



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA MECÂNICA**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA DE ENERGIAS RENOVÁVEIS**

**PEDRO FELIPE BEZERRA DA SILVA**

**REVISÃO BIBLIOGRÁFICA DO USO DE INTELIGÊNCIA ARTIFICIAL EM**  
**SISTEMAS DE ENERGIAS RENOVÁVEIS**

**FORTALEZA**

**2026**

PEDRO FELIPE BEZERRA DA SILVA

REVISÃO BIBLIOGRÁFICA DO USO DE INTELIGÊNCIA ARTIFICIAL EM SISTEMAS  
DE ENERGIAS RENOVÁVEIS

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Engenharia de Energias  
Renováveis da Universidade Federal do Ceará,  
como requisito parcial à obtenção do grau de  
Engenheiro de Energias Renováveis.

Orientadora: Prof<sup>ª</sup>. Dr<sup>ª</sup>. Ana Fabiola Leite  
Almeida

FORTALEZA

2026

PEDRO FELIPE BEZERRA DA SILVA

REVISÃO BIBLIOGRÁFICA DO USO DE INTELIGÊNCIA ARTIFICIAL EM SISTEMAS  
DE ENERGIAS RENOVÁVEIS

Trabalho de Conclusão de Curso apresentado ao  
Curso de Graduação em Engenharia de Energias  
Renováveis da Universidade Federal do Ceará,  
como requisito parcial à obtenção do grau de  
Engenheiro de Energias Renováveis.

Aprovada em:    /    /    .

BANCA EXAMINADORA

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Ana Fabiola Leite Almeida (Orientadora)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Francisco Nivaldo Aguiar Freire  
Universidade Federal do Ceará (UFC)

---

Prof<sup>ª</sup>. Dr<sup>ª</sup>. Maria Aleksandra de Sousa Rios  
Universidade Estadual do Ceará (UECE)

A minha família.

## AGRADECIMENTOS

À minha mãe e à minha família, pelo apoio imprescindível ao longo de toda essa trajetória. Obrigado pela compreensão em minhas faltas e pelo incentivo sempre presente, que foram fundamentais para que eu pudesse me dedicar aos estudos e finalizar esta fase.

A minha orientadora, Prof.<sup>a</sup> Dr.<sup>a</sup> Ana Fabiola Leite Almeida, pela direção deste trabalho, pelas orientações acadêmicas que possibilitaram o aperfeiçoamento desta investigação.

Ao Prof. Dr. Francisco Nivaldo Aguiar Freire e aos integrantes do Laboratório de Filmes Finos e Energias Renováveis (LAFFER) pelo ambiente técnico de aprendizado e pela infraestrutura oferecida, que foram fundamentais para minha formação acadêmica e profissional.

À equipe da RETECjr, agradeço pela colaboração, pelo compartilhamento de experiências e pelo crescimento mútuo que vivenciamos na empresa júnior, que enriquece a visão prática da engenharia.

À secretária Maria Cristina, pela eficiência, presteza e paciência na tramitação dos processos administrativos e na solução das pendências ao longo do processo.

“Se cada instrumento pudesse realizar a sua própria obra, obedecendo ou antecipando a vontade de outros [...] os mestres não precisariam de servos, nem os senhores de escravos.” (ARISTÓTELES, 2019, p. 26).

## RESUMO

A inclusão ampla de fontes de energia renováveis na matriz elétrica levanta desafios técnicos significativos, devido à sua natureza intermitente e estocástica. Este trabalho investiga a aplicação da inteligência artificial como uma ferramenta estratégica para gerir e otimizar esses sistemas, por meio de uma revisão bibliográfica na base de dados Scopus, abrangendo o intervalo de 2015 a 2024. A análise qualitativa de 40 publicações selecionadas possibilitou a identificação de tendências estabelecidas na literatura, ressaltando uma prevalência de aplicações direcionadas às energias solar e eólica. Constatou-se que as metodologias de *deep learning* firmaram-se como a principal escolha nas previsões de geração e na manutenção preditiva; mais precisamente, os estudos examinados ressaltam a primazia das redes neurais de memória de longo e curto prazo ao gerenciar a não linearidade dos dados climáticos, superando abordagens estatísticas tradicionais. Dentro do contexto da manutenção preditiva, as redes neurais convolucionais se destacam como o modelo ideal para a identificação automática de defeitos. De forma concomitante, a literatura aponta que algoritmos de otimização meta-heurísticos são fundamentais para a maximização da eficácia em sistemas fotovoltaicos e eólicos. Entretanto, essa integração não ocorre sem enfrentar desafios significativos: a análise sinaliza limitações técnicas concernentes à qualidade e à disponibilidade de dados, além de abordar o paradoxo energético inerente ao treinamento de modelos de grande escala e a fragmentação do conhecimento. As projeções futuras indicam a imprescindibilidade de estratégias mais integradas. Conclui-se que a inteligência artificial constitui um vetor transformador, apto a propiciar a aceleração da transição energética em escala global; no entanto, é necessária a cooperação entre pesquisadores, setor industrial e formuladores de políticas para vencer os desafios apontados.

**Palavras-chave:** Energias renováveis; inteligência artificial; *machine learning*; *deep learning*; otimização energética

## ABSTRACT

The widespread integration of renewable energy sources into the grid raises significant technical challenges due to their intermittent and stochastic nature. This work investigates the application of artificial intelligence as a strategic tool to manage and optimize these systems through a literature review in the Scopus database, spanning the period from 2015 to 2024. The qualitative analysis of 40 selected publications allowed for the identification of established trends in the literature, highlighting a prevalence of applications directed towards solar and wind energy. It was found that deep learning methodologies have established themselves as the primary choice for generation forecasting and predictive maintenance; more precisely, the examined studies highlight the primacy of Long Short-Term Memory neural networks in managing the non-linearity of climate data, outperforming traditional statistical approaches. Within the context of predictive maintenance, Convolutional Neural Networks stand out as the ideal model for automatic defect identification. Concomitantly, the literature indicates that meta-heuristic optimization algorithms are fundamental for maximizing efficiency in photovoltaic and wind systems. However, this integration does not occur without facing challenges: the analysis signals technical limitations regarding data quality and availability, in addition to addressing the energy paradox inherent in training large-scale models and knowledge fragmentation. Future projections indicate the indispensability of more integrated strategies. It is concluded that artificial intelligence constitutes a transformative vector capable of accelerating the energy transition on a global scale; however, cooperation among researchers, the industrial sector, and policymakers is necessary to overcome the identified challenges.

**Keywords:** Renewable energy; artificial intelligence; machine learning; deep learning; energy optimization

## LISTA DE FIGURAS

Figura 1 - Expansão e previsão da capacidade instalada de fontes de energias renováveis globalmente (2000-2028).....	13
Figura 2 - Processo de seleção de artigos inspirados no método PRISMA.....	20
Figura 3 - (a) Gráfico demonstrando o processo de classificação (b) Gráfico que ilustra a regressão linear .....	24
Figura 4 - Quantidade de artigos por temática dominante.....	29
Figura 5 - Em quantos artigos cada categoria é citada .....	30

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>13</b>
<b>2</b>	<b>OBJETIVOS .....</b>	<b>16</b>
<b>3</b>	<b>METODOLOGIA.....</b>	<b>17</b>
<b>3.1</b>	<b>Procedimentos Técnicos: Revisão Bibliográfica Estruturada .....</b>	<b>17</b>
<i>3.1.1</i>	<i>Delimitação Temporal.....</i>	<i>17</i>
<i>3.1.2</i>	<i>Estratégia de Busca .....</i>	<i>17</i>
<i>3.1.3</i>	<i>CrITÉRIOS de Inclusão e Exclusão .....</i>	<i>18</i>
<i>3.1.4</i>	<i>Seleção, Análise e Síntese do Material .....</i>	<i>19</i>
<b>4</b>	<b>FUNDAMENTAÇÃO TEÓRICA .....</b>	<b>21</b>
<b>4.1</b>	<b>O Cenário Energético Contemporâneo e o Desafio da Variabilidade .....</b>	<b>21</b>
<b>4.2</b>	<b>A Solução: A Inteligência Artificial como Ferramenta de Gestão.....</b>	<b>22</b>
<i>4.2.1</i>	<i>Técnicas de Inteligência Artificial .....</i>	<i>22</i>
<i>4.2.1.1</i>	<i>Machine Learning .....</i>	<i>22</i>
<i>4.2.1.2</i>	<i>Deep Learning.....</i>	<i>25</i>
<i>4.2.1.3</i>	<i>Algoritmos de busca e otimização.....</i>	<i>26</i>
<b>5</b>	<b>DISCUSSÃO DOS RESULTADOS.....</b>	<b>29</b>
<b>5.1</b>	<b>Síntese dos Principais Achados.....</b>	<b>29</b>
<i>5.1.1</i>	<i>Macro Padrões da Literatura analisada.....</i>	<i>29</i>
<i>5.1.2</i>	<i>Solucionando problemas com IA.....</i>	<i>30</i>
<i>5.1.2.1</i>	<i>Olhando para o Futuro.....</i>	<i>30</i>
<i>5.1.2.2</i>	<i>Busque Sempre o Melhor.....</i>	<i>32</i>
<b>5.2</b>	<b>Lacunas identificadas .....</b>	<b>33</b>
<b>5.3</b>	<b>Comparando Técnicas Computacionais .....</b>	<b>34</b>
<b>5.4</b>	<b>Desafios e Limitações .....</b>	<b>35</b>
<i>5.4.1</i>	<i>Paradoxo do Uso de IA em Energias Renováveis .....</i>	<i>36</i>
<i>5.4.2</i>	<i>Limitações Técnicas .....</i>	<i>36</i>
<i>5.4.3</i>	<i>Inteligência Natural .....</i>	<i>37</i>
<i>5.4.4</i>	<i>Caixa Preta .....</i>	<i>37</i>
<b>5.5</b>	<b>Perspectivas Futuras .....</b>	<b>38</b>
<i>5.5.1</i>	<i>Consolidação de Tecnologias .....</i>	<i>38</i>
<i>5.5.2</i>	<i>Novos Horizontes.....</i>	<i>38</i>
<i>5.5.2.1</i>	<i>Energia dos Oceanos.....</i>	<i>39</i>
<i>5.5.2.2</i>	<i>Tecnologias do Hidrogênio.....</i>	<i>39</i>


<b>6</b>	<b>CONCLUSÃO.....</b>	<b>41</b>
	<b>REFERÊNCIAS .....</b>	<b>43</b>

## 1 INTRODUÇÃO

A transformação energética no âmbito global configura-se como um dos mais significativos desafios e oportunidades do século XXI. Em face da emergência climática e da imperiosa necessidade de diminuir as emissões de gases de efeito estufa, as fontes de energias renováveis emergiram como elementos essenciais para o desenvolvimento de um sistema energético sustentável. Nos anos recentes, notou-se um aumento exponencial na capacidade instalada de fontes renováveis em todo o mundo, alterando o cenário energético global e reconfigurando os paradigmas convencionais de geração, transmissão e distribuição de energia.

Conforme informações da Agência *International Energy Agency* (2024), o setor de energias renováveis apresentou um crescimento extraordinário entre os anos de 2000 e 2023 como se pode ver pelo gráfico da Figura 1, firmando-se como a principal fonte de ampliação da capacidade elétrica mundial. Esse fenômeno não implica apenas uma alteração tecnológica, mas uma transformação sistêmica que reconfigura a geopolítica energética e gera novos desafios técnicos e operacionais.

