v7.n10.2026

REVISTA CIENTÍFICA - RECIMA21 ISSN 2675-6218

PREVISÃO DE GERAÇÃO DE ENERGIA EÓLICA E SOLAR UTILIZANDO REDES NEURAIS RECORRENTES E CONVOLUCIONAIS: UMA ABORDAGEM HÍBRIDA CNN-GRU

FORECASTING WIND AND SOLAR ENERGY GENERATION USING RECURRENT AND CONVOLUTIONAL NEURAL NETWORKS: A HYBRID CNN-GRU APPROACH

PRONÓSTICO DE GENERACIÓN DE ENERGÍA EÓLICA Y SOLAR UTILIZANDO REDES NEURONALES RECURRENTES Y CONVOLUCIONALES: UN ENFOQUE HÍBRIDO CNN-GRU

Fábio Pinto Monte[1], Fidelis Zanetti de Castro[2], Cassius Zanetti Resende[3]

e7108797
https://doi.org/10.47820/recima21.v7i10.8797

PUBLICADO: 10/2026

RESUMO

Este artigo expande um trabalho anterior que investigou a previsão de geração de energia eólica e solar utilizando redes neurais recorrentes (LSTM e GRU). Reconhecendo a importância da precisão para a integração de energias renováveis na rede elétrica, o presente estudo aprimora a metodologia original ao incorporar uma camada de Rede Neural Convolucional (CNN) a um modelo GRU, criando uma arquitetura híbrida CNN-GRU. O objetivo é explorar como a CNN pode melhorar a extração de características de dados meteorológicos, otimizando a previsão. A metodologia envolveu a coleta e pré-processamento de dados meteorológicos e de geração de energia do IEEE DataPort, seguida pela construção, treinamento e avaliação dos modelos LSTM, GRU e CNN-GRU utilizando validação cruzada temporal. Os resultados demonstraram que, embora o LSTM tenha apresentado o melhor desempenho médio (R^2 de 0,946 ± 0,005), o modelo híbrido CNN-GRU (R^2 de 0,925 ± 0,008) superou o GRU autônomo (R^2 de 0,917 ± 0,008). Esta melhoria sugere que a camada CNN foi eficaz na identificação de padrões locais nos dados meteorológicos, contribuindo para previsões mais robustas. O estudo conclui que a abordagem híbrida CNN-GRU é promissora para aprimorar a previsão de energia renovável, especialmente em cenários com dados de entrada complexos.

PALAVRAS-CHAVE: Energia renovável. LSTM. GRU. CNN-GRU.

ABSTRACT

This article expands on previous work that investigated wind and solar energy generation forecasting using recurrent neural networks (LSTM and GRU). Recognizing the importance of accuracy for the integration of renewable energies into the electrical grid, the present study enhances the original methodology by incorporating a Convolutional Neural Network (CNN) layer into a GRU model, creating a hybrid CNN-GRU architecture. The objective is to explore how CNN can improve feature extraction from meteorological data, optimizing forecasting. The methodology involved the collection and preprocessing of meteorological and energy generation data from the IEEE DataPort, followed by the construction, training, and evaluation of LSTM, GRU, and CNN-GRU models using temporal cross-validation.

[1] Graduado em Matemática pelo Centro Universitário São Camilo - ES. Mestrando no Programa de Pós-Graduação em Engenharia de Controle e Automação pelo Instituto Federal do Espírito Santo (Ifes), Campus Serra.
[2] Graduado e mestre em Matemática pela Universidade Federal do Espírito Santo (UFES) e doutor em Matemática Aplicada pela Universidade Estadual de Campinas (UNICAMP), com tese premiada. É professor e pesquisador do Instituto Federal do Espírito Santo (Ifes), com atuação na graduação e na pós-graduação. Desenvolve pesquisas nas áreas de Inteligência Computacional, aprendizado de máquina, redes neurais artificiais, processamento de imagens e linguagem natural.
[3] Graduado, mestre e doutor em Engenharia Elétrica pela Universidade Federal do Espírito Santo (UFES). É professor do Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo (Ifes). Atua nas áreas de eletrônica de potência, automação, robótica móvel, sistemas inteligentes e sistemas embarcados.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

