Aplicações de Inteligência Artificial para o Uso de Energia Renovável na Agricultura

Danilo Christensen – Universidade Estadual de Ponta Grossa – UEPG – danilocarneiro7@gmail.com
Railson Rodrigues – Universidade Estadual de Ponta Grossa – UEPG – railson_0612@hotmail.com
Oséias Silva Chagas Magalhães – Universidade Estadual de Ponta Grossa – UEPG – 10.oseias@gmail.com
Zito Palhano da Fonseca – Universidade Estadual de Ponta Grossa – UEPG – zpfonseca@uepg.br

Resumo: Este artigo aborda a crescente necessidade de substituir fontes de energia tradicionais por fontes renováveis, devido aos impactos negativos das primeiras sobre o meio ambiente e o esgotamento dos recursos naturais. A produção de energia renovável enfrenta desafios relacionados à sua variabilidade e instabilidade, o que pode ser mitigado pela aplicação de IA (*Artificial Intelligence* – Inteligência Artificial) e ML (*Machine Learning* – Aprendizado de Máquina). A revisão sistemática segue seis passos, incluindo a definição de estratégias de pesquisa e a análise crítica de artigos relevantes. A integração de IA em energias renováveis, utilizando técnicas como ANNs (*Artificial Neural Networks* - Redes Neurais Artificiais), CNNs (*Convolutional Neural Networks* - Redes Neurais Convolucionais) e LSTM (*Long Short-Term Memory* - Memória Longa de Curto Prazo), tem demonstrado potencial significativo na previsão precisa e eficiente da geração e consumo de energia. Estudos revelam que modelos híbridos, combinando diferentes técnicas de ML com sistemas de inferência fuzzy e otimização baseada em meta-heurísticas, melhoram a gestão de energia renovável. Apesar dos desafios de implementação e custo, a IA é essencial para otimizar a eficácia e sustentabilidade dos sistemas de energia renovável, tornando-os mais resilientes e confiáveis.

Palavras-chave: Energias renováveis, Inteligência Artificial, Aprendizado de Máquina, Agricultura.

Applications of artificial intelligence for the use of renewable energy in agriculture

Abstract: *This article addresses the growing need to replace traditional energy sources with renewable ones due to the negative impacts of the former on the environment and the depletion of natural resources. Renewable energy production faces challenges related to its variability and instability, which can be mitigated by applying artificial intelligence (AI) and machine learning (ML). The systematic review follows six steps, including the definition of research strategies and the critical analysis of relevant articles. The integration of AI into renewable energies, using techniques such as Artificial Neural Networks (ANNs), Convolutional Neural Networks (CNNs), and Long Short-Term Memory Networks (LSTM), has shown significant potential in accurately and efficiently predicting energy generation and consumption. Studies reveal that hybrid models, combining different ML techniques with fuzzy inference systems and optimization based on metaheuristics, improve the management of renewable energy. Despite the challenges of implementation and cost, AI is essential for optimizing the effectiveness and sustainability of renewable energy systems, making them more resilient and reliable.*
Key-words: *Renewable Energy, Artificial Intelligence, Machine Learning, Agriculture.*

1. Introdução

A utilização de fontes de energia tradicionais tem causado diversos problemas globais, sendo o aquecimento global um dos mais graves. Como resultado, há uma tendência atual de adotar fontes renováveis em vez das tradicionais, devido à preocupação com a poluição ambiental e ao esgotamento contínuo dos recursos energéticos convencionais. As fontes de energia renovável (RESs) produzem energia limpa e não impactam negativamente o meio ambiente, ao contrário das fontes tradicionais. No entanto, a produção irregular de energia a partir de fontes renováveis, devido à sua natureza instável e flutuações, tem gerado desafios (Sinha e Bajpai, 2020). Para otimizar os processos de energia renovável, é possível aplicar os princípios da IA e do ML, uma abordagem relativamente recente no âmbito da energia. Esses conceitos podem ser ferramentas promissoras para operar sistemas, uma vez que incorporam informações do passado e previsões futuras, visando aumentar a eficácia desses sistemas (Entezari et al., 2023). A IA engloba diversos métodos baseados em dados capazes de solucionar uma ampla gama de questões relacionadas à energia. Embora esses métodos enfrentem desafios, permitem que a

