



**Revista Brasileira
de Climatologia**

Brazilian Journal of Climatology



APLICAÇÕES E DESAFIOS DA INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DA RADIAÇÃO SOLAR: UMA REVISÃO SISTEMÁTICA

*Applications and Challenges of Artificial Intelligence in Solar
Radiation Forecasting: A Systematic Review*

*Aplicaciones y Desafíos de la Inteligencia Artificial en la
Predicción de la Radiación Solar: Una Revisión Sistemática*

Camila Piacitelli Tieghi  

Universidade de São Paulo (USP)

camilapiacitelli@yahoo.com.br

Fernando de Lima Caneppele  



Universidade de São Paulo (USP)

caneppele@usp.br

Alexandre Dal Pai  

Universidade Estadual Paulista Júlio de Mesquita Filho (UNESP)

dal.pai@unesp.br

Emmanuel Zullo Godinho  

Universidade de São Paulo (USP)

emmanuel.godinho@unisagrado.edu.br

Carlos Frederico Meschini Almeida  

Universidade de São Paulo (USP)

cfmalmeida@usp.br

Diego Cunha Malagueta  

Universidade Federal do Rio de Janeiro (UFRJ)

diego.c.malagueta@macae.ufrj.br

Resumo: A previsão precisa da radiação solar é fundamental para diversas áreas, como energia solar e agricultura. A Inteligência Artificial (IA) tem se mostrado uma ferramenta poderosa para aprimorar essas previsões. Este estudo analisou diversas pesquisas que utilizam IA para prever a radiação solar. As técnicas mais comuns incluem redes neurais, máquinas de vetores de suporte e aprendizado profundo. Essas técnicas são capazes de identificar padrões complexos nos dados e relacionar a radiação solar com fatores como temperatura, umidade e nebulosidade. Os modelos de IA são treinados com grandes conjuntos de dados meteorológicos e de radiação solar, o que lhes permite aprender a fazer previsões mais precisas. As métricas utilizadas para avaliar o desempenho desses modelos incluem o erro médio quadrático (RMSE), o coeficiente de determinação (R^2) e o erro percentual absoluto médio (MAPE). A revisão demonstra que a IA tem um grande potencial para melhorar a previsão da radiação solar. As previsões mais precisas podem otimizar a produção de energia solar, melhorar a gestão da irrigação e auxiliar em diversos outros processos que dependem da radiação solar.

Palavras-chave: Aprendizado de máquina. Aprendizado Profundo. Modelo de previsão. Redes Neurais Artificiais.

Abstract: Accurate forecasting of solar radiation is essential for many areas, such as solar energy and agriculture. Artificial Intelligence (AI) has proven to be a powerful tool for improving these forecasts. This study analyzed several studies that use AI to predict solar radiation. The most commonly used techniques include neural networks, support vector machines and deep learning. These techniques can identify complex patterns in data and establish relationships between solar radiation to factors such as temperature, humidity and cloud cover. AI models are trained on large sets of weather and solar radiation, enabling them to generate more accurate predictions. The metrics used to evaluate the performance of these models include the root mean square error (RMSE), the coefficient of determination (R^2), and the mean absolute percentage error (MAPE). This review demonstrates the significant potential of AI in enhancing solar radiation forecasting. More accurate predictions can optimize solar energy production, enhance irrigation management, support various other processes dependent on solar radiation.

Keywords: Machine Learning. Deep learning. Prediction model. Artificial Neural Networks.

Resumen: La previsión precisa de la radiación solar es esencial para diversos ámbitos, como la energía solar y la agricultura. La Inteligencia Artificial (IA) ha demostrado ser una poderosa herramienta para mejorar estas previsiones. Este estudio analizó diversas investigaciones que emplean IA para predecir la radiación solar. Las técnicas más comunes incluyen redes neuronales, máquinas de vectores de soporte y aprendizaje profundo. Estas técnicas son capaces de identificar patrones complejos en los datos y relacionar la radiación solar con factores como la temperatura, la humedad y la nubosidad. Los modelos de IA son entrenados con grandes conjuntos de datos meteorológicos y de radiación solar, lo que les permite generar predicciones más precisas. Las métricas empleadas para evaluar el desempeño de estos modelos incluyen el error cuadrático medio (RMSE), el coeficiente de determinación (R^2) y el error porcentual medio absoluto (MAPE). La revisión demuestra que la IA posee un alto potencial para optimizar la predicción de la radiación solar. Predicciones más precisas pueden optimizar la producción de energía solar, mejorar la gestión del riego y contribuir a otros procesos que dependen de la radiación solar.

Palabras clave: Aprendizaje automático. Aprendizaje profundo. Modelo de predicción. Redes neuronales artificiales.

Submetido em: 17/08/2024

Aceito para publicação em: 01/02/2025

Publicado em: 04/02/2025

1. INTRODUÇÃO

A avaliação da incidência de energia solar em uma região específica é crucial para a implementação bem-sucedida de sistemas de energia limpa, como os painéis fotovoltaicos. No entanto, esse processo enfrenta desafios devido à falta de dados confiáveis sobre a radiação solar e o clima local. A obtenção de informações precisas é essencial para determinar a viabilidade da instalação de coletores solares. Uma solução promissora para esse problema é o uso de dados de satélite, que oferecem registros históricos do clima global necessários para a análise da viabilidade do projeto (Alkahtani, Aldhyani, Alsubari, 2023; Rajasundrapandiyaneebanon *et al.*, 2023).

Além disso, a aplicação de inteligência artificial (IA) na previsão da incidência de energia solar tem se mostrado cada vez mais eficaz. O uso de técnicas como Aprendizado de Máquina, Redes Neurais Artificiais, NeuroFuzzy, Aprendizado Profundo e Máquinas de Vetores de Suporte permitem uma análise mais precisa e abrangente dos padrões de radiação solar em uma determinada área. Esses métodos são capazes de processar grandes volumes de dados e identificar correlações complexas entre variáveis climáticas, topográficas e temporais, fornecendo previsões mais confiáveis para orientar a implementação de sistemas de energia solar. A integração dessas tecnologias avançadas não apenas otimiza a eficiência na utilização de energias renováveis, mas também contribui significativamente para a transição para uma matriz energética mais sustentável e amigável ao meio ambiente (Mousavi, Mostafavi, Jiao, 2017; Olatomiwa *et al.*, 2015; Shboul *et al.*, 2021).

Esta revisão sistemática foi conduzida em resposta à escassez de revisões recentes abordando as tecnologias de IA utilizadas globalmente para a previsão eficiente e precisa de dados. A lacuna identificada reflete a necessidade de atualizações que incorporem os avanços mais recentes nesse campo dinâmico. Surpreendentemente, apenas duas revisões, datadas de 2015, realizada na Malásia, e em 2022, realizada na Índia foram encontradas durante a busca bibliográfica. Essa falta de revisões atualizadas ressalta a importância de uma análise abrangente que abarque as inovações mais recentes e sua aplicabilidade em diferentes contextos e regiões. A rápida evolução das tecnologias de IA, especialmente em previsão de dados, destaca a urgência de uma revisão atualizada que possa orientar práticas e políticas baseadas em evidências. Portanto, este estudo visa preencher essa lacuna ao fornecer uma

análise abrangente e atualizada das técnicas de IA utilizadas globalmente para previsão de dados em diversos domínios e aplicações.

É importante destacar que a crescente integração da inteligência artificial nos estudos de previsão solar reflete uma mudança de paradigma nas abordagens tradicionais, que muitas vezes dependem de modelos baseados apenas em dados meteorológicos históricos ou suposições simplificadas. As técnicas de IA permitem uma abordagem mais holística, que incorpora uma ampla gama de variáveis, incluindo dados de satélite, informações geoespaciais e até mesmo dados de comportamento humano, o que contribui para a criação de modelos preditivos mais robustos e adaptáveis. A utilização dessas tecnologias representa, portanto, não apenas uma melhoria técnica, mas também uma transformação na forma como os sistemas de energia solar são planejados e otimizados.

Ademais, o uso de IA também facilita a adaptação de modelos preditivos para diferentes condições locais. Isso é particularmente relevante em um contexto global em que as condições climáticas e geográficas variam consideravelmente. As abordagens baseadas em IA podem ser ajustadas para refletir essas particularidades regionais, promovendo soluções mais eficientes e personalizadas para a geração de energia solar em diversas partes do mundo. Essa flexibilidade é crucial para a expansão de tecnologias de energia renovável, contribuindo para a democratização do acesso à energia limpa e, consequentemente, para um futuro mais sustentável.

2. METODOLOGIA

2.1. Procedimentos metodológicos

Fez-se um estudo aprofundado de artigos de pesquisa e revisão sistemática de literatura nas principais bases científicas, como a ScienceDirect®, Springer e Scopus®.

Foram utilizadas as palavras-chave "prediction", "model", "solar", "radiation", "artificial", "intelligence" em combinação com os critérios de inclusão estabelecidos.

A busca foi realizada nas bases de dados selecionadas, aplicando os filtros de ano, tipo de documento e subárea. No Quadro 1 são apresentados os critérios de inclusão e exclusão aplicados na pesquisa dos artigos.