The results demonstrated that, although LSTM showed the best average performance (R^2 of 0.946 ± 0.005), the hybrid CNN-GRU model (R^2 of 0.925 ± 0.008) outperformed the standalone GRU model (R^2 of 0.917 ± 0.008). This improvement suggests that the CNN layer was effective in identifying local patterns in meteorological data, contributing to more robust forecasts. The study concludes that the hybrid CNN-GRU approach is promising for enhancing renewable energy forecasting, especially in scenarios with complex input data.

KEYWORDS: *Renewable energy. LSTM. GRU. CNN-GRU.*

RESUMEN
Este artículo amplía un trabajo anterior que investigó la previsión de generación de energía eólica y solar utilizando redes neuronales recurrentes (LSTM y GRU). Reconociendo la importancia de la precisión para la integración de energías renovables en la red eléctrica, el presente estudio mejora la metodología original al incorporar una capa de Red Neuronal Convolucional (CNN) a un modelo GRU, creando una arquitectura híbrida CNN-GRU. El objetivo es explorar cómo la CNN puede mejorar la extracción de características de los datos meteorológicos, optimizando la previsión. La metodología implicó la recopilación y el preprocesamiento de datos meteorológicos y de generación de energía del IEEE DataPort, seguido de la construcción, entrenamiento y evaluación de los modelos LSTM, GRU y CNN-GRU utilizando validación cruzada temporal. Los resultados demostraron que, aunque LSTM mostró el mejor rendimiento promedio (R^2 de 0.946 ± 0.005), el modelo híbrido CNN-GRU (R^2 de 0.925 ± 0.008) superó al modelo GRU autónomo (R^2 de 0.917 ± 0.008). Esta mejora sugiere que la capa CNN fue efectiva en la identificación de patrones locales en los datos meteorológicos, contribuyendo a pronósticos más robustos. El estudio concluye que el enfoque híbrido CNN-GRU es prometedor para mejorar la previsión de energía renovable, especialmente en escenarios con datos de entrada complejos.

PALABRAS CLAVE*: Energía renovable. LSTM. GRU. CNN-GRU.*

INTRODUÇÃO

Este artigo expande o trabalho previamente apresentado em congresso, que abordou a previsão de geração de energia eólica e solar utilizando Redes Neurais Recorrentes (RNNs), especificamente os modelos Long Short-Term Memory (LSTM) e Gated Recurrent Unit (GRU). A crescente demanda por fontes de energia renováveis e a inerente intermitência de sua geração ressaltam a importância de sistemas de previsão precisos para a integração eficiente na rede elétrica [1].

O trabalho original demonstrou a eficácia de modelos LSTM e GRU na captura de padrões temporais complexos em dados meteorológicos e de geração de energia. No entanto, a literatura recente tem explorado a combinação de diferentes arquiteturas de redes neurais para otimizar ainda mais a capacidade preditiva, especialmente em cenários com dados multidimensionais como os meteorológicos [2].

O objetivo geral deste trabalho é desenvolver e avaliar um modelo aprimorado para a previsão de geração de energia eólica e solar, integrando uma camada de Redes Neurais

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

Convolucionais (CNN) a arquiteturas recorrentes para otimizar a extração de características de dados meteorológicos e aumentar a precisão preditiva.

Para alcançar este objetivo geral, foram definidos os seguintes objetivos específicos:

- Integrar uma camada CNN a um modelo GRU para formar uma arquitetura híbrida (CNN-GRU) capaz de processar eficientemente dados meteorológicos;
- Comparar o desempenho do modelo híbrido CNN-GRU com os modelos LSTM e GRU autônomos, avaliando a melhoria na precisão da previsão;
- Analisar a contribuição da camada CNN na extração de características relevantes dos dados meteorológicos para a previsão de energia;
- Discutir as implicações práticas e teóricas da abordagem híbrida para a previsão de energia renovável.

