

MODELAGEM PREDITIVA DE PROPRIEDADES ELÉTRICAS DE MATERIAIS PARA SISTEMAS DE ENERGIA USANDO INTELIGÊNCIA ARTIFICIAL

PREDICTIVE MODELING OF ELECTRICAL PROPERTIES OF MATERIALS FOR ENERGY SYSTEMS USING ARTIFICIAL INTELLIGENCE

MODELADO PREDITIVO DE LAS PROPIEDADES ELÉCTRICAS DE LOS MATERIALES PARA SISTEMAS DE ENERGÍA MEDIANTE INTELIGENCIA ARTIFICIAL

Weicianne Kanandra Marques Diniz¹, Daniel Jordan Macedo dos Santos², Marcia Regina Barbosa Marques³, Weidson Pablo Marques Diniz⁴

DOI: 10.54899/dcs.v23i88.4872

Recibido: 03/02/2026 | Aceptado: 26/02/2026 | Publicación en línea: 06/03/2026.

RESUMO

Considerando a necessidade de acelerar a descoberta e a otimização de materiais para sistemas de energia sustentável, diante das limitações de custo, tempo e complexidade dos métodos tradicionais, objetiva-se compreender como a inteligência artificial pode aprimorar a predição das propriedades elétricas de materiais aplicados ao setor energético. Para tanto, procede-se à realização de uma revisão bibliográfica descritiva, com buscas nas bases SciELO, Scopus e Web of Science, contemplando estudos publicados entre 2014 e 2025 sobre modelagem preditiva, aprendizado de máquina e sistemas energéticos. Desse modo, observa-se que modelos de *machine learning*, *deep learning* e abordagens híbridas apresentam alta precisão, redução significativa de erros e maior capacidade de explorar espaços composicionais complexos, inclusive com recursos de explicabilidade. O que permite concluir que a inteligência artificial constitui ferramenta estratégica para o desenvolvimento de materiais e sistemas energéticos mais eficientes, resilientes e alinhados às demandas da transição energética sustentável, inteligência artificial e características elétricas.

Palavras-chave: Inteligência Artificial. Modelagem Preditiva. Propriedades Elétricas. Sistemas de Energia.

¹ Mestra em Engenharia de Materiais, Instituto Federal do Maranhão (IFMA), São Luís, Maranhão, Brasil. E-mail: kanandradiniz@gmail.com Orcid: <https://orcid.org/0000-0002-0411-9282>

² Graduando em Tecnólogo de Processos Químicos, Instituto Federal do Maranhão (IFMA), São Luís, Maranhão, Brasil. E-mail: danieljordan1995@gmail.com Orcid: <https://orcid.org/0009-0004-7531-1142>

³ Graduada em Pedagogia, Universidade Estadual Vale do Aracá (UVA), São Luís, Maranhão, Brasil. E-mail: marcinhadiniz58@gmail.com Orcid: <https://orcid.org/0009-0008-2682-9374>

⁴ Mestre em Gestão e Atenção à Saúde, Universidade Ceuma (UNICEUMA), São Luís, Maranhão, Brasil. E-mail: dinizmarques94@gmail.com Orcid: <https://orcid.org/0000-0001-6004-6500>

ABSTRACT

Considering the need to accelerate the discovery and optimization of materials for sustainable energy systems, given the high cost, time demands, and computational complexity of traditional methods, this study aims to understand how artificial intelligence can improve the prediction of electrical properties of materials applied to the energy sector. To achieve this, a descriptive literature review was conducted using the SciELO, Scopus, and Web of Science databases, covering studies published between 2014 and 2025 on predictive modeling, machine learning, and energy systems. Thus, it is observed that machine learning, deep learning, and hybrid approaches demonstrate high predictive accuracy, significant error reduction, and enhanced capability to explore complex compositional spaces, including the use of explainable AI techniques. This allows us to conclude that artificial intelligence represents a strategic tool for developing more efficient, resilient, and sustainable energy materials and systems aligned with global energy transition demands, artificial intelligence and electrical characteristics.

Keywords: Artificial Intelligence. Predictive Modeling. Electrical Properties. Energy Systems.

RESUMEN

Teniendo en cuenta la necesidad de acelerar el descubrimiento y la optimización de materiales para sistemas de energía sostenible, ante las limitaciones de coste, tiempo y complejidad de los métodos tradicionales, el objetivo es comprender cómo la inteligencia artificial puede mejorar la predicción de las propiedades eléctricas de los materiales aplicados al sector energético. Para ello, se lleva a cabo una revisión bibliográfica descriptiva, con búsquedas en las bases SciELO, Scopus y Web of Science, que abarca estudios publicados entre 2014 y 2025 sobre modelización predictiva, aprendizaje automático y sistemas energéticos. De este modo, se observa que los modelos de aprendizaje automático, aprendizaje profundo y enfoques híbridos presentan una alta precisión, una reducción significativa de los errores y una mayor capacidad para explorar espacios composicionales complejos, incluso con recursos de explicabilidad. Esto permite concluir que la inteligencia artificial constituye una herramienta estratégica para el desarrollo de materiales y sistemas energéticos más eficientes, resilientes y alineados con las demandas de la transición energética sostenible, la inteligencia artificial y las características eléctricas.

Palabras clave: Inteligencia Artificial. Modelización Predictiva. Propiedades Eléctricas. Sistemas Energéticos.



Esta obra está bajo una [Licencia Creative Commons Atribución- NoComercial 4.0 Internacional](https://creativecommons.org/licenses/by-nc/4.0/)

INTRODUÇÃO

A modelagem preditiva de propriedades elétricas de materiais (como condutividade elétrica, coeficiente de *Seebeck* e fator de potência) por meio de inteligência artificial é de extrema relevância para o avanço dos sistemas de energia sustentável. Em um contexto de transição

energética urgente, onde a humanidade precisa abandonar os combustíveis fósseis, Yao *et al.* (2023) enfatizam que o machine learning (ML) se tornou essencial para acelerar descobertas em materiais para colheita, armazenamento e conversão de energia renovável, representando uma das ferramentas mais poderosas para superar os limites atuais de eficiência e escalabilidade tecnológica.