Quadro 1- Critérios de inclusão e exclusão de artigos

Critério de inclusão		Critério de exclusão
1	Artigos que envolveram o uso da IA para previsão e modelagem da energia solar	Artigos que não focaram em IA para previsão ou modelagem da energia solar Artigos duplicados de outras bases de dados acadêmicas Artigos com mais de 10 anos de publicação
2	Publicações originadas de artigos científicos	
3	Os artigos devem ter sido publicados de 2013 a 2023	
4	Artigos relacionados com IA para previsão ou modelagem solar que tenham maiores relevância	
5	Subárea: Energia	

Fonte: Elaborado pelos autores (2024).

As perguntas norteadoras desta pesquisa foram:

1. Quais técnicas de IA foram utilizadas para previsão da radiação solar?
2. Qual é a natureza dos conjuntos de dados usados na previsão da radiação solar?
3. Quais técnicas de IA se destacaram na precisão da previsão da radiação solar?
4. Quais métricas de desempenho são usadas para avaliar a previsão da radiação solar?

Os resultados da busca foram filtrados conforme os critérios de inclusão..

Na ScienceDirect, foram identificados inicialmente 5.399 resultados, reduzidos para 157 após a aplicação dos filtros de ano, tipo de documento e subárea.

No Scopus, de 238 resultados iniciais, 50 foram mantidos após a filtragem. Na Springer, 10.467 resultados foram reduzidos para 277.

3. DESENVOLVIMENTO

Considerando o problema da pesquisa apresentado, a questão central desta proposta está na variabilidade e imprevisibilidade das condições ambientais que afetam a geração de energia renovável, gerando desafios para o planejamento energético e para a integração eficaz de fontes renováveis na matriz energética.

A hipótese em análise sugere que a aplicação de técnicas de IA, especificamente o aprendizado de máquina e a análise avançada de dados, pode aumentar significativamente a precisão nas previsões de geração de energia renovável.

Há indicativos preliminares na literatura científica de que a IA tem um papel significativo na previsão de energia. Estudos de caso e pesquisas iniciais apontam que técnicas de aprendizado de máquina e análise avançada de dados podem superar limitações dos modelos de previsão energética tradicionais, gerando previsões mais precisas e robustas.

Foram selecionados 25 artigos no Quadro 2, apresentando alguns resultados de pesquisas utilizando IA para estimar a incidência de radiação solar.

Quadro 2- IA para estimar a incidência de radiação solar

N.	Autor e Ano	Título	Local	Citações	JCR	Revista
1	Mousavi, S.M., Mostafavi, E.S., Jiao, P., 2017	Next generation prediction model for daily solar radiation on horizontal surface using a hybrid neural network and simulated annealing method	Irã	68	9.9	Science direct
2	Olatomiwa, L., et al, 2015.	A support vector machine–firefly algorithm-based model for global solar radiation prediction	Nigéria	300	6.0	Scopus
3	Alkahtani, H., Aldhyani, T.H.H., Alsubari, S.N., 2023	Application of Artificial Intelligence Model Solar Radiation Prediction for Renewable Energy Systems	Arábia Saudita	2	3.6	Science direct
4	Sudharshan, K., et al, 2022	Systematic Review on Impact of Different Irradiance Forecasting Techniques for Solar Energy Prediction	Índia	19	3.0	Scopus
5	Shboul, B et al, 2021	A new ANN model for hourly solar radiation and wind speed prediction: A case study over the north & south of the Arabian Peninsula	Jordânia e Omã	40	1.375 7.1	Scopus

6	Chen, Y. et al, 2023	Proactively selection of input variables based on information gain factors for deep learning models in short-term solar irradiance forecasting	China	1	9	Scopus
7	Neshat, M. et al, 2023	Short-term solar radiation forecasting using hybrid deep residual learning and gated LSTM recurrent network with differential covariance matrix adaptation evolution strategy	EUA	8	9	Scopus
8	Alizamir ET AL, 2020	A comparative study of several machine learning based non-linear regression methods in estimating solar radiation: Case studies of the USA and Turkey regions	Turquia e EUA	89	9	Science direct
9	Lima, M. A. F. B. et al, 2020	Improving solar forecasting using Deep Learning and Portfolio Theory integration	Brasil e Espanha	50	9	Science direct
10	Malik, P. et al, 2022	A Review on ANN Based Model for Solar Radiation and Wind Speed Prediction with Real-Time Data	Índia	28	9.3	Springer
11	Rajasundrapandiyanlee banon, T. et al, 2023	Solar Energy Forecasting Using Machine Learning and Deep Learning Techniques	Índia	2	9.3	Springer
12	AL-Rousan, N. & Al-Najjar, H. 2021	A Comparative Assessment of Time Series Forecasting Using NARX and SARIMA to Predict Hourly, Daily, and Monthly Global Solar Radiation Based on Short-Term Dataset	Coréia	3	2.7	Springer
13	Huang, J & Liu, H., 2021	A hybrid decomposition-boosting model for short-term multi-step solar radiation forecasting with NARX neural network	China	12	3.2	Springer

14	Adedeji, P. A. et al., 2023	Evolutionary-based neurofuzzy model with wavelet decomposition for global horizontal irradiance medium-term prediction	África do Sul	2	1.7	Scopus
15	Kamel Aimeur, Saoud, L.S. Endereço: Ghorbani, R. 2020	Short-Term Solar Irradiance Forecasting and Photovoltaic System Management Using Octonion Neural Networks	Argélia	3	11.44	Scopus
16	Tian, C., Huang, M., Zhu, Q., 2018	Hourly solar irradiance forecast based on EMD-LMD-LSSVM joint model	China	32	3.0	Scopus
17	Alizamir, M., et al, 2023	A New Insight for Daily Solar Radiation Prediction by Meteorological Data Using an Advanced Artificial Intelligence Algorithm: Deep Extreme Learning Machine Integrated with Variational Mode Decomposition Technique	Iraque	2	3.3	Scopus
18	Hedar, A.-R., et al, 2021	Hybrid machine learning for solar radiation prediction in reduced feature spaces	Egito	9	3.0	Scopus
19	Zeng, J., Qiao, W., 2013	Short-term solar power prediction using a support vector machine	EUA	408	9	Science direct
20	McCandless, T.C., Haupt, S.E., Young, G.S., 2015	A model tree approach to forecasting solar irradiance variability	EUA	40	6	Science direct
21	Lou, S., et al., 2016	Prediction of diffuse solar irradiance using machine learning and multivariable regression	China	82	10.01	Science direct
22	Khosravi, A., et. al, 2018	Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms	Irã	158	9.7	Science direct
23	Fan, J. et. al, 2018	Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting	China	373	9.9	Science direct

24	Ramedani, Z., et al, 2014	daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China A comparative study between fuzzy linear regression and support vector regression for global solar radiation prediction in Iran	Irã	63	6.0	Science direct
25	Barrera, J.M. et al, 2020	Solar energy prediction model based on artificial neural networks and open data	Espanha	30	3.6	Science direct

Fonte: Elaborado pelos autores (2024).

A presente revisão sistemática analisou uma seleção criteriosa de 25 artigos, onde os resumos foram minuciosamente examinados para extrair informações relevantes sobre as técnicas de previsão, fontes de dados e eficiência das técnicas estudadas. Esta abordagem meticulosa permitiu uma compreensão abrangente das práticas de previsão em uma variedade de contextos e disciplinas. A tabela resultante destaca a diversidade de métodos de previsão empregados, assim como as fontes de dados utilizadas para embasar essas previsões. Além disso, a eficiência das técnicas estudadas emergiu como um tema central, oferecendo insights valiosos sobre as abordagens mais eficazes e as áreas potenciais para melhorias. Este estudo oferece uma visão abrangente do estado atual da pesquisa em previsão da radiação solar utilizando técnicas da Inteligência Artificial em várias localidades ao redor do mundo, fornecendo uma base sólida para futuras investigações e aplicações práticas.

No Quadro 3, a seguir são mostradas as informações relevantes de cada artigo estudado nesta pesquisa, com informações sobre as Técnicas de Previsão, Fonte dos dados utilizados e a Eficiência das técnicas estudadas.