Justificativa: A precisão na previsão de geração de energia renovável é crucial para a estabilidade da rede elétrica e para a otimização da gestão de recursos. A introdução de uma camada CNN pode capturar padrões espaciais ou locais nos dados meteorológicos que podem não ser totalmente explorados por RNNs puras, potencialmente levando a previsões mais robustas e precisas. Este estudo justifica-se pela necessidade de desenvolver modelos mais completos e validados, capazes de lidar com a complexidade da previsão de energia renovável, contribuindo assim para avanços significativos no estado da arte da área.

Problema: Como a integração de uma camada CNN a modelos GRU pode melhorar a precisão da previsão de geração de energia eólica e solar a partir de dados meteorológicos, e qual o impacto dessa abordagem híbrida em comparação com modelos RNN tradicionais?

1. REFERENCIAL TEÓRICO

A previsão de geração de energia renovável é um campo de pesquisa vital, impulsionado pela necessidade de integrar fontes como a eólica e a solar de forma confiável nas redes elétricas. A intermitência e a variabilidade dessas fontes exigem modelos preditivos robustos para otimizar a operação da rede, gerenciar a demanda e evitar desequilíbrios energéticos [3].

1.1. Redes Neurais Recorrentes (RNNs): LSTM e GRU

As Redes Neurais Recorrentes (RNNs) são amplamente reconhecidas por sua capacidade de processar sequências de dados, tornando-as ideais para tarefas de previsão de séries temporais. Entre as variantes de RNNs, as Long Short-Term Memory (LSTM) e as Gated Recurrent Unit (GRU) se destacam por sua habilidade em lidar com o problema do gradiente evanescente, permitindo a captura de dependências de longo prazo nos dados [4].

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

As LSTMs, introduzidas por Hochreiter e Schmidhuber [5], utilizam uma arquitetura complexa com células de memória e três portões (entrada, esquecimento e saída) que controlam o fluxo de informações. Essa estrutura permite que as LSTMs armazenem e recuperem informações por longos períodos, sendo eficazes em tarefas de previsão de energia [6].

As GRUs, propostas por Cho et al. [7], são uma variação mais simplificada das LSTMs, com dois portões (atualização e reset). Apesar de sua menor complexidade, as GRUs frequentemente alcançam desempenho comparável às LSTMs, com a vantagem de um menor custo computacional e tempo de treinamento [8]. O trabalho original demonstrou que o GRU apresentou um desempenho ligeiramente superior ao LSTM para a previsão de energia eólica e solar [1].

1.2. Redes Neurais Convolucionais (CNNs) para séries temporais

Tradicionalmente, as Redes Neurais Convolucionais (CNNs) são associadas ao processamento de imagens, onde se destacam na extração de características espaciais. No entanto, as CNNs também têm se mostrado eficazes no processamento de séries temporais, especialmente com o uso de camadas Conv1D [9]. Ao aplicar filtros convolucionais unidimensionais, as CNNs podem identificar padrões locais e hierárquicos nos dados sequenciais, como tendências e sazonalidades em dados meteorológicos [10].

A capacidade das CNNs de extrair características de forma automática e hierárquica as torna valiosas para pré-processar dados de séries temporais, reduzindo a dimensionalidade e destacando informações relevantes antes de serem alimentadas em modelos sequenciais como as RNNs. Isso é particularmente útil para dados meteorológicos, onde padrões locais (p. ex., variações de temperatura em curtos períodos) podem ser cruciais para a previsão de energia [2].

1.3. Modelos híbridos CNN-RNN

A combinação de CNNs e RNNs em modelos híbridos tem ganhado destaque na literatura para tarefas de previsão de séries temporais complexas. A arquitetura híbrida aproveita o melhor de ambos os mundos: a capacidade da CNN de extrair características locais e a habilidade da RNN de modelar dependências temporais de longo prazo [8].