Figura 1 - Expansão e previsão da capacidade instalada de fontes de energias renováveis globalmente (2000-2028)



Fonte: *International Energy Agency* (2024, p. 15)

Entretanto, este avanço vertiginoso não ocorre sem obstáculos significativos. As energias renováveis variáveis (ERVs), como solar e eólica, apresentam uma característica intrínseca de intermitência e imprevisibilidade que desafia a operação estável dos sistemas elétricos tradicionais. A variabilidade dessas fontes introduz complexidades na gestão da rede, como flutuações de frequência, problemas de qualidade de energia, risco de *curtailment* (desperdício de energia) e dificuldades no planejamento operacional. Em um sistema com elevada participação de fontes renováveis, a capacidade de prever com precisão a geração, otimizar recursos e responder rapidamente a distúrbios torna-se não apenas desejável, mas essencial para a segurança energética.

Neste contexto, a inteligência artificial (IA) emerge como uma ferramenta transformadora com potencial para superar tais desafios. A convergência entre o crescimento exponencial de dados gerados pelos sistemas energéticos modernos e o avanço em técnicas de aprendizado de máquina, *deep learning* e otimização computacional criou condições propícias para uma nova era na gestão de energias renováveis. A IA oferece mecanismos sofisticados para a previsão de geração, detecção de falhas, otimização de operação, controle dinâmico e planejamento estratégico, tornando os sistemas energéticos mais resilientes, eficientes e adaptáveis.

O presente trabalho de conclusão de curso tem por objetivo conduzir uma revisão bibliográfica acerca da aplicação de inteligência artificial em sistemas de energias renováveis, com ênfase no intervalo de 2015 a 2024. A opção por este recorte temporal fundamenta-se na consolidação das modernas técnicas de inteligência artificial, em particular do aprendizado profundo, além da evolução das tecnologias de energia renovável ao longo desse intervalo. A pesquisa tem como objetivo realizar um mapeamento crítico das aplicações atualmente em uso, reconhecer padrões presentes na literatura acadêmica, avaliar a eficácia relativa das diversas técnicas computacionais e indicar lacunas, bem como direções futuras para pesquisa e desenvolvimento.

A importância deste estudo está na sua habilidade de compilar conhecimentos dispersos em diversas subáreas, proporcionando percepções significativas para pesquisadores, especialistas da área energética e responsáveis pela elaboração de políticas públicas. Em um período em que a transição energética avança rapidamente ao redor do mundo e os aportes em tecnologias de digitalização para o setor aumentam de forma exponencial, compreender de que maneira a inteligência artificial pode facilitar a integração eficaz e econômica das fontes de energias renováveis torna-se fundamental para o progresso sustentável.

Este texto é organizado em seis capítulos. Após essa introdução, o capítulo 2 expõe os objetivos específicos da pesquisa. O terceiro capítulo descreve a metodologia empregada na revisão da literatura. O quarto capítulo elabora a base teórica, discutindo os obstáculos relacionados à variabilidade das fontes de energias renováveis e as metodologias de inteligência artificial pertinentes ao setor. O quinto capítulo aborda os resultados da revisão, examinando padrões, lacunas e perspectivas para o futuro. Por fim, o capítulo 6 finaliza o estudo, reunindo as principais contribuições e sugestões para investigações futuras.

## **2 OBJETIVOS**

Elucidar, de forma crítica, como a inteligência artificial está sendo aplicada no setor de energias renováveis, mapeando usos, ganhos, limitações e tendências a partir de revisão bibliográfica estruturada (2015–2024). Para auxiliar esta análise, os seguintes objetivos específicos foram delineados:

- a) Contextualizar o uso contemporâneo das energias renováveis, oferecendo um panorama do cenário atual.
- b) Identificar as áreas de aplicação da inteligência artificial dentro do setor de energias renováveis, explorando as possibilidades e os modelos mais adequados para cada contexto.

### 3 METODOLOGIA

Este capítulo descreve os procedimentos metodológicos adotados para a elaboração deste trabalho de conclusão de curso, que foi construído com o objetivo de investigar o uso da inteligência artificial no campo das energias renováveis, identificando as principais aplicações, desafios e tendências futuras documentadas na literatura científica.

Para tanto, o estudo classifica-se metodologicamente sob três aspectos fundamentais. Quanto à sua natureza, caracteriza-se como pesquisa básica pois, de acordo com Gil (2008), objetiva gerar conhecimentos novos úteis para o avanço da ciência e aprofundar o entendimento teórico, sem uma aplicação prática prevista de imediato. No que tange à abordagem do problema, trata-se de uma pesquisa qualitativa; segundo Sampieri, Collado e Lucio (2013), essa modalidade concentra-se na compreensão de fenômenos complexos e na interpretação da literatura para identificar padrões, sem basear-se exclusivamente em dados estatísticos. Por fim, do ponto de vista dos objetivos, a pesquisa define-se como exploratória, visto que seu propósito principal é proporcionar maior familiaridade com o problema e estimular a compreensão do tema através de levantamento bibliográfico, conforme preconizam Prodanov e Freitas (2013).

#### 3.1 Procedimentos Técnicos: Revisão Bibliográfica Estruturada

O procedimento técnico central para a realização deste trabalho foi a revisão bibliográfica. Para garantir o rigor e a transparência na seleção do material, o processo foi estruturado nas seguintes etapas:

##### 3.1.1 *Delimitação Temporal*

O período analisado nesta pesquisa abrange os anos de 2015 a 2024. Esta delimitação justifica-se pela necessidade de focar na literatura mais recente, período que coincide com a consolidação da IA moderna especialmente o *deep learning* e a rápida evolução das tecnologias de gestão de energia renovável. Publicações anteriores a 2015 foram excluídas por refletirem paradigmas tecnológicos que podem não representar o estado da arte atual.

##### 3.1.2 *Estratégia de Busca*

A busca bibliográfica foi realizada exclusivamente na base de dados Scopus, uma das mais abrangentes e respeitadas bases internacionais de literatura científica indexada. A escolha do Scopus se justifica por sua alta cobertura em áreas de engenharia, ciência da computação, energia e sustentabilidade, além de seu rigoroso processo de seleção de periódicos

(baseado em critérios de qualidade editorial, revisão por pares e impacto científico). Ademais, o Scopus oferece ferramentas avançadas de busca estruturada, filtragem por tipo de documento, idioma, ano e fonte, o que permite maior precisão e reprodutibilidade.

As buscas foram conduzidas no idioma inglês, predominante na literatura científica da área. Para a construção da consulta de busca, foram definidos descritores alinhados ao objetivo da pesquisa, combinados por meio de operadores booleanos. A estratégia principal consistiu na intersecção dos termos "*Artificial Intelligence*" e "*Renewable energy*" (utilizando o operador *AND*). De forma complementar, foi incluído o termo "*Green AI*" (conectado pelo operador *OR*) para assegurar a cobertura de terminologias emergentes associadas à sustentabilidade computacional.

Para o refinamento dos resultados, foram aplicados filtros específicos diretamente na interface de busca avançada:

- **Recorte temporal:** A pesquisa limitou-se ao período de **2015 a 2024**, garantindo a análise de dados contemporâneos e a evolução recente das tecnologias;
- **Tipo de documento:** Foram selecionados exclusivamente **artigos de revisão**, visando obter uma visão panorâmica e consolidada do estado da arte;
- **Área temática:** A busca foi restringida à grande área de **Energia**, para evitar resultados dispersos em outras disciplinas não pertinentes ao escopo deste trabalho;
- **Idioma:** Selecionaram-se apenas publicações em língua **inglesa**

### ***3.1.3 Critérios de Inclusão e Exclusão***

Os artigos retornados pela busca foram submetidos a um processo de triagem baseado nos seguintes critérios explicitados:

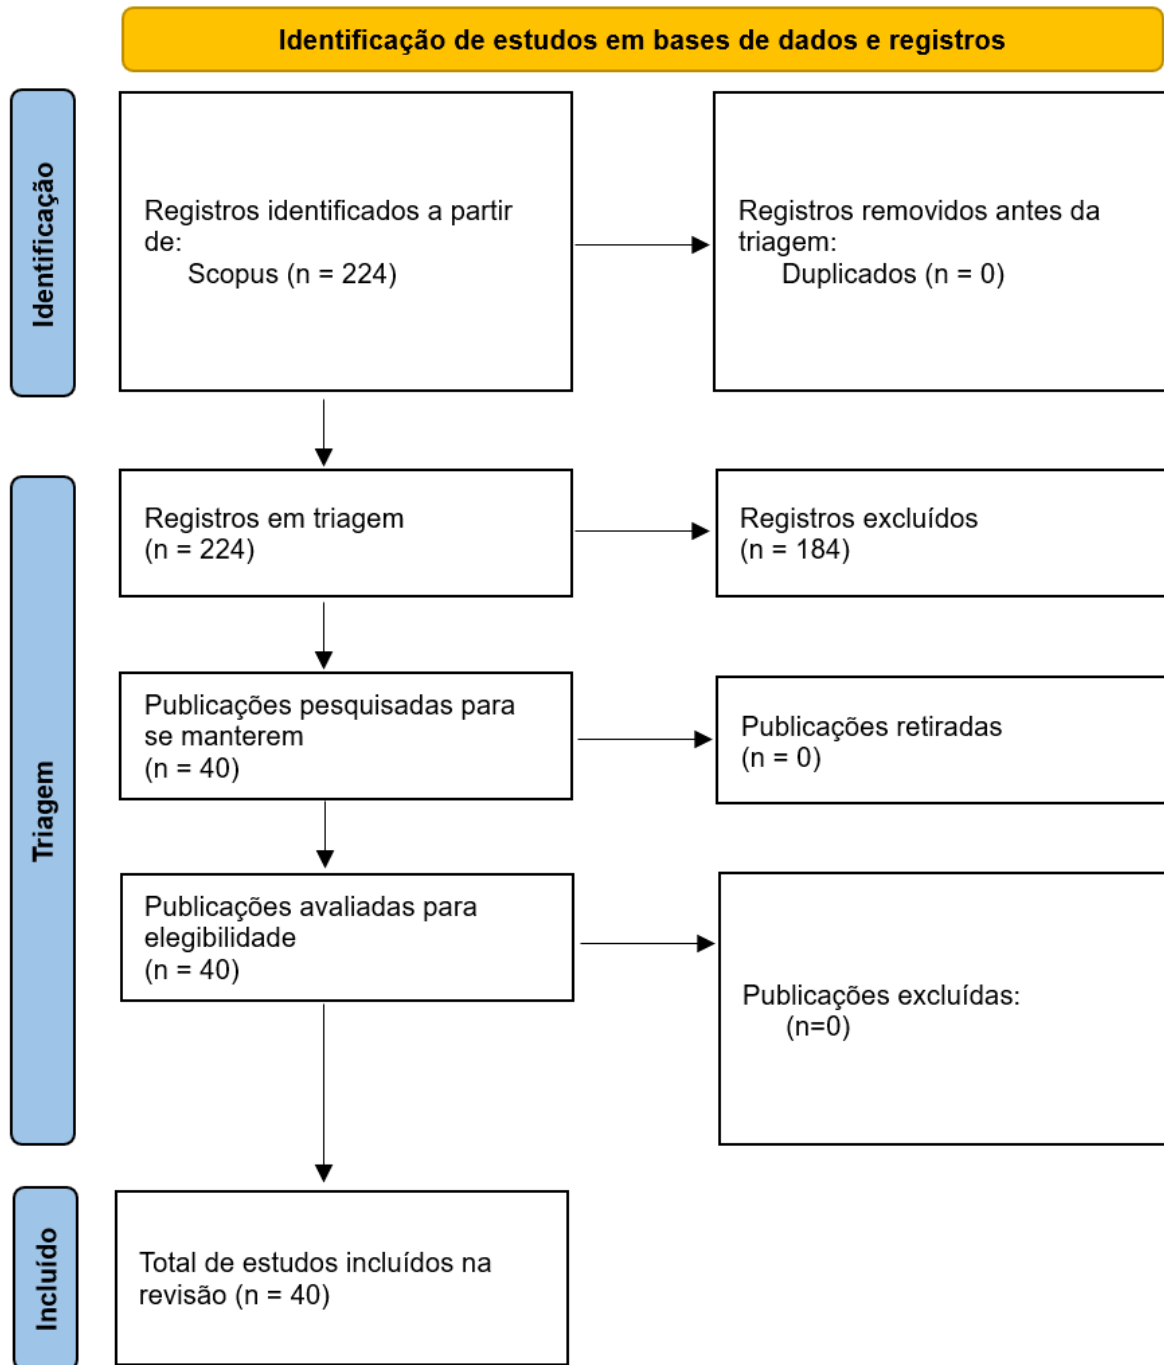
- **Critérios de Inclusão:**
  - Ser um artigo de revisão publicado em periódico científico e revisado por pares;
  - Abordar diretamente a aplicação de Inteligência Artificial no setor de energias renováveis;
  - Estar publicado dentro do período estipulado (2015-2024).
- **Critérios de Exclusão:**
  - Artigos duplicados;
  - Artigos primários (não-revisões), editoriais, cartas ao editor, resumos de conferência ou materiais de divulgação;
  - Artigos que mencionam os termos apenas tangencialmente, sem foco na intersecção dos temas.

