

INTELIGÊNCIA ARTIFICIAL APLICADA À PRODUÇÃO DE ENERGIA RENOVÁVEL

Blanca Ribeiro Silva
Graduanda em Ciência da Computação – Uni-FACEF
blancaribeirosilva72@gmail.com

Prof. Geraldo Henrique Neto
Docente do Departamento de Computação – Uni-FACEF
geraldohenriqueneto@gmail.com

Resumo

Diante da crescente urgência dos desafios ambientais e da necessidade de diversificar as matrizes energéticas globais, a busca por soluções inovadoras em energias renováveis (ER) tem se intensificado. Neste contexto, a inteligência artificial (IA) surge como uma ferramenta transformadora, capaz de otimizar a eficiência, confiabilidade e sustentabilidade dos sistemas de energia limpa. Este trabalho apresenta uma revisão bibliográfica aprofundada, fundamentada na análise de artigos científicos, teses e relatórios especializados consultados em bases de dados como Google Acadêmico, IEEE Xplore, ScienceDirect, Scopus e SciELO.

O estudo teve como objetivo investigar as principais aplicações, desafios e tendências futuras da IA na produção de ER. Os resultados revelam que a IA desempenha um papel crucial na previsão de demanda e oferta energética, na otimização de recursos e na eficiência energética de sistemas híbridos solares e eólicos, e na gestão inteligente de redes elétricas (*Smart Grids*). Modelos de aprendizado de máquina (AM), como as RNNs (*Recurrent Neural Network* - Redes Neurais Recorrentes), mostraram-se particularmente eficazes para a previsão de séries temporais em contextos de alta variabilidade. Contudo, foram identificados desafios significativos, incluindo a fragmentação e falta de padronização de dados, altas demandas computacionais, riscos de segurança cibernética e questões regulatórias e éticas. Conclui-se que a IA é um catalisador fundamental para a transição energética global, promovendo maior aproveitamento de fontes limpas e contribuindo para a luta contra as mudanças climáticas. Para o avanço pleno desse potencial, são essenciais a padronização de dados, a articulação entre diversos setores e o investimento em medidas de segurança robustas.

Palavras-chave: energia renovável; inteligência artificial; aprendizado de máquina; otimização.

Abstract

Faced with the growing urgency of environmental challenges and the need to diversify global energy matrices, the search for innovative solutions in renewable energy has intensified. In this context, artificial intelligence emerges as a transformative tool, capable of optimizing the efficiency, reliability, and sustainability of clean energy systems. This paper presents an in-depth literature review, based on the analysis of scientific articles, theses and specialized reports consulted in databases such as Google Scholar, IEEE Xplore, ScienceDirect, Scopus and SciELO. The study aimed to investigate the main applications, challenges, and future trends of artificial intelligence

in renewable energy production. The results reveal that artificial intelligence plays a crucial role in forecasting energy demand and supply, resource optimization, energy efficiency of solar and wind hybrid systems, and in the intelligent management of electricity grids. Machine learning models, such as recurrent neural networks, have been shown to be particularly effective for predicting time series in contexts of high variability. However, significant challenges were identified, including data fragmentation and lack of standardization, high computational demands, cybersecurity risks, and regulatory and ethical issues. It is concluded that artificial intelligence is a key catalyst for the global energy transition, promoting greater use of clean sources and contributing to the fight against climate change. For the full advancement of this potential, data standardization, articulation between various sectors, and investment in robust security measures are essential.

Keywords: *renewable energy; artificial intelligence; machine learning; optimization.*

1 Introdução

Esta seção apresentará a contextualização do tema, problema de pesquisa, objetivos, justificativa, metodologia e estrutura do trabalho.

1.1 Tema e justificativa

A busca por soluções inovadoras para a produção de energia renovável tem se tornado uma prioridade global, impulsionada pelos desafios ambientais e pela necessidade de diversificação das matrizes energéticas. Neste contexto, a IA emerge como uma ferramenta fundamental para a otimização dos sistemas de energia sustentável, promovendo eficiência, confiabilidade e acessibilidade. O desenvolvimento e a aplicação dessas tecnologias permitem avanços significativos na previsão de demanda e geração de energia, na gestão de redes elétricas inteligentes e na redução de custos operacionais, tornando a ER cada vez mais competitiva e viável.

A importância desta pesquisa pode ser compreendida a partir de três perspectivas principais: acadêmica, social e tecnológica. No âmbito acadêmico, o estudo sobre a IA aplicada às ERs constitui um campo interdisciplinar que conecta engenharia elétrica, ciência da computação e estudos ambientais. A interação entre essas áreas possibilita o desenvolvimento de novas metodologias e algoritmos capazes de solucionar desafios complexos e avançar o conhecimento científico, além de contribuir para a formação de profissionais qualificados. Socialmente, a aplicação da IA na produção de energia sustentável desempenha um papel essencial na luta contra as mudanças climáticas, promovendo a transição para fontes limpas e reduzindo os impactos ambientais negativos causados pela dependência de combustíveis fósseis. Além disso, ao viabilizar maior eficiência e acessibilidade à ER, a IA pode contribuir para a democratização do acesso à eletricidade em regiões remotas e subdesenvolvidas.

A princípio, sob o aspecto tecnológico, a IA representa uma revolução no setor energético ao permitir a análise de grandes volumes de dados, a identificação de padrões de consumo e a automação inteligente dos processos de geração e distribuição de energia. Sua capacidade de previsão de demanda e redução de custos

operacionais impulsiona avanços como redes elétricas inteligentes e sistemas de armazenamento de energia mais sofisticados.

Diante desse cenário, a questão central deste estudo busca, por meio de uma revisão bibliográfica, investigar as principais aplicações, desafios e tendências futuras da IA na produção de ER, visando compreender como essa tecnologia contribui para a otimização da eficiência, confiabilidade e sustentabilidade no setor.

1.2 Metodologia

Para atingir o objetivo principal do trabalho, o estudo segue uma abordagem bibliográfica, baseada na seleção e análise de materiais acadêmicos e técnicos relacionados à aplicação da IA na produção de ER. Para isso, foram consultadas fontes como artigos científicos, teses, dissertações e relatórios especializados. A revisão bibliográfica busca identificar contribuições teóricas e práticas da IA no setor energético, destacando avanços, desafios e oportunidades.

Como um estudo exclusivamente bibliográfico, este trabalho não envolveu o desenvolvimento de software ou a utilização de linguagens de programação. Contudo, as tecnologias e técnicas de IA, como AM, ANN (*Artificial Neural Network* - Redes Neurais Artificiais) e DL (*Deep Learning* - Aprendizado Profundo), são abordadas teoricamente, conforme a literatura acadêmica.