Em contextos de previsão de energia, modelos híbridos CNN-LSTM ou CNN-GRU têm demonstrado resultados promissores ao integrar informações de diferentes naturezas, como dados meteorológicos e históricos de geração. A camada CNN pode atuar como um extrator de características para os dados de entrada, fornecendo representações mais ricas e compactas para as camadas RNN subsequentes, que então processam essas características

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

sequencialmente para fazer a previsão [9]. Esta abordagem tem o potencial de superar o desempenho de modelos autônomos, especialmente quando os dados de entrada possuem uma estrutura complexa e multidimensional, como é o caso dos dados meteorológicos utilizados neste estudo.

2. METODOLOGIA

Esta seção detalha a metodologia empregada para adaptar e aprimorar o modelo de previsão de geração de energia eólica e solar, incorporando uma arquitetura híbrida CNN-GRU. A abordagem segue as etapas de coleta e pré-processamento de dados, construção do modelo híbrido, treinamento e avaliação, com o objetivo de comparar seu desempenho com os modelos LSTM e GRU autônomos previamente estudados.

2.1. Coleta e pré-processamento de dados

Os dados utilizados neste estudo são provenientes do IEEE DataPort, consistindo em informações meteorológicas históricas e dados de geração de energia eólica e solar. O conjunto de dados inclui variáveis como temperatura, umidade, velocidade do vento, irradiação solar e a geração de energia correspondente. Para garantir a consistência e a qualidade dos dados, as seguintes etapas de pré-processamento foram realizadas: (i) Limpeza de Dados, com a identificação e tratamento de valores ausentes ou anômalos; (ii) Normalização, onde os dados numéricos foram escalados para um intervalo entre 0 e 1 utilizando o MinMaxScaler, etapa crucial para otimizar o treinamento de redes neurais; (iii) Engenharia de Características, com a extração e codificação de variáveis temporais como hora do dia, dia da semana e mês, conforme a abordagem do trabalho original, para capturar padrões sazonais e diários; e (iv) Criação de Sequências, transformando os dados em sequências de entrada e saída utilizando uma janela deslizante, onde para cada ponto no tempo t, a entrada do modelo consiste em uma sequência de n observações anteriores e a saída é a previsão para o próximo passo de tempo t+1.

2.2. Arquitetura do modelo híbrido CNN-GRU

O modelo híbrido proposto integra uma camada de Rede Neural Convolucional (CNN) unidimensional com uma camada de Gated Recurrent Unit (GRU). Esta arquitetura é projetada para aproveitar a capacidade da CNN de extrair características locais e relevantes dos dados meteorológicos, e a habilidade da GRU de modelar dependências temporais de longo prazo nas sequências resultantes.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

A estrutura do modelo é composta por uma camada Conv1D inicial com 64 filtros e um tamanho de núcleo (kernel size) de 3, responsável por escanear as sequências de entrada para identificar padrões locais, utilizando a função de ativação ReLU para introduzir não-linearidade. Em seguida, uma camada MaxPooling1D com tamanho de pool igual a 2 é aplicada para reduzir a dimensionalidade das características extraídas, mantendo as informações mais relevantes. Para prevenir o overfitting, uma camada de Dropout com taxa de 0,2 é inserida. A sequência processada é então alimentada em uma camada GRU com 64 unidades, configurada para retornar apenas a saída do último passo de tempo. Finalmente, uma camada densa de saída com uma única unidade gera a previsão final da geração de energia. O modelo é compilado utilizando o otimizador Adam e a função de perda de erro quadrático médio (MSE).

2.3. Treinamento e avaliação do modelo

O treinamento e a avaliação do modelo híbrido CNN-GRU seguem uma metodologia rigorosa para garantir a robustez e a generalização dos resultados. A validação cruzada temporal (TimeSeriesSplit) foi empregada com 5 divisões (splits), garantindo que os dados de validação sejam sempre cronologicamente posteriores aos dados de treinamento, simulando um cenário de previsão real.