Os métodos convencionais de descoberta de materiais, experimentos laboratoriais caros e simulações de primeiros princípios baseadas em DFT, são lentos e demandam recursos computacionais elevados. Don-tsa *et al.* (2024) demonstram que modelos de ML supervisionados, treinados com dados de cálculos de alto rendimento, conseguem prever propriedades termoelétricas de compostos inorgânicos com precisão de até 95 %, reduzindo drasticamente o tempo e o custo necessários para identificar materiais promissores para geração de energia termoelétrica.

Essa capacidade de predição rápida e precisa ganha ainda mais força quando aplicada ao design inverso e à otimização multiobjetivo. Wang *et al.* (2025), em revisão abrangente, destacam que o ML permite decifrar relações estrutura-propriedade para condutividade elétrica, coeficiente de Seebeck e concentração de portadores, reduzindo os ciclos de descoberta em até 73 % e abrindo caminho para materiais de alto zT que podem ser usados em recuperação de calor residual, refrigeração sólida e geração de energia limpa.

Portanto, discutir o tema não é apenas uma questão acadêmica: é uma necessidade estratégica para viabilizar tecnologias energéticas mais eficientes, acessíveis e ambientalmente responsáveis, contribuindo diretamente para as metas globais de descarbonização nas próximas décadas.

Nesse contexto, o objetivo dessa pesquisa é compreender o uso da modelagem preditiva de propriedades elétricas de materiais para sistemas de energia usando inteligência artificial. Assim, será possível responder: De que forma a inteligência artificial pode melhorar a predição das propriedades elétricas de materiais utilizados em sistemas de energia em relação aos métodos tradicionais?

METODOLOGIA

Tratou-se de uma revisão bibliográfica, de caráter descritivo, realizada a partir de buscas em bases de dados eletrônicas reconhecidas na literatura científica. As bases utilizadas foram:

SciELO, Scopus e Web of Science.

Para a busca dos artigos, foram utilizados descritores controlados e não controlados, relacionados à temática da pesquisa, nas línguas portuguesa, inglesa e espanhola, bem como suas combinações por meio do uso dos operadores booleanos “AND” e “OR”. Os descritores empregados foram: “*inteligência artificial*”, “*modelagem preditiva*”, “*propriedades elétricas*”, “*materiais*” e “*sistemas de energia*”; bem como seus correspondentes em inglês (“*artificial intelligence*”, “*predictive modeling*”, “*electrical properties*”, “*materials*”, “*energy systems*”) e em espanhol (“*inteligencia artificial*”, “*modelado predictivo*”, “*propiedades eléctricas*”, “*materiales*”, “*sistemas de energía*”).

Os critérios de inclusão definidos para a seleção dos artigos foram: artigos originais e artigos de revisão sistemática da literatura; publicados nos idiomas português, inglês e espanhol; disponíveis na íntegra; que abordassem a aplicação da inteligência artificial na modelagem preditiva de propriedades elétricas de materiais voltados a sistemas de energia; e artigos publicados e indexados nas referidas bases de dados no período compreendido entre 2014 e 2025.

Foram excluídos artigos duplicados, estudos que não apresentaram relação direta com o tema proposto, trabalhos incompletos, resumos, editoriais, cartas ao editor e publicações fora do período estabelecido.

RESULTADOS E DISCUSSÃO

No Quadro 1, apresentam-se os estudos selecionados que compõem o referencial desta revisão bibliográfica. Foram selecionados nove (9) estudos, os quais abordam, de forma convergente, a aplicação da inteligência artificial na modelagem preditiva voltada a sistemas de energia e materiais. Os principais tópicos contemplados incluem: previsão de geração e radiação solar e eólica, descoberta e caracterização preditiva de materiais avançados, modelagem de propriedades elétricas, otimização e resiliência de redes elétricas, bem como o uso de arquiteturas avançadas de aprendizado de máquina e aprendizado profundo em sistemas energéticos. Esses trabalhos evidenciam o potencial da IA para aumentar a eficiência, a confiabilidade e a sustentabilidade dos sistemas de energia.