Quadro 3: Panorama Detalhado das Técnicas de Previsão de Radiação Solar: Analisando Técnicas, Fontes de Dados e Eficiência para Previsões Precisas

Autor(s)	Técnicas de Previsão	Fonte de Dados	Eficiência das Técnicas Estudadas
1	Rede Neural Artificial (RNA) e Simulated Annealing (SA)	Observações diárias de uma cidade no Irã (1995-2014)	O modelo RNA/SA demonstrou precisão na previsão da radiação solar diária, superando RNA, Máquinas de Vetores de Suporte (SVM) e modelos existentes de regressão e aprendizado de máquina.
2	Máquinas de Vetores de Suporte (SVM) e Algoritmo Firefly (FFA)	Dados meteorológicos	O modelo SVM-FFA mostrou ser mais preciso em comparação com os modelos de Redes Neurais Artificiais (RNA) e Programação Genética (GP), com base em indicadores como RMSE, R^2 , coeficiente de correlação e MAPE.
3	Redes neurais convolucionais de aprendizado profundo combinado com memória de longo e curto prazo (CNN-LSTM)	Dados meteorológicos coletados de uma estação meteorológica da NASA.	O modelo CNN-LSTM demonstrou superar outros modelos de inteligência artificial, com um coeficiente máximo de determinação (R^2) superior a 95% e um erro quadrático médio mínimo (MSE) de 0,000987 na etapa de teste.
	Modelo de Rede Neural Artificial de Retropropagação Feed-Forward (FBANN).	Dados meteorológicos coletados das regiões Norte e Sul da Península Arábica.	O modelo FBANN proposto atinge altos níveis de precisão, com um coeficiente de correlação (R) superior a 0,96 e um erro percentual médio absoluto (MAPE) que não ultrapassa 3%.
5	Modelo híbrido de aprendizado residual profundo e uma rede recorrente de memória de longo curto prazo. Modelo auto-regressivo (AR), Árvore de decisão de aumento de gradiente (GBDT), Rede Neural Convolucional (CNN), Memória de Longo e Curto Prazo (LSTM) e Memória Convolucional	Dados meteorológicos reais e de radiação de ondas curtas (SRAD1) foram coletados no Lago Michigan, Chicago, EUA. Variáveis adicionais combinadas com Irradiância Global Horizontal (GHI) e inseridas nos modelos mencionados.	As técnicas estudadas foram altamente eficazes, especialmente o modelo híbrido de aprendizagem residual profunda, que superou outros métodos. Uma arquitetura combinando GRU e LSTM também melhorou o desempenho em relação a modelos convolucionais. Um sintonizador de hiperparâmetros evolucionário foi essencial para melhorar a precisão das previsões de radiação solar. Não fornecida no texto.

6	<p>de Longo Curto Prazo (ConvLSTM).</p> <p>Árvore de aumento de gradiente (GBT), Rede Neural Perceptron Multicamadas (MLPNN), Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS) baseados em agrupamento fuzzy c-means (ANFIS-FCM) e agrupamento subtrativo (ANFIS-SC), Spline de Regressão Adaptativa Multivariada (MARS), Árvore de Classificação e Regressão (CART). Modelo híbrido de aprendizado residual profundo e uma rede recorrente de memória de longo curto prazo.</p>	<p>Dados de radiação solar, Dados climáticos, incluindo velocidade do vento, temperatura máxima do ar, temperatura mínima do ar e umidade relativa. de duas estações em diferentes locais, Turquia e EUA. Dados meteorológicos reais e de radiação de ondas curtas (SRAD1) foram coletados no Lago Michigan, Chicago, EUA.</p>	<p>O modelo GBT apresentou melhor desempenho em comparação com MLPNN, ANFIS, MARS e CART na modelagem da radiação solar, conforme avaliado pelos indicadores estatísticos: raiz do erro quadrático médio (RMSE), coeficiente de correlação (R), erro médio absoluto (MAE) e coeficiente de eficiência Nash-Sutcliffe (NS). As técnicas estudadas foram altamente eficazes, especialmente o modelo híbrido de aprendizagem residual profunda, que superou outros métodos. Uma arquitetura combinando GRU e LSTM também melhorou o desempenho em relação a modelos convolucionais. Um sintonizador de hiperparâmetros evolucionário foi essencial para melhorar a precisão das previsões de radiação solar.</p>
7	<p>Deep Learning (DL), Multilayer Perceptron, Função de Base Radial, Regressão de Vetores de Suporte. Árvore de aumento de gradiente (GBT), Rede Neural Perceptron Multicamadas (MLPNN), Sistemas de Inferência Neuro-Fuzzy Adaptativos (ANFIS) baseados em agrupamento fuzzy c-means (ANFIS-FCM) e agrupamento subtrativo (ANFIS-SC), Spline de Regressão Adaptativa Multivariada (MARS), Árvore de Classificação e Regressão (CART).</p>	<p>Dados de irradiação solar da Espanha e do Brasil. Dados de radiação solar, Dados climáticos, incluindo velocidade do vento, temperatura máxima do ar, temperatura mínima do ar e umidade relativa. de duas estações em diferentes locais, Turquia e EUA.</p>	<p>O Erro Percentual Médio Absoluto (MAPE) para previsões usando Deep Learning foi de 6,89% para os dados da Espanha e 6,08% para os dados do Brasil. Já a integração proposta, denominada PrevPT, teve um MAPE de 5,36% para os dados da Espanha e 4,52% para os dados do Brasil. Em ambos os casos, os resultados de Deep Learning e PrevPT foram melhores do que as outras técnicas utilizadas. O modelo GBT apresentou melhor desempenho em comparação com MLPNN, ANFIS, MARS e CART na modelagem da radiação solar, conforme avaliado pelos indicadores estatísticos: raiz do erro quadrático médio (RMSE), coeficiente de correlação (R), erro médio absoluto (MAE) e</p>

8	<p>Redes neurais artificiais (RP), incluindo os algoritmos gradiente RP, Levenberg Marquardt (LM), gradiente de atualização Polak-Ribière (CGP) e OSS (secante de um passo).Deep Learning (DL), Multilayer Perceptron, Função de Base Radial, Regressão de Vetores de Suporte.</p>	<p>Dados ambientais, tais como temperatura, umidade relativa, radiação solar, chuva e velocidade do vento.Dados de irradiação solar da Espanha e do Brasil.</p>	<p>coeficiente de eficiência Nash-Sutcliffe (NS).</p> <p>Não há informações específicas sobre a eficiência das técnicas estudadas.O Erro Percentual Médio Absoluto (MAPE) para previsões usando Deep Learning foi de 6,89% para os dados da Espanha e 6,08% para os dados do Brasil. Já a integração proposta, denominada PrevPT, teve um MAPE de 5,36% para os dados da Espanha e 4,52% para os dados do Brasil. Em ambos os casos, os resultados de Deep Learning e PrevPT foram melhores do que as outras técnicas utilizadas.</p>
9	<p>Modelo de previsão baseado na radiação solar global de curto prazo, utilizando a rede neural exógena autorregressiva não linear (NARX) e a média móvel integrada autorregressiva sazonal (SARIMA).Abordagens de aprendizado de máquina e aprendizado profundo para a previsão de energia solar.Redes neurais artificiais (RP), incluindo os algoritmos gradiente RP, Levenberg Marquardt (LM), gradiente de atualização Polak-Ribière (CGP) e OSS (secante de um passo).</p>	<p>Radiação solar horária global de Seul. Coréia do Sul.Dados relacionados à radiação solar global (GSR) e outros dados meteorológicos relevantes.Dados ambientais, tais como temperatura, umidade relativa, radiação solar, chuva e velocidade do vento.</p>	<p>O modelo NARX obteve um coeficiente de determinação (R^2) de 0,95 e um RMSE de 0,23 MJ/m² para dados horários, mostrando eficiência na previsão da radiação solar. Os melhores resultados para previsão diária e mensal foram alcançados com o modelo NARX e dados horários.O texto se concentra em fornecer uma visão geral das abordagens de previsão e não detalha os métodos de pré-processamento de dados.</p> <p>Não há informações específicas sobre a eficiência das técnicas estudadas.</p>
10	<p>Um novo modelo de aumento de decomposição usando inteligência artificial, composto por decomposição de sinal (EWT), rede neural (NARX), Adaboost e ARIMA.Modelo de</p>	<p>Três conjuntos de dados reais de radiação solar de Changde, China.Radiação solar horária global de Seul. Coréia do Sul.Dados relacionados à</p>	<p>O texto menciona que o modelo proposto apresenta o melhor desempenho dentre todos os modelos avaliados, mas não fornece métricas específicas de eficiência, como coeficiente de determinação (R^2) ou erro médio quadrático (RMSE).O modelo NARX obteve um coeficiente de</p>