Diante disso, para garantir a consistência e qualidade das referências utilizadas, a pesquisa foi conduzida em bases de dados reconhecidas, incluindo Google Acadêmico, IEEE Xplore, ScienceDirect, Scopus e SciELO. Esses repositórios possibilitam o acesso a estudos atualizados e relevantes, essenciais para a construção da fundamentação teórica da pesquisa.

Por fim, a Tabela 1 apresenta os 5 artigos mais utilizados nesta revisão bibliográfica, que foram escolhidos por abordarem temas relevantes e essenciais de forma ímpar para a construção da fundamentação teórica. Todos esses artigos foram encontrados no Google Acadêmico, com filtro de data, a maioria é revisão bibliográfica, publicados em língua inglesa e o mais citado é brasileiro.

Tabela 1 - Artigos mais utilizados

Artigo:	Artificial Intelligence and Sustainable Energy Development: A Review of Applications, Challenges, and Future Directions	Forecasting Renewable Energy Generation with Machine Learning and Deep Learning: Current Advances and Future Prospects	Aplicação de Aprendizado de Máquina para previsão de Energia Eólica Gerada	Aplicações de Inteligência Artificial em Energias Renováveis: Uma Revisão Sistemática	Evolutionary algorithms and their applications to engineering problems
Autores:	ADEWOYIN, ADEDIWIN, AUDU	BENTI, CHAKA, SEMIE	GERHARDT	SANTOS, OTTONI, NEPOMUCENO	SLOWIK, KWASNICKA
Citações:	Duas	Duas	Duas	Cinco	Três

Encontrado em:	Google acadêmico	Google acadêmico	Google acadêmico	Google acadêmico	Google acadêmico
Palavras-chave de busca:	“artificial intelligence”, “sustainable energy”	“renewable energy”, “machine learning”	“aprendizado de máquina”, “energia eólica”	“Inteligência artificial”, “energia renovável”	“evolutionary algorithms”
Filtros de busca:	2020 - 2025	2020 - 2025	2020 - 2025	2020 - 2025	2020 - 2025
Quantidade de artigos encontrados:	Quinhentos e noventa e três mil	Duzentos e noventa e sete mil	Três mil e oitocentos	Sete quatrocentos e oitenta	Quinhentos e vinte e oito mil
Quantidade de artigos lidos:	Cinco	Seis	Seis	Oito	Sete
País:	Nigéria	Etiópia	Brasil	Brasil	Polônia
Ano de publicação:	2025	2023	2021	2022	2020
Número de artigos relacionados publicados no mesmo ano:	Quarenta e seis mil e duzentos	Cinquenta e nove mil seiscentos	Seiscentos e trinta e oito	Mil duzentos e dez	Cento e quatro mil
Tipo de aplicação:	Revisão narrativa	Revisão narrativa	Prática com revisão sistemática	Revisão sistemática	Revisão narrativa

Fonte: Elaborado pela autora

1.3 Estrutura do Trabalho

Este estudo está organizado em cinco tópicos, compreendendo esta introdução, fundamentos teóricos, aplicações da inteligência artificial na energia renovável, desafios, limitações, tendências futuras e a conclusão com a revisão dos objetivos alcançados, considerações finais e sugestões para trabalhos futuros.

2 Fundamentos Teóricos

Esta seção apresentará as revisões bibliográficas mais significativas relacionadas ao tema em questão.

2.1 Energia Renovável: Conceitos e Tipos

Nesta seção, serão apresentados os conceitos fundamentais das principais formas de ER, bem como suas características. A ER é essencial para a sustentabilidade ambiental e para a redução da dependência de combustíveis fósseis.

2.1.1 Energia Solar

Segundo Carvalho (2023), a energia solar provém da radiação solar e pode ser convertida em outras formas de energia, como a elétrica ou térmica. A

energia fotovoltaica utiliza células solares para transformar a luz solar diretamente em eletricidade, enquanto a energia solar térmica utiliza coletores solares para aquecer um fluido, que pode ser usado para gerar eletricidade ou para aquecimento de água e ambientes.

A energia solar tem sido adotada por muitos brasileiros, abrangendo uma ampla gama de usos em residências, estabelecimentos comerciais de todos os tamanhos, indústrias, propriedades rurais e até mesmo em serviços públicos, como a iluminação de praças e escolas.

Em vista disso, a energia solar no Brasil é vista como um segmento que irá auxiliar na redução de custos da conta de luz e apoiar as concessionárias a reduzir a sobrecarga na rede de distribuição devido à falta de estrutura, bem como, redução de impactos ambientais.

2.1.2 Energia Eólica

A energia dos ventos é conhecida há milhares de anos pelos egípcios e utilizada para mover embarcações a vela pelo Rio Nilo. Nas datações históricas têm-se conhecimento também do uso das forças dos ventos em moinhos verticais construídos na Pérsia e China para moer grãos e para bombear a água que vinha do subsolo (Assis, 2022).

De acordo com Dalmaz, Passos e Colle (2008), a utilização dos ventos para geração de eletricidade começou no final do século XIX, com a primeira turbina eólica para geração de energia elétrica desenvolvida pelo americano Charles Brush (1849 – 1929) e com o desenvolvimento de uma turbina eólica pelo dinamarquês Poul la Cour (1846 – 1908), considerado o precursor dos modernos aerogeradores.

Nos dias atuais, a humanidade enfrenta um grande desafio para suprir a demanda de energia, evitando agressões ao meio ambiente. Uma das soluções apontadas é a energia eólica, que por ser uma fonte renovável, abundante e limpa, aproveita a dinâmica da atmosfera terrestre e a força dos ventos originada da diferença no aquecimento da superfície terrestre pelo Sol.

2.1.3 Energia Hidrelétrica e outras fontes

Segundo Soares (2023), a energia hidrelétrica funciona por meio da energia cinética da água em movimento que é capturada com a queda d'água de uma represa. As pás da turbina são acionadas pela água em movimento, em seguida a potência mecânica aciona um gerador que converte a energia mecânica em energia elétrica.

Atualmente, a energia hidrelétrica é amplamente reconhecida como uma das fontes de energia mais econômicas disponíveis. De forma geral, o custo associado à geração dessa modalidade de ER pode apresentar uma variação que oscila entre 30 e 60 dólares por cada MWh gerado.

Todavia, apesar de ser uma fonte de energia limpa, as represas hidroelétricas inevitavelmente têm impactos ambientais significativos nos rios e ecossistema terrestre adjacente. Após o uso, problemas como a sedimentação

acumulada nos reservatórios, bem como os diversos impactos negativos sobre a vida aquática, tornam-se desafios complexos e importantes que devem ser considerados.