Quadro 1. Síntese dos estudos selecionados

Autor(Ano)	Objetivo	Metodologia	Principais Resultados
Mamodiya <i>et al.</i> (2025)	Desenvolver um sistema híbrido de energia solar inteligente, adaptável e escalável	CNN-LSTM (previsão de irradiância) + Reinforcement Learning (tracking de eixo duplo) + Edge AI + nanocoatings auto-limpantes + PCM de dupla camada + células perovskita-silício adaptativas + blockchain para trading P2P	+41,4 % rendimento anual +18,7 % eficiência espectral -11,9 °C temperatura média do painel Latência despachada 180 → 48 ms Vida útil da bateria +60 %
Mashhadimoslem <i>et al.</i> (2026)	Acelerar descoberta de materiais de alta entropia (especialmente MXenes) para baterias e supercapacitores	Revisão de quantum computing, codificação/decodificação de estruturas cristalinas, <i>deep learning</i> para predição pré-síntese	Potencial de novos materiais antes da síntese física; discute caminhos futuros com QC + AI
Maleki, Asadnia & Razmjou (2022)	Mapear o uso de IA na descoberta de materiais para energias limpas	Revisão sistemática de aplicações, vantagens, desafios e perspectivas futuras	AI reduz custo e tempo de desenvolvimento; caminho para transição para economia de baixo carbono
Strielkowski <i>et al.</i> (2025)	Aumentar resiliência e eficiência de redes elétricas com análise preditiva	Modelo híbrido: regressão linear/logística + árvores de decisão + random forests + clustering em dados OEDI (DOE)	Eficiência do sistema +14 % a +24 % Melhora em índices de confiabilidade, redução de emissões e custo operacional
Alkahtani, Aldhyani & Alsubari (2023)	Prever radiação solar com alta precisão para sistemas fotovoltaicos/térmicos	CNN-LSTM treinado com dados meteorológicos NASA (temperatura, umidade, velocidade do vento)	$R^2 > 95$ % MSE mínimo = 0,000987 (melhor que todos os outros modelos testados)
Qayyum <i>et al.</i> (2023)	Prever constante dielétrica de cerâmicas PZT com explicabilidade	TabNet (<i>deep learning</i> tabular) + análise SHAP	MSE = 0,047 MAE = 0,042 Fatores mais importantes: d33, perda tangente e fórmula química
Abdul Baseer <i>et al.</i> (2023)	Prever geração de energia eólica e solar com máxima precisão	Modelos ANN individuais + modelo ensemble híbrido (combinação de LSTM, LightGBM, seq-GRU)	Wind: MAE 0,782 / MAPE 0,702 / RMSE 0,833 Solar: MAE 1,082 / MAPE 0,921 / RMSE 1,055 $R^2 = 0,9821$ (melhor desempenho geral)
Imam Rahmani <i>et al.</i> (2024)	Previsão de potência em sistemas híbridos renováveis com sensores nanoeletrônicos	Otimização Grey Wolf Optimizer (GWO) + Radial Basis Function Neural Network (RBFNN)	Excelente desempenho em MAE, MSE, RMSE e MAPE; modelo robusto e adaptativo
Rahman <i>et al.</i> (2021)	Revisar arquiteturas de redes neurais artificiais para previsão em sistemas híbridos renováveis	Revisão de MLP, RNN, CNN e LSTM aplicados a séries temporais de energia solar, eólica e hidrelétrica	Modelos de rede neural conseguem capturar não-linearidades e fornecer previsões precisas de curto e médio prazo

Fonte: autora

Para a melhor compreensão dos estudos, os mesmos foram organizados por similaridade, no quadro 2 seção, são apresentados os estudos relacionados à descoberta de materiais com o uso de inteligência artificial, com foco na aceleração do desenvolvimento e na caracterização preditiva de materiais aplicados a sistemas de energia. Os trabalhos selecionados exploram o

emprego de técnicas de aprendizado de máquina, aprendizado profundo e abordagens híbridas, incluindo métodos explicáveis, para a identificação de propriedades elétricas e o mapeamento de novos materiais antes da síntese experimental.

Quadro 2. Descoberta de Materiais com IA (Materials Discovery)

Autor(Ano)	Metodologia	Principais Resultados
Mashhadimoslem <i>et al.</i> (2026)	Revisão de quantum computing + codificação de estruturas cristalinas + <i>deep learning</i> pré-síntese	Potencial de novos materiais antes da síntese física; caminhos futuros com QC + AI
Maleki, Asadnia & Razmjou (2022)	Revisão sistemática de aplicações, vantagens, desafios e perspectivas	AI reduz custo/tempo; caminho para economia de baixo carbono
Qayyum <i>et al.</i> (2023)	TabNet (<i>deep learning</i>) + análise SHAP	MSE = 0,047; MAE = 0,042; principais fatores: d33, perda tangente, fórmula química

Fonte: autora

No que se refere à inteligência artificial, Mashhadimoslem *et al.* (2026) abordam a IA como ferramenta central para acelerar a descoberta, o design e a otimização de materiais de alta entropia (HEMs) aplicados a baterias e supercapacitores. Os autores destacam que algoritmos de machine learning e *deep learning* permitem prever propriedades estruturais, eletrônicas, térmicas e eletroquímicas dos materiais antes da síntese experimental, reduzindo custos, tempo e tentativas empíricas no desenvolvimento de novos materiais energéticos.

O artigo de Mashhadimoslem *et al.* (2026) enfatiza o papel da IA na codificação e decodificação de estruturas cristalinas complexas, apontando que a ausência de descritores adequados é um dos maiores gargalos da área. Nesse sentido, redes neurais profundas são utilizadas para aprender automaticamente representações estruturais a partir de dados provenientes de DFT, AIMD e simulações quânticas, superando métodos tradicionais baseados em descritores fixos. A IA também é apresentada como essencial para explorar espaços químicos de alta dimensionalidade, viabilizando a análise de sistemas com cinco ou mais elementos, característica típica dos HEMs.

Além disso, os autores Mashhadimoslem *et al.* (2026) discutem a integração entre IA e computação quântica, indicando que, no futuro, algoritmos de quantum machine learning (QML) poderão aprender diretamente de dados quânticos, ampliando drasticamente a capacidade preditiva em comparação aos métodos clássicos. A IA, nesse contexto, é vista não apenas como uma ferramenta de previsão, mas como um elo entre dados quânticos, simulações computacionais e descoberta autônoma de materiais, possibilitando modelos híbridos clássico-quânticos para o avanço da ciência dos materiais no setor energético.

Acrescentando ao contexto da inteligência artificial, Maleki, Asadnia e Razmjou (2022) abordam a inteligência artificial como um elemento estratégico para acelerar a descoberta, o design e a otimização de materiais voltados ao futuro da energia limpa, destacando seu papel na transição para uma economia de baixo carbono. Os autores enfatizam que métodos baseados em IA permitem reduzir drasticamente o tempo, o custo e a dependência de tentativas experimentais na identificação de novos materiais para baterias, sistemas termelétricos e outras tecnologias energéticas sustentáveis.

Além disso, Maleki, Asadnia e Razmjou (2022) discutem que a IA atua de forma integrada com química computacional e mecânica quântica, utilizando dados gerados por DFT e dinâmicas moleculares para treinar modelos de machine learning e *deep learning* capazes de prever propriedades de materiais com alta precisão. Além disso, os autores ressaltam o uso de processamento de linguagem natural (NLP) e text mining como ferramentas de IA fundamentais para extrair dados não estruturados de artigos científicos, patentes e relatórios técnicos, transformando-os em grandes bases de dados utilizáveis para a descoberta de materiais, especialmente no campo das baterias.