	<p>previsão baseado na radiação solar global de curto prazo, utilizando a rede neural exógena autorregressiva não linear (NARX) e a média móvel integrada autorregressiva sazonal (SARIMA). Abordagens de aprendizado de máquina e aprendizado profundo para a previsão de energia solar.</p>	<p>radiação solar global (GSR) e outros dados meteorológicos relevantes.</p>	<p>determinação (R^2) de 0,95 e um RMSE de 0,23 MJ/m² para dados horários, mostrando eficiência na previsão da radiação solar. Os melhores resultados para previsão diária e mensal foram alcançados com o modelo NARX e dados horários. O texto se concentra em fornecer uma visão geral das abordagens de previsão e não detalha os métodos de pré-processamento de dados.</p>
11	<p>O estudo investiga o sistema de inferência neurofuzzy adaptativo autônomo (ANFIS) e seu híbrido com algoritmos evolutivos (algoritmo genético - GA e otimização de enxame de partículas - PSO), em uma escala temporal de médio prazo, além da decomposição wavelet. Um novo modelo de aumento de decomposição usando inteligência artificial, composto por decomposição de sinal (EWT), rede neural (NARX), Adaboost e ARIMA. Modelo de previsão baseado na radiação solar global de curto prazo, utilizando a rede neural exógena autorregressiva não linear (NARX) e a média móvel integrada autorregressiva sazonal (SARIMA).</p>	<p>Dados de séries temporais de irradiância horizontal global. Três conjuntos de dados reais de radiação solar de Changde, China. Radiação solar horária global de Seul. Coréia do Sul.</p>	<p>Os modelos autônomos de aprendizado de máquina, principalmente o LSSVM autônomo, mostraram-se mais eficientes e precisos em comparação com os modelos híbridos que incluíam a decomposição wavelet. O texto menciona que o modelo proposto apresenta o melhor desempenho dentre todos os modelos avaliados, mas não fornece métricas específicas de eficiência, como coeficiente de determinação (R^2) ou erro médio quadrático (RMSE). O modelo NARX obteve um coeficiente de determinação (R^2) de 0,95 e um RMSE de 0,23 MJ/m² para dados horários, mostrando eficiência na previsão da radiação solar. Os melhores resultados para previsão diária e mensal foram alcançados com o modelo NARX e dados horários.</p>
12	<p>O artigo investiga a utilização da rede neural octonion para prever a irradiância solar de curto</p>	<p>Dados de irradiância solar. Dados de séries temporais de irradiância horizontal</p>	<p>O texto não fornece métricas específicas de eficiência das técnicas estudadas. No entanto, destaca que o método proposto é</p>

13	<p>prazo.O estudo investiga o sistema de inferência neurofuzzy adaptativo autônomo (ANFIS) e seu híbrido com algoritmos evolutivos (algoritmo genético - GA e otimização de enxame de partículas - PSO), em uma escala temporal de médio prazo, além da decomposição wavelet.Um novo modelo de aumento de decomposição usando inteligência artificial, composto por decomposição de sinal (EWT), rede neural (NARX), Adaboost e ARIMA.</p> <p>O artigo apresenta um novo modelo de previsão de radiação solar horária baseado na decomposição em modo empírico (EMD) e decomposição média local (LMD) combinada com o método de aprendizado de máquina LSSVM (Máquina de Vetores de Suporte de Mínimos Quadrados Únicos).O artigo investiga a utilização da rede neural octonion para prever a irradiância solar de curto prazo.O estudo investiga o sistema de inferência neurofuzzy adaptativo autônomo (ANFIS) e seu híbrido com algoritmos evolutivos (algoritmo genético - GA e otimização de enxame de partículas - PSO), em</p>	<p>global.Três conjuntos de dados reais de radiação solar de Changde, China.</p> <p>Séries temporais de radiação solar horária.Dados de irradiância solar.Dados de séries temporais de irradiância horizontal global.</p>	<p>promissor para lidar com o problema de previsão de irradiância solar e menciona benefícios na quantidade de módulos utilizados e na energia solicitada da bateria em sistemas fotovoltaicos autônomos.Os modelos autônomos de aprendizado de máquina, principalmente o LSSVM autônomo, mostraram-se mais eficientes e precisos em comparação com os modelos híbridos que incluíam a decomposição wavelet.O texto menciona que o modelo proposto apresenta o melhor desempenho dentre todos os modelos avaliados, mas não fornece métricas específicas de eficiência, como coeficiente de determinação (R^2) ou erro médio quadrático (RMSE).</p> <p>O novo modelo de previsão mostrou um melhor desempenho do que o modelo único, com uma melhoria na raiz média do erro quadrático médio em 24,59%.O texto não fornece métricas específicas de eficiência das técnicas estudadas. No entanto, destaca que o método proposto é promissor para lidar com o problema de previsão de irradiância solar e menciona benefícios na quantidade de módulos utilizados e na energia solicitada da bateria em sistemas fotovoltaicos autônomos.Os modelos autônomos de aprendizado de máquina, principalmente o LSSVM autônomo, mostraram-se mais eficientes e precisos em comparação com os modelos híbridos que incluíam a decomposição wavelet.</p>
----	--	---	--

14

uma escala temporal de médio prazo, além da decomposição wavelet.

O estudo desenvolveu treze modelos diferentes de inteligência artificial, incluindo splines de regressão adaptativa multivariada (MARS), máquina de aprendizagem extrema (ELM), máquina de aprendizagem extrema Kernel (KELM), máquina de aprendizagem extrema sequencial online (OSELM), máquina de aprendizagem extrema otimizada (OPELM), máquina de aprendizagem extrema robusta e atípica (ORELM), máquina de aprendizagem extrema profunda (DELM), e suas versões combinadas com decomposição de modo variacional (VMD) como modelos integrados para estimativa de radiação solar. O artigo apresenta um novo modelo de previsão de radiação solar horária baseado na decomposição em modo empírico (EMD) e decomposição média local (LMD) combinada com o método de aprendizado de máquina LSSVM (Máquina de Vetores de Suporte de Mínimos Quadrados Únicos). O artigo investiga a utilização da rede neural octonion para prever a irradiância solar de curto prazo.

Dados meteorológicos diários de 2017 a 2018 das estações Darbandikhan e Dukan, no Iraque. Séries temporais de radiação solar horária. Dados de irradiância solar.

O modelo VMD-DELM proposto melhorou consideravelmente a precisão da simulação da previsão diária da radiação solar em comparação com os modelos autônomos. Houve uma melhoria média em termos de RMSE para a estação Darbandikhan entre 13,3% e 48,25%, e para a estação Dukan entre 5,22% e 40,33%. O novo modelo de previsão mostrou um melhor desempenho do que o modelo único, com uma melhoria na raiz média do erro quadrático médio em 24,59%. O texto não fornece métricas específicas de eficiência das técnicas estudadas. No entanto, destaca que o método proposto é promissor para lidar com o problema de previsão de irradiância solar e menciona benefícios na quantidade de módulos utilizados e na energia solicitada da bateria em sistemas fotovoltaicos autônomos.

<p>15</p> <p>O artigo propõe novas abordagens híbridas de aprendizado de máquina que exploram dados numéricos auxiliares, combinando modelos numéricos de previsão do tempo (NWP) com modelos de inteligência artificial. Diferentes modelos de aprendizado de máquina são utilizados, incluindo técnicas de seleção, classificação e regressão de recursos. O estudo desenvolveu treze modelos diferentes de inteligência artificial, incluindo splines de regressão adaptativa multivariada (MARS), máquina de aprendizagem extrema (ELM), máquina de aprendizagem extrema Kernel (KELM), máquina de aprendizagem extrema sequencial online (OSELM), máquina de aprendizagem extrema otimizada (OPELM), máquina de aprendizagem extrema robusta e atípica (ORELM), máquina de aprendizagem extrema profunda (DELM), e suas versões combinadas com decomposição de modo variacional (VMD) como modelos integrados para estimativa de radiação solar. O artigo apresenta um novo modelo de previsão de radiação solar horária baseado na decomposição em modo</p>	<p>Dados de radiação solar e outros parâmetros relevantes para a previsão do tempo, coletados em diferentes regiões da Arábia Saudita. Dados meteorológicos diários de 2017 a 2018 das estações Darbandikhan e Dukan, no Iraque. Séries temporais de radiação solar horária.</p>	<p>Os modelos híbridos propostos apresentaram melhorias significativas na precisão da previsão em comparação com modelos numéricos e de aprendizado de máquina tradicionais. A redução de recursos alcançou taxas de classificação mais altas de até 8,5% e melhorias na raiz média do erro quadrático médio de até 5,6% e em valores médios de erro absoluto de até 8,3%. O modelo VMD-DELM proposto melhorou consideravelmente a precisão da simulação da previsão diária da radiação solar em comparação com os modelos autônomos. Houve uma melhoria média em termos de RMSE para a estação Darbandikhan entre 13,3% e 48,25%, e para a estação Dukan entre 5,22% e 40,33%. O novo modelo de previsão mostrou um melhor desempenho do que o modelo único, com uma melhoria na raiz média do erro quadrático médio em 24,59%.</p>
---	--	--

16

empírico (EMD) e decomposição média local (LMD) combinada com o método de aprendizado de máquina LSSVM (Máquina de Vetores de Suporte de Mínimos Quadrados Únicos).

O modelo proposto é baseado em Máquina de Vetores de Suporte (SVM) de Mínimos Quadrados (LS) para previsão de energia solar de curto prazo (SPP). O artigo propõe novas abordagens híbridas de aprendizado de máquina que exploram dados numéricos auxiliares, combinando modelos numéricos de previsão do tempo (NWP) com modelos de inteligência artificial. Diferentes modelos de aprendizado de máquina são utilizados, incluindo técnicas de seleção, classificação e regressão de recursos. O estudo desenvolveu treze modelos diferentes de inteligência artificial, incluindo splines de regressão adaptativa multivariada (MARS), máquina de aprendizagem extrema (ELM), máquina de aprendizagem extrema Kernel (KELM), máquina de aprendizagem extrema sequencial online (OSELM), máquina de aprendizagem extrema otimizada (OPELM),

Os dados foram obtidos do Banco Nacional de Radiação Solar (NSRDB). Dados de radiação solar e outros parâmetros relevantes para a previsão do tempo, coletados em diferentes regiões da Arábia Saudita. Dados meteorológicos diários de 2017 a 2018 das estações Darbandikhan e Dukan, no Iraque.