### ***3.1.4 Seleção, Análise e Síntese do Material***

O processo de seleção dos artigos está ilustrado no fluxograma da Figura 2, inspirado no protocolo PRISMA (*Preferred Reporting Items for Systematic Reviews and Meta-Analyses*) (PAGE *et al.*, 2021). A partir dos descritores apresentados em 3.1.2 foram obtidos 224 artigos e não havia duplicatas entre eles. Em seguida, passou-se para a etapa de triagem na qual os títulos e resumos dos estudos foram avaliados para verificar sua aderência ao tema e objetivos deste trabalho.

No final da triagem, foram excluídos 184 trabalhos sobrando 40 para verificação de acesso e foi possível acessar todos os artigos. Dessa forma, os 40 entraram para a fase de leitura completa e todos eles foram inclusos neste estudo.

Figura 2 - Processo de seleção de artigos inspirados no método PRISMA



Fonte: Elaborado pelo autor

## 4 FUNDAMENTAÇÃO TEÓRICA

### 4.1 O Cenário Energético Contemporâneo e o Desafio da Variabilidade

O cenário energético mundial está passando por uma transformação radical, motivada não apenas pela urgência climática de descarbonização, mas também por uma reconfiguração essencial na maneira como a energia é produzida, distribuída e consumida. De acordo com a análise realizada por Franki et al. (2023), o setor elétrico experimenta a convergência de três megatendências — descarbonização, descentralização e digitalização — que estão rompendo com o modelo convencional de utilidade verticalmente integrada, em prol de ecossistemas distribuídos e bidirecionais. No cenário atual, as fontes de energia renovável variável (ERV), principalmente as solar e eólica, passaram de um papel secundário para uma posição central na matriz energética, acarretando desafios técnicos.

A integração massiva de ERVs alterou a dinâmica operacional dos sistemas de potência. Ao contrário das usinas termelétricas tradicionais, que proporcionam inércia rotacional e controle na programação da geração, as fontes renováveis contemporâneas apresentam estocasticidade e dependem de inversores eletrônicos. Yousef et al. (2023) sustentam que essa alteração exerce uma pressão significativa sobre a estabilidade da rede: a geração deixa de acompanhar a carga de maneira previsível, demandando que o sistema gerencie variações repentinas de tensão e frequência em intervalos de milissegundos.

Esse desafio é intensificado pela descentralização. O advento de *microgrids* e a geração distribuída converteram consumidores previamente passivos em prosumidores atuantes. Rinaldi *et al.* (2021) e Zulu et al. (2023) enfatizam que, apesar de essa arquitetura melhorar a resiliência local, ela traz uma complexidade operacional na qual o fluxo de potência se torna bidirecional e intermitente, o que torna ultrapassados os métodos de proteção e controle concebidos para fluxos unidirecionais. O panorama contemporâneo, assim sendo, não se resume apenas à adoção de fontes renováveis, mas envolve a administração de uma rede fragmentada e instável.

Ademais, a incorporação de fontes renováveis alcança um ponto crítico em que a variabilidade resulta em custos exponenciais. Tayal (2017) analisa o conceito de curva de impedimentos, evidenciando que, quando a inserção de ERVs supera limites de 30-40%, os desafios técnicos relacionados ao balanceamento de carga e os custos de integração sofrem um aumento considerável, a não ser que ocorra uma intervenção tecnológica inovadora. Nesse cenário, a variabilidade representa não apenas um risco técnico relacionado a apagões ou

distorções harmônicas conforme exposto por Khokhar et al., 2015, mas também um risco financeiro que compromete a viabilidade econômica da transição energética.

Dessa forma, o desafio atual consiste em converter essa variabilidade intrínseca — anteriormente considerada um problema das fontes renováveis — em um ativo que possa ser gerido. A produção literária aponta para a constatação de que não basta apenas a construção de uma infraestrutura física, sem uma camada de inteligência computacional capaz de coordenar essa complexa operação em tempo real.

## 4.2 A Solução: A Inteligência Artificial como Ferramenta de Gestão

A IA refere-se a sistemas computacionais capazes de simular o comportamento da inteligência humana para realizar tarefas complexas. No contexto energético, a essa tecnologia transforma o grande volume de dados gerados por medidores, sensores, satélites e consumidores em *insights* acionáveis para previsão, otimização e controle (FRANKI *et al.*, 2023). As subáreas da IA mais relevantes para a gestão de ER são o *machine learning* e os algoritmos meta-heurísticos.

### 4.2.1 Técnicas de Inteligência Artificial

#### 4.2.1.1 Machine Learning

O aprendizado de máquina (*machine learning* - ML) é um ramo da IA focado no desenvolvimento de algoritmos que permitem aos computadores aprender com dados. Diferentemente das abordagens de programação tradicionais, onde as regras são explicitamente definidas, o ML constrói modelos capazes de identificar padrões e utilizá-los para fazer previsões em ambientes incertos. De forma fundamental, um agente que utiliza ML é aquele que aprimora seu desempenho em tarefas futuras após fazer observações sobre o mundo. Esse processo permite ao agente aprender com a experiência, melhorando seu desempenho progressivamente à medida que é exposto a novos dados (RUSSELL, 2010).

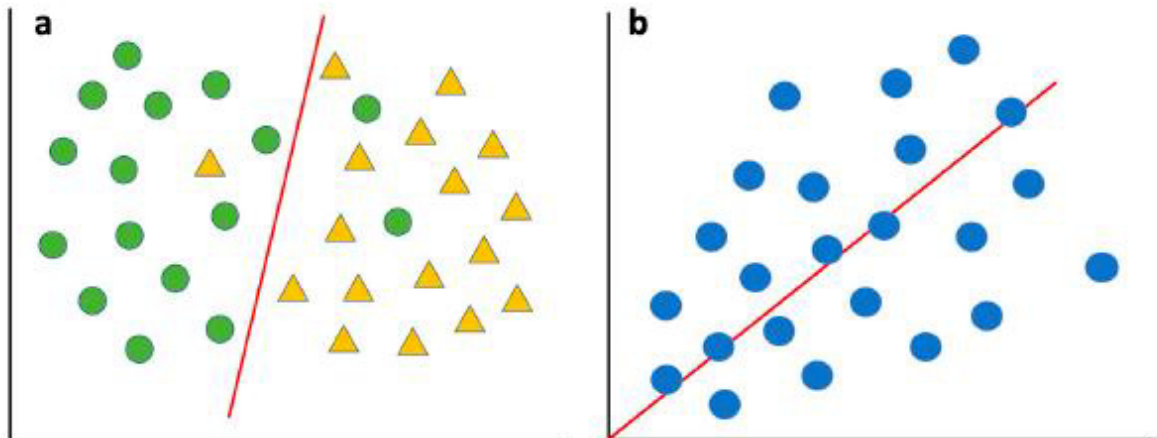
As técnicas de ML são tipicamente classificadas em 3 categorias:

1. Aprendizagem Supervisionada: É a abordagem mais comum, na qual o algoritmo aprende a partir de um conjunto de dados previamente rotulado, mapeando variáveis de entrada para uma variável de saída conhecida. Esta categoria divide-se em duas tarefas principais:
  - a. Classificação: utilizada quando o resultado de saída consiste em categorias discretas, por exemplo, para identificar o estado do sistema como normal, sob falta permanente ou transitória. O algoritmo aprende

padrões que permitem traçar fronteiras de decisão para separar as classes, como ilustrado na Figura 3 (a). Essa abordagem é aplicada com sucesso em sistemas de detecção e classificação de falhas em microrredes. Por exemplo, redes neurais artificiais (*artificial neural network* - ANN) têm sido amplamente utilizadas para classificar diferentes tipos de falhas — como falhas linha-terra, linha-linha ou trifásicas — em microrredes híbridas CA/CC, permitindo uma resposta rápida e adequada aos distúrbios (ZULU *et al.*, 2023).

- b. Regressão: técnica utilizada quando a variável de saída é contínua, como na previsão da velocidade do vento ou da quantidade de energia gerada. O algoritmo aprende a ajustar uma função aos dados, como é possível notar na Figura 3 (b), identificando relações complexas entre variáveis meteorológicas e produção de energia. Neste contexto, métodos baseados no princípio de minimização do risco estrutural, como as máquinas de vetores de suporte (*support vector machines* - SVM), têm demonstrado eficácia particular. Originalmente desenvolvidas por Vapnik para problemas de classificação, as SVMs foram posteriormente estendidas ao domínio da regressão, dando origem à regressão por vetores de suporte (*support vector regression* - SVR). A SVR minimiza um limite superior do risco esperado, possibilitando não apenas o ajuste preciso aos dados de treinamento, mas também melhor capacidade de generalização. Dado que a previsão de geração de energia fotovoltaica constitui um problema típico de análise de séries temporais com variáveis contínuas, a SVR apresenta-se como uma abordagem particularmente adequada para este tipo de aplicação (DAS *et al.*, 2018).

Figura 3 - (a) Gráfico demonstrando o processo de classificação (b) Gráfico que ilustra a regressão linear



Fonte: Yousef et al. (2023, p. 5)

2. Aprendizagem não supervisionada: nesta abordagem, o algoritmo recebe dados não rotulados e deve encontrar padrões ou estruturas ocultas por conta própria. A técnica mais comum é o *clustering* (agrupamento), usada, por exemplo, para segmentar clientes com perfis de consumo de energia semelhantes ou identificar padrões de comportamento de sistemas energéticos (PÉREZ-ORTIZ *et al.*, 2016).
3. Aprendizagem por reforço (*reinforcement learning* – RL) é um método de aprendizado automático no qual um agente interage com um ambiente por meio de decisões sequenciais, buscando maximizar a recompensa acumulada ao longo do tempo. Diferentemente de métodos supervisionados, o RL não depende de rótulos prévios, mas sim da exploração de ações em um processo de tentativa e erro. Essa exploração pode ser feita em tempo real sendo assim usada em problemas de controle autônomo de tensão em tempo real e coordenação entre bancos de capacitores e sistemas de armazenamento (LI *et al.*, 2023).

Apesar da sua eficácia, os modelos de ML tradicionais enfrentam limitações. O desafio mais comum é o fenômeno do *overfitting* que consiste em um modelo “decorar” o padrão específico dos dados de treino, mas falhar em generalizar para novos dados. Outra restrição, é lidar com problemas complexos de relações não-lineares, como a previsão meteorológica instável, os modelos de ML tradicionais podem falhar em capturar essas dinâmicas, levando a um desempenho inferior em comparação com as abordagens de *deep learning* (YOUSSEF *et al.*, 2023)

#### 4.2.1.2 Deep Learning

O *deep learning* (DL) é uma subárea da inteligência artificial, sendo um tipo específico de ML. Esta área está historicamente ligada às ANNs, que são sistemas computacionais inspirados no cérebro biológico. As ANNs baseiam-se na premissa de que o comportamento inteligente emerge da interligação em rede de um vasto número de unidades computacionais simples, conhecidas como unidades ocultas, *hidden units* (GOODFELLOW, 2016).