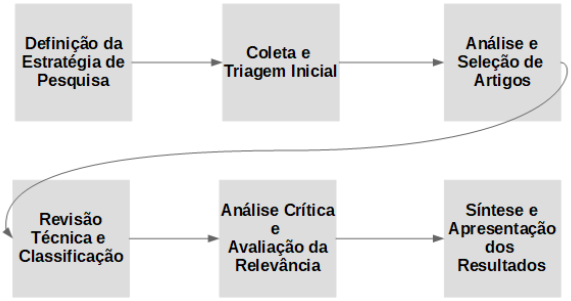
máquina raciocine de maneira semelhante a um ser humano, aprenda com erros e aprimore seu desempenho (Alzahrani et al., 2022). Com os avanços nas tecnologias de aprendizado de máquina e sistemas orientados por dados, a gestão e o controle dos recursos energéticos tornaram-se mais simples e práticos do que no passado (Banu et al., 2022).

2. Material e Métodos

Esta revisão sistemática consiste em seis passos definidos para realizar uma análise abrangente da literatura.

1. Definição de uma estratégia de pesquisa. Isso envolve a identificação de palavras-chave relevantes ao tema de estudo. Para esta revisão, as palavras-chave selecionadas foram "*Energy Renewable*", "*Artificial Intelligence*", "*Agriculture*", "*Machine Learning*", "*Deep Neurals Networks*" e "*Energy Optimization*". Além disso, foram estabelecidos critérios de filtragem. Um limite temporal foi definido, restringindo a busca a artigos publicados nos últimos cinco anos. As bases de dados escolhidas para esta pesquisa foram o Portal de Periódicos da CAPES, IEEE Xplore, Agriculture e Scopus; 2. Coleta e triagem inicial. Nesta etapa, aproximadamente 80 artigos foram selecionados, todos relevantes para a área de energia renovável, e que aplicavam princípios de Inteligência Artificial. Os artigos que não estavam vinculados com o termo "*Agriculture*", ou tinham uma relevância superficial aos tópicos discutidos anteriormente foram excluídos; 3. Análise e seleção de artigos. Nesta fase, os artigos são submetidos a uma análise mais detalhada. São aplicados critérios específicos como qualidade do periódico, impacto da pesquisa, e relevância com o tema de estudo. Artigos com um impacto de pesquisa menor ou com um QUALIS inferior a B2 foram excluídos; 4. Revisão técnica e classificação. Esta etapa envolveu a identificação dos temas por meio das propostas sugeridas pelo autor, resumo, principais resultados, métodos e princípios de inteligência artificial utilizados; 5. Análise crítica e avaliação da relevância. Para cada artigo selecionado foi realizada uma pesquisa para verificar a qualidade da pesquisa avaliada, juntamente com a relevância das soluções propostas e os métodos de inteligência artificial empregados; 6. Síntese e apresentação dos resultados, nesta etapa final, as descobertas e análises obtidas ao longo da pesquisa são sintetizadas e organizadas de maneira coesa.

Figura 1. Etapas da Pesquisa



Fonte: Os autores

3. Resultados e Discussões

A busca por um futuro energético mais sustentável e resiliente impulsiona a rápida evolução das tecnologias renováveis com sua aplicação voltada à agricultura. Nesse cenário, a IA se destaca como uma ferramenta poderosa, capaz de revolucionar a forma como geramos, armazenamos e distribuímos energia limpa.

3.1 Conceitos de Inteligência Artificial

O ML tem experimentado um rápido progresso nos últimos anos. Esse avanço possibilita a implementação de funções inteligentes em aplicações que fazem uso de computação e análise de dados. Além disso, permite que sistemas aprendam e melhorem a partir da experiência, sem a necessidade de programação específica, sendo considerado uma das tecnologias mais influentes da Quarta Revolução Industrial. A eficácia e a confiabilidade das soluções baseadas em ML dependem dos dados utilizados e do desempenho dos algoritmos de aprendizado (Alloghani et al., 2020).