Os resultados das simulações computacionais mostram que o modelo proposto superou significativamente um modelo autorregressivo de referência (AR) e também obteve melhores resultados do que um modelo baseado em rede neural de função de base radial (RBFNN) em termos de precisão de previsão. Além disso, a utilização da transmissividade atmosférica como entrada do modelo foi considerada superior às funções sigmóides para normalização de dados. Também foi constatado que a inclusão de variáveis meteorológicas adicionais, especialmente a cobertura do céu, melhorou a precisão do SPP. Os modelos híbridos propostos apresentaram melhorias significativas na precisão da previsão em comparação com modelos numéricos e de aprendizado de máquina tradicionais. A redução de recursos alcançou taxas de classificação mais altas de até 8,5% e melhorias na raiz média do erro quadrático médio de até 5,6% e em valores médios de erro absoluto de até 8,3%. O modelo VMD-DELM proposto melhorou consideravelmente a precisão da simulação da previsão diária da radiação solar em comparação com os modelos autônomos. Houve uma melhoria média em termos de RMSE para a estação Darbandikhan entre 13,3% e 48,25%, e para a

17	<p>máquina de aprendizagem extrema robusta e atípica (ORELM), máquina de aprendizagem extrema profunda (DELM), e suas versões combinadas com decomposição de modo variacional (VMD) como modelos integrados para estimativa de radiação solar.</p> <p>A técnica de previsão proposta é uma árvore modelo com uma opção de vizinho mais próximo para prever diretamente a variabilidade da irradiância solar. O modelo proposto é baseado em Máquina de Vetores de Suporte (SVM) de Mínimos Quadrados (LS) para previsão de energia solar de curto prazo (SPP). O artigo propõe novas abordagens híbridas de aprendizado de máquina que exploram dados numéricos auxiliares, combinando modelos numéricos de previsão do tempo (NWP) com modelos de inteligência artificial. Diferentes modelos de aprendizado de máquina são utilizados, incluindo técnicas de seleção, classificação e regressão de recursos.</p> <p>Os dados incluem medidas de Irradiância Horizontal Global (GHI) em diferentes locais no Vale do Sacramento, utilizados para calcular a variabilidade temporal e espacial da irradiância. Os dados foram obtidos do Banco Nacional de Radiação Solar (NSRDB). Dados de radiação solar e outros parâmetros relevantes para a previsão do tempo, coletados em diferentes regiões da Arábia Saudita.</p>	<p>estação Dukan entre 5,22% e 40,33%.</p> <p>A técnica da árvore modelo reduziu o erro médio absoluto da previsão da variabilidade entre 10% e 55% em comparação ao uso de valores médios climatológicos do desvio padrão do IGF temporal e espacial. Além disso, um experimento de negação de dados mostrou que a adição de observações meteorológicas de superfície melhorou a habilidade de previsão da árvore modelo em aproximadamente 10%. Os resultados das simulações computacionais mostram que o modelo proposto superou significativamente um modelo autorregressivo de referência (AR) e também obteve melhores resultados do que um modelo baseado em rede neural de função de base radial (RBFNN) em termos de precisão de previsão. Além disso, a utilização da transmissividade atmosférica como entrada do modelo foi considerada superior às funções sigmóides para normalização de dados. Também foi constatado que a inclusão de variáveis meteorológicas adicionais, especialmente a cobertura do céu, melhorou a precisão do SPP. Os modelos híbridos propostos apresentaram melhorias significativas na precisão da previsão em comparação com modelos numéricos e de</p>
----	--	---

18

Um algoritmo de aprendizado de máquina, especificamente regressão logística, foi empregado para prever a irradiância horizontal difusa no céu. A técnica de previsão proposta é uma árvore modelo com uma opção de vizinho mais próximo para prever diretamente a variabilidade da irradiância solar. O modelo proposto é baseado em Máquina de Vetores de Suporte (SVM) de Mínimos Quadrados (LS) para previsão de energia solar de curto prazo (SPP).

Os dados foram coletados em Hong Kong de 2008 a 2013 e incluem medições de irradiância solar horizontal global, de feixe direto e difusa no céu. Os dados incluem medidas de Irradiância Horizontal Global (GHI) em diferentes locais no Vale do Sacramento, utilizados para calcular a variabilidade temporal e espacial da irradiância. Os dados foram obtidos do Banco Nacional de Radiação Solar (NSRDB).

aprendizado de máquina tradicionais. A redução de recursos alcançou taxas de classificação mais altas de até 8,5% e melhorias na raiz média do erro quadrático médio de até 5,6% e em valores médios de erro absoluto de até 8,3%.

O erro absoluto médio (MAE) da regressão logística utilizando os preditores mencionados foi inferior a 21,5 W/m² e 30 W/m² para Hong Kong e Denver, EUA, respectivamente. A técnica da árvore modelo reduziu o erro médio absoluto da previsão da variabilidade entre 10% e 55% em comparação ao uso de valores médios climatológicos do desvio padrão do IGF temporal e espacial. Além disso, um experimento de negação de dados mostrou que a adição de observações meteorológicas de superfície melhorou a habilidade de previsão da árvore modelo em aproximadamente 10%. Os resultados das simulações computacionais mostram que o modelo proposto superou significativamente um modelo autorregressivo de referência (AR) e também obteve melhores resultados do que um modelo baseado em rede neural de função de base radial (RBFNN) em termos de precisão de previsão. Além disso, a utilização da transmissividade atmosférica como entrada do modelo foi considerada superior às funções sigmóides para normalização de dados. Também foi constatado que a inclusão de variáveis meteorológicas adicionais, especialmente a cobertura do céu, melhorou a precisão do SPP.

19	<p>Foram utilizados algoritmos de aprendizado de máquina, incluindo redes neurais feed-forward multicamadas (MLFFNN), redes neurais de função de base radial (RBFNN), regressão vetorial de suporte (SVR), sistema de inferência fuzzy (FIS) e sistema de inferência neuro-fuzzy adaptativo (ANFIS). Um algoritmo de aprendizado de máquina, especificamente regressão logística, foi empregado para prever a irradiância horizontal difusa no céu. A técnica de previsão proposta é uma árvore modelo com uma opção de vizinho mais próximo para prever diretamente a variabilidade da irradiância solar.</p>	<p>Utiliza hora local, temperatura, pressão, velocidade do vento e umidade relativa como variáveis de entrada. Os dados foram coletados em Hong Kong de 2008 a 2013 e incluem medições de irradiância solar horizontal global, de feixe direto e difusa no céu. Os dados incluem medidas de Irradiância Horizontal Global (GHI) em diferentes locais no Vale do Sacramento, utilizados para calcular a variabilidade temporal e espacial da irradiância.</p>	<p>Os resultados indicam que, para os modelos N1, SVR e MLFFNN apresentam desempenho máximo para prever a irradiância solar com coeficientes de correlação (R) de 0,9999 e 0,9795, respectivamente. Para os modelos N2, SVR, MLFFNN e ANFIS relataram um coeficiente de correlação superior a 0,95 para o conjunto de dados de teste. O erro absoluto médio (MAE) da regressão logística utilizando os preditores mencionados foi inferior a 21,5 W/m² e 30 W/m² para Hong Kong e Denver, EUA, respectivamente. A técnica da árvore modelo reduziu o erro médio absoluto da previsão da variabilidade entre 10% e 55% em comparação ao uso de valores médios climatológicos do desvio padrão do IGF temporal e espacial. Além disso, um experimento de negação de dados mostrou que a adição de observações meteorológicas de superfície melhorou a habilidade de previsão da árvore modelo em aproximadamente 10%.</p>
20	<p>Foram utilizados dois algoritmos de aprendizado de máquina: Support Vector Machine (SVM) e Extreme Gradient Boosting (XGBoost). Foram utilizados algoritmos de aprendizado de máquina, incluindo redes neurais feed-forward multicamadas (MLFFNN), redes neurais de função de base radial (RBFNN), regressão vetorial de suporte (SVR), sistema de inferência fuzzy (FIS) e sistema de inferência neuro-fuzzy adaptativo</p>	<p>Os dados consistem em informações diárias de radiação solar global, temperaturas do ar, precipitação e radiação solar extraterrestre. Durante os períodos de 1966–2000 e 2001–2015 de três estações de radiação na região subtropical úmida da China. Utiliza hora local, temperatura, pressão, velocidade do vento e umidade relativa como variáveis de</p>	<p>Os modelos de aprendizado de máquina (SVM e XGBoost) superaram os quatro modelos empíricos selecionados. O desempenho dos modelos de aprendizado de máquina foi melhorado em 5,9–12,2% para a fase de treinamento e em 8,0–11,5% para a fase de teste em termos de RMSE quando as informações de precipitação foram incluídas posteriormente. O modelo XGBoost apresentou uma velocidade de computação muito maior que o modelo SVM, com aumento médio de 6,3% no RMSE em comparação com 10,5% do SVM. Os resultados indicam que, para os modelos N1, SVR e MLFFNN apresentam desempenho</p>

