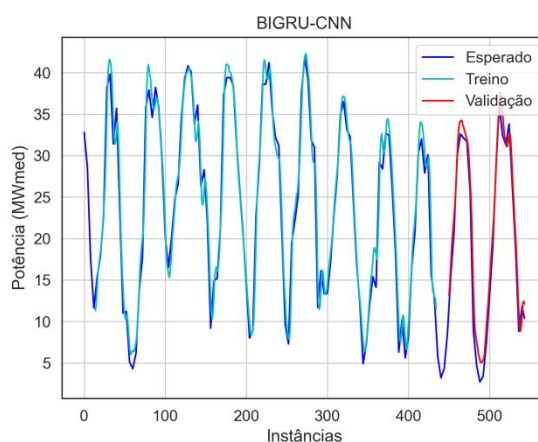


Figura 7. Rede BIGRU-CNN – treino e validação

Teste:

Para comparar o potencial dos modelos de previsão, utilizados neste trabalho, realizou-se uma comparação entre os modelos BIGRU-CNN, LSTM, GRU e CNN. Na Tabela 4 apresentam-se, para estes modelos, os dados observados e preditos para as 12 instâncias, do conjunto de teste, que não participaram da etapa de treino e validação.

Tabela 4. Previsão de geração eólica (MWmed)

Instância	Observado	BIGRU-CNN	LSTM	GRU	CNN
1	11,3	11,12	12,02	11,88	12,01
2	12,7	12,27	12,88	12,41	13,32
3	14,1	13,43	14,09	13,63	14,81
4	15,5	15,24	15,19	14,26	17,07
5	17,625	17,63	16,64	15,76	18,78
6	19,75	19,71	18,55	17,2	20,93
7	21,875	22,01	19,8	18,75	23
8	24	24,15	20,94	20,08	24,73
9	26,2	26,07	22,01	21,32	26,5
10	28,4	27,98	23,02	22,25	28,09
11	30,6	29,75	24,29	23,74	29,77
12	32,8	31,58	25,47	24,99	31,95

Os resultados das previsões, da geração eólica do conjunto de teste, em termos gráficos, são apresentados na Figura 8.

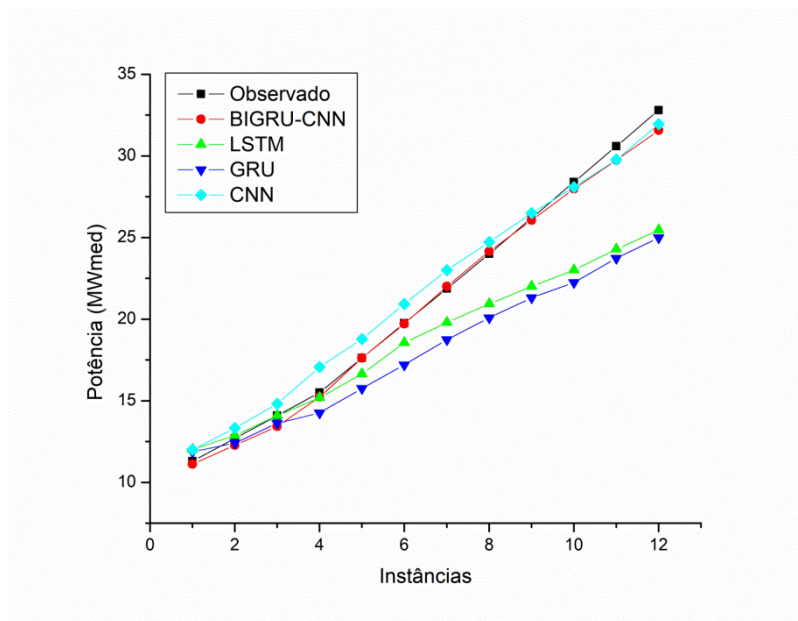


Figura 8. Previsões – conjunto de teste

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

Tabela 5. Métricas – Conjunto de teste

Métrica	Modelo			
	BIGRU-CNN	LSTM	GRU	CNN
MAE (MWmed)	0,37	2,64	3,3	0,84
RMSE (MWmed)	0,51	3,61	4,14	0,97
MAPE (%)	1,76	10,13	13,25	4,57