Os autores Maleki, Asadnia e Razmjou (2022) concluem que a inteligência artificial não apenas acelera a descoberta de novos materiais, mas também orienta simulações computacionais, prevendo resultados antes da execução completa e otimizando condições de cálculo, o que reduz erros e custos computacionais. Apesar do grande potencial, o estudo aponta desafios relevantes, como a escassez de bases de dados padronizadas, a necessidade de modelos mais generalizáveis e a integração de critérios de sustentabilidade ambiental nos algoritmos. Assim, a IA é apresentada como um catalisador essencial para a inovação em materiais energéticos, capaz de conectar ciência dos materiais, computação avançada e sustentabilidade na construção de um futuro energético limpo.

Qayyum *et al.* (2023) abordam a aplicação de inteligência artificial explicável (Explainable AI – XAI) na predição de propriedades de materiais, com foco na constante dielétrica de cerâmicas PZT (*lead zirconate titanate*). O estudo utiliza um modelo de *deep learning* interpretável chamado TabNet, projetado para dados tabulares, com o objetivo de superar a limitação dos modelos tradicionais de machine learning frequentemente considerados “caixas-pretas”. A IA é aplicada para aprender relações complexas entre composição química, parâmetros de processamento e propriedades funcionais, oferecendo simultaneamente alta precisão preditiva e transparência.

No que diz respeito à inteligência artificial, o trabalho destaca o uso de *Shapley Additive Explanations* (SHAP) como ferramenta central para interpretação do modelo. A abordagem SHAP permite identificar e quantificar a contribuição individual de cada variável de entrada nas previsões, revelando que parâmetros como d33, *tangent loss* e fórmula química exercem forte influência positiva sobre a constante dielétrica, enquanto o tempo de processo apresenta impacto negativo. Essa análise demonstra que a IA não apenas prevê resultados, mas também gera conhecimento científico interpretável, alinhado com princípios físicos e de engenharia de materiais (Qayyum *et al.*, 2023).

Os autores Qayyum *et al.* (2023) concluem que a combinação de TabNet com técnicas de IA explicável supera modelos como ANN e XGBoost, alcançando MSE de 0,047 e MAE de 0,042, e representa um avanço significativo para a descoberta, otimização e design de materiais cerâmicos. Apesar dos desafios inerentes à complexidade dos dados e à generalização dos modelos, o estudo evidencia que a inteligência artificial explicável é um pilar fundamental para sistemas preditivos confiáveis em ciência dos materiais, com aplicações diretas em P&D, controle de qualidade, sustentabilidade e desenvolvimento industrial de cerâmicas PZT.

No Quadro 3, apresentam-se os estudos relacionados aos sistemas solares inteligentes e à previsão de radiação solar, com ênfase no uso de inteligência artificial e aprendizado profundo para otimização do desempenho energético. Os trabalhos selecionados demonstram a aplicação de modelos híbridos, como CNN-LSTM e aprendizado por reforço, integrados a tecnologias emergentes, incluindo edge computing, materiais avançados e sistemas adaptativos, visando aumentar a eficiência, a confiabilidade e a capacidade de previsão de sistemas fotovoltaicos e térmicos. Os resultados evidenciam ganhos expressivos em rendimento energético, precisão preditiva e eficiência operacional, reforçando o papel da IA na evolução dos sistemas solares inteligentes.


Quadro 3. Sistemas Solares Inteligentes e Previsão de Radiação

Autor(Ano)	Metodologia	Principais Resultados
Mamodiya <i>et al.</i> (2025)	CNN-LSTM + Reinforcement Learning + Edge AI + nanocoatings + PCM + perovskita adaptativa + blockchain	+41,4 % rendimento anual +18,7 % absorção espectral -11,9 °C temperatura Latência 180→48 ms Bateria +60 %
Alkahtani, Aldhyani e Alsubari (2023)	CNN-LSTM com dados meteorológicos NASA (temp., umidade, vento)	R ² > 95 % MSE mínimo = 0,000987 (melhor que todos os modelos comparados)

Fonte: autora

Mamodiya *et al.* (2025) falam sobre o desenvolvimento de um sistema híbrido de energia solar baseado em inteligência artificial, que integra previsão inteligente, controle adaptativo, materiais inteligentes, células fotovoltaicas avançadas e *blockchain*, com o objetivo de tornar a geração de energia solar mais eficiente, autônoma e sustentável (Figura 1).

Figura 1. Configuração experimental em ambiente real do sistema de rastreamento solar de dois eixos baseado em inteligência artificial em Sitapura, Jaipur, Índia (2022).⁵



Fonte: Mamodiya *et al.* (2025)

Os autores propõem uma arquitetura multicamadas que combina CNN-LSTM para previsão precisa da irradiância solar, aprendizado por reforço para rastreamento solar em tempo real, Edge AI para decisões rápidas, além do uso de nanorrevestimentos, materiais de mudança de fase e células fotovoltaicas perovskita-silício adaptativas, capazes de ajustar suas propriedades elétricas conforme as condições ambientais.

O estudo de Mamodiya *et al.* (2025) demonstra, por meio de validação experimental realizada ao longo de um ano em Jaipur (Índia), que o sistema proposto supera significativamente os modelos tradicionais. Os resultados indicam aumento expressivo no rendimento energético

⁵ Photovoltaic (PV) Panels (335W each) = Painéis Fotovoltaicos (335 W cada); Mechanical Actuator System (Gear Arrangement and Linear Actuator) = Sistema de Atuador Mecânico (Conjunto de Engrenagens e Atuador Linear); Battery Storage = Armazenamento em Bateria; Dual-Axis Mechanical Tracking System = Sistema Mecânico de Rastreamento de Dois Eixos; Real-Time Performance Monitoring (Analog Performance Measurement & Data Logging) = Monitoramento de Desempenho em Tempo Real (Medição Analógica de Desempenho e Registro de Dados); Sensor & Data Acquisition Unit (Control Circuit & Sensor Integration) = Unidade de Sensores e Aquisição de Dados (Circuito de Controle e Integração de Sensores).

anual, melhoria na eficiência de absorção espectral, redução da temperatura média dos painéis e maior vida útil do sistema de armazenamento de energia. Além disso, a adoção do blockchain possibilitou transações energéticas descentralizadas e seguras, reduzindo a latência na distribuição de energia e eliminando limitações de sistemas centralizados convencionais.