	<p>(ANFIS).Um algoritmo de aprendizado de máquina, especificamente regressão logística, foi empregado para prever a irradiância horizontal difusa no céu.</p>	<p>entrada.Os dados foram coletados em Hong Kong de 2008 a 2013 e incluem medições de irradiância solar horizontal global, de feixe direto e difusa no céu.</p>	<p>máximo para prever a irradiância solar com coeficientes de correlação (R) de 0,9999 e 0,9795, respectivamente. Para os modelos N2, SVR, MLFFNN e ANFIS relataram um coeficiente de correlação superior a 0,95 para o conjunto de dados de teste.O erro absoluto médio (MAE) da regressão logística utilizando os preditores mencionados foi inferior a 21,5 W/m² e 30 W/m² para Hong Kong e Denver, EUA, respectivamente.</p>
21	<p>Foram desenvolvidos três modelos distintos para prever a radiação solar global (GSR) na província de Teerão, Irã. As técnicas utilizadas foram regressão linear difusa (FLR), função de base polinomial (SVR_poly) e função de base radial (SVR_rbf) como função kernel da regressão vetorial de suporte (SVR).Foram utilizados dois algoritmos de aprendizado de máquina: Support Vector Machine (SVM) e Extreme Gradient Boosting (XGBoost).Foram utilizados algoritmos de aprendizado de máquina, incluindo redes neurais feed-forward multicamadas (MLFFNN), redes neurais de função de base radial (RBFNN), regressão vetorial de suporte (SVR), sistema de inferência fuzzy (FIS) e sistema de inferência neuro-fuzzy adaptativo (ANFIS).</p>	<p>Os dados meteorológicos foram obtidos da única estação na região de estudo, que registra a radiação solar global (GSR) e outras variáveis meteorológicas relevantes.Os dados consistem em informações diárias de radiação solar global, temperaturas do ar, precipitação e radiação solar extraterrestre. durante os períodos de 1966–2000 e 2001–2015 de três estações de radiação na região subtropical úmida da China.Utiliza hora local, temperatura, pressão, velocidade do vento e umidade relativa como variáveis de entrada.</p>	<p>Os resultados experimentais mostram que os modelos SVR_poly e SVR_rbf apresentaram maior precisão preditiva e capacidade de generalização em comparação com o modelo FLR. O erro quadrático médio calculado e o coeficiente de correlação revelaram que o modelo SVR_rbf teve um bom desempenho na previsão de GSR.Os modelos de aprendizado de máquina (SVM e XGBoost) superaram os quatro modelos empíricos selecionados. O desempenho dos modelos de aprendizado de máquina foi melhorado em 5,9–12,2% para a fase de treinamento e em 8,0–11,5% para a fase de teste em termos de RMSE quando as informações de precipitação foram incluídas posteriormente. O modelo XGBoost apresentou uma velocidade de computação muito maior que o modelo SVM, com aumento médio de 6,3% no RMSE em comparação com 10,5% do SVM.Os resultados indicam que, para os modelos N1, SVR e MLFFNN apresentam desempenho máximo para prever a irradiância solar com coeficientes de correlação (R) de 0,9999 e 0,9795, respectivamente. Para os modelos N2, SVR, MLFFNN e ANFIS</p>

22	<p>Utilização de Redes Neurais Artificiais (RNA) para prever a produção de energia de fontes sustentáveis ao longo do ano para um determinado local.</p> <p>Análise de diferentes fatores que afetam a previsão da produção de energia, como variação da velocidade do vento e da luz do dia ao longo do ano. Foram desenvolvidos três modelos distintos para prever a radiação solar global (GSR) na província de Teerão, Irã. As técnicas utilizadas foram regressão linear difusa (FLR), função de base polinomial (SVR_poly) e função de base radial (SVR_rbf) como função kernel da regressão vetorial de suporte (SVR). Foram utilizados dois algoritmos de aprendizado de máquina: Support Vector Machine (SVM) e Extreme Gradient Boosting (XGBoost).</p>	<p>Fontes de dados abertos.</p> <p>Sensores e instalações de Internet das Coisas (IoT) distribuídas por toda a Europa. Os dados meteorológicos foram obtidos da única estação na região de estudo, que registra a radiação solar global (GSR) e outras variáveis meteorológicas relevantes. Os dados consistem em informações diárias de radiação solar global, temperaturas do ar, precipitação e radiação solar extraterrestre. durante os períodos de 1966–2000 e 2001–2015 de três estações de radiação na região subtropical úmida da China.</p>	<p>relataram um coeficiente de correlação superior a 0,95 para o conjunto de dados de teste.</p> <p>A solução proposta fornece uma camada de abstração focada na produção de energia, em vez de dados de radiação.</p> <p>Testes mostraram que a proposta melhora a precisão da previsão, obtendo um erro quadrático médio (MSE) menor de 0,040 em comparação com um MSE de 0,055 de outras propostas na literatura. Os resultados experimentais mostram que os modelos SVR_poly e SVR_rbf apresentaram maior precisão preditiva e capacidade de generalização em comparação com o modelo FLR. O erro quadrático médio calculado e o coeficiente de correlação revelaram que o modelo SVR_rbf teve um bom desempenho na previsão de GSR. Os modelos de aprendizado de máquina (SVM e XGBoost) superaram os quatro modelos empíricos selecionados. O desempenho dos modelos de aprendizado de máquina foi melhorado em 5,9–12,2% para a fase de treinamento e em 8,0–11,5% para a fase de teste em termos de RMSE quando as informações de precipitação foram incluídas posteriormente. O modelo XGBoost apresentou uma velocidade de computação muito maior que o modelo SVM, com aumento médio de 6,3% no RMSE em comparação com 10,5% do SVM.</p>
23	<p>Utilização de Redes Neurais Artificiais (RNA) para prever a produção de energia de fontes sustentáveis ao longo do</p>	<p>Fontes de dados abertos.</p> <p>Sensores e instalações de Internet das Coisas (IoT) distribuídas por</p>	<p>A solução proposta fornece uma camada de abstração focada na produção de energia, em vez de dados de radiação.</p> <p>Testes mostraram que a proposta melhora a precisão da previsão,</p>

	<p>ano para um determinado local.</p> <p>Análise de diferentes fatores que afetam a previsão da produção de energia, como variação da velocidade do vento e da luz do dia ao longo do ano. Foram desenvolvidos três modelos distintos para prever a radiação solar global (GSR) na província de Teerão, Irã. As técnicas utilizadas foram regressão linear difusa (FLR), função de base polinomial (SVR_poly) e função de base radial (SVR_rbf) como função kernel da regressão vetorial de suporte (SVR).</p>	<p>toda a Europa. Os dados meteorológicos foram obtidos da única estação na região de estudo, que registra a radiação solar global (GSR) e outras variáveis meteorológicas relevantes.</p>	<p>obtendo um erro quadrático médio (MSE) menor de 0,040 em comparação com um MSE de 0,055 de outras propostas na literatura. Os resultados experimentais mostram que os modelos SVR_poly e SVR_rbf apresentaram maior precisão preditiva e capacidade de generalização em comparação com o modelo FLR. O erro quadrático médio calculado e o coeficiente de correlação revelaram que o modelo SVR_rbf teve um bom desempenho na previsão de GSR.</p>
24	<p>Utilização de Redes Neurais Artificiais (RNA) para prever a produção de energia de fontes sustentáveis ao longo do ano para um determinado local.</p> <p>Análise de diferentes fatores que afetam a previsão da produção de energia, como variação da velocidade do vento e da luz do dia ao longo do ano.</p>	<p>Fontes de dados abertos.</p> <p>Sensores e instalações de Internet das Coisas (IoT) distribuídas por toda a Europa.</p>	<p>A solução proposta fornece uma camada de abstração focada na produção de energia, em vez de dados de radiação.</p> <p>Testes mostraram que a proposta melhora a precisão da previsão, obtendo um erro quadrático médio (MSE) menor de 0,040 em comparação com um MSE de 0,055 de outras propostas na literatura.</p>
25			

Fonte: Elaborado pelos autores (2024).

1. Quais técnicas de IA foram utilizadas para previsão da radiação solar?

Na análise das técnicas de Inteligência Artificial (IA) empregadas na previsão da radiação solar, podemos categorizá-las em diferentes grupos com base em suas abordagens e características. Uma das categorias inclui abordagens baseadas em redes neurais, como a

RNA/ANN (Rede Neural Artificial) combinada com o algoritmo SA (Simulated Annealing), que se destaca pela sua capacidade de aprender padrões complexos nos dados. Além disso, as Máquinas de Vetores de Suporte (SVM) em conjunto com o algoritmo Firefly (FFA) representam outra categoria, aproveitando a capacidade das SVMs em lidar com relações complexas entre variáveis. Uma terceira categoria abrange técnicas de aprendizado profundo, como as Redes Neurais Convolucionais de Longo e Curto Prazo (CNN-LSTM), que são eficazes na captura de informações espaciais e temporais nos dados de radiação solar. Outras categorias incluem modelos híbridos, como o FBANN (Rede Neural Artificial de Retropropagação Feed-Forward), e modelos baseados em ensemble, como o Extreme Gradient Boosting (XGBoost), que combinam múltiplos modelos para melhorar a precisão das previsões. Adicionalmente, técnicas como ARIMA (média móvel integrada autorregressiva), ANFIS (sistema de inferência neurofuzzy adaptativo autônomo) e LSSVM (Máquina de Vetores de Suporte de Mínimos Quadrados Únicos) representam outras abordagens utilizadas na previsão da radiação solar, cada uma com suas próprias vantagens e aplicações específicas dentro do contexto da IA. Essa variedade de técnicas reflete a complexidade do problema de previsão da radiação solar e a necessidade de abordagens diversificadas para lidar com diferentes aspectos e desafios dos dados envolvidos.