Por meio dos resultados apresentados, na Tabela 5, conclui-se que o modelo BIGRU-CNN apresentou melhor desempenho, em relação as métricas MAE, RMSE e MAPE, que os modelos LSTM, GRU e CNN. Resultado equivalente foi encontrado por Soares et al. (2022), ao comparar, na previsão da demanda elétrica de curto prazo, a rede BIGRU-CNN com outras redes neurais.

4. CONSIDERAÇÕES FINAIS

Neste trabalho foram utilizados; na previsão da geração de energia do parque eólico de Icaraizinho, modelos de redes neurais artificiais de arquitetura BIGRU-CNN, LSTM, GRU e CNN. Os modelos foram construídos com base nos dados fornecidos pelo operador nacional do sistema elétrico (ONS).

Observou-se, para um horizonte de curto prazo (12 instâncias), que as taxas de erro, MAE, RMSE e MAPE, do modelo de previsão BIGRU-CNN foram menores que as taxas dos modelos LSTM, GRU e CNN. Observou-se também que as previsões, do modelo BIGRU-CNN para o conjunto de teste, foram bem precisas e as diferenças entre valores reais e preditos foram pequenas. Portanto, a proximidade entre valores preditos e reais demonstram a boa capacidade de generalização, para um horizonte de curto prazo, do modelo BIGRU-CNN.

Embora, a rede BIGR-CNN tenha apresentado bons resultados, quando comparados com as redes LSTM, GRU e CNN, sugere-se, para trabalhos futuros, uma comparação com outras redes híbridas.

REFERÊNCIAS

- ABRAHAM, B. **Statistical methods for forecasting**. New York: Wiley & Sons, 2019.
- AQUILA, G.; PAMPLONA, E.; QUEIROZ, A. R.; ROTE, J. P.; FONSECA, M. N. An overview of incentive policies for the expansion of renewable energy generation in electricity power systems and the Brazilian experience. **Renew. Sustain. Energy Ver**, 70(1), 2017.
- BASTIANI, M.; SANTOS, J. A. A.; SCHMIDT, C. A. P.; SEPULVEDA, G. P. L. Application of data mining algorithms in the management of the broiler production. **Geintec**, v. 8, 2018.
- BULHÕES, D. B. **Estratégias de previsão de geração de energia eólica utilizando redes neurais artificiais**. Dissertação de Mestrado, Universidade Federal de Sergipe, São Cristovão, 2015.
- CANKURT, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, 2015.
- COELHO, I. **Estudo sobre a aplicação de redes neurais recorrentes para previsão da geração eólica e do preço de liquidação das diferenças**. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, 2018.
- DALMAZ, A. **Estudo do potencial eólico e previsão de ventos para geração de eletricidade em Santa Catarina**. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, 2007.
- EPBR. **Novas usinas devem aumentar capacidade de geração de energia em 7,6 GW, diz Aneel**. Disponível em: <https://epbr.com.br/novas-usinas-devem-aumentar-geracao-de-energia-em-76-gw-diz-aneel/>. Acesso em 15 mar. 2022.
- FARIA, J. G. **Machine learning aplicado à previsão de geração de energia eólica com diferentes modelos de previsão numérica do tempo**. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, 2020.
- GRAVES A. **Towards end-to-end speech recognition with recurrent neural networks**. In: 31st International Conference on Machine Learning, Proceedings [...]. Beijing: ICML-14, 2014.
- HAYKIN, S. **Neural networks: a comprehensive foundation**. New Delhi: Pearson Prentice Hall, 2001.
- HIRUMA, F. S. **Previsão da geração de energia eólica com redes neurais artificiais**. Dissertação de Mestrado. Universidade Federal do Paraná, Curitiba, 2016.
- LAWAL, A.; REHMAN, S; ALEMS, L. M.; ALAM, M. Wind Speed Prediction Using Hybrid 1D CNN and BLSTM Network. **IEEE Acess**, 9(1), 2021.
- MOREIRA, R. N.; VIANA, A. F.; OLIVEIRA, D. A. B.; VIDAL, F. A. B. Energia eólica no quintal da nossa casa?! Percepção ambiental dos impactos socioambientais na instalação e operação de uma usina na comunidade de sítio de Cumbe em Aracati-CE. **Revista de Gestão Ambiental e Sustentabilidade – GeAS**, 2(1), 2013.