Além do aprendizado de máquina, as ANNs são modelos computacionais inspirados no sistema nervoso central humano, com o objetivo de replicar suas habilidades de aprendizado. Elas são uma parte fundamental do campo de aprendizado de máquina e têm sido aplicadas com sucesso em uma ampla gama de tarefas, incluindo reconhecimento de padrões, previsão de séries temporais e diagnóstico médico (Karunakaran; Balakrishnan, 2024).

Existem vários tipos de ANNs, cada um com sua própria arquitetura e método de aprendizado. Um dos tipos mais comuns é a MLP (*Multi-Layer Perceptron* - Rede Neural Multicamadas), que consiste em pelo menos três camadas de nós: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. O aprendizado em uma MLP é geralmente realizado usando o algoritmo de retropropagação, que ajusta os pesos das conexões para minimizar a diferença entre a saída da rede e a saída desejada (Muthudoss et al., 2023; Sayah et al., 2020).

As CNNs são uma extensão das ANNs que têm se mostrado altamente eficazes no processamento e análise de dados visuais. A arquitetura das CNNs inclui camadas convolucionais, camadas de *pooling* e camadas totalmente conectadas, cada uma desempenhando uma função específica (Wu et al., 2020).

3.2 **Aplicações de IA em Energias Renováveis**

A integração de IA em sistemas de gestão de energia renovável apresenta diversos desafios, como a complexidade dos dados e a necessidade de modelos de previsão precisos. Além disso, a segurança cibernética e a privacidade dos dados são questões críticas que precisam ser abordadas. Uma área promissora de pesquisa é a formulação de modelos híbridos de previsão, que combinam dados físicos e temporais (Kumari et al., 2020; Aguilar et al., 2019).

Diversos estudos têm explorado o uso de ANNs para prever variáveis críticas em energias renováveis. Aurangzeb et al. (2023) utilizaram ANNs, especificamente três CNNs, para prever irradiância solar e velocidade do vento. Com o emprego de camadas totalmente conectadas e a função de ativação *ReLU (Rectified Linear Unit* – Unidade Linear Retificada), os modelos atingiram um *MAPE* (*Mean Absolute Percentage Error* - Erro Percentual Absoluto Médio) de 2,26% e um *NRMSE* (*Normalized Root Mean Squared Error* - Erro Médio Quadrático Normalizado) de 0,18 para a previsão de vento, enquanto na previsão de radiação solar os valores foram de 30,77% e 47,96%, respectivamente. Esses resultados demonstram o potencial das CNNs em capturar padrões complexos nos dados de entrada.

Outro estudo relevante é o de Ghimire et al., que utilizou uma rede neural *feed-forward backpropagation* de três camadas para prever radiação solar. Testando 154 configurações de modelos, os autores alcançaram taxas de erro de previsão entre 77% e 87%. Esse estudo destaca a importância da experimentação na configuração de redes neurais para otimizar a precisão das previsões.

Além das ANNs padrão, redes neurais recorrentes do tipo LSTM têm se mostrado eficazes na previsão de curto prazo da produção de energia solar. Harrou, Kadri e Sun (2020) aplicaram LSTM em uma planta de 9 MWp, obtendo um coeficiente de determinação R^2 de 0,98 e um erro percentual médio de 8,93%. A capacidade do modelo em explicar a variabilidade dos dados reforça a eficácia das LSTMs em cenários de energias renováveis.

A aplicação de técnicas híbridas, que combinam IA com métodos de otimização e inferência *fuzzy*, também tem mostrado resultados promissores. Dehghani et al. utilizaram o sistema *ANFIS* (*Adaptive Neuro-Fuzzy Inference System* - Sistema de Inferência Fuzzy Neuro-Adaptativo) otimizado pelo GWO *(Gray Wolf Optimizer* - Otimizador de Lobos-Cinzentos) para prever a geração de energia hidrelétrica, alcançando uma eficiência de 78%. Este estudo ilustra como a combinação de técnicas pode aumentar a precisão das previsões.

Hanoon et al. (2023) aplicaram uma abordagem de combinação de modelos preditivos, utilizando ANN, SVM (*Support Vector Machine* - Máquina de Vetores de Suporte) e ARIMA (*Autoregressive Integrated Moving Average* - Média Móvel Integrada Autoregressiva) para prever a geração de energia hidrelétrica em diferentes escalas temporais. Embora as ANNs tenham mostrado o melhor desempenho, os modelos SVM e ARIMA também apresentaram resultados sólidos, evidenciando a eficácia de metodologias híbridas e de combinação de modelos em previsões energéticas.