Assim sendo, é fundamental estabelecer regulamentações, investimentos em pesquisa e educação sobre sustentabilidade para enfrentar os desafios do pós-uso e garantir que a geração de energia por meio de fontes renováveis seja sustentável em longo prazo.

2.2 Desafios na Produção de Energia Renovável

De acordo com Dias (2024), desafios técnicos e de infraestrutura estão entre os principais obstáculos à adoção massiva de ERs. A natureza mutável de fontes como solar e eólica exige avanços em sistemas de armazenamento de energia e infraestrutura de rede para garantir a confiabilidade e estabilidade do fornecimento de energia.

Além disso, marcos políticos e regulatórios são fundamentais no desenvolvimento e implantação de projetos de ER. No entanto, a burocracia, inconsistência nas políticas e falta de diretrizes claras podem interromper o crescimento desse setor.

Para Ang, Salem, Kamarol, Das, Nazari e Prabaharan (2022), a maioria dos países em desenvolvimento depende principalmente da eletricidade gerada por usinas hidrelétricas, que é acessível e altamente eficiente. Por outro lado, nações com abundância de recursos energéticos estão gradualmente avançando para práticas mais sustentáveis. Um dos principais desafios para a adoção de fontes limpas é a disponibilidade de combustíveis fósseis, que desvia a atenção das autoridades e da sociedade da importância de fontes renováveis.

Nesse contexto, o custo inicial de inovação e pesquisa em recursos sustentáveis é relativamente elevado, tornando-se mais viável para países pioneiros se envolverem e absorverem esses investimentos. Ademais, as nações desenvolvidas frequentemente assumem o papel de precursoras na criação de novas políticas, enquanto os países emergentes adaptam as políticas de suporte, aprimorando-as com a adição de várias regulamentações específicas.

2.3 Inteligência Artificial: Conceitos e Técnicas

Nesta seção serão apresentados os conceitos essenciais da IA, bem como suas principais técnicas. A IA é fundamental para a otimização e automação de diversos tipos de tecnologia.

2.3.1 Aprendizado de Máquina

Segundo Mahesh (2020), o AM é o estudo científico de algoritmos e modelos estatísticos que os sistemas de computador usam para executar uma tarefa específica sem serem explicitamente programados. Algoritmos de aprendizado estão presentes em muitas aplicações que usamos diariamente. Por exemplo, um dos motivos pelos quais mecanismos de buscas na web, como o Google, funcionam tão bem é porque existe um algoritmo de aprendizado que aprendeu a classificar páginas da web.

O AM pode ser supervisionado ou não supervisionado. Se houver menos dados e dados claramente rotulados para treinamento, o aprendizado supervisionado é a melhor opção. O aprendizado não supervisionado geralmente oferece melhor desempenho e resultados para grandes conjuntos de dados. Caso exista um enorme conjunto de dados facilmente disponível, técnicas de aprendizado profundo serão mais adequadas (Mahesh, 2020).

Conforme Chatterjee, Khan e Byun (2024), embora o AM seja um método amplamente empregado para treinar processadores no objetivo de executar tarefas de forma autônoma, é comum que intervenções humanas sejam indispesáveis em múltiplos estágios do processo de AM, dependendo da especificidade de cada aplicação.

Por conseguinte, o AM é uma tecnologia fundamental para uma variedade de propósitos, em razão de exercer uma ampla influência sobre as empresas comerciais e nos sistemas econômicos, sendo algo evidente não apenas por suas contribuições diretas, mas igualmente pela sua destacada capacidade de incentivar, encorajar e promover inovações tecnológicas que sejam complementares.

2.3.2 Redes Neurais Artificiais

De acordo com Dastres e Soori (2021), uma ANN é um modelo de processamento de dados baseado na maneira como os sistemas nervosos biológicos, como o cérebro, processam dados. Eles são focados na estrutura neuronal do córtex cerebral de mamíferos, mas em uma escala muito menor. Muitos especialistas em IA acreditam que as ANNs são a melhor, e talvez, a única esperança para projetar uma máquina inteligente.

Uma alta taxa de aprendizado reduz o tempo de treinamento, mas reduz a precisão geral, enquanto uma baixa taxa de aprendizado leva mais tempo, mas tem potencial para maior precisão. Embora as ANNs possam lidar com a maioria das tarefas se tiverem a oportunidade de se preparar para elas, o maior desafio é o tempo que leva para treiná-las e o poder de computação necessário para uma tarefa complexa. O desempenho de modelos de ANN em problemas complexos depende fortemente da arquitetura de rede para atingir as melhores soluções para os desafios simulados (Dastres e Soori, 2021).

Atualmente, existe uma variedade de aplicações para as ANNs, como veículos autônomos, reconhecimento de caracteres, compressão de imagens, previsão do mercado de ações, sistemas de análise de risco, controle de drones, análise de qualidade de soldagem, análise de qualidade de computador e testes de sala de emergência.

Por fim, os sistemas avançados de ANN podem ser aplicados para modelagem de problemas complexos de engenharia e física para obter a melhor solução. Apesar de existirem algumas abordagens para fazer as máquinas pensarem e se comportarem como humanos, ainda há muito a descobrir. O trabalho dos

pesquisadores pode, no entanto, ajudar as ANNs a eventualmente quebrarem o ciclo geracional que as viu entrando e saindo de moda nas últimas sete décadas.

2.3.3 Algoritmos Evolutivos

De acordo com Slowik e Kwasnicka (2020), o algoritmo genético (AG) é uma das técnicas de otimização mais antigas e conhecidas, que se baseia na natureza. No AG, a busca pelo espaço de solução imita o processo natural que ocorre no ambiente, e a teoria darwiniana da evolução das espécies é levada em consideração. Nos AGs, temos uma população de indivíduos; cada um, chamado cromossomo, representa uma solução potencial para o problema. O problema a ser resolvido é definido pela função objetivo. Dependendo de quão “bom” o indivíduo dado é ajustado à função objetivo, o valor que representa sua qualidade é atribuído a ele.

A priori, as estratégias de evolução (EE) são diferentes quando comparadas aos AGs, principalmente no procedimento de seleção. Nos AGs, a próxima geração é criada a partir da população parental escolhendo indivíduos dependendo de seu valor de aptidão, mantendo um tamanho constante da população. Na EE, uma população temporária é criada; ela tem um tamanho diferente da população parental (dependendo dos parâmetros assumidos). Nesta etapa, os valores de aptidão não são importantes (Slowik e Kwasnicka, 2020).