O termo "*deep*" (profundo) refere-se à utilização de múltiplas camadas (*layers*) no modelo, formando uma cadeia de funções computacionais. Esta arquitetura permite ao computador aprender uma hierarquia de conceitos, na qual conceitos complexos são construídos a partir de conceitos mais simples. Desta forma, o modelo aprende a representar o mundo como uma hierarquia aninhada de conceitos, onde representações mais abstratas são computadas com base em representações menos abstratas.

Para processar tipos de dados específicos, foram desenvolvidas arquiteturas especializadas:

- 1) Redes neuronais convolucionais (*convolutional neural network* - CNNs): são especializadas em processar dados com uma topologia conhecida em forma de grelha (*grid-like*), por exemplo, imagens. Um caso de uso é a detecção de rachaduras em hélices de turbinas eólicas por meio de imagens (CHATTERJEE *et al.*, 2021).
- 2) Redes neuronais recorrentes (*recurrent neural network* - RNNs): são uma família de redes neuronais especializadas no processamento de dados sequenciais, como séries temporais ou sequências moleculares para análise da qualidade de combustão de um biocombustível (JHA *et al.*, 2017).
- 3) RNNs *Gated*: o principal desafio matemático das RNNs tradicionais é a dificuldade em aprender dependências de longo prazo, padrões que se estendem por muitos passos de tempo. Para resolver esta dificuldade, foram criadas as RNNs *gated*. Estas incluem a *long short-term memory* (LSTM) e as *gated recurrent units* (GRUs). Estes modelos utilizam um mecanismo chamado de portões (*gates*) internos que aprendem a decidir quando acumular nova informação e quando esquecer estados antigos, permitindo que a informação flua por longos períodos. Dessa forma, são ótimos para avaliar tanto grandes quanto pequenas quantidades de dados principalmente em problemas de predição seja de geração (DING *et al.*, 2019) ou de demanda (NAM *et al.*, 2020).

Esse tipo de IA é sim mais robusto, porém isso vem com um preço. O sucesso desses algoritmos está diretamente ligado à capacidade de lhes fornecer os recursos necessários, que incluem grandes volumes de dados de alta qualidade, que são frequentemente indisponíveis ou de baixa precisão, especialmente em regiões com infraestrutura de monitoramento limitada ou em desenvolvimento (ZWANE *et al.*, 2022). Outro desafio prático é a seleção de hiperparâmetros, que são as configurações que controlam o comportamento do algoritmo, por exemplo, a taxa de aprendizagem ou o número de camadas. O ajuste manual destes parâmetros é complexo e depende frequentemente da experiência prévia de quem desenvolve o modelo (ABUALIGAH *et al.*, 2022). Por fim, a complexidade destes modelos gera dificuldades de interpretação como se elas fossem caixas pretas já que em redes profundas e não lineares não é possível saber qual foi o processo matemático pelo qual elas chegam a uma previsão (YOUSEF *et al.*, 2023).

#### 4.2.1.3 Algoritmos de busca e otimização

Dada a natureza variável das fontes e a complexidade dos sistemas de energia, encontrar a solução ótima — seja para o dimensionamento de um sistema híbrido, o *layout* de um parque eólico ou o rastreamento da potência máxima — raramente é uma tarefa trivial.

Muitos desses problemas são classificados como NP-difíceis, caracterizados por espaços de busca vastos, não lineares e multimodais. Em tais cenários, métodos de otimização tradicionais e determinísticos, muitas vezes falham por convergirem prematuramente para ótimos locais.

É neste contexto que os métodos de busca meta-heurísticos se destacam como ferramentas essenciais, que diferentemente dos algoritmos tradicionais de busca, os meta-heurísticos não garantem encontrar a solução ótima global, porém visam encontrar soluções muito boas em um tempo computacional razoável (TALBI, 2009).

Esses algoritmos podem ser agrupados em duas famílias:

- 1 Meta-heurísticas baseadas em solução única (*S-metaheuristics*): essas estratégias modificam e refinam iterativamente uma única solução candidata. Elas usam mecanismos determinísticos ou probabilísticos para aceitar movimentos que pioram a solução atual, permitindo-lhes descer de um ótimo local com fito de subir para um ponto ainda melhor do que já estava escapando assim de ótimos locais.
  - a. *Simulated Annealing* (SA) é um modelo dessa família e foi inspirado no processo metalúrgico de recozimento (*annealing*), o SA aceita probabilisticamente soluções piores com base em um parâmetro de

temperatura. No início, à alta temperatura, a busca é quase aleatória à medida que a temperatura esfria, a busca torna-se mais seletiva convergindo para uma solução de alta qualidade. Esse princípio é utilizado no dimensionamento de sistemas híbridos de energias renováveis para encontrar a configuração ótima que minimize a probabilidade de falha no fornecimento de energia e maximize a autonomia do sistema (ZAHRAEE *et al.*, 2016).

- 2 Meta-heurísticas baseadas em população (*P-metaheuristics*): mantêm e evoluem um conjunto de soluções candidatas simultaneamente. A interação entre as soluções na população permite uma exploração mais robusta do espaço de busca. O funcionamento desses algoritmos segue uma estrutura comum que se inicia com a geração de uma população inicial de soluções distribuídas aleatoriamente no espaço de busca. Em seguida, cada solução candidata é avaliada através da função objetivo, que quantifica a qualidade da configuração proposta. Com base nessas avaliações, o algoritmo aplica operadores específicos de busca para gerar novas soluções candidatas, explorando regiões promissoras do espaço de decisão. Este processo iterativo de avaliação, seleção e geração de novas soluções continua até que um critério de parada seja satisfeito, como um número máximo de iterações ou a estagnação da melhoria nas soluções encontradas (LI *et al.*, 2018).
  - a. *Genetic algorithms* (GA) são algoritmos evolutivos inspirados no processo de seleção natural de Darwin. No contexto de sistemas fotovoltaicos, os GAs são utilizados para rastreamento do ponto de máxima potência (*maximum power point tracking* - MPPT) em condições de sombreamento parcial (LI *et al.*, 2018).
  - b. *Particle swarm optimization* (PSO) é uma técnica de inteligência de enxame (*swarm intelligence* - SI) na qual cada partícula, membro do enxame, é uma solução candidata. As partículas ajustam suas trajetórias com base em duas memórias: sua melhor posição histórica individual (*pbest*) e a melhor posição histórica de todo o enxame (*gbest*). Essa dupla influência permite que o enxame navegue pelo cenário multimodal e na conjuntura de melhorar o *layout* de parques de conversores de energia das ondas convirja para o posicionamento de máxima produção de energia (TEIXEIRA-DUARTE *et al.*, 2022).

Com relação as limitações, nenhum dos modelos garante que verdadeiramente a solução encontrada é a melhor dentre todas as possibilidades. Além disso, também não há garantia de proximidade com o que seria a melhor solução. Apesar de Li et al. (2018) comparar vários modelos meta-heurísticos de população não é possível saber qual dos resultados está perto do ótimo global.

Em situações que envolvam simulações físicas detalhadas, por exemplo, simulação do comportamento do oceano, Teixeira-Duarte et al. (2022) adverte que a avaliação da função objetivo nesses casos torna inviável o uso direto de meta-heurísticas populacionais, como GA ou PSO, que geralmente requerem milhares de avaliações para convergir.

Outra limitação relevante é a convergência prematura, especialmente em problemas multimodais, como o rastreamento do ponto global de máxima potência em sistemas fotovoltaicos sob sombreamento parcial. Nesse cenário, a curva de potência apresenta múltiplos picos locais, e as meta-heurísticas podem estagnar em máximos subótimos se não forem devidamente configuradas com mecanismos de diversificação (ZAHRAEE *et al.*, 2016).

## 5 DISCUSSÃO DOS RESULTADOS

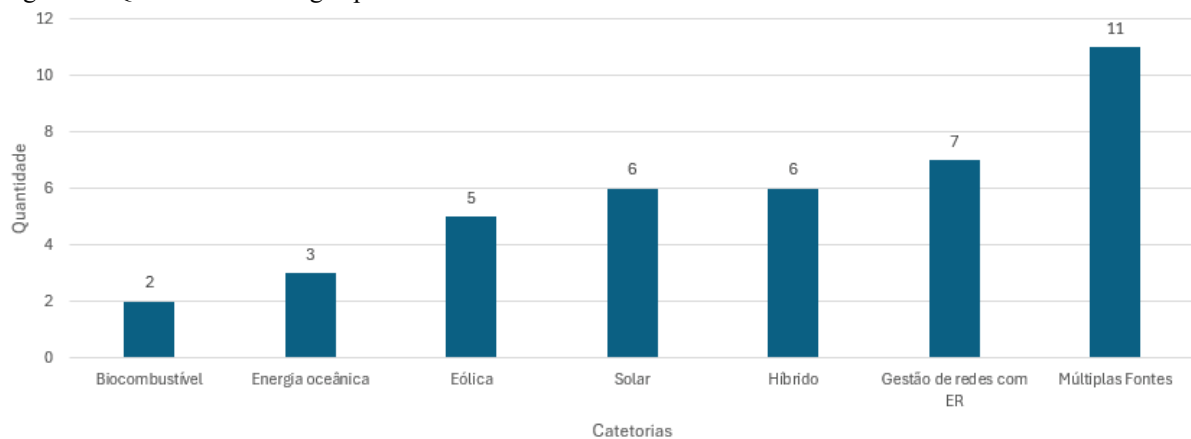
A partir da revisão da literatura realizada, analisou-se 40 publicações científicas para mapear o panorama atual da aplicação de inteligência artificial no setor de energias renováveis. Este capítulo se dedica a discutir os resultados obtidos, sintetizando os principais achados, identificando as lacunas de pesquisa, confrontando a eficácia das diferentes técnicas, abordando os desafios inerentes e, por fim, delineando as perspectivas futuras deste campo de pesquisa.

### 5.1 Síntese dos Principais Achados

#### 5.1.1 Macro Padrões da Literatura analisada

Das fontes renováveis a que mais se destaca é a energia solar. Na Figura 4, o gráfico categoriza os 40 estudos pela fonte de energia renovável predominantes na publicação e nota-se que a energia solar é o tema dominante em 6 artigos totalizando 15% da literatura analisada. Porém, pode-se ir além e perceber que essa fonte está presente nas outras pesquisas de forma menos abrangente, como na categoria “Híbrido” que engloba os sistemas de energia com mais de uma fonte renovável e na categoria “Múltiplas Fontes” na qual está presente, por exemplo, análises do uso de um tipo de IA em mais de uma fonte de energia.


Figura 4 - Quantidade de artigos por temática dominante



Fonte: Elaborado pelo autor

Dessa maneira, se essas duas categorias forem eliminadas e ao invés de contar os artigos por categorias e contar em quantos artigos cada fonte de energia é citada o gráfico resultante é ilustrado na Figura 5 deixando a energia solar em evidência como a mais citada empatada com a energia eólica. Esses resultados vão ao encontro com os achados da revisão bibliométrica de Zhang *et al.* (2022) que destaca as energias solar e eólica como as fontes renováveis nas quais a IA é mais aplicada.

Figura 5 - Em quantos artigos cada categoria é citada



Fonte: Elaborado pelo autor

Outra tendência encontrada é a concentração de estudos com a temática de gestão de redes com ER como pode ser visto na Figura 5 representando 17,5% dos estudos. Isso se justifica pelo fato que ao introduzir uma fonte renovável em uma malha elétrica na qual não foi projetada para esse tipo de energia criam-se instabilidades na rede que não podem ser negligenciadas e a IA revela-se como uma ferramenta de qualidade para lidar com esses problemas.