2. Qual é a natureza dos conjuntos de dados usados na previsão da radiação solar?

A natureza dos conjuntos de dados utilizados na previsão da radiação solar é predominantemente composta por dados meteorológicos reais, que abrangem variáveis como temperatura, umidade relativa, radiação solar, chuva e velocidade do vento. Além disso, os conjuntos de dados frequentemente incluem medidas específicas de radiação solar, como radiação de ondas curtas e radiação solar global. Esses conjuntos de dados são fundamentais para alimentar os modelos de inteligência artificial (IA) empregados na previsão da radiação solar, pois fornecem informações detalhadas sobre as condições climáticas e ambientais que influenciam a quantidade de radiação solar disponível em determinado local e momento. Ao integrar esses dados variados e abrangentes, os modelos de IA podem aprender padrões complexos e desenvolver previsões precisas da radiação solar, auxiliando em diversas aplicações, como energia solar, agricultura e planejamento urbano.

3. Quais técnicas de IA se destacaram na precisão da previsão da radiação solar?

Dentre as técnicas de previsão da radiação solar investigadas, foram identificados vários modelos que se destacaram em termos de desempenho estatístico. A Rede Neural Artificial (RNA/ANN) combinada com o algoritmo SA (Simulated Annealing) demonstrou ser uma das abordagens mais eficazes. Isso se deve à capacidade das redes neurais artificiais em capturar padrões complexos nos dados de radiação solar, enquanto o Simulated Annealing ajuda a otimizar os parâmetros do modelo para melhor ajuste aos dados observados, resultando em previsões mais precisas.

Outro modelo que se destacou foi a combinação de Máquinas de Vetores de Suporte (SVM) com o algoritmo Firefly (FFA). As SVMs são conhecidas por sua eficácia na modelagem de relações complexas entre variáveis, enquanto o algoritmo Firefly é utilizado para otimizar os hiperparâmetros do modelo SVM. Essa combinação resultou em previsões precisas de radiação solar, conforme evidenciado pelos indicadores de desempenho, incluindo RMSE, R^2 , coeficiente de correlação e MAPE.

Além disso, a arquitetura CNN-LSTM, que combina Redes Neurais Convolucionais (CNN) com Memória de Longo e Curto Prazo (LSTM), também se destacou na previsão da radiação solar. As CNNs são eficazes na extração de características espaciais dos dados, enquanto as LSTMs são capazes de capturar dependências temporais. Essa combinação de técnicas permite que o modelo capture nuances complexas nos padrões de radiação solar, resultando em previsões altamente precisas, como indicado pelo coeficiente máximo de determinação (R^2) superior a 95% e um erro quadrático médio mínimo (MSE) de 0,000987.

Além desses modelos, outros também apresentaram desempenho notável. A Rede Neural Artificial de Retropropagação Feed-Forward (FBANN) demonstrou um coeficiente de correlação superior a 0,96 e um erro percentual médio absoluto (MAPE) abaixo de 3%, destacando-se por sua capacidade de capturar relações complexas nos dados de radiação solar. Da mesma forma, a Rede Neural Exógena Autorregressiva Não Linear (NARX) exibiu um coeficiente de determinação (R^2) de 0,95 e um RMSE de 0,23 MJ/m², indicando sua habilidade em modelar eficazmente padrões temporais na radiação solar.

Apesar de não especificamente quantificados nos resultados fornecidos, os modelos LSSVM, DELM + VMD, Extreme Gradient Boosting (XGBoost), SVR_poly e SVR_rbf também mostraram promessa na previsão da radiação solar. Esses modelos empregam diferentes abordagens, como máquinas de vetores de suporte, métodos de aprendizagem profunda, e técnicas de regressão, todos adaptados para capturar as complexidades dos dados de radiação solar e produzir previsões precisas. Em resumo, esses onze modelos apresentam diversas abordagens que se destacaram no estudo de previsão de radiação solar, cada uma contribuindo com suas próprias vantagens e técnicas distintas para estimar com precisão a quantidade de radiação solar.

4. Quais métricas de desempenho são usadas para avaliar a previsão da radiação solar?

As métricas de desempenho desempenham um papel fundamental na avaliação da eficácia dos modelos de previsão de radiação solar, permitindo uma análise quantitativa e comparativa das diferentes abordagens. Entre as métricas mais comumente utilizadas, o **Erro Quadrático Médio (MSE)** e o **Raiz do Erro Quadrático Médio (RMSE)** são frequentemente empregados para medir a magnitude do erro entre as previsões e os valores reais observados. O **MSE** calcula a média dos quadrados das diferenças entre as previsões e os valores reais, enquanto o **RMSE** fornece uma medida do erro em termos de unidades originais dos dados, facilitando a interpretação dos resultados. Quanto mais baixos esses valores, maior a precisão do modelo.

O **Coefficiente de Determinação (R^2)** é outra métrica amplamente utilizada para avaliar o desempenho dos modelos de previsão. O R^2 quantifica a proporção da variabilidade dos dados observados que é explicada pelo modelo. Um valor de R^2 próximo a 1 indica que o modelo está explicando a maior parte da variabilidade dos dados, refletindo um bom ajuste entre as previsões e os dados reais.

O **Coefficiente de Correlação (r)** também é uma métrica importante, pois indica a força e a direção da relação entre as previsões e os dados observados. Valores de r próximos de +1 ou -1 indicam uma forte correlação positiva ou negativa, respectivamente, enquanto valores próximos de 0 indicam uma relação fraca ou inexistente. Essa métrica é útil para avaliar a consistência do modelo em diferentes cenários e condições.

Além dessas, o **Erro Percentual Médio Absoluto (MAPE)** é frequentemente utilizado para medir o erro relativo entre as previsões e os valores reais. O **MAPE** expressa o erro médio como uma porcentagem, o que permite uma comparação mais direta entre diferentes modelos ou regiões, independentemente da unidade de medida. Um **MAPE** baixo indica uma boa precisão do modelo, especialmente em contextos práticos onde a precisão relativa é importante.

Essas métricas são essenciais para validar a eficácia dos modelos de previsão e garantir que os resultados sejam confiáveis e úteis para aplicações práticas, como o dimensionamento e otimização de sistemas de energia solar, onde a precisão das previsões tem impacto direto na viabilidade econômica e no desempenho dos sistemas.

4. CONSIDERAÇÕES FINAIS

Considerando a variabilidade e imprevisibilidade das condições ambientais que afetam a geração de energia renovável, a hipótese analisada sugere que a aplicação de técnicas de IA pode aumentar significativamente a precisão nas previsões de geração de energia solar. Foram selecionados 25 artigos que apresentaram pesquisas utilizando IA para estimar a incidência de radiação solar. As técnicas empregadas incluíram redes neurais artificiais, máquinas de vetores de suporte, aprendizado profundo e modelos híbridos. Os resultados destacaram a eficácia de várias técnicas, incluindo RNA/ANN combinada com SA, SVM em conjunto com FFA, e CNN-LSTM, demonstrando suas capacidades em lidar com a complexidade dos dados e capturar padrões espaciais e temporais.

Além disso, a diversidade de métricas de desempenho utilizadas para avaliar os modelos reflete a importância de uma avaliação abrangente e holística do desempenho dos modelos de previsão da radiação solar. Indicadores como RMSE, R^2 , coeficiente de correlação e MAPE forneceram insights valiosos sobre a precisão e confiabilidade das previsões, destacando a necessidade de uma abordagem multifacetada na avaliação dos modelos.

Em última análise, a revisão sistemática destaca o potencial da IA na previsão da radiação solar, oferecendo insights valiosos para pesquisadores, profissionais e tomadores de decisão envolvidos em aplicações relacionadas à energia solar, agricultura, planejamento urbano e outras áreas. Com o contínuo avanço das técnicas de IA e a disponibilidade crescente

de dados meteorológicos e de radiação solar, espera-se que esses modelos se tornem cada vez mais sofisticados e precisos, contribuindo para um uso mais eficiente e sustentável da energia solar e recursos naturais.

5. AGRADECIMENTOS

Os autores agradecem o apoio financeiro pelo Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Chamada CNPq/MCTI Nº 10/2023 - Faixa A - Grupos Emergentes, Processo 401718/2023-9.