Algoritmos evolutivos são utilizados principalmente em áreas como: engenharia elétrica eletrônica, ciência da computação, inteligência artificial, sistemas de controle de automação e ciência de gerenciamento de pesquisa operacional. Apesar dos AE serem uma área de pesquisa muito interessante, há muitos problemas de pesquisa em aberto, como: controle do equilíbrio entre as propriedades de exploração e aproveitamento; o controle autoadaptativo (ou adaptativo) dos parâmetros de direção; redução do número de parâmetros do algoritmo CMA-ES; introdução de novos esquemas de seleção; e aumento de sua eficácia. Este último é importante especialmente na área de design evolutivo e em hardware evolutivo (Slowik e Kwasnicka, 2020).

Portanto, os algoritmos evolutivos (AEs) são técnicas estocásticas, cada vez que é executado, um resultado diferente pode ser obtido. Diante disso, o foco principal deve ser garantir a repetibilidade dos resultados gerados pelas técnicas de AE. Esta questão é muito importante para a aplicação desses métodos na indústria. Em resumo, é provável que futuramente novos AEs sejam desenvolvidos, e os problemas de pesquisa conectados com algoritmos evolucionários continuem sendo uma pauta para os pesquisadores.

2.3.4 Sistemas Especialistas

Conforme Asemi, Ko e Nowkarizi (2021), Sistemas especialistas (SEs) são sistemas baseados em computador que simulam a tomada de decisão humana. Eles podem se integrar com sistemas de informação para melhorar sua precisão e desempenho. Em geral, esses sistemas consistem em dois elementos principais: Uma

base de conhecimento e um mecanismo de inferência. A base de conhecimento abrange todas as necessidades de informação que os especialistas humanos/bibliotecários estão usando para decidir. Essas informações estão presentes na base de conhecimento como fatos e regras.

Primeiramente, a criação de um SE inclui a extração do conhecimento relevante do ser humano especialista, e muitas vezes é heurística da natureza. Os SEs usam a resolução de problemas em diferentes áreas, como medicina, negócios, ciência da computação, direito, defesa, educação, matemática, engenharia, geologia, entre outros.

De acordo com Janjanam, Ganesh e Manjunathao (2021), o desempenho de um SE depende do uso do máximo de conhecimento de domínio possível para fornecer conselhos inteligentes sobre um domínio específico. O conhecimento de domínio coletado como o conhecimento do sistema se forma como uma base de conhecimento que é o componente essencial de um sistema especialista

Por fim, os SEs são uma das áreas importantes da IA na resolução de problemas, uma vez que são baseados em conhecimento, permitindo especificamente que o computador auxilie na solução de problemas mal estruturados e não determinísticos; como em atividades de design, incluindo síntese, avaliação e modelagem e processos de tomada de decisão. Assim sendo, o desenvolvimento de um SE requer uma ferramenta que forneça melhores meios de aquisição de conhecimento, mecanismo de inferência e interface de usuário.

3 Aplicações da Inteligência Artificial na Energia Renovável

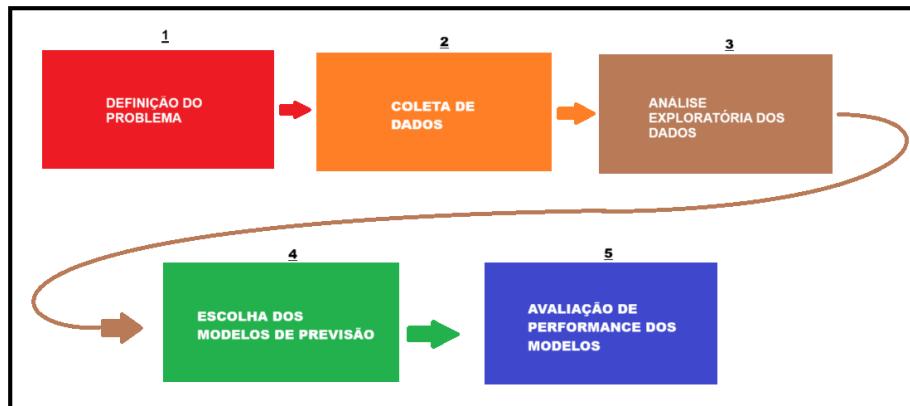
Nesta seção serão exploradas as diversas aplicações da IA no contexto das ERs que desempenham um papel crucial na maximização da eficiência energética, previsão de geração de energia e gestão inteligente de recursos.

3.1 Previsão de demanda e oferta energética

De acordo com Silva (2023), por meio da análise de séries temporais é possível examinar variáveis ao longo de um período definido, identificar os fenômenos presentes e, assim, estimar a geração de energia esperada para um horizonte determinado. Esse processo envolve investigar o mecanismo que dá origem à série, prever valores futuros e compreender o comportamento e a periodicidade nos dados observados.

Segundo Hyndman e Athanasopoulos (2021), a análise e previsão de séries temporais requerem cinco etapas principais, como ilustrado na Figura 1. A primeira etapa envolve a definição do problema, na qual se estabelece como as previsões serão utilizadas. Em seguida, ocorre a coleta de informações, que pode incluir dados estatísticos ou informações coletadas por terceiros que já tenham sido utilizadas em previsões anteriores. A terceira etapa consiste na análise preliminar, em que os dados são representados graficamente para identificar padrões de comportamento na série. Já na quarta etapa, que é a seleção e ajuste dos modelos, o modelo ideal é escolhido com base no histórico de dados disponíveis, na relação entre a variável prevista e as variáveis explicativas, e na aplicação prática das previsões. Finalmente, na quinta etapa, utiliza-se o modelo para fazer as previsões e avalia-se seu desempenho, considerando os dados de periodicidade disponíveis.

Figura 1 - Etapas de análise e previsão de séries temporais



Fonte: Adaptado de Hyndman e Athanasopoulos (2021)

Por fim, de acordo com Barchi et al. (2024), em relação a otimização de sistemas de distribuição de energia, por meio de algoritmos avançados, torna-se possível equilibrar, em tempo real, a oferta e a demanda, contribuindo para uma maior estabilidade das redes elétricas. Em tecnologias modernas, como as redes inteligentes, a IA desempenha um papel essencial na gestão do fluxo de energia entre geradores distribuídos, consumidores e sistemas de armazenamento. Isso resulta em uma maior eficiência, com a diminuição de desperdícios, o balanceamento da rede, a prevenção de sobrecargas e o aproveitamento máximo das fontes de energia renováveis.