### 5.1.2 Solucionando problemas com IA

A literatura mostra que algumas abordagens de inteligência artificial já se firmaram como padrões para classes específicas de problemas no setor energético, e há uma tendência crescente de se combinar essas abordagens de forma estratégica. Essa especialização não acontece por acaso; ela é o resultado das particularidades físicas e dos desafios operacionais que cada fonte de energia renovável apresenta.

#### 5.1.2.1 Olhando para o Futuro

Particularmente no que se refere à predição de variáveis energéticas, que pode englobar desde a disponibilidade de recursos naturais, como a irradiação solar ou a velocidade do vento, até a previsão precisa da produção e da demanda, os algoritmos de inteligência

artificial, especialmente as redes neurais artificiais demonstram superioridade ao realizar essas previsões

Embora outras técnicas de ML, como máquinas de vetores de suporte, sejam eficazes em cenários de menor complexidade ou com conjuntos de dados escassos, elas apresentam limitações intrínsecas quando confrontadas com a alta dimensionalidade e a não-linearidade severa dos dados meteorológicos. Conforme Stetco *et al.* (2019) discutem enquanto o SVM exige uma engenharia manual de características e ajuste fino de parâmetros para performar bem em ambientes ruidosos, as redes neurais possuem a capacidade intrínseca de aprender padrões complexos diretamente dos dados brutos, dispensando intervenções manuais que podem introduzir erros e viés humano.

Essas características das ANNs as tornar a melhor escolha para regiões de clima instável ou tropicais, onde mudanças repentinas na nebulosidade e episódios de chuvas intensas geram séries temporais caóticas. Nesses cenários, o comportamento do recurso natural torna-se extremamente não linear. Para capturar essas dinâmicas, arquiteturas de aprendizado profundo, como as redes neurais recorrentes e, especificamente, as redes LSTM são mandatórias. Como evidenciado por Zhou (2022a) as redes LSTM superam as demais redes neurais nesse aspecto por sua capacidade de memorizar, permitindo o processamento de dados de séries temporais com retenção de padrões de longo prazo.

Além disso, a literatura aponta que, à medida que a quantidade de dados aumenta — comportamento característico da era do *Big Data* e da *IoT* em parques de energia renovável —, a performance dos algoritmos convencionais tende a estagnar, enquanto o *deep learning* continua a escalar em precisão. Stetco *et al.* (2019) argumentam, destacando que redes neurais profundas são capazes de aprender funções não lineares complexas que escapam à capacidade de modelos tradicionais, justificando sua adoção como o estado da arte para a garantia de confiabilidade e eficiência no suprimento energético moderno.

No contexto da energia solar fotovoltaica, a predominância das técnicas de aprendizado profundo não se resume apenas na previsão, mas está presente também nas atividades de manutenção, especificamente as redes neurais convolucionais, que são capazes de fazer uma análise visual em larga escala. Conforme demonstrado por Thakfan et al. (2024), a inteligência artificial superou métodos manuais de inspeções visual e medições elétricas ao possibilitar a detecção automática de microfissuras e pontos quentes mediante imagens térmicas com precisão superior a 90%. Essa capacidade de processamento de dados visuais representa um avanço significativo na inspeção e manutenção de sistemas fotovoltaicos, reduzindo custos operacionais e aumentando a confiabilidade dos parques solares.

No setor da energia eólica, os estudos estão concentrados no controle dinâmico da geração e na manutenção condicional. A literatura demonstra uma mudança evidente dos controladores convencionais PID (Proporcional-Integral-Derivativo) para controladores inteligentes que conseguem gerenciar a não linearidade do vento. Elkodama et al. (2023) indicam que, ao contrário das abordagens tradicionais, as técnicas de redes neurais, se destacam no ajuste fino dos sistemas de *pitch* (passo) e *yaw* (guinada) do aerogerador, resultando em menos fadiga mecânica e uma maior durabilidade das turbinas.

#### 5.1.2.2 *Busque Sempre o Melhor*

Para além da capacidade preditiva das técnicas de aprendizado de máquina, os algoritmos de busca e otimização consolidaram-se como alicerces indispensáveis na engenharia de sistemas renováveis

No âmbito da geração fotovoltaica, a literatura evidencia a superioridade dos algoritmos bio-inspirados para problemas de otimização. Conforme argumentado por Li et al., (2018) métodos convencionais de rastreamento como perturba e observa tornam-se ineficazes sob condições de sombreamento parcial, pois tendem a estagnar em picos de potência locais. Em contrapartida, meta-heurísticas exemplificadas pela otimização por enxame de partículas e a colônia de formigas demonstram robustez ao explorar todo o espaço de busca, garantindo a extração máxima de energia mesmo em cenários de irradiância não uniforme.

Quando se trata de setores em desenvolvimento, como a energia das ondas, a complexidade aumenta consideravelmente. Ao contrário da energia solar, onde o design segue critérios geométricos mais simples, os parques de ondas enfrentam interações hidrodinâmicas complexas. De acordo com Teixeira-Duarte et al. (2022), esses efeitos destrutivos não podem ser capturados por meio de modelos analíticos simplificados. Nesse contexto, tanto os algoritmos evolutivos quanto os genéticos se destacam como a melhor solução computacional capaz de otimizar o posicionamento estratégico de conversores para maximizar a produção de energia, reduzindo ao mesmo tempo as perdas aerodinâmicas e hidrodinâmicas.

Na fronteira dos vetores energéticos químicos, especificamente na produção de hidrogênio via biomassa, a otimização transcende o *layout* físico e adentra no controle de reações. Obiora et al. (2024), destacam que a IA é crítica para modelar a complexidade termoquímica de processos como gaseificação e pirólise. A aplicação de algoritmos de ML permite ajustar, com precisão variáveis como temperatura e carga de catalisadores para maximizar o rendimento de hidrogênio, superando as limitações da experimentação empírica tradicional.

Por fim, no planejamento de sistemas híbridos e microrredes, é essencial realizar uma otimização multiobjetivo que concilie a confiabilidade técnica com a viabilidade econômica. A pesquisa de Thirunavukkarasu et al. (2023), indica que a inclusão de baterias em sistemas híbridos demanda algoritmos capazes de navegar por *trade-offs* conflitantes — como minimizar o preço médio pelo qual a eletricidade deve ser vendida durante toda a vida útil de um projeto para que ele se pague completamente e maximizem a confiabilidade do sistema —.

## 5.2 Lacunas identificadas

Não obstante o crescimento exponencial da utilização da IA na indústria de energia renovável, a revisão expõe desproporções e lacunas significativas que obstruem a ampla adoção dessa tecnologia. A literatura indica que o desenvolvimento não ocorre de maneira uniforme, havendo uma disparidade entre a sofisticação dos algoritmos e a infraestrutura de dados disponível para treiná-los.

A lacuna mais significativa encontra-se na carência e na ausência de padronização dos dados. De acordo com Rinaldi *et al.* (2021) a eficácia dos modelos de aprendizado profundo é diretamente relacionada à quantidade e diversidade dos dados utilizados para treinamento. Entretanto, nota-se uma ausência de bancos de dados públicos e rotulados que incluam falhas reais em sistemas fotovoltaicos, como imagens térmicas de *hotspots* ou curvas I-V deterioradas. Isso obriga os pesquisadores a depender de dados sintéticos ou simulações, o que restringe a capacidade de generalização dos modelos para cenários reais e ruidosos de operação.

Uma segunda lacuna significativa diz respeito à compreensão fragmentada da integração sistêmica. Embora a literatura apresente diversas otimizações de componentes isolados, como apenas a turbina ou unicamente o painel solar, Hsu *et al.* (2023) destacam a falta de abordagens holísticas que considerem a energia de forma integrada. Há uma carência de pesquisas abrangentes que integrem, de forma simultânea e sob uma única governança algorítmica, a geração de energia renovável, o armazenamento térmico ou elétrico e a resposta à demanda. A maior parte dos modelos contemporâneos funciona em silos, desconsiderando as sinergias termodinâmicas e econômicas inerentes a sistemas de múltiplas energias.

Por último, observa-se uma carência na análise econômica referente à aplicação da inteligência artificial. A literatura especializada concentra-se amplamente em métricas de precisão, como acurácia e RMSE (*root mean square error*), porém aborda de forma esporádica o retorno sobre o investimento (ROI) relacionado à troca de métodos estatísticos simples por redes neurais mais sofisticadas. Na análise de Franki et al. (2023) indicam que, para diversas organizações, os gastos com computação e infraestrutura necessários para a adoção de soluções

avançadas de IA ainda não foram adequadamente compensados pelos ganhos operacionais concretos, estabelecendo assim um obstáculo para a entrada no mercado.

### 5.3 Comparando Técnicas Computacionais

A comparação das metodologias indica que não há uma supremacia total de um único algoritmo, mas sim uma adequação particular que depende da essência dos dados sejam visuais, temporais ou físicos e da dinâmica do problema em questão: previsão, controle ou otimização.

Na análise de dados visuais e termográficos, a comparação entre abordagens tradicionais e contemporâneas de ML demonstra benefícios específicos de acordo com o contexto. Thakfan et al. (2024) evidenciam que técnicas fundamentadas em *deep learning*, em particular as CNNs, demonstram predominância em contextos de ampla escala e complexidade. A proposição fundamental encontra-se na habilidade de extração automática de características: como dito em 5.1.2.1 não só SVM, mas a maioria dos métodos clássicos de ML depende de intervenção humana gerando viés e falhas em problemas com dados ruidosos.

Entretanto, a pesquisa reconhece que as máquinas de vetores de suporte apresentam elevada eficácia em várias aplicações de identificação de falhas, frequentemente obtendo precisões superiores a 97%, especialmente ao lidar com conjuntos de dados reduzidos ou quando a interpretabilidade é prioritária. A decisão entre metodologias contemporâneas e tradicionais deve levar em conta aspectos como a disponibilidade de dados, os recursos computacionais, a necessidade de interpretabilidade e as particularidades do tipo de falha a ser identificada — salientando que, apesar de as redes neurais se destacarem na capacidade de aprendizado complexo, técnicas como SVM permanecem significativas em contextos específicos de inspeção fotovoltaica.

No contexto dos dados físicos, especialmente no domínio do controle dinâmico de turbinas eólicas. Os controladores PID, que são considerados padrões na indústria, apresentam falhas em cenários de vento turbulento em virtude de sua linearidade e da dependência de modelos matemáticos constantes, que não conseguem abranger a complexa aerodinâmica das pás em condições estocásticas. Por outro lado, metodologias baseadas em lógica fuzzy, redes neurais e aprendizado por reforço revelam uma notável superioridade ao modelar essas não linearidades e interações aerodinâmicas de maneira adaptativa. Isso possibilita um controle de passo e de guinada que não só maximiza a potência, mas também diminui de forma significativa a fadiga estrutural, algo que não pode ser alcançado por métodos tradicionais sem ajustes dispendiosos e frequentes. Essa vantagem é fortemente sustentada por Dong et al. (2022), que

demonstram que estratégias de controle adaptativo fundamentadas em RL são aptas a equilibrar, em tempo real, a eficiência energética e a integridade do ativo por meio de funções de recompensa com múltiplos objetivos.

Ao confrontar algoritmos de meta-heurística entre si, os resultados variam conforme a complexidade do problema. No contexto do rastreamento de ponto de potência máxima solar, Li et al. (2018) argumentam que, embora os algoritmos genéticos sejam robustos na exploração global, eles frequentemente apresentam um custo computacional alta para aplicações em tempo real devido à complexidade dos operadores de cruzamento e mutação. Em contraste, a otimização por enxame de partículas destaca-se pela simplicidade de implementação e convergência mais rápida em cenários dinâmicos de irradiância, embora sofra com oscilações em torno do ponto ótimo em estágios finais de convergência.