REFERÊNCIAS

- ADEDEJI, P. A. *et al.* **Evolutionary-based neurofuzzy model with wavelet decomposition for global horizontal irradiance medium-term prediction.** Journal of Ambient Intelligence and Humanized Computing, 14 jan. 2022.
- AL-ROUSAN, N.; AL-NAJJAR, H. **A Comparative Assessment of Time Series Forecasting Using NARX and SARIMA to Predict Hourly, Daily, and Monthly Global Solar Radiation Based on Short-Term Dataset.** Arabian Journal for Science and Engineering, 4 maio. 2021.
- ALKAHTANI, H.; ALDHYANI, T. H. H.; ALSUBARI, S. N. **Application of Artificial Intelligence Model Solar Radiation Prediction for Renewable Energy Systems.** Sustainability, v. 15, n. 8, p. 6973, 21 abr. 2023.
- ALASSERY, F. *et al.* **An artificial intelligence-based solar radiation prophesy model for green energy utilization in energy management system.** Sustainable Energy Technologies and Assessments, v. 52, p. 102060, ago. 2022.
- ALIZAMIR, M. *et al.* **A comparative study of several machine learning based non-linear regression methods in estimating solar radiation: Case studies of the USA and Turkey regions.** Energy, v. 197, p. 117239, abr. 2020.
- ALIZAMIR, M. *et al.* **Improving the accuracy of daily solar radiation prediction by climatic data using an efficient hybrid deep learning model: Long short-term memory (LSTM) network coupled with wavelet transform.** Engineering Applications of Artificial Intelligence, v. 123, p. 106199, ago. 2023.
- CHEN, Y. *et al.* **Proactively selection of input variables based on information gain factors for deep learning models in short-term solar irradiance forecasting.** Energy, v. 284, p. 129261, 1 dez. 2023.

FAN, J. *et al.* **Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China.** *Energy Conversion and Management*, v. 164, p. 102–111, 15 maio 2018.

FENG, Y. *et al.* **Comparison of artificial intelligence and empirical models for estimation of daily diffuse solar radiation in North China Plain.** v. 42, n. 21, p. 14418–14428, 1 maio 2017.

GÜREL, A. E. *et al.* **A state of art review on estimation of solar radiation with various models.** *Heliyon*, p. e13167, jan. 2023.

HEDAR, Abdel-Rahman *et al.* **Hybrid Machine Learning for Solar Radiation Prediction in Reduced Feature Spaces.** *Energies*, v. 14, n. 23, p. 7970, 1 jan. 2021.

HUANG, J.; LIU, H. **A hybrid decomposition-boosting model for short-term multi-step solar radiation forecasting with NARX neural network.** *Journal of Central South University*, v. 28, n. 2, p. 507–526, 1 fev. 2021.

JAFRI, N.; T., M. ; AHAD, A. **The role of artificial intelligence in solar harvesting, storage, and conversion.** Disponível em: <<https://www.sciencedirect.com/science/article/abs/pii/B9780323906012000106>>. Acesso em: 21 jul. 2023.

AIMEUR, K.; SAOUD, L. S.; GHORBANI, R. **Short-Term Solar Irradiance Forecasting and Photovoltaic System Management Using Octonion Neural Networks.** *Applied Solar Energy*, v. 56, n. 3, p. 219–226, maio 2020.

KHOSRAVI, A. *et al.* **Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms.** *Journal of Cleaner Production*, v. 176, p. 63–75, mar. 2018 a.

KHOSRAVI, A. *et al.* **Comparison of artificial intelligence methods in estimation of daily global solar radiation.** *Journal of Cleaner Production*, v. 194, p. 342–358, set. 2018 b.

KHOSRAVI, A. *et al.* **Energy modeling of a solar dish/Stirling by artificial intelligence approach.** *Energy Conversion and Management*, v. 199, p. 112021, 1 nov. 2019.

KOSOVIC, I. N.; MASTELIC, T.; IVANKOVIC, D. **Using Artificial Intelligence on environmental data from Internet of Things for estimating solar radiation: Comprehensive analysis.** *Journal of Cleaner Production*, v. 266, p. 121489, set. 2020.

LIMA, M. A. F.B. *et al.* **Improving solar forecasting using Deep Learning and Portfolio Theory integration.** *Energy*, v. 195, p. 117016, mar. 2020.

LOU, S. *et al.* **Prediction of diffuse solar irradiance using machine learning and multivariable regression.** *Applied Energy*, v. 181, p. 367–374, nov. 2016.

MALIK, P. *et al.* **A Review on ANN Based Model for Solar Radiation and Wind Speed Prediction with Real-Time Data.** Archives of Computational Methods in Engineering, v. 29, n. 5, p. 3183–3201, 6 jan. 2022.

MCCANDLESS, T.C.; HAUPT, S.E.; YOUNG, G.S. **A model tree approach to forecasting solar irradiance variability.** Solar Energy, v. 120, p. 514–524, out. 2015.

MEHDIZADEH, S.; BEHMANESH, J.; KHALILI, K. **Comparison of artificial intelligence methods and empirical equations to estimate daily solar radiation.** Journal of Atmospheric and Solar-Terrestrial Physics, v. 146, p. 215–227, ago. 2016.

ALIZAMIR, M. *et al.* **A New Insight for Daily Solar Radiation Prediction by Meteorological Data Using an Advanced Artificial Intelligence Algorithm: Deep Extreme Learning Machine Integrated with Variational Mode Decomposition Technique.** Sustainability, v. 15, n. 14, p. 11275–11275, 19 jul. 2023.

MOHAMMADI, B. *et al.* **Application of ERA-Interim, empirical models, and an artificial intelligence-based model for estimating daily solar radiation.** Ain Shams Engineering Journal, v. 13, n. 1, p. 101498, 1 jan. 2022.

NAWAB, F. *et al.* **Solar irradiation prediction using empirical and artificial intelligence methods: A comparative review.** Heliyon, v. 9, n. 6, p. e17038, 1 jun. 2023.

NESHAT, M. *et al.* **Short-term solar radiation forecasting using hybrid deep residual learning and gated LSTM recurrent network with differential covariance matrix adaptation evolution strategy.** Energy, v. 278, p. 127701, 1 set. 2023.

OLABI, A.G. *et al.* **Application of artificial intelligence for prediction, optimization, and control of thermal energy storage systems.** Thermal Science and Engineering Progress, p. 101730, fev. 2023.

OLATOMIWA, Lanre *et al.* **A support vector machine–firefly algorithm-based model for global solar radiation prediction.** Solar Energy, v. 115, p. 632–644, maio 2015.

RAJASUNDRAPANDIYANLEEBANON, T. *et al.* **Solar Energy Forecasting Using Machine Learning and Deep Learning Techniques.** Archives of Computational Methods in Engineering, 24 fev. 2023.

SAYED, E. T. *et al.* **Application of artificial intelligence techniques for modeling, optimizing, and controlling desalination systems powered by renewable energy resources.** Journal of Cleaner Production, v. 413, p. 137486, 10 ago. 2023.

MOUSAVI, S. M.; MOSTAFAVI, E. S.; JIAO, P. **Next generation prediction model for daily solar radiation on horizontal surface using a hybrid neural network and simulated annealing method.** Energy Conversion and Management, v. 153, p. 671–682, 1 dez. 2017.

SENGUPTA, M. *et al.* **The National Solar Radiation Data Base (NSRDB).** Renewable and Sustainable Energy Reviews, v. 89, p. 51-60, 2018.

GESHNIGANI, F. S. *et al.* **Daily solar radiation estimation in Belleville station, Illinois, using ensemble artificial intelligence approaches.** Engineering Applications of Artificial Intelligence, v. 120, p. 105839, abr. 2023.

SUDHARSHAN, K. *et al.* **Systematic Review on Impact of Different Irradiance Forecasting Techniques for Solar Energy Prediction.** Energies, v. 15, n. 17, p. 6267, 1 jan. 2022.

TAOM, H. *et al.* **Global solar radiation prediction over North Dakota using air temperature: Development of novel hybrid intelligence model.** Energy Reports, v. 7, p. 136–157, nov. 2021.

VEISI, O.; SHAKIBAMANESH, A.; RAHBAR, M. **Using intelligent multi-objective optimization and artificial neural networking to achieve maximum solar radiation with minimum volume in the archetype urban block.** Sustainable Cities and Society, v. 86, p. 104101, 1 nov. 2022.

WANG, Z. *et al.* **Hourly Solar Radiation Forecasting Using a Volterra-Least Squares Support Vector Machine Model Combined with Signal Decomposition.** v. 11, n. 1, p. 68–68, 1 jan. 2018.

WANG, Z. *et al.* **Taxonomy research of artificial intelligence for deterministic solar power forecasting.** Energy Conversion and Management, v. 214, p. 112909, 15 jun. 2020.

YÜZER, E. Ö; BOZKURT, A. **Deep learning model for regional solar radiation estimation using satellite images.** Ain Shams Engineering Journal, p. 102057, dez. 2022.

ZAIM, S. *et al.* **Using artificial intelligence for global solar radiation modeling from meteorological variables.** Renewable Energy, v. 215, p. 118904, 1 out. 2023.

ZHOU, Y. **Artificial intelligence in renewable systems for transformation towards intelligent buildings.** Energy and AI, v. 10, p. 100182, nov. 2022.