3.2 Otimização de recursos e eficiência energética

Conforme apontado por Santos, Ottoni e Nepomuceno (2022), os métodos de otimização desempenham um papel relevante no campo das ERs. Nesse contexto, são apresentadas duas abordagens de otimização aplicadas a sistemas híbridos de energia solar e eólica. O Algoritmo Singular é utilizado para otimizar sistemas híbridos considerando aspectos econômicos, ambientais e de confiabilidade. Além disso, é introduzido o método de otimização chamado *Improved Whale Optimization Algorithm*, que se baseia em princípios semelhantes ao Algoritmo Genético para maximizar a captação de energia em sistemas solares fotovoltaicos. A eficiência do algoritmo desenvolvido é ressaltada como uma solução eficaz para o problema abordado.

Inicialmente, uma abordagem econômica leva em conta a renda anual gerada pela venda de energia eólica, considerando a produção individual de cada turbina. Por sua vez, a técnica de Kusiak e Zheng (2010 apud Santos; Ottoni; Nepomuceno, 2022) utiliza algoritmos evolutivos para otimizar os dados e definir as configurações de controle ideais para o funcionamento de uma turbina eólica. Já o modelo de Kusiak e Song (2010 apud Santos; Ottoni; Nepomuceno, 2022) analisa a posição das turbinas eólicas com base na distribuição do vento local, permitindo calcular as perdas relacionadas à localização das turbinas e à direção dos ventos.

Portanto, no modelo proposto por Kusiak e Song, destacam-se os algoritmos de otimização que analisam variáveis como velocidade e direção do vento,

além da parametrização de curvas, para desenvolver um design eficiente e funcional. Além disso, o estudo aborda aspectos relacionados à geração sustentável de energia elétrica a partir da força do vento. Com base nessa abordagem, Adedeji (2021 apud Santos; Ottoni; Nepomuceno, 2022) explora a aplicação de um modelo híbrido de lógica fuzzy, visando identificar as condições ideais de incidência de vento e otimizar a produção de energia elétrica utilizando três diferentes tipos de geradores eólicos. Por fim, Petković (2014 apud Santos; Ottoni; Nepomuceno, 2022) propõe um controlador inteligente, baseado na inferência adaptativa de neurofuzzy, projetado para maximizar a potência de saída das turbinas eólicas.

3.3 Gestão de redes inteligentes (*Smart Grids*)

De acordo com Viali et al. (2025), uma *smart grid* é uma rede inteligente que combina energia elétrica e comunicação digital, permitindo otimizar os processos de distribuição e monitorar o consumo de forma eficiente. Essa tecnologia também facilita o uso de fontes como painéis solares e baterias para veículos elétricos.

Primeiramente, o Centro Inteligente de Operação realiza o monitoramento, controle e otimização da distribuição de energia em tempo real, garantindo eficiência e confiabilidade no fornecimento. A integração de diferentes plataformas e fontes, como o armazenamento de biogás, assegura resiliência energética. Além disso, as redes de distribuição e sistemas de comunicação conectam todos os componentes, permitindo o controle remoto de dispositivos. Nos setores residencial, público e industrial, o uso de tecnologias como energia solar, fotovoltaica e iluminação LED contribui para maior eficiência energética e gestão otimizada do consumo.

Dessa forma, as *smart grids* destacam-se pela capacidade de equilibrar oferta e demanda por meio de sistemas de armazenamento, como o biogás, e pela geração de ER, como a solar. Essa integração de tecnologias avançadas promove sustentabilidade, reduz a dependência de fontes convencionais e contribui para um futuro energético mais eficiente e confiável.

3.4 Análise de Caso de Estudo na Literatura: Aplicação prática em sistemas eólicos

De acordo com Gerhardt (2021), o processo KDD (*Knowledge Discovery in Data mining* - Descoberta de Conhecimento em Mineração de dados) descreve etapas fundamentais para o AM, que vão desde a coleta de dados até o ajuste de modelos para alcançar resultados precisos. Essas etapas incluem o tratamento dos dados para corrigir erros e vieses, a escolha de modelos adequados às metas definidas e o treinamento para melhorar continuamente o desempenho. Cada passo é essencial para garantir previsões confiáveis e alinhadas às necessidades específicas.

Como exemplo prático, um parque eólico localizado na Turquia foi utilizado como base para um caso de estudo, fornecendo dados reais sobre sua operação, incluindo informações meteorológicas e de desempenho energético. Esses dados passaram por um processo de limpeza e organização para corrigir erros e remover vieses. Em seguida, foram aplicados os algoritmos LSTM (Sepp Hochreiter e Jürgen Schmidhuber, 1997) e XGBoost (Tianqi Chen, 2014) para prever a geração de

energia eólica com base nas condições específicas do local. O desenvolvimento dos modelos foi realizado no ambiente de programação Colaboratory Google, utilizando ferramentas como Python, API Keras e TensorFlow, que são fundamentais para o treinamento e avaliação de redes neurais voltadas para IA.

A fase de avaliação foi crucial para testar a eficácia dos modelos em dados não utilizados no treinamento inicial. Com base nos resultados, ajustes nos parâmetros e novas iterações no treinamento foram realizados, otimizando ainda mais a capacidade dos modelos de atender a diferentes cenários e demandas energéticas. Esse processo demonstrou como o AM pode melhorar as previsões, possibilitando maior eficiência no uso de recursos eólicos.

Portanto, o estudo evidenciou o potencial da aplicação de AM em sistemas eólicos, mostrando como ferramentas avançadas transformam dados em previsões úteis e precisas. Essa abordagem reforça o papel da IA na otimização de fontes renováveis, promovendo sustentabilidade e eficiência na geração de energia.

3.5 Modelos de aprendizado de máquina para previsão de produção energética em sistemas renováveis

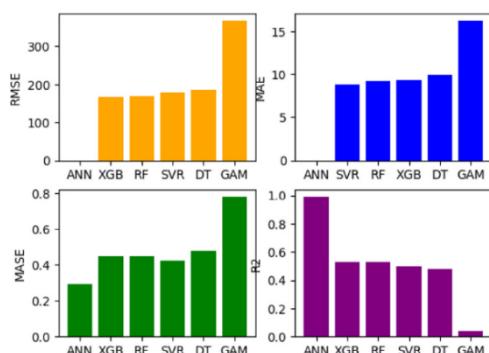
De acordo com Benti, Chaka e Semie (2023), as RNNs têm demonstrado sucesso notável em tarefas que envolvem dados sequenciais, como reconhecimento de fala, análise de sentimentos, tradução automática e até mesmo previsão de séries temporais, incluindo previsão de ER. Diversos estudos de pesquisa investigaram o uso de RNNs para previsão de ER.