Já na otimização espacial de parques de energia das ondas, a escala do problema inverte essa lógica de desempenho. Faraggiana et al. (2018) realizaram uma análise comparativa crítica e observaram que, enquanto o PSO demonstrou desempenho superior para arranjos pequenos de até dois conversores, sua eficácia degrada significativamente em parques maiores, falhando em encontrar o ótimo global à medida que a dimensionalidade do problema aumenta. Para arranjos de larga escala, os GA mantêm-se como a técnica dominante utilizada em 17% dos estudos revisados por Teixeira-Duarte et al. (2022), oferecendo o melhor equilíbrio entre exploração do espaço de busca e precisão final, apesar do alto custo computacional.

Além disso, Teixeira-Duarte et al. (2022) apresentam a comparação com abordagens mais contemporâneas, como a estratégia de evolução com adaptação da matriz de covariância (CMA-ES). A análise indicou que, apesar de o CMA-ES exibir taxas de convergência superiores em relação ao GA e ao PSO em determinados cenários hidrodinâmicos, ele demonstra uma precisão inferior na estimativa final da produção de energia. Isso sugere um *trade-off* significativo entre a velocidade de processamento e a confiabilidade da solução obtida. Assim, a seleção da meta-heurística não é uma tarefa simples e deve considerar a dimensão do sistema.

#### **5.4 Desafios e Limitações**

A mudança para sistemas energéticos administrados por inteligência artificial apresenta desafios e contradições que vão além da tecnologia, envolvendo aspectos de segurança, confiabilidade do sistema e social.

#### 5.4.1 Paradoxo do Uso de IA em Energias Renováveis

Por mais que seja evidente que o uso de IA em energias renováveis seja capaz de potencializar a produção de energia e aumentar a vida útil dos equipamentos envolvidos existe uma contradição que é o custo energético associado ao desenvolvimento e implementação das técnicas. Para exemplificar melhor, a *OpenAI* precisou de aproximadamente 100 dias e 60 GWh para treinar o ChatGPT-4 (INSTITUTE, 2024) e isso é equivalente ao gasto residencial anual de 94.837 cearenses usando como parâmetro 632,67 kWh/hab no ano base de 2024 segundo dados Empresa de Pesquisa Energética (2025). Do ponto de vista demográfico, essa demanda energética corresponde ao suprimento, durante um ano, de todas as residências de um município de tamanho semelhante a Aquiraz, que possui uma população de 80.645 habitantes (IBGE, 2022).

#### 5.4.2 Limitações Técnicas

Um desafio essencial reside na veracidade e na qualidade dos dados obtidos em ambientes operacionais reais. Stetco et al. (2019) sustentam que a indústria enfrenta o desafio dos "4 Vs" do *Big Data*, sendo eles:

1. Volume: a quantidade de dados gerados por equipamento e como armazená-lo;
2. Velocidade: frequência com a qual os dados são produzidos e transmitidos;
3. Variedade: os tipos de dados que são usados no monitoramento, por exemplo, imagens do painel solar e planilha com os dados de geração por minuto;
4. Veracidade: não pode existir lacunas nos dados e nem dados fora da realidade.

Dentre esses, a veracidade é o aspecto mais vulnerável, pois as informações reais provenientes de sensores podem apresentar valores impossíveis, ruídos ou lacunas temporais que podem comprometer o treinamento dos modelos. Rinaldi et al. (2021) confirmam essa limitação, advertindo que defeitos nos sistemas de comunicação ou nós sensores em si ocasionam conjuntos de dados corrompidos ou incompletos, compelindo os operadores a descartar informações valiosas ou a utilizar técnicas de imputação que agregam incertezas adicionais.

Além disso, a integridade física da coleta de dados é comprometida pelo ambiente industrial em si. Hsu et al. (2023) ressalta que a interferência eletromagnética, assim como os efeitos de múltiplos caminhos percorridos pelos dados transmitidos, em fábricas e usinas, impacta a qualidade de serviço das redes de sensores sem fio, comprometendo a confiabilidade dos dados brutos que sustentam as inteligências artificiais.

### 5.4.3 Inteligência Natural

Além das restrições técnicas, observa-se a presença de um déficit significativo de capital humano capacitado. A eficiente integração entre fontes de energia renováveis e inteligência artificial demanda um perfil profissional híbrido que é raro no mercado. Mitchell et al. (2022) reconhecem que a escassez de talentos em IA e, de maneira significativa, a carência de conhecimento cruzado e a complexidade de treinar a força de trabalho existente configuram-se como um gargalo logístico tão severo quanto o desenvolvimento tecnológico em si.

### 5.4.4 Caixa Preta

Conforme evidenciado por Sellak et al. (2017), os sistemas tradicionais de tomada de decisão baseados em ML no planejamento energético costumam não oferecer a devida transparência aos interessados envolvidos. Os autores sustentam que as abordagens convencionais carecem de inteligência adequada para: (i) reconhecer e examinar as interações entre as entradas iniciais, os perfis dos participantes e os resultados alcançados; (ii) oferecer interpretações lógicas e premissas racionais a partir das saídas; e (iii) extrair conhecimento suplementar do processo de tomada de decisão. A falta de transparência dos sistemas prejudica não apenas a confiança dos operadores e reguladores, mas também a habilidade de realizar auditorias e o aprimoramento contínuo dos modelos.

Os autores ainda enfatizam que, em ambientes de planejamento energético que incluem diversos *stakeholders* com metas divergentes, a clareza nas orientações se torna um componente fundamental para a aceitação social e a viabilidade técnica das escolhas realizadas. Quando os sistemas falham em justificar determinadas recomendações, em particular em cenários caracterizados por elevada incerteza e complexidade, os decisores mantêm uma postura cética em relação às soluções sugeridas. A insuficiência de justificativas racionais revela-se especialmente preocupante em infraestruturas essenciais, como os sistemas elétricos, em que decisões equivocadas podem acarretar consequências sociais, econômicas e ambientais relevantes. Nesse contexto, os autores sugerem uma abordagem fundamentada em conhecimentos especializados, que incorpora elementos explicativos em todas as etapas do processo decisório — antes, durante e após as recomendações estratégicas — assegurando, assim, uma maior transparência e credibilidade nas soluções de planejamento energético de nova geração.

## 5.5 Perspectivas Futuras

A evolução da IA no campo das energias renováveis indica uma mudança paradigmática: o abandono de modelos estáticos e reativos em prol de sistemas dinâmicos, autônomos e integrados. A literatura examinada neste estudo indica que o futuro dessa integração tecnológica se baseará em quatro pilares essenciais: a evolução dos algoritmos de controle, a virtualização de ativos físicos, a ampliação para novas fronteiras de geração e a sustentabilidade computacional.

### 5.5.1 Consolidação de Tecnologias

Em primeiro lugar, nota-se um desgaste das abordagens convencionais de aprendizado de máquina diante da crescente complexidade das redes elétricas contemporâneas. Conforme abordado por Gu e Li (2022) e Li et al. (2023) observa-se uma tendência de migração para o aprendizado por reforço profundo *deep reinforcement learning* (DRL) e para redes neurais profundas, incluindo LSTMs e CNNs. Ao contrário dos controladores tradicionais (PID) ou de algoritmos simples de ML, o DRL e DP apresentam a habilidade de gerenciar um grande volume de dados complexos e de natureza estocásticos em tempo real. Isso possibilitará que microredes funcionem não apenas de acordo com diretrizes previamente definidas, mas que aprendam métodos de estabilização de tensão e frequência em resposta a distúrbios inéditos, assegurando a resiliência essencial para contextos de elevada inserção de fontes renováveis intermitentes.

Em um segundo aspecto, a administração de ativos físicos passará de uma manutenção preditiva isolada para uma adoção sistêmica de gêmeos digitais (*digital twin*). A integração proposta por Ranawaka et al. (2022) indica que a inteligência artificial não se restringirá a ser apenas uma ferramenta de análise de dados, mas se tornará parte da infraestrutura. Neste contexto, robôs autônomos e sensores de internet das coisas (*IoT*) fornecerão dados a modelos virtuais em tempo real, possibilitando simulações de situações de falha e decisões de manutenção sem a necessidade de intervenção humana direta diminuindo os riscos de acidentes, principalmente em ambientes adversos, como parques eólicos *offshore*.

### 5.5.2 Novos Horizontes

Adicionalmente, a execução estratégica da inteligência artificial deve se expandir para além das fontes renováveis já estabelecidas, como a solar e a eólica, a fim de fomentar o progresso de vetores energéticos emergentes.

### 5.5.2.1 Energia dos Oceanos

Na pesquisa de Zhou (2022b) evidência-se de maneira clara que a energia oceânica, apesar de seu considerável potencial, estimado em até 93.000 TWh anuais apenas na forma de ondas, continua a ser subutilizada devido a desafios técnicos associados à sua intermitência, variações espaciais e temporais, além da instabilidade no fornecimento de energia.

Nesse contexto, a mesma pesquisa indica que a implementação diversificada da IA— englobando redes neurais profundas para a previsão de recursos oceânicos, bem como algoritmos genéticos para a otimização do arranjo dos conversores de onda — pode diminuir consideravelmente o custo nivelado da energia (LCOE) em até 35%, ao passo que eleva a eficiência energética por meio da sinergia entre distintas fontes de energia oceânica como térmica, das ondas, das marés e das correntes.

### 5.5.2.2 Tecnologias do Hidrogênio

Na produção de hidrogênio a partir de biomassa, Obiora et al. (2024) destacam que processos como a gaseificação envolvem variáveis termodinâmicas complexas e interdependentes — temperatura, pressão e razão de equivalência —, cuja otimização por métodos convencionais apresenta limitações significativas devido à natureza não linear das reações envolvidas. Nesse contexto, técnicas avançadas de inteligência artificial e machine learning emergem como ferramentas indispensáveis para identificar condições operacionais ideais, maximizando a produção de H<sub>2</sub> e minimizando a formação de subprodutos indesejados como alcatrão. Como apontam os autores, esses métodos computacionais superam as abordagens tradicionais de engenharia de processos ao permitir prever e avaliar a produção de hidrogênio via gaseificação de biomassa em água supercrítica com maior precisão e eficiência, reduzindo custos experimentais e acelerando o desenvolvimento de sistemas de produção de hidrogênio mais sustentáveis e economicamente viáveis.

A aplicação da IA também se estende às tecnologias de células a combustível e sistemas de armazenamento energético. Conforme análise de Zhou (2022a), técnicas de aprendizado de máquina, como redes neurais artificiais e máquinas de vetores de suporte, permitem prever com precisão a degradação e a vida útil das células a combustível de membrana de troca de prótons (PEMFCs), além de acelerar a descoberta de eletrocatalisadores inovadores — um avanço que reduz drasticamente a dependência de experimentos físicos demorados e custosos.

No âmbito de redes de energia, a integração do hidrogênio em microredes híbridas exige estratégias de dimensionamento capazes de conciliar a intermitência das renováveis com a resposta gradual dos sistemas de armazenamento químico. Thirunavukkarasu et al. (2023)

comprovam que algoritmos bio-inspirados, como a otimização por enxame de partículas, superam métodos determinísticos clássicos ao otimizar simultaneamente a capacidade de eletrolisadores, tanques de armazenamento de hidrogênio e células a combustível. Essa abordagem não só garante a estabilidade operacional da rede, mas também reforça a viabilidade econômica do hidrogênio como vetor para armazenamento de energia em longo prazo.

## 6 CONCLUSÃO

A inteligência artificial consolida-se como um vetor transformador indispensável para a transição energética global, atuando como elo fundamental entre a complexidade dos sistemas renováveis e a necessidade de gestão eficiente em escala. Esta revisão bibliográfica revelou não apenas o estado atual da integração entre essas tecnologias, mas apontou caminhos promissores para pesquisas futuras que podem acelerar a descarbonização do setor energético tendo assim alcançado os objetivos delineados.