Os autores Mamodiya *et al.* (2025) chegam à conclusão de que a integração sinérgica entre inteligência artificial, materiais inteligentes, células solares adaptativas e blockchain representa um avanço disruptivo para os sistemas de energia renovável. O modelo proposto mostra-se viável, escalável e resiliente, capaz de aprender, se adaptar e se autoajustar a condições ambientais dinâmicas, superando sistemas estáticos ou baseados em regras fixas. Assim, o estudo contribui significativamente para o desenvolvimento de redes solares inteligentes, autônomas e sustentáveis, com potencial aplicação tanto em redes urbanas inteligentes quanto em áreas rurais e sistemas isolados.

Por outro lado, Alkahtani *et al.* (2023) falam sobre a aplicação de modelos de inteligência artificial, especialmente *deep learning*, para a previsão da radiação solar, com foco no uso eficiente de sistemas de energia renovável. Os autores destacam que a previsão precisa da radiação solar é essencial para o planejamento, a operação e o gerenciamento de sistemas fotovoltaicos e térmicos, uma vez que a indisponibilidade ou imprecisão desses dados pode comprometer o desempenho energético e a estabilidade da rede elétrica. Nesse contexto, a IA é apresentada como uma alternativa eficaz aos métodos tradicionais de previsão, por sua capacidade de lidar com dados meteorológicos complexos e não lineares.

O estudo enfatiza o uso do modelo híbrido CNN-LSTM, que combina redes neurais convolucionais (CNN) para extração de padrões espaciais dos dados meteorológicos e redes LSTM para capturar dependências temporais. A inteligência artificial é aplicada à análise de variáveis como temperatura, umidade relativa, velocidade do vento e registros históricos de radiação solar, demonstrando elevada correlação entre essas variáveis e a radiação incidente. Os autores mostram que o modelo CNN-LSTM supera outros modelos de IA e métodos estatísticos, alcançando coeficiente de determinação superior a 95% (R^2) e baixo erro médio quadrático, evidenciando alta precisão preditiva (Alkahtani *et al.*, 2023).

Os autores Alkahtani *et al.* (2023) chegam à conclusão de que a inteligência artificial baseada em *deep learning* representa uma ferramenta robusta, precisa e de baixo custo para a previsão de radiação solar, contribuindo diretamente para a eficiência energética, o equilíbrio entre oferta e demanda e a expansão do uso da energia solar. O modelo proposto demonstra forte

potencial para aplicações reais em gestão de energia, monitoramento da rede elétrica e apoio à tomada de decisão, reforçando o papel da IA como elemento estratégico na transição para sistemas energéticos sustentáveis e inteligentes.

No Quadro 4, apresentam-se os estudos voltados à previsão de demanda e geração de energia renovável, com foco na aplicação de técnicas de inteligência artificial e aprendizado de máquina para o aumento da eficiência e da resiliência dos sistemas elétricos. Os trabalhos selecionados exploram modelos híbridos e modelos ensemble, capazes de capturar padrões complexos em dados energéticos, contribuindo para a melhoria da confiabilidade operacional, a redução de custos e a mitigação de emissões ambientais. Os resultados evidenciam o papel estratégico da modelagem preditiva baseada em IA no planejamento e na operação de redes elétricas modernas.


Quadro 4. Previsão de Demanda e Geração de Energia Renovável

Autor(Ano)	Metodologia	Principais Resultados
Strielkowski <i>et al.</i> (2025)	Modelo híbrido: regressão + árvores + random forests + clustering (dados OEDI)	Eficiência +14 % a +24 % Melhora em confiabilidade, redução de emissões e custo
Abdul Baseer <i>et al.</i> (2023)	Modelos ANN + modelo ensemble híbrido (LSTM + LightGBM + seq-GRU)	Wind: MAE 0,782 / MAPE 0,702 / RMSE 0,833 Solar: MAE 1,082 / MAPE 0,921 / RMSE 1,055 R ² = 0,9821

Fonte: autora

Semelhantemente, Strielkowski *et al.* (2025) falam sobre o uso de inteligência artificial e machine learning aplicados à análise preditiva da demanda em sistemas elétricos, com o objetivo de aumentar a resiliência, a eficiência operacional e a confiabilidade das redes de energia. Os autores propõem um *modelo* que integra métodos supervisionados e não supervisionados, como regressão linear e logística, árvores de decisão, *random forests* e algoritmos de clusterização, combinando previsão de demanda de curto prazo com a detecção antecipada de falhas, curtos-circuitos e anomalias operacionais.

Figura 2. Sistema energético moderno com a participação de fontes de energia renováveis.



Fonte: Strielkowski *et al.* (2025)

No que diz respeito à inteligência artificial, o estudo de Strielkowski *et al.* (2025) aborda a IA como elemento-chave para a automação do monitoramento, da tomada de decisão e do controle em sistemas elétricos inteligentes (*smart grids*). A IA é utilizada para analisar grandes volumes de dados provenientes de IoT, Big Data e sensores de rede, permitindo prever padrões de consumo, otimizar a combinação de fontes energéticas (solar, eólica, baterias e geradores a diesel) e reduzir desperdícios. Os algoritmos preditivos possibilitam identificar configurações ótimas do sistema energético, minimizando o uso de fontes fósseis e aumentando a autonomia energética.