Particularmente, um desses estudos realizado por Kisvari et al. (2021 apud Benti; Chaka; Semie, 2023), sugere um método baseado em dados para previsão de energia eólica que envolve pré-processamento, detecção de anomalias, engenharia de recursos e ajuste de hiperparâmetros usando modelos de DL recorrentes com portas. Os pesquisadores também compararam uma nova rede neural de DL da GRU (*Gated Recurrent Unit* - Unidades Recorrentes com portas) com a LSTM. A abordagem atinge alta precisão com custos computacionais mais baixos, e a GRU supera a LSTM em precisão preditiva.

O estudo de Ahmad et al. (2018, apud Ledmaoui et al., 2023) demonstra a eficácia da SVR (*Support Vector Regression* - Regressão de Vetores de Suporte) para prever a produção de energia solar térmica e destaca a importância de selecionar os recursos de entrada e hiperparâmetros apropriados para obter o melhor desempenho. Além desse modelo, Matsumoto e Yamada (2021, apud Ledmaoui et al., 2023) apontam que quando a relação entre a resposta e os preditores é complexa e não pode ser totalmente descrita por modelos lineares, os GAMs (*Generalized Additive Model* - Modelo Aditivo Generalizado) são muito úteis, podendo ser usados para a previsão da produção de energia solar.

Os resultados do estudo de Liu e Sun (2019), Chahboun e Maaroufi (2021) mostraram que a RF (Random Forest - Floresta Aleatória) superou outras técnicas de aprendizado de máquina na previsão da produção de energia solar. A precisão dos modelos melhorou quando recursos de entrada adicionais, como a irradiação solar e a temperatura, foram incluídos no modelo. O algoritmo desenvolve múltiplas árvores de decisão que são mescladas para uma previsão mais precisa (Ledmaoui et al., 2023).

Figura 2 - Classificação dos seis algoritmos



Fonte: Ledmaoui et al. (2023)

Portanto, conforme a Figura 2, que compara as métricas de desempenho de diferentes algoritmos na previsão da produção de energia, o estudo de Ledmaoui demonstrou que o modelo ANN apresentou os melhores resultados entre os seis modelos. Analisando as métricas, o ANN obteve os menores valores de RMSE (*Root Mean Square Error* - Raiz do Erro Quadrático Médio), MAE (*Mean Absolute Error* - Erro Absoluto Médio) e MASE (*Mean Absolute Scaled Error* - Erro Médio Absoluto Escalado), e o maior valor de R² (coeficiente de determinação), indicando sua superioridade em termos de precisão preditiva. Ademais, os parâmetros utilizados para essa análise foram implementados usando a biblioteca Scikit-learn, uma estrutura de AM amplamente utilizada em Python. Diante disso, a melhor previsão de desempenho energético é obtida pelo algoritmo de ANN, seguido pelo algoritmo XGboost.

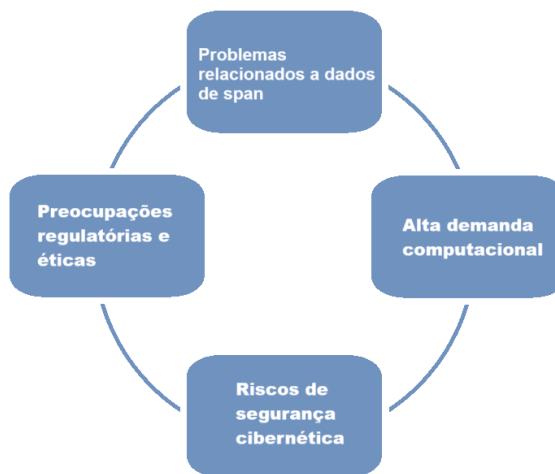
4 Desafios, limitações e tendências futuras

Esta seção apresentará os principais desafios e limitações sobre a aplicação da IA em sistemas de ER, assim como novas oportunidades e perspectivas do tema em questão.

4.1 Barreiras tecnológicas, econômicas e ambientais

Apesar do potencial transformador da IA no desenvolvimento de energia sustentável, vários desafios impedem sua ampla adoção e eficácia. Esses desafios abrangem questões relacionadas a dados, altas demandas computacionais, riscos de segurança cibernética e preocupações regulatórias e éticas, conforme mostrado na figura 3 (Awonuga et al., 2024).

Figura 3 - Desafios na implementação de IA para energia sustentável



Fonte: Adaptado de Awonuga et al. (2024)

De acordo com Adewoyin, Adediwin e Audu (2025), a integração de dados no setor de energia é um desafio devido à sua infraestrutura fragmentada. As informações vêm de diversas fontes, como redes elétricas, ERs, indústrias e consumo doméstico, e são geradas em formatos variados. A falta de sensores e o isolamento de dados entre diferentes entidades como empresas, governos e instituições de pesquisa resultam em informações incompletas e inconsistentes.

Primeiramente, para que a IA funcione de forma eficaz, é crucial ter dados padronizados. Atualmente, a falta de uniformidade em unidades de medida e formatos de relatório dificulta o processamento e a comparação de dados pelos modelos de IA. A criação de padrões globais para a coleta e o compartilhamento de dados é essencial para prever com mais precisão, tomar decisões mais assertivas e permitir que as soluções de IA em energia se expandam.

Além disso, sistemas de energia que usam IA enfrentam sérios riscos de segurança cibernética. Hackers podem manipular os algoritmos da IA para enganá-los, o que representa um tipo de ataque. A privacidade dos dados dos consumidores é uma preocupação, já que esses sistemas coletam informações detalhadas sobre o uso de energia. Se não forem protegidos, esses dados podem ser usados para vigilância ilegal, roubo de identidade ou fraude.

Segundo Kearney e Hansmann (2024), o crescimento acelerado da IA está impulsionando uma demanda energética sem precedentes, colocando pressão sobre a infraestrutura elétrica atual. Os *data centers* (centrais de processamentos de dados) de IA exigem fornecimento contínuo e confiável de energia, o que desafia a expansão sustentável da rede. A resposta imediata tem sido recorrer a fontes fósseis, como gás natural, o que compromete metas climáticas e a competitividade econômica.

Diante das evidentes e desastrosas implicações ecológicas dessa alta demanda energética da IA, os autores defendem que essa exigência incessante por poder computacional é melhor correspondida a um conjunto de fontes novas de energia limpa e confiável. Isso inclui a fissão nuclear avançada, que pode ser

implantada rapidamente em pequena escala, e a energia geotérmica de próxima geração, que pode ser instalada em qualquer lugar e a qualquer momento.