O processo de treinamento utiliza o mecanismo de Early Stopping, configurado para monitorar a perda de validação com uma paciência de 5 épocas, restaurando os melhores pesos encontrados para evitar o sobreajuste. O treinamento é executado por até 50 épocas com um tamanho de lote (batch size) de 32. Para a avaliação do desempenho, o coeficiente de determinação R^2 é calculado utilizando os valores desnormalizados, garantindo que a métrica reflita a precisão na escala original dos dados de geração de energia. A média e o desvio padrão do R^2 entre os folds da validação cruzada são utilizados como a medida final de eficácia do modelo híbrido.

3. RESULTADOS E DISCUSSÃO

Nesta seção, apresentamos e discutimos os resultados obtidos com os três modelos de previsão: LSTM, GRU e o modelo híbrido CNN-GRU. A avaliação foi realizada utilizando validação cruzada temporal com 5 folds, e o desempenho de cada modelo foi quantificado pelo coeficiente de determinação R^2 (calculado sobre os valores desnormalizados), além da análise das curvas de perda durante o treinamento.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

3.1. Desempenho comparativo dos modelos

A Tabela 1 sumariza o desempenho médio (R^2) e o desvio padrão para cada um dos modelos avaliados nos 5 folds da validação cruzada.

Tabela 1. Desempenho comparativo dos modelos LSTM, GRU e CNN-GRU em termos de R^2 médio

Modelo	R^2 Médio ± Desvio Padrão
LSTM	0,946 ± 0,005
GRU	0,917 ± 0,008
CNN-GRU	0,925 ± 0,008

Os resultados indicam que o modelo LSTM apresentou o melhor desempenho médio em termos de R^2, com um valor de 0,946. O modelo híbrido CNN-GRU obteve um R^2 médio de 0,925, superando o modelo GRU autônomo, que registrou 0,917. A inclusão da camada CNN no modelo GRU resultou em uma melhoria no desempenho, sugerindo que a capacidade da CNN de extrair características locais dos dados meteorológicos contribuiu positivamente para a precisão da previsão.

Embora o LSTM tenha demonstrado o R^2 médio mais alto, é importante notar que o CNN-GRU apresentou um desvio padrão similar ao GRU, indicando uma consistência comparável nos resultados entre os folds. A melhoria do CNN-GRU em relação ao GRU puro reforça a hipótese de que a combinação de arquiteturas pode ser benéfica para capturar diferentes aspectos dos dados de séries temporais complexas, como os dados meteorológicos e de geração de energia.

3.2. Análise da convergência e perda

A análise das curvas de perda (loss) durante o treinamento de cada fold para o modelo CNN-GRU demonstrou uma convergência estável, com a perda de validação acompanhando de perto a perda de treinamento e indicando a eficácia do mecanismo de Early Stopping em evitar o overfitting.

3.3. Discussão dos resultados

A superioridade do LSTM em relação ao GRU observada neste estudo pode ser atribuída à sua capacidade de lidar com dependências de longo prazo de forma mais robusta, apesar da maior complexidade. A introdução da camada CNN no modelo GRU visava aprimorar a extração de características, especialmente para dados meteorológicos, que podem conter padrões locais

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

importantes. Os resultados mostram que essa estratégia foi bem-sucedida em melhorar o desempenho do GRU, elevando seu R² médio de 0,917 para 0,925.

Essa melhoria sugere que a camada Conv1D foi eficaz em identificar e processar características relevantes nos dados de entrada antes que fossem alimentadas na camada GRU. Isso é particularmente relevante para dados meteorológicos, onde variações rápidas e padrões espaciais podem influenciar significativamente a geração de energia. A combinação da capacidade de extração de características da CNN com a habilidade de modelagem sequencial da GRU demonstra um potencial promissor para aprimorar a previsão de séries temporais complexas.

Futuras investigações poderiam explorar a otimização dos hiperparâmetros da camada CNN (p. ex., número de filtros, tamanho do kernel) e aprofundar a análise de quais características específicas estão sendo capturadas, a fim de maximizar ainda mais o desempenho do modelo híbrido.