Os autores Strielkowski *et al.* (2025) chegam à conclusão de que a inteligência artificial aplicada à análise preditiva promove ganhos significativos de eficiência (entre 14% e 24%), melhora índices de confiabilidade, reduz impactos ambientais e apoia o planejamento estratégico de sistemas elétricos, especialmente em *microgrids* e sistemas locais. Apesar dos desafios regulatórios, da escassez de dados globais padronizados e das preocupações com segurança e confiabilidade das decisões automatizadas, o estudo evidencia que a IA representa um pilar fundamental para o desenvolvimento de redes elétricas resilientes, autônomas e sustentáveis, com grande potencial de expansão futura, sobretudo na integração de energias renováveis, armazenamento avançado e tecnologias veículo-rede (V2G).

Baseer *et al.* (2023) abordam a aplicação de técnicas de inteligência artificial e machine learning para a previsão da geração de energia elétrica a partir de fontes renováveis, com ênfase

em energia solar e eólica no contexto da transição energética e da expansão econômica do Oriente Médio. O estudo parte do desafio da alta variabilidade e não linearidade dos dados de séries temporais associados às fontes renováveis, que dificultam previsões precisas por métodos tradicionais, destacando a IA como solução eficaz para apoiar investidores, operadores de rede e planejadores energéticos.

No que se refere à inteligência artificial, os autores Baseer *et al.* (2023) exploram diferentes modelos de redes neurais artificiais (ANNs) e propõem um modelo híbrido baseado em ensemble learning (EL), que combina múltiplos modelos complementares para aumentar a robustez e a precisão das previsões. A abordagem integra técnicas avançadas como LSTM, LightGBM e GRU sequencial, demonstrando que o método ensemble supera os modelos individuais na previsão de geração de energia renovável tanto em curto prazo (24 horas) quanto em horizontes de longo prazo, a partir de dados históricos e variáveis meteorológicas como velocidade do vento e irradiância solar.

Os resultados indicam que a metodologia de ensemble learning apresenta desempenho superior, alcançando R^2 de 0,9821, além de menores valores de erro (MAE, MAPE e RMSE) em comparação com LSTM, LightGBM e GRU, tanto para energia eólica quanto solar. Os autores Baseer *et al.* (2023) concluem que a inteligência artificial baseada em modelos híbridos e ensembles representa uma ferramenta altamente confiável para a previsão da geração de energia renovável, contribuindo para a integração eficiente dessas fontes em redes elétricas inteligentes, melhoria da estabilidade do sistema e apoio à transição energética sustentável. Apesar de limitações associadas à sensibilidade de alguns modelos, como o LightGBM, o estudo evidencia que a IA desempenha um papel fundamental no planejamento energético, na descentralização da geração e no desenvolvimento de sistemas elétricos mais resilientes e eficientes.

Quadro 5. Sistemas Híbridos Renováveis e Previsão de Potência

Autor(Ano)	Metodologia	Principais Resultados
Rahmani <i>et al.</i> (2024)	Grey Wolf Optimizer (GWO) + Radial Basis Function Neural Network (RBFNN)	Excelente desempenho em MAE, MSE, RMSE e MAPE; modelo robusto e adaptativo
Rahman <i>et al.</i> (2021)	Revisão de MLP, RNN, CNN, LSTM aplicados a séries temporais de solar, eólica e hidrelétrica	Modelos ANN capturam não-linearidades e fornecem previsões precisas de curto/médio prazo

Fonte: autora

Rahmani *et al.* (2024) abordam o uso de inteligência artificial aplicada à previsão de geração de energia elétrica em Sistemas Híbridos de Energia Renovável (HRES), integrando

sensores nanoeletrônicos e técnicas avançadas de aprendizado de máquina. O estudo busca enfrentar os desafios associados à complexidade, variabilidade e não linearidade da geração de energia em sistemas híbridos que combinam múltiplas fontes renováveis, como solar e eólica, destacando o papel da IA no aumento da confiabilidade e eficiência desses sistemas.

No contexto da inteligência artificial, os autores Rahmani *et al.* (2024) propõem um modelo preditivo inovador baseado na combinação de Redes Neurais de Função de Base Radial (RBFNN) com o *Grey Wolf Optimizer* (GWO). A RBFNN é utilizada por sua capacidade de capturar padrões não lineares complexos nos dados provenientes dos sensores nanoeletrônicos, enquanto o GWO atua na otimização automática dos parâmetros da rede neural, reduzindo a necessidade de ajuste manual e aumentando a precisão preditiva. Essa abordagem híbrida permite que o modelo se adapte dinamicamente a diferentes condições ambientais e operacionais do HRES.

Os resultados mostram que o modelo proposto apresenta desempenho superior em relação a modelos tradicionais, com reduções significativas nos erros de previsão (MAE, MSE, RMSE e MAPE), além de maior robustez e capacidade de generalização para dados não vistos. Os autores Rahmani *et al.* (2024) concluem que a inteligência artificial combinada com técnicas de otimização bioinspiradas e sensores nanoeletrônicos representa um avanço relevante para o gerenciamento eficiente da energia, tomada de decisão em tempo real e planejamento de sistemas híbridos renováveis, contribuindo diretamente para o aumento da sustentabilidade, confiabilidade e eficiência dos sistemas energéticos modernos.

Rahman *et al.* (2021) apresentam uma revisão abrangente sobre o uso de inteligência artificial, com ênfase em redes neurais artificiais (ANNs), na previsão de energia em Sistemas Híbridos de Energia Renovável (HRES). O estudo parte do contexto da crescente dependência global de combustíveis fósseis e da necessidade de fontes energéticas sustentáveis, especialmente para áreas remotas e rurais, onde os sistemas híbridos que combinam solar, eólico e hidrelétrico surgem como alternativa viável. A natureza incerta e altamente variável das fontes renováveis motiva o uso da IA, dada sua capacidade de lidar com séries temporais complexas, não lineares e não estacionárias.