Portanto, para combater essas diversas ameaças, é crucial padronizar os dados para obter maior viabilidade econômica, usar medidas de segurança avançadas em sistemas de energia inteligentes, como autenticação via *blockchain*, modelos de IA criptografados e sistemas de detecção de ameaças que também utilizem IA. Ademais, embora a fissão nuclear seja uma alternativa promissora, ela não é renovável, pois depende de urânio que é um recurso finito, gera resíduos radioativos e perigosos que perduram por milhares de anos, além de apresentar riscos de acidentes nucleares como os registrados em Chernobyl e Fukushima. Diante disso, o uso da energia geotérmica se mostra mais sustentável para o abastecimento de grandes *data centers* de IA, representando uma alternativa renovável, limpa, segura e escalável.

4.2 Novas oportunidades com IA em energia renovável

As tendências futuras apontadas por Adewoyin, Adediwin e Audu (2025), mostram que à medida que a IA se desenvolve, seu papel na energia sustentável se torna cada vez mais importante. Avanços futuros em algoritmos, integração com sistemas de energia, uso da IA na economia circular e a colaboração entre governos e empresas podem otimizar a produção de energia, reduzir o impacto ambiental e, assim, aumentar a sustentabilidade global.

Segundo Gerhardt (2021), para concretizar plenamente as perspectivas da aplicação de AM no setor de ER, uma área de pesquisa é melhorar a qualidade e a consistência dos dados. A padronização da coleta e do compartilhamento de dados pode aprimorar o desenvolvimento de modelos de AM e aumentar sua interpretabilidade.

Além disso, pesquisas futuras podem se concentrar no desenvolvimento de novos algoritmos e modelos que possam lidar efetivamente com as características únicas dos dados de ER, como alta variabilidade, não linearidade e sazonalidade. A inclusão de dados qualitativos pode proporcionar uma compreensão mais abrangente das aplicações práticas do AM no setor de ER e identificar áreas para futuras pesquisas e desenvolvimento.

Portanto, pesquisas são necessárias para investigar mais a fundo o potencial da combinação do AM com outras tecnologias, como *blockchain* e a Internet das Coisas (IoT), para aprimorar o desempenho e a sustentabilidade do setor de ER.

5 Conclusão

Esta seção apresentará a revisão dos objetivos alcançados do trabalho, considerações finais e sugestões para trabalhos futuros.

5.1 - Revisão dos objetivos alcançados e considerações finais

Este artigo teve como objetivo fazer uma revisão bibliográfica sobre como a aplicação de técnicas de IA pode otimizar a eficiência, confiabilidade e a sustentabilidade na produção de ER. O estudo evidencia o potencial da IA em

sistemas renováveis como um catalisador na transição energética, essencial no combate às mudanças climáticas.

A princípio, a IA emergiu como um fator revolucionário na busca por um desenvolvimento energético sustentável. Ao longo desta revisão, foram destacadas diversas aplicações da IA em sistemas de ER, incluindo previsão de demanda e oferta energética, otimização de recursos, a melhoria da eficiência energética, a gestão de redes inteligentes e o uso de AM para a previsão de produção.

O artigo também revelou que, apesar dos inúmeros benefícios da IA no setor de ER, ainda existem desafios significativos. Eles estão relacionados principalmente a dados, às altas demandas computacionais e energéticas, aos riscos de segurança cibernética, bem como às preocupações regulatórias e éticas. Para superá-los, o estudo ressalta que a padronização dos dados, o uso de potentes fontes renováveis como a energia geotérmica, a articulação entre empresas, governos e instituições de pesquisa, e o investimento em medidas de segurança são fundamentais para o avanço da IA em sistemas renováveis.

Por fim, a análise sobre o AM aplicado à previsão de produção energética apontou que, embora modelos de RF tenham demonstrado desempenho superior a outras técnicas na previsão de ER por sua capacidade de lidar com relações não lineares e dados complexos, métodos de ANNs especializados em séries temporais, como as RNNs, mostraram-se mais adequados para capturar padrões e tendências em dados com espaçamento irregular, fornecendo previsões mais precisas neste contexto específico. Dessa forma, o uso de modelos especializados como as RNNs representa um avanço significativo para a obtenção de soluções mais robustas e eficientes no gerenciamento de ER.

5.2 - Sugestões para trabalhos futuros

Com base nesta revisão, é possível sugerir diversas perspectivas para trabalhos futuros no campo da IA aplicada à produção de ER. Uma área de pesquisa necessária é o desenvolvimento de métodos para melhorar a qualidade e consistência dos dados do setor, que frequentemente se apresentam incompletos e inconsistentes devido à falta de padronização na coleta. Futuros estudos podem focar em como padronizar o compartilhamento de informações, assim, permitindo que as soluções de IA se expandam de forma mais eficaz.

Outra sugestão importante é explorar outros tipos de algoritmos além das ANNs, que sejam adequados para diferentes cenários. A investigação desses outros métodos de AM é fundamental para solucionar problemas específicos do setor, como os que envolvem a alta variabilidade e sazonalidade dos dados. Nesse sentido, a busca por novos algoritmos que reduzam a demanda computacional pode tornar as soluções mais viáveis.

Portanto, além dos desafios técnicos, dada a urgência de mitigar o impacto ambiental associado à alta demanda energética da IA, é imprescindível que trabalhos posteriores abordem de forma aprofundada o potencial da robusta energia geotérmica que, até o momento, se destaca como a única alternativa renovável capaz de atender consistentemente à demanda 24/7 (capaz de operar 24 horas por dia, 7 dias por semana) dos grandes *data centers* de IA.

Referências

ADEWOYIN, ADEDIWIN, AUDU. Artificial Intelligence and Sustainable Energy Development: A Review of Applications, Challenges, and Future Directions. International Journal of Multidisciplinary Research and Growth Evaluation, Vol. 6, p. 197-201, 2025. Disponível em: <https://doi.org/10.54660/IJMRGE.2025.6.2.196-203>. Acesso em: 28 out. 2025.

ANG, KAMAROL, DAS, NAZARI, PRABAHARAN. A comprehensive study of renewable energy sources: Classifications, challenges and suggestions. ScienceDirect, Energy Strategy Reviews journal, v. 43, 2022. Disponível em: <https://doi.org/10.1016/j.esr.2022.100939>. Acesso em: 22 ago. 2025.

ASEMI, KO, NOWKARIZI. Intelligent libraries: a review on expert systems, artificial intelligence, and robot, Library Hi Tech, Vol. 39 No. 2, p. 412-434, 2021. Disponível em: <https://doi.org/10.1108/LHT-02-2020-0038>. Acesso em: 05 set. 2025.