4. CONSIDERAÇÕES FINAIS

As Redes Neurais Recorrentes (RNNs), como LSTM e GRU, demonstraram ser ferramentas eficazes para a previsão de geração de energia eólica e solar, conforme evidenciado no trabalho original. Este estudo buscou aprimorar essa capacidade preditiva através da integração de uma camada de Rede Neural Convolucional (CNN) a um modelo GRU, criando uma arquitetura híbrida CNN-GRU, com o objetivo de otimizar a extração de características de dados meteorológicos e, consequentemente, a precisão das previsões.

Os resultados comparativos revelaram que o modelo LSTM manteve o melhor desempenho geral em termos de R² médio (0,946 ± 0,005). No entanto, a introdução da camada CNN no modelo GRU resultou em uma melhoria notável no desempenho do GRU autônomo, elevando seu R² médio de 0,917 ± 0,008 para 0,925 ± 0,008. Essa melhoria sugere que a camada Conv1D foi bem-sucedida em capturar padrões locais e características relevantes nos dados meteorológicos, que são cruciais para a previsão de energia renovável. A capacidade da CNN de processar dados multidimensionais e extrair características de forma hierárquica complementou a habilidade da GRU em modelar dependências temporais, resultando em um modelo mais robusto.

A principal contribuição deste trabalho reside na demonstração da eficácia de modelos híbridos CNN-GRU para aprimorar a previsão de geração de energia eólica e solar, especialmente quando dados meteorológicos complexos são utilizados como entrada. A

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

abordagem híbrida oferece um caminho promissor para desenvolver sistemas de previsão mais precisos e confiáveis, o que é fundamental para a gestão eficiente de redes elétricas com alta penetração de energias renováveis.

Contudo, o estudo apresenta algumas limitações. A otimização dos hiperparâmetros da camada CNN e a exploração de diferentes configurações da arquitetura híbrida poderiam ser investigadas mais a fundo. Além disso, a análise de outros conjuntos de dados e a comparação com uma gama mais ampla de modelos híbridos poderiam fornecer uma visão mais abrangente do desempenho. Como futuras pesquisas, sugere-se a investigação de mecanismos de atenção para identificar a importância relativa das características extraídas pela CNN, a aplicação de técnicas de ensemble para combinar as previsões de múltiplos modelos, e a exploração de modelos de *deep learning* mais avançados para a previsão de energia renovável em diferentes horizontes de tempo.

REFERÊNCIAS

[1] Monte, F. P., Merlo, D. B., Castro, F. Z., & Resende, C. Z. (2025). Forecasting Wind and Solar Energy Generation Using Recurrent Neural Networks: A Comparison Between LSTM and GRU. In Proceedings of the XLVI Ibero-Latin American Congress on Computational Methods in Engineering, CILAMCE-2025.

[2] Aljuaydi, F. (2025). A *Deep learning* CNN-GRU-RNN Model for Sustainable Energy Forecasting. Engineering, Technology & Applied Science Research, 15(1), 9247.
[3] Cunha, B. A. (2021). Previsão intra-diária de geração fotovoltaica usando redes neurais. Repositório Institucional UNESP.

[4] Mahjoub, S., et al. (2022). Predicting Energy Consumption Using LSTM, Multi-Layer Perceptron and GRU. Sensors, 22(11), 4062.
[5] Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735-1780.

[6] Fernandes, J. V. C. (2025). Previsão de Irradiação Solar Usando Redes Neurais Recorrentes. Anais do Congresso Brasileiro de Qualidade de Energia Elétrica.

[7] Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation. Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP), 1724-1734.

[8] Soares, L. D. (2021). Redes Neurais Artificiais BiGRU_CNN Aplicadas à Previsão. Repositório Institucional UNIOESTE.

[9] Santos, A. H. R. (2026). Previsão de vento e energia com IA. Repositório Institucional UTFPR.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.

[10] Conte, S. (2021). Aplicação Híbrida com Redes Neurais Profundas e Algoritmo Genético. Anais do Congresso Brasileiro de Inteligência Computacional.

Este artigo é publicado em acesso aberto (Open Access) sob a licença Creative Commons Atribuição 4.0 Internacional (CC-BY), que permite uso, distribuição e reprodução irrestritos em qualquer meio, desde que o autor original e a fonte sejam creditados.