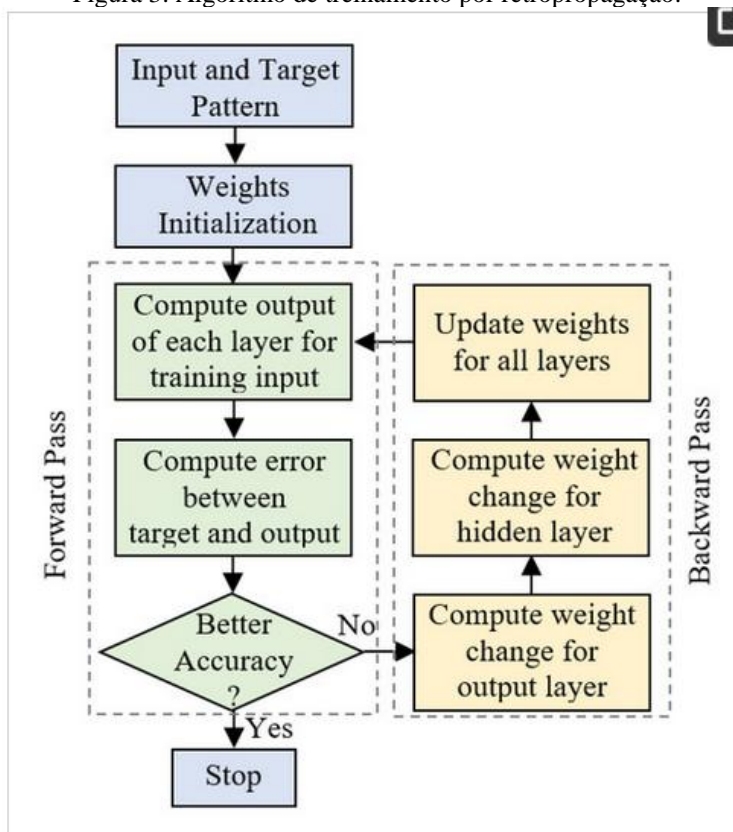
No que se refere à inteligência artificial, os autores Rahman *et al.* (2021) analisam diferentes arquiteturas de redes neurais artificiais aplicadas à previsão de geração de energia, incluindo *Multi-Layer Perceptron* (MLP), Redes Neurais Recorrentes (RNN), Redes Neurais Convolucionais (CNN) e *Long Short-Term Memory* (LSTM). O artigo destaca que, embora o

MLP apresente desempenho superior aos métodos lineares tradicionais, modelos de *deep learning* como CNN e LSTM demonstram maior precisão e robustez em problemas de previsão de séries temporais energéticas, sobretudo quando há grande volume de dados e relações não lineares complexas. Além disso, o estudo enfatiza que métricas como RMSE e R^2 são mais adequadas para avaliar o desempenho dos modelos do que MAE ou MAPE em certos cenários.

Os autores Rahman *et al.* (2021) concluem que a inteligência artificial baseada em ANNs representa uma ferramenta essencial para a previsão precisa da geração de energia renovável, contribuindo para o planejamento, controle e gerenciamento eficiente de sistemas híbridos. Apesar dos desafios relacionados à seleção da arquitetura ideal, otimização de parâmetros, disponibilidade de dados de qualidade e escassez de especialistas, o estudo evidencia que a IA possui grande potencial para mitigar a incerteza inerente às fontes renováveis. O trabalho aponta ainda direções futuras, como o uso de modelos híbridos, técnicas avançadas de *deep learning* (BLSTM, DNN, ELM) e a integração com Internet das Coisas (IoT), reforçando o papel da inteligência artificial como pilar estratégico no desenvolvimento de sistemas energéticos inteligentes, sustentáveis e resilientes.

A Figura 3 mostra o algoritmo de treinamento por retropropagação do erro (*et al*), que foi trabalhado por Rahman *et al.* (2021) no qual uma rede neural aprende de forma supervisionada. O processo começa com a definição dos dados de entrada e dos valores-alvo, seguida da inicialização dos pesos. Na passagem direta, a rede calcula as saídas a partir das entradas e compara o resultado com o valor esperado para obter o erro. Em seguida, na passagem reversa, esse erro é propagado de volta da camada de saída para as camadas ocultas, permitindo o ajuste dos pesos de todas as conexões com o objetivo de minimizar o erro. Esse ciclo é repetido até que a acurácia desejada seja alcançada, momento em que o treinamento é finalizado.

Figura 3. Algoritmo de treinamento por retropropagação.⁶



Fonte: Rahman *et al.* (2021)

Retomando a pergunta da pesquisa: De que forma a inteligência artificial pode melhorar a predição das propriedades elétricas de materiais utilizados em sistemas de energia em relação aos métodos tradicionais? Com base nos estudos levantados, percebe-se que a inteligência artificial melhora de forma expressiva a predição das propriedades elétricas de materiais usados em sistemas de energia em relação aos métodos tradicionais (simulações DFT, testes experimentais iterativos e modelagem físico-química clássica), que são lentos, caros e limitados na exploração de grandes espaços composicionais.

Os autores Qayyum *et al.* (2023), Mashhadimoslem *et al.* (2026) e Maleki *et al.* (2022) mostram que modelos de *deep learning* (TabNet + SHAP, algoritmos de alta entropia e revisões sistemáticas de IA) conseguem prever com alta precisão e explicabilidade propriedades elétricas

⁶ Input and Target Pattern= Padrões de Entrada e Alvo; Weights Initialization= Inicialização dos Pesos; Forward Pass (Passagem Direta): Compute output of each layer for training input = Calcular a saída de cada camada para a entrada de treinamento; Compute error between target and output= Calcular o erro entre o valor-alvo e a saída Better Accuracy?= Melhor acurácia? Yes=Sim;No= Não Backward Pass (Passagem Reversa): Compute weight change for output layer= Calcular a variação dos pesos da camada de saída; Compute weight change for hidden layer= Calcular a variação dos pesos da camada oculta; Update weights for all layers= Atualizar os pesos de todas as camadas; Stop= Parar.

críticas, como constante dielétrica de cerâmicas PZT, condutividade iônica, bandgap e capacidade de armazenamento em materiais de alta entropia, antes mesmo da síntese física.