ONS, Operador Nacional do Sistema Elétrico. **O sistema interligado nacional**. Disponível em: <http://www.ons.org.br>. Acesso em 15 mar. 2022.

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.

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**, 2020.

QUIROZ, D. E. S. **Análise comparativa de diferentes metodologias de redes neurais artificiais para previsão de geração eólica**. Dissertação de Mestrado, Universidade Federal de Santa Catarina, Florianópolis, 2017.

SANTOS, J. A. A. Previsão do preço da arroba do boi gordo: um estudo de caso usando ARIMA e GRU. **Revista Tekhne e Logos**, 12(3), 2021.

SANTOS, J. A. Previsão do preço do café arábica: uma aplicação de redes neurais CNN-BLSTM. **Research, Society and Development**, 11(3), 2022.

SANTOS, J. A. A.; CHAUKOSKI, Y. Previsão do consume de energia elétrica na região sudeste: um estudo de caso usando SARIMA e LSTM. **Revista CEREUS**, vol. 12, n. 4, 2020.

SEBASTIAN, S. Performance evaluation by artificial neural network using WEKA. **International Research Journal of Engineering and Technology**, v. 3, 2016.

SILVA, M., SANTOS, P.; FORERO, L.; JUNIOR, H. M. **Previsão de carga horária como parâmetro do modelo de precificação e despacho hidrotérmico de curto prazo (DESSEM)**. Disponível em: <http://abricom.org.br/eventos/cbic2019/cbic2019-96/>. Acesso em: 12 mar. 2022.

SHEWALKAR, A.; NYAVANANDI, D.; LUDWIG, S. A. Performance evaluation of deep neural networks applied to speech recognition; RNN, LSTM and GRU. **JAICR**, 2019.

SOARES, L. D. **Redes neurais artificiais BiGRU-CNN aplicadas a previsão de demanda de energia elétrica de curto prazo**. Dissertação de mestrado, Universidade Estadual do Paraná – UNIOESTE, Foz do Iguaçu, 2021.

SOARES, L. D.; CARREÑO, E. M.; BiGRU-CNN neural network applied to short-term electric load forecasting. **Production**, 32(1), 2022.

SPANCERSKI, J. S.; SANTOS, J. A. A. Aplicação de redes neurais recorrentes na previsão de geração eólica. **Revista CEREUS**, 13(1), 217-227, 2021.

Tutorial Example. **LSTM Vs GRU Network: Which Has better Performance? – Deep Learning Tutorial**. 2020, Disponível em: < <https://www.tutorialexample.com/lstm-vs-gru-network-which-has-better-performance-deep-learning-tutorial/>>. Acesso em: 12 mar. 2022.

VARGAS, A. C. G.; PAES, A.; VASCONCELOS, C. N. **Um estudo sobre redes neurais convolucionais e sua aplicação em detecção de pedestres**. Disponível em: <<http://sibgrapi.sid.inpe.br/col/sid.inpe.br/sibgrapi/2016/09.12.15.44/doc/um-estudo-sobre.pdf>>. Acesso em: 19 mar. 2022.

WANG, F.; SHI, Y.; LIU, B.; ZUO, Y.; FU, Z. ALI, J. Health state estimation of lithium-ion batteries based on attention augmented BiGRU. **Energy Storage Science and Technology**, 10(6), 2021.

YIN, X.; KIU, C.; FANG, X. Sentiment analysis based on BiGRU information enhancement. **In: Journal of Physics (ISCME 2020)**, 2021.