Finalmente, Mohamed et al. (2022)

destacaram o uso eficaz das ANNs na previsão do consumo de energia renovável na União Europeia, com um coeficiente de correlação de 0,9953. Esse estudo reforça a capacidade das ANNs de lidar com variáveis complexas e fornecer previsões precisas em contextos de grande escala.

As aplicações de IA em energias renováveis não apenas melhoram a precisão das previsões de geração e consumo de energia, mas também contribuem para a otimização do gerenciamento de recursos, tornando os sistemas de energia mais eficientes e resilientes. As técnicas avançadas de aprendizado de máquina e redes neurais continuam a evoluir, prometendo ainda mais avanços e inovações no campo das energias renováveis. A Tabela 1 apresenta os resultados dos estudos.

Tabela 1 – Resumo dos Resultados

Estudo	Técnica Utilizada	Objetivo	Resultados
Aurangzeb et al. (2023)	ANNs com CNNs e função de ativação ReLU	Previsão de irradiância solar e velocidade do vento	MAPE de 2,26% e NRMSE de 0,18 para vento; MAPE de 30,77% e NRMSE de 47,96% para radiação solar.
Ghimire et al.	Rede neural feed-forward backpropagation de três camadas	Previsão de radiação solar	Taxas de erro de previsão entre 77% e 87% testando 154 configurações de modelos.
Harrou, Kadri e Sun (2020)	LSTM (Long Short-Term Memory)	Previsão de curto prazo de produção de energia solar	Coeficiente de determinação R^2 de 0,98 e erro percentual médio de 8,93% para uma planta de 9 MWp.
Dehghani et al.	ANFIS otimizado pelo GWO	Previsão de geração de energia hidrelétrica	Eficiência de 78% na previsão da geração de energia hidrelétrica.
Hanoon et al. (2023)	Combinação de ANN, SVM, e ARIMA	Previsão de geração de energia hidrelétrica	ANNs mostraram melhor desempenho, mas SVM e ARIMA também apresentaram resultados sólidos.
Mohamed et al. (2022)	ANNs	Previsão de consumo de energia renovável	Coeficiente de correlação de 0,9953 na previsão do consumo de energia renovável na União Europeia.

Fonte: Os autores

4. Conclusões e Perspectivas de Pesquisas Futuras

A adoção de energias renováveis tem crescido globalmente, impulsionada pela necessidade de mitigar os impactos das mudanças climáticas e do aquecimento global. Além de representar um setor estratégico de pesquisa e desenvolvimento, essas fontes de energia oferecem soluções eficazes para as economias modernas, frente ao esgotamento dos recursos naturais e à urgência de proteger o meio ambiente. No campo da agricultura, a aplicação de energias renováveis, como a hidrelétrica, a solar e a eólica, está transformando práticas produtivas, tornando-as mais sustentáveis e eficientes. Nesse contexto, a inteligência artificial também tem sido incorporada para otimizar o uso dessas energias, melhorando a gestão de recursos e contribuindo para uma agricultura mais limpa e resiliente.

A IA apresenta uma solução a ser integrada no nível microeconômico, minimizando os riscos associados à variabilidade das fontes renováveis por meio de análises preditivas, identificação de padrões, redução dos custos de armazenamento e melhoria da conectividade entre redes e usuários, o que resulta em maior estabilidade, confiabilidade e sustentabilidade das redes energéticas.

No entanto, a adoção dessas tecnologias ainda enfrenta desafios, como o custo inicial de implementação e a necessidade de infraestrutura adequada. Incentivos governamentais, políticas de apoio e investimentos em pesquisa e desenvolvimento são essenciais para superar essas barreiras e promover a adoção generalizada de energias renováveis e IA na agricultura.

Referências

ALASSERY, F.; ALZAHRANI, A.; KHAN, A. I.; IRSHAD, K.; ISLAM, S. **An artificial intelligence-based solar radiation prophesy model for green energy utilization in energy management system.** *Sustainable Energy Technologies and Assessments*, v. 52, p. 102060, 2022. DOI: 10.1016/j.seta.2022.102060.