ASSIS. GESTÃO DA MANUTENÇÃO DE PARQUE EÓLICO: PROPOSTA DE UM PLANO DE MANUTENÇÃO. p.27, 2022. Disponível em: <https://repositorio.ufersa.edu.br/items/d5cc446f-2965-4a3d-ba97-e123585b3176>. Acesso em: 25 jul. 2025.

AWONUGA, NWANKWO, OLADAPO, OKOYE, ODUNAYA, SCHOLASTICA. Driving sustainable growth in SME manufacturing: The role of digital transformation, project, and capture management. International Journal of Science and Research Archive, 2024. Disponível em: <https://doi.org/10.30574/ijrsa.2024.11.1.0270>. Acesso em: 19 set. 2025.

BARCHI, SANTOS, VEITÍA, JR., SIQUEIRA. Tendências na Otimização de Energias Renováveis com Inteligência Artificial: Uma Abordagem Cienciométrica no Campo das EngenhariaS. ConBRepro, p. 2-3, 2024. Disponível em: https://aprepro.org.br/conbapro/analises/2024/arquivos/10272024_221010_671ee7ba6dd4f.pdf. Acesso em: 12 set. 2025

BENTI, CHAKA, SEMIE. Forecasting Renewable Energy Generation with Machine Learning and Deep Learning: Current Advances and Future Prospects, 2023. Disponível em: <https://doi.org/10.3390/su15097087>. Acesso em: 15 set. 2025.

CARVALHO, C. A. A evolução da energia solar e sua contribuição socioambiental no Brasil. Ciências Exatas e da Terra, v. 27, n. 127, p. 1-15, 2023. Disponível em: <https://revistaft.com.br/a-evolucao-da-energia-solar-e-sua-contribuicao-socioambiental-no-brasil/>. Acesso em: 25 jul. 2025.

CHATTERJEE, KHAN, BYUN. Recent advances and applications of machine learning in the variable renewable energy sector. ScienceDirect, Energy Reports journal, v.12, p. 5047, 2024. Disponível em: <https://doi.org/10.1016/j.egyr.2024.09.073> . Acesso em: 05 set. 2025.

DALMAZ, Alessandro; PASSOS, Júlio César; COLLE, Sérgio. Energia eólica para geração de eletricidade e a importância da previsão. Revista ABCM – Engenharia, Rio de Janeiro, Vol. XIII - No 1. p. 2, 2008. Disponível em: <https://lepten.ufsc.br/disciplinas/emc5489/arquivos/pdf/textos/eolica/textoeolica5.pdf> . Acesso em: 22 ago. 2025.

DASTRES, SOORI. Artificial Neural Network Systems. International Journal of Imaging and Robotics (IJIR), 21 (2), p. 13-25, 2021. Disponível em: <https://hal.science/hal-03349542/> . Acesso em: 05 set. 2025.

DIAS. O PAPEL DAS ENERGIAS RENOVÁVEIS NO CUMPRIMENTO DOS ODS: OPORTUNIDADES E DESAFIOS. RECIMA21 - REVISTA CIENTÍFICA MULTIDISCIPLINARISSN 2675-6218, p. 9, 2024. Disponível em: <https://doi.org/10.47820/recima21.v5i1.4845> . Acesso em: 22 ago. 2025.

GERHARDT. Aplicação de Aprendizado de Máquina para previsão de Energia Eólica Gerada. IEEE LATIN AMERICA TRANSACTIONS, VOL. 14, NO. 8, p. 4-5, 2021. Disponível em: <https://repositorio.ucs.br/11338/12419>. Acesso em: 28 out. 2025.

HYNDMAN, R.J.; ATHANASOPOULOS, G. Forecasting: principles and practice. 3 ed. Melbourne, Australia: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>. Acesso em: 12 set. 2025.

JANJANAM, GANESH, MANJUNATHA. Design of an expert system architecture: An overview. J. Phys.: Conf. Ser. 1767 012036, p. 1-8, 2021. Disponível em: <https://doi.org/10.1088/1742-6596/1767/1/012036> . Acesso em: 05 set. 2025.

KEARNEY, M.; HANSMANN, L. Por que a Inteligência Artificial e a energia limpa precisam uma da outra. MIT Technology Review Brasil, 2024. Disponível em: <https://mittechreview.com.br/ia-energia-limpa-revolucao-tecnologica> . Acesso em: 28 out. 2025.

LEDMAOUI, MAGHRAOUI, AROUSSI, SAADANE, CHEBAK, CHEHRI. Forecasting solar energy production: A comparative study of machine learning algorithms. ScienceDirect, Energy Reports, p. 1007-1009, 2023. Disponível em: <https://doi.org/10.1016/j.egyr.2023.07.042>.

Acesso em: 15 set. 2025.

MAHESH. Machine Learning Algorithms - A Review. International Journal of Science and Research (IJSR), v. 9, p. 381-386, 2020. Disponível em: <https://doi.org/10.21275/ART20203995>.

Acesso em: 05 set. 2025.

SANTOS, OTTONI, NEPOMUCENO. Aplicações de Inteligência Artificial em Energias Renováveis: Uma Revisão Sistemática. Vol. 3, N.o 1, 2022. Disponível em: <https://doi.org/10.20906/CBA2022/3530>.

Acesso em: 12 set. 2025.

SILVA. Geração de energia hidrelétrica: uma análise comparativa de métodos de previsão estatísticos e de inteligência artificial aplicados a dados da região sul do Brasil. 2023. Trabalho de Conclusão de Curso (Licenciatura em Matemática) - Universidade Tecnológica Federal do Paraná, Pato Branco, p. 2, 2023. Disponível em: <http://repositorio.utfpr.edu.br/jspui/handle/1/33931>.

Acesso em: 12 set. 2025.

SLOWIK, KWASNICKA. Evolutionary algorithms and their applications to engineering problems. Neural Comput & Applic 32, p. 12363–12379, 2020. Disponível em: <https://doi.org/10.1007/s00521-020-04832-8>.

Acesso em: 05 set. 2025.

SOARES. ESTUDO SOBRE A GERAÇÃO DE ENERGIA ELÉTRICA POR FONTES RENOVÁVEIS NA PARAIBA. p. 34-39, 2023.

Disponível em:

<https://repositorio.ufpb.br/jspui/handle/123456789/31935>.

Acesso em: 22 ago. 2025.

VIALI, GONÇALVES, SILVA, GAZZANI. Uma análise da utilização de smart grids no sistema elétrico brasileiro. Caderno Pedagógico, 22(1), e13341, p. 6-8, 2025. Disponível em:

<https://doi.org/10.54033/cadpedv22n1-138>.

Acesso em: 12 set. 2025.