As tendências emergentes de pesquisa apontam para uma evolução paradigmática no campo. Observa-se um movimento crescente em direção a sistemas autônomos de gerenciamento de rede elétricas, impulsionados pelo amadurecimento do *deep reinforcement learning*, que permitirá adaptação mais eficiente a distúrbios não previstos. Paralelamente, a consolidação dos gêmeos digitais está transformando a manutenção preditiva em uma gestão holística de ativos, integrando robótica, *IoT* e simulações em tempo real para operações mais seguras e eficientes, especialmente em ambientes extremos como parques eólicos *offshore*.

Entretanto, a combinação de inteligência artificial e fontes de energia renováveis não se revela livre de desafios significativos. O paradoxo energético associado ao treinamento de modelos sofisticados – evidenciado pelo elevado consumo de recursos computacionais – opõe-se aos princípios de sustentabilidade que fundamentam a transição energética. Demais obstáculos relevantes consistem na escassez e na ausência de dados de alta qualidade padronizados; na falta de profissionais com formação híbrida em inteligência artificial e energia; bem como na questão da "caixa preta", que prejudica a transparência e a confiança nos sistemas de suporte à decisão.

Considerando esse contexto, sugere-se que investigações futuras deem prioridade às seguintes áreas:

1. Sustentabilidade computacional: desenvolvimento de metodologias e arquiteturas de IA energeticamente eficientes, alinhando o custo computacional aos princípios de sustentabilidade.
2. Abordagens sistêmicas e holísticas: criação de modelos de integração que considerem, sob uma única governança algorítmica, a geração renovável, o armazenamento (térmico, elétrico e químico) e a resposta à demanda, explorando sinergias termodinâmicas e econômicas.

3. exploração de fontes subutilizadas: aplicação estratégica de IA em fontes emergentes e de alto potencial, como a energia oceânica e as tecnologias do hidrogênio verde.

Por fim, a tendência mais transformadora aponta para uma mudança de paradigma na relação entre energia e sociedade, com a IA possibilitando soluções centradas no consumidor final. O desenvolvimento de algoritmos capazes de personalizar estratégias de eficiência energética, adaptar perfis de consumo às condições da rede e empoderar consumidores com informações inteligíveis representa não apenas uma oportunidade técnica, mas um imperativo para a aceitação social da transição energética.

A plena realização deste potencial exigirá uma colaboração interdisciplinar, envolvendo não apenas engenheiros e cientistas da computação, mas também especialistas em políticas públicas, economistas e representantes da sociedade civil. Somente através desta convergência de conhecimentos será possível desenvolver soluções que equilibrem avanço tecnológico, eficiência energética, viabilidade econômica e justiça social, pavimentando o caminho para um sistema energético verdadeiramente sustentável para as próximas gerações.

## REFERÊNCIAS

ABUALIGAH, Laith et al. Wind, Solar, and Photovoltaic Renewable Energy Systems with and without Energy Storage Optimization: a survey of advanced machine learning and deep learning techniques. *Energies*, [S.L.], v. 15, n. 2, p. 578, 14 jan. 2022. MDPI AG.

<http://dx.doi.org/10.3390/en15020578>. Disponível em: <https://doi.org/10.3390/en15020578>. Acesso em: 6 fev. 2025.

AHMAD, Iftikhar et al. Machine Learning Applications in Biofuels' Life Cycle: soil, feedstock, production, consumption, and emissions. *Energies*, [S.L.], v. 14, n. 16, p. 5072, 18 ago. 2021. MDPI AG. <http://dx.doi.org/10.3390/en14165072>. Disponível em:

<https://doi.org/10.3390/en14165072>. Acesso em: 1 fev. 2025.

ARÉVALO, Paul; JURADO, Francisco. Impact of Artificial Intelligence on the Planning and Operation of Distributed Energy Systems in Smart Grids. *Energies*, [S.L.], v. 17, n. 17, p. 4501, 8 set. 2024. MDPI AG. <http://dx.doi.org/10.3390/en17174501>. Disponível em:

<https://doi.org/10.3390/en17174501>. Acesso em: 8 jan. 2025.

ARISTÓTELES. *Política*. São Paulo: 1, 2019. 352 p. (Vozes de Bolso).

CHATTERJEE, Joyjit et al. Scientometric review of artificial intelligence for operations & maintenance of wind turbines: the past, present and future. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 144, p. 111051, jul. 2021. Elsevier BV.

<http://dx.doi.org/10.1016/j.rser.2021.111051>. Disponível em:

<https://doi.org/10.1016/j.rser.2021.111051>. Acesso em: 6 out. 2025.

DAS, Utpal Kumar et al. Forecasting of photovoltaic power generation and model optimization: a review. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 81, p. 912-928, jan. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2017.08.017>. Disponível em:

<https://doi.org/10.1016/j.rser.2017.08.017>. Acesso em: 10 jan. 2025.

DING, Min et al. A gated recurrent unit neural networks based wind speed error correction model for short-term wind power forecasting. *Neurocomputing*, [S.L.], v. 365, p. 54-61, nov.

2019. Elsevier BV. <http://dx.doi.org/10.1016/j.neucom.2019.07.058>. Disponível em: <https://doi.org/10.1016/j.neucom.2019.07.058>. Acesso em: 23 fev. 2025.

ELKODAMA, Amira et al. Control Methods for Horizontal Axis Wind Turbines (HAWT): state-of-the-art review. *Energies*, [S.L.], v. 16, n. 17, p. 6394, 4 set. 2023. MDPI AG. <http://dx.doi.org/10.3390/en16176394>. Disponível em: <https://doi.org/10.3390/en16176394>. Acesso em: 27 jan. 2025.

EMPRESA DE PESQUISA ENERGÉTICA. **Anuário Estatístico de Energia Elétrica de 2025**. [S.I]: Empresa de Pesquisa Energética, 2025. Disponível em: [https://dashboard.epe.gov.br/apps/anuario-livro/#313\\_Consumo\\_m%C3%A9dio\\_anual\\_per\\_capita\\_por\\_UF\\_\(kWhhab\)](https://dashboard.epe.gov.br/apps/anuario-livro/#313_Consumo_m%C3%A9dio_anual_per_capita_por_UF_(kWhhab)). Acesso em: 15 out. 2025.

ESLAMI, Ahmadreza et al. Review of AI applications in harmonic analysis in power systems. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 154, p. 111897, fev. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2021.111897>. Disponível em: <https://doi.org/10.1016/j.rser.2021.111897>. Acesso em: 6 fev. 2025.

FARAGGIANA, E. et al. Design of an optimization scheme for the WaveSub array. In: INTERNATIONAL CONFERENCE ON RENEWABLE ENERGIES OFFSHORE (RENEW), 3., 2018, Lisboa. *Advances in renewable energies offshore: proceedings [...]*. Londres: CRC Press, 2018. p. 1-6. Disponível em: [https://www.researchgate.net/profile/Emilio-Faraggiana/publication/328065462\\_Design\\_of\\_an\\_optimization\\_scheme\\_for\\_the\\_WaveSub\\_array/links/5c4aff3c92851c22a38ee726/Design-of-an-optimization-scheme-for-the-WaveSub-array.pdf](https://www.researchgate.net/profile/Emilio-Faraggiana/publication/328065462_Design_of_an_optimization_scheme_for_the_WaveSub_array/links/5c4aff3c92851c22a38ee726/Design-of-an-optimization-scheme-for-the-WaveSub-array.pdf). Acesso em: 21 fev. 2025.

FIROOZI, Ali Akbar et al. Advancing Wind Energy Efficiency: a systematic review of aerodynamic optimization in wind turbine blade design. *Energies*, [S.L.], v. 17, n. 12, p. 2919, 13 jun. 2024. MDPI AG. <http://dx.doi.org/10.3390/en17122919>. Disponível em: <https://doi.org/10.3390/en17122919>. Acesso em: 23 jan. 2025.

FRANKI, Vladimir et al. A Comprehensive Review of Artificial Intelligence (AI) Companies in the Power Sector. *Energies*, [S.L.], v. 16, n. 3, p. 1077, 18 jan. 2023. MDPI AG.

<http://dx.doi.org/10.3390/en16031077>. Disponível em: <https://doi.org/10.3390/en16031077>.

Acesso em: 5 out. 2025.

GIL, Antônio Carlos. *Métodos e Técnicas de Pesquisa Social*. 6. ed. São Paulo: Atlas S.A., 2008.

GOODFELLOW, Ian. Introduction. In: GOODFELLOW, Ian et al. *Deep Learning*. [S.I.]: Mit Press, 2016. Cap. 1. p. 1-11. <Http://www.deeplearningbook.org>. Disponível em:

<https://www.deeplearningbook.org/>. Acesso em: 3 fev. 2025.

GU, Chengcheng; LI, Hua. Review on Deep Learning Research and Applications in Wind and Wave Energy. *Energies*, [S.L.], v. 15, n. 4, p. 1510, 17 fev. 2022. MDPI AG.

<http://dx.doi.org/10.3390/en15041510>. Disponível em: <https://doi.org/10.3390/en15041510>.

Acesso em: 7 fev. 2025.

HSU, Chao-Chung et al. A Survey on Recent Applications of Artificial Intelligence and Optimization for Smart Grids in Smart Manufacturing. *Energies*, [S.L.], v. 16, n. 22, p. 7660, 20 nov. 2023. MDPI AG. <http://dx.doi.org/10.3390/en16227660>. Disponível em:

<https://doi.org/10.3390/en16227660>. Acesso em: 14 fev. 2025.

INSTITUTE, Electric Power Research. *Powering Intelligence: Analyzing Artificial Intelligence and Data Center Energy Consumption*. [S.I.]: Epr, 2024. 35 p. Disponível em:

<https://www.epri.com/research/products/3002028905>. Acesso em: 26 abr. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). *Aquiraz: panorama*. Rio de Janeiro, [2022]. Disponível em: <https://cidades.ibge.gov.br/brasil/ce/aquiraz/panorama>.

Acesso em: 23 out. 2025.

INTERNATIONAL ENERGY AGENCY. *Renewables 2023: analysis and forecast to 2028*.

Paris: Iea, 2024. Disponível em: <https://www.iea.org/reports/renewables-2023>. Acesso em: 18 out. 2025.

JHA, Sunil Kr. et al. Renewable energy: present research and future scope of artificial intelligence. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 77, p. 297-317, set. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2017.04.018>. Disponível em: <https://doi.org/10.1016/j.rser.2017.04.018>. Acesso em: 17 fev. 2025.

KHOKHAR, Suhail et al. A comprehensive overview on signal processing and artificial intelligence techniques applications in classification of power quality disturbances. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 51, p. 1650-1663, nov. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2015.07.068>. Disponível em: <https://doi.org/10.1016/j.rser.2015.07.068>. Acesso em: 1 fev. 2025.

LI, Xiangda et al. A method for optimizing installation capacity and operation strategy of a hybrid renewable energy system with offshore wind energy for a green container terminal. *Ocean Engineering*, [S.L.], v. 186, p. 106125, ago. 2019. Elsevier BV. <http://dx.doi.org/10.1016/j.oceaneng.2019.106125>. Disponível em: <https://doi.org/10.1016/j.oceaneng.2019.106125>. Acesso em: 9 fev. 2025.

LI, Guiqiang et al. Application of bio-inspired algorithms in maximum power point tracking for PV systems under partial shading conditions – A review. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 81, p. 840-873, jan. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2017.08.034>. Disponível em: <https://doi.org/10.1016/j.rser.2017.08.034>. Acesso em: 4 fev. 2025.