ALI, H.; MUTHUDOSS, P.; RAMALINGAM, M. et al. **Machine Learning–Enabled NIR Spectroscopy. Part 2: Workflow for Selecting a Subset of Samples from Publicly Accessible Data**. *AAPS PharmSciTech*, v. 24, p. 34, 2023. DOI: 10.1208/s12249-022-02493-5.

ALLOGHANI, M.; AL-JUMEILY, D.; MUSTAFINA, J.; HUSSAIN, A.; ALJAAF, A. J. **A Systematic Review on Supervised and Unsupervised Machine Learning Algorithms for Data Science.** In: *Supervised*

and Unsupervised Learning for Data Science. Berlin/Heidelberg: Springer, 2020.

AURANGZEB, K.; ASLAM, S.; HAIDER, S. I.; MOHSIN, S. M.; ISLAM, S. u.; KHATTAK, H. A.; SHAH, S. **Energy forecasting using multiheaded convolutional neural networks in efficient renewable energy resources equipped with energy storage system.** *International Transactions on Electrical Energy Systems*, 2019. DOI: 10.1002/ett.3837.

BARUA, Smita; BAJPAI, Prabodh**. Power management of hybrid energy storage system in a standalone DC microgrid**. *Journal of Energy Storage*, [s.l.], v. 30, p. 101523, 2020.

DEHGHANI, M.; RIAHI-MADVAR, H.; HOOSHYARIPOR, F.; MOSAVI, A.; SHAMSHIRBAND, S.; ZAVADSKAS, E. K.; CHAU, K. W. **Prediction of hydropower generation using grey wolf optimization adaptive neuro-fuzzy inference system.** *Energies*, v. 12, p. 289, 2019.

ENTEZARI, A.; ESAN, O. C.; YAN, X.; WANG, R.; AN, L. **Sorption-Based Atmospheric Water Harvesting: Materials, Components, Systems, and Applications.** *Advanced Materials*, v. 35, n. 9, p. 2100957, 2023. DOI: 10.1002/adma.202210957.

FARITHA BANU, J.; ATUL MAHAJAN, R.; SAKTHI, U.; KUMAR NASSA, V.; LAKSHMI, D.; NADANAKUMAR, V. **Artificial intelligence with attention-based BiLSTM for energy storage system in hybrid renewable energy sources.** *Sustainable Energy Technologies and Assessments*, v. 52, p. 102334, 2022.

GHIMIRE, et al. **The Impacts of Agricultural Trade on Economic Growth and Environmental Pollution: Evidence from Bangladesh Using ARDL in the Presence of Structural Breaks.** *Sustainability*, v. 13, p. 8336, 2021. DOI: 10.3390/su13158336.

HANOON, M. S.; AHMED, A. N.; RAZZAQ, A.; OUDAH, A. Y.; ALKHAYYAT, A.; HUANG, Y. F.; KUMAR, P.; EL-SHAFIE, A**. Prediction of hydropower generation via machine learning algorithms at Three Gorges Dam, China**. *Ain Shams Engineering Journal*, 2022. Disponível em: https://doi.org/10.1016/j.asej.2022.101919.

HARROU, F.; KADRI, F.; SUN, Y. **Forecasting of Photovoltaic Solar Power Production Using LSTM Approach.** In: *Title of the Book*. IntechOpen, 2023.

KARUNAKARAN, Deepak; BALAKRISHNAN, **M. Prediction of Fish Yields in Lakes and Reservoirs from Simple Empirical Models using Artificial Neural Network (ANN): A Review**. 2019. DOI: 10.32628/cseit195110. Disponível em: https://dx.doi.org/10.32628/cseit195110. Acesso em: 7 jun. 2024.

MOHAMED ELMI, A.; SELAM, A. A.; ATALAY, A. K**. Prediction of renewable energy consumption of European Union using artificial neural networks.** *Black Sea*, 2022.

SAYAH, Z.; KAZAR, O.; LEJDEL, B.; LAOUID, A.; GHENABZIA, A. **An intelligent system for energy management in smart cities based on big data and ontology**. *Smart and Sustainable Built Environment*, 2020.