Enquanto isso, Mamodiya *et al.* (2025) vão além da simples previsão e demonstram o uso de IA (CNN-LSTM + *Reinforcement Learning* + células perovskita-silício adaptativas) para ajustar em tempo real características elétricas dinâmicas, como *bandgap* e tensão de saída.

Assim, enquanto uns autores focam na previsão precisa e explicável das propriedades intrínsecas dos materiais, outros já avançam para a adaptação inteligente e em tempo real dessas mesmas propriedades durante o funcionamento dos sistemas de energia, duas frentes complementares que juntas representam um avanço muito maior do que os enfoques tradicionais.

CONSIDERAÇÕES FINAIS

A presente revisão evidenciou que a inteligência artificial tem transformado de maneira significativa a modelagem preditiva de propriedades elétricas de materiais aplicados a sistemas de energia. Diferentemente dos métodos tradicionais, marcados por alto custo computacional, longos ciclos experimentais e limitação na exploração de amplos espaços composicionais, os modelos baseados em *machine learning* e *deep learning* demonstram elevada capacidade de prever propriedades como constante dielétrica, condutividade, bandgap e desempenho termoelétrico com alta precisão e menor tempo de processamento.

Os estudos analisados indicam que a IA não apenas acelera a descoberta de novos materiais, mas também amplia a compreensão das relações estrutura–propriedade, especialmente quando associada a técnicas explicáveis, como SHAP, que conferem transparência às decisões algorítmicas. Além disso, observa-se um avanço relevante na integração entre modelagem preditiva e aplicação prática, com sistemas capazes de adaptar dinamicamente propriedades elétricas em tempo real, como demonstrado em arquiteturas híbridas para sistemas solares inteligentes.

Outro ponto relevante refere-se ao uso de modelos híbridos e *ensemble*, que combinam diferentes arquiteturas neurais e algoritmos de otimização, resultando em maior robustez, generalização e desempenho preditivo. Essa abordagem tem se mostrado particularmente eficaz em contextos de alta variabilidade, como sistemas híbridos de energia renovável, contribuindo para maior estabilidade, eficiência operacional e integração sustentável à rede elétrica.

Apesar dos avanços, persistem desafios relacionados à padronização de bases de dados, generalização dos modelos, integração com critérios ambientais e confiabilidade em ambientes reais de operação. Ainda assim, os achados reforçam que a inteligência artificial representa um eixo estratégico para a transição energética, ao conectar ciência dos materiais, computação avançada e sustentabilidade.

Assim, conclui-se que a inteligência artificial melhora substancialmente a predição das propriedades elétricas de materiais para sistemas de energia ao oferecer maior precisão, rapidez, capacidade de adaptação e suporte à tomada de decisão em comparação aos métodos convencionais. Mais do que uma ferramenta auxiliar, a IA consolida-se como protagonista no desenvolvimento de materiais e sistemas energéticos mais eficientes, resilientes e alinhados às demandas de descarbonização e inovação tecnológica das próximas décadas.

REFERÊNCIAS

- ABDUL BASEER, M.; ALMUNIF, A.; ALSADUNI, I.; TAZEEN, N. Electrical power generation forecasting from renewable energy systems using artificial intelligence techniques. **Energies**, 2023; 16(18): 6414.
- ALKAHTANI, H.; ALDHYANI, T. H. H.; ALSUBARI, S. N. Application of artificial intelligence model solar radiation prediction for renewable energy systems. **Sustainability**, 2023; 15: 6973.
- DON-TSA, Delchere *et al.* Predictive models for inorganic materials thermoelectric properties with machine learning. **Machine Learning: Science and Technology**, Bristol, v. 5, n. 3, 035067, 2024. DOI: <https://doi.org/10.1088/2632-2153/ad6831>.
- IMAM RAHMANI, Mohammad Khalid *et al.* An Artificial Intelligence-Based Predictive Modelo for Power Forecasting Using Nano-Electronic Sensors in Hybrid Renewable Energy System. **Journal of Nanoelectronics and Optoelectronics**, v. 19, n. 2, p. 188-201, 2024.
- MALEKI, Reza; ASADNIA, Mohsen; RAZMJOU, Amir. Artificial intelligence-based material discovery for clean energy future. **Advanced Intelligent Systems**, v. 4, n. 10, p. 2200073, 2022.
- MAMODIYA, U.; KISHOR, I.; GARINE, R. *et al.* Artificial intelligence based hybrid solar energy systems with smart materials and adaptive photovoltaics for sustainable power generation. **Scientific Reports**, v. 15, 17370, 2025.
- MASHHADIMOSLEM, H.; KARIMI, P.; ELKAMEL, A. *et al.* Toward high entropy material discovery for energy applications using computational and machine learning methods. **npj Computational Materials**, v. 12, 50, 2026.
- QAYYUM, F.; KHAN, M. A.; KIM, D.-H.; KO, H.; RYU, G.-A. Explainable AI for material

property prediction based on energy cloud: a Shapley-driven approach. **Materials**, 2023; 16: 7322.

RAHMAN, M. M.; SHAKERI, M.; TIONG, S. K.; KHATUN, F.; AMIN, N.; PASUPULETI, J.; HASAN, M. K. Prospective methodologies in hybrid renewable energy systems for energy prediction using artificial neural networks. **Sustainability**, 2021; 13(4): 2393.

STRIELKOWSKI, Wadim *et al.* Predictive demand analytics and machine learning in electric power systems for enhancing resilience and efficiency. **Sustainable Energy, Grids and Networks**, p. 101722, 2025.

WANG, Yuelin; ZHONG, Chengquan; LIN, Xi. Machine learning for predictive design and optimization of high-performance thermoelectric materials: a review. **Journal of Materials Informatics**, [S.l.], v. 5, 41, 2025. DOI: <https://doi.org/10.20517/jmi.2025.18>.

YAO, Zhenpeng *et al.* Machine learning for a sustainable energy future. **Nature Reviews Materials**, [S.l.], v. 8, p. 202-215, 2023. DOI: <https://doi.org/10.1038/s41578-022-00490-5>.