LI, Qingyan *et al.* Review of Deep Reinforcement Learning and Its Application in Modern Renewable Power System Control. **Energies**, [S.L.], v. 16, n. 10, p. 4143, 17 maio 2023. MDPI AG. <http://dx.doi.org/10.3390/en16104143>. Disponível em: <https://doi.org/10.3390/en16104143>. Acesso em: 9 fev. 2025.

LIU, Zhengxuan et al. Artificial intelligence powered large-scale renewable integrations in multi-energy systems for carbon neutrality transition: challenges and future perspectives. *Energy And Ai*, [S.L.], v. 10, p. 100195, nov. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.egyai.2022.100195>. Disponível em: <https://doi.org/10.1016/j.egyai.2022.100195>. Acesso em: 21 fev. 2025.

LYTRAS, Miltiadis D.; CHUI, Kwok Tai. The Recent Development of Artificial Intelligence for Smart and Sustainable Energy Systems and Applications. *Energies*, [S.L.], v. 12, n. 16, p. 3108, 13 ago. 2019. MDPI AG. <http://dx.doi.org/10.3390/en12163108>. Disponível em: <https://doi.org/10.3390/en12163108>. Acesso em: 9 jan. 2025.

MAGHAMI, Mohammad Reza; MUTAMBARA, Arthur Guseni Oliver. Challenges associated with Hybrid Energy Systems: an artificial intelligence solution. *Energy Reports*, [S.L.], v. 9, p. 924-940, dez. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.egy.2022.11.195>. Disponível em: <https://doi.org/10.1016/j.egy.2022.11.195>. Acesso em: 24 jan. 2025.

MITCHELL, Daniel; BLANCHE, Jamie; HARPER, Sam; LIM, Theodore; GUPTA, Ranjeetkumar; ZAKI, Osama; TANG, Wenshuo; ROBU, Valentin; WATSON, Simon; FLYNN, David. A review: challenges and opportunities for artificial intelligence and robotics in the offshore wind sector. *Energy And Ai*, [S.L.], v. 8, p. 100146, maio 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.egyai.2022.100146>. Disponível em: <https://doi.org/10.1016/j.egyai.2022.100146>. Acesso em: 16 jan. 2025.

MORKUNAS, Mangirdas; WANG, Yufei; WEI, Jinzhao. Role of AI and IoT in Advancing Renewable Energy Use in Agriculture. *Energies*, [S.L.], v. 17, n. 23, p. 5984, 28 nov. 2024. MDPI AG. <http://dx.doi.org/10.3390/en17235984>. Disponível em: <https://doi.org/10.3390/en17235984>. Acesso em: 9 fev. 2025.

NAM, Kijeon et al. A deep learning-based forecasting model for renewable energy scenarios to guide sustainable energy policy: a case study of korea. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 122, p. 109725, abr. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2020.109725>. Disponível em: <https://doi.org/10.1016/j.rser.2020.109725>. Acesso em: 26 fev. 2025.

OBIORA, Nebechi Kate et al. Production of hydrogen energy from biomass: prospects and challenges. *Green Technologies And Sustainability*, [S.L.], v. 2, n. 3, p. 100100, set. 2024. Elsevier BV. <http://dx.doi.org/10.1016/j.grets.2024.100100>. Disponível em: <https://doi.org/10.1016/j.grets.2024.100100>. Acesso em: 27 fev. 2025.

PAGE, Matthew J et al. The PRISMA 2020 statement: an updated guideline for reporting systematic reviews. *Bmj*, [S.L.], p. 71, 29 mar. 2021. *BMJ*. <http://dx.doi.org/10.1136/bmj.n71>. Disponível em: <https://doi.org/10.1136/bmj.n71>. Acesso em: 5 out. 2025.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico. 2. ed. Rio Grande do Sul: Editora Feevale, 2013. Disponível em: <https://www.feevale.br/Comum/midias/0163c988-1f5d-496f-b118-a6e009a7a2f9/E-book%20Metodologia%20do%20Trabalho%20Cientifico.pdf>. Acesso em: 8 jun. 2025.

PIJARSKI, Paweł et al. Application of Methods Based on Artificial Intelligence and Optimisation in Power Engineering—Introduction to the Special Issue. *Energies*, [S.L.], v. 17, n. 2, p. 516, 20 jan. 2024. MDPI AG. <http://dx.doi.org/10.3390/en17020516>. Disponível em: <https://doi.org/10.3390/en17020516>. Acesso em: 25 fev. 2025.

PÉREZ-ORTIZ, María et al. A Review of Classification Problems and Algorithms in Renewable Energy Applications. *Energies*, [S.L.], v. 9, n. 8, p. 607, 2 ago. 2016. MDPI AG. <http://dx.doi.org/10.3390/en9080607>. Disponível em: <https://doi.org/10.3390/en9080607>. Acesso em: 2 fev. 2025.

RANAWAKA, Ama et al. Leveraging the Synergy of Digital Twins and Artificial Intelligence for Sustainable Power Grids: a scoping review. *Energies*, [S.L.], v. 17, n. 21, p. 5342, 27 out. 2024. MDPI AG. <http://dx.doi.org/10.3390/en17215342>. Disponível em: <https://doi.org/10.3390/en17215342>. Acesso em: 1 mar. 2025.

RINALDI, Giovanni et al. Current Status and Future Trends in the Operation and Maintenance of Offshore Wind Turbines: a review. *Energies*, [S.L.], v. 14, n. 9, p. 2484, 27 abr. 2021. MDPI AG. <http://dx.doi.org/10.3390/en14092484>. Disponível em: <https://doi.org/10.3390/en14092484>. Acesso em: 8 fev. 2025.

RUSSELL, Stuart J.. LEARNING FROM EXAMPLES. In: RUSSELL, Stuart J.; NORVIG, Peter. *Artificial Intelligence A Modern Approach*. 3. ed. Upper Saddle River: Prentice Hall, 2010. Cap. 18. p. 693-693.

SAMPIERI, Roberto Hernández; COLLADO, Carlos Fernández; LUCIO, María del Pilar Baptista. *Metodologia de Pesquisa*. 5. ed. Porto Alegre: Penso, 2013.

SELLAK, Hamza et al. Towards next-generation energy planning decision-making: an expert-based framework for intelligent decision support. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 80, p. 1544-1577, dez. 2017. Elsevier BV.

<http://dx.doi.org/10.1016/j.rser.2017.07.013>. Disponível em:

<https://doi.org/10.1016/j.rser.2017.07.013>. Acesso em: 6 mar. 2025.

SHARMA, Amandeep; KAKKAR, Ajay. Forecasting daily global solar irradiance generation using machine learning. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 82, p. 2254-2269, fev. 2018. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2017.08.066>. Disponível em:

<https://doi.org/10.1016/j.rser.2017.08.066>. Acesso em: 19 jan. 2025.

STETCO, Adrian et al. Machine learning methods for wind turbine condition monitoring: a review. *Renewable Energy*, [S.L.], v. 133, p. 620-635, abr. 2019. Elsevier BV.

<http://dx.doi.org/10.1016/j.renene.2018.10.047>. Disponível em:

<https://doi.org/10.1016/j.renene.2018.10.047>. Acesso em: 10 out. 2025.

TALBI, El-Ghazali. *Metaheuristics: From Design to Implementation*. Hoboken,: John Wiley & Sons,, 2009.

TAYAL, Dev. Achieving high renewable energy penetration in Western Australia using data digitisation and machine learning. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 80, p. 1537-1543, dez. 2017. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2017.07.040>.

Disponível em: <https://doi.org/10.1016/j.rser.2017.07.040>. Acesso em: 14 jan. 2025.

TEIXEIRA-DUARTE, Felipe et al. Review on layout optimization strategies of offshore parks for wave energy converters. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 163, p. 112513, jul. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2022.112513>.

Disponível em: <https://doi.org/10.1016/j.rser.2022.112513>. Acesso em: 10 out. 2025.

THAKFAN, Ali et al. Artificial-Intelligence-Based Detection of Defects and Faults in Photovoltaic Systems: a survey. *Energies*, [S.L.], v. 17, n. 19, p. 4807, 25 set. 2024. MDPI

AG. <http://dx.doi.org/10.3390/en17194807>. Disponível em:  
<https://doi.org/10.3390/en17194807>. Acesso em: 1 mar. 2025.

THIRUNAVUKKARASU, M. et al. A comprehensive review on optimization of hybrid renewable energy systems using various optimization techniques. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 176, p. 113192, abr. 2023. Elsevier BV.  
<http://dx.doi.org/10.1016/j.rser.2023.113192>. Disponível em:  
<https://doi.org/10.1016/j.rser.2023.113192>. Acesso em: 18 fev. 2025.

YOUSEF, Latifa A. et al. Artificial Intelligence for Management of Variable Renewable Energy Systems: a review of current status and future directions. *Energies*, [S.L.], v. 16, n. 24, p. 8057, 14 dez. 2023. MDPI AG. <http://dx.doi.org/10.3390/en16248057>. Disponível em:  
<https://doi.org/10.3390/en16248057>. Acesso em: 16 jan. 2025.

YUAN, Zixia; XIONG, Guojiang; FU, Xiaofan. Artificial Neural Network for Fault Diagnosis of Solar Photovoltaic Systems: a survey. *Energies*, [S.L.], v. 15, n. 22, p. 8693, 19 nov. 2022. MDPI AG. <http://dx.doi.org/10.3390/en15228693>. Disponível em:  
<https://doi.org/10.3390/en15228693>. Acesso em: 3 mar. 2025.

ZAHRAEE, S.M. et al. Application of Artificial Intelligence Methods for Hybrid Energy System Optimization. *Renewable And Sustainable Energy Reviews*, [S.L.], v. 66, p. 617-630, dez. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.rser.2016.08.028>. Disponível em:  
<https://doi.org/10.1016/j.rser.2016.08.028>. Acesso em: 19 fev. 2025.

ZHANG, Lili et al. Artificial intelligence in renewable energy: a comprehensive bibliometric analysis. *Energy Reports*, [S.L.], v. 8, p. 14072-14088, nov. 2022. Elsevier BV.  
<http://dx.doi.org/10.1016/j.egy.2022.10.347>. Disponível em:  
<https://doi.org/10.1016/j.egy.2022.10.347>. Acesso em: 27 jan. 2025.

ZHOU, Yuekuan. Advances of machine learning in multi-energy district communities—mechanisms, applications and perspectives. *Energy And Ai*, [S.L.], v. 10, p. 100187, nov. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.egyai.2022.100187>. Disponível em:  
<https://doi.org/10.1016/j.egyai.2022.100187>. Acesso em: 26 fev. 2025.

ZHOU, Yuekuan. Ocean energy applications for coastal communities with artificial intelligence a state-of-the-art review. *Energy And Ai*, [S.L.], v. 10, p. 100189, nov. 2022. Elsevier BV. <http://dx.doi.org/10.1016/j.egyai.2022.100189>. Disponível em: <https://doi.org/10.1016/j.egyai.2022.100189>. Acesso em: 27 jan. 2025.

ZULU, Musawenkosi Lethumcebo Thanduxolo et al. A Comprehensive Review: study of artificial intelligence optimization technique applications in a hybrid microgrid at times of fault outbreaks. *Energies*, [S.L.], v. 16, n. 4, p. 1786, 10 fev. 2023. MDPI AG. <http://dx.doi.org/10.3390/en16041786>. Disponível em: <https://doi.org/10.3390/en16041786>. Acesso em: 30 jan. 2025.

ZWANE, Nosipho et al. A Bibliometric Analysis of Solar Energy Forecasting Studies in Africa. *Energies*, [S.L.], v. 15, n. 15, p. 5520, 29 jul. 2022. MDPI AG. <http://dx.doi.org/10.3390/en15155520>. Disponível em: <https://doi.org/10.3390/en15155520>. Acesso em: 3 out. 2025.