XXI ENTAC – Encontro Nacional de Tecnologia do Ambiente Construído
14 a 16 de outubro de 2026 | Goiânia-Brasil
DOI: https://doi.org/10.46421/entac.v21i1.8335

SolarisBIM.AI: planejamento sustentável de edificações com estimativa de geração fotovoltaica baseada em BIM e redes neurais feedforward

SolarisBIM.AI: Sustainable building planning with photovoltaic generation estimation based on BIM and feedforward neural networks

Josivan Leite Alves
Universidade Federal de Pernambuco | Recife | Brasil | Josivan.leite@ufpe.br
Adiel Teixeira de Almeida Filho
Universidade Federal de Pernambuco | Recife | Brasil | Adielfilho@cin.ufpe.br
Fabrício Bradaschia
Universidade Federal de Pernambuco | Recife | Brasil | Fabricio.bradaschia@ufpe.br
Rachel Perez Palha
Universidade Federal de Pernambuco | Recife | Brasil | Rachel.palha@ufpe.br

Resumo

Ao passo que a expansão urbana intensificou a atividade da construção civil e elevou a demanda, houve um esgotamento das reservas de combustíveis fósseis e aumento dos impactos ambientais associados às emissões de gases de efeito estufa. Nesse contexto, a integração de fontes de energia renováveis tornou-se fundamental para o alcance dos objetivos de desenvolvimento sustentável. Dentre as alternativas disponíveis, a energia fotovoltaica destaca-se como solução para suprir a crescente demanda energética em edificações. Diante disso, este estudo apresenta o SolarisBIM.AI, um framework que integra a previsão de radiação solar baseada em aprendizado de máquina a uma rotina desenvolvida no Dynamo, visando quantificar a produção de energia solar e as emissões de CO_2 evitadas. Para isso, foi utilizada uma série histórica de 49 anos de dados de radiação solar de seis cidades de Pernambuco, aplicada ao treinamento de redes neurais *feedforward*. Aplicado a um estudo de caso, o SolarisBIM.AI estimou uma produção anual de 381.802 kWh para o ano de 2023, representando uma superestimação de apenas 2% em relação à produção medida de 374.204 kWh no prédio escolar do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco. Os resultados demonstram que a abordagem proposta pode auxiliar arquitetos, engenheiros e planejadores na quantificação da geração de energia solar e na avaliação do desempenho sustentável de edifícios ainda na fase de concepção.

Palavras-chave: Inteligência artificial. Sustentabilidade. Energia fotovoltaica. Aprendizado profundo. Modelagem da Informação da Construção.

Abstract

As urban expansion intensified construction activity and increased demand, it led to a depletion of fossil fuel reserves and a rise in environmental impacts associated with greenhouse gas emissions. In this context, the integration of renewable energy sources has become fundamental to achieving sustainable development goals. Among the available alternatives, photovoltaic energy stands out as a solution to meet the growing energy demand in buildings.

Como citar:
ALVES, J.L., ALMEIDA FILHO, A.T., BRADASCHIA, F.PALHA, R.P A. SolarisBIM.AI: planejamento sustentável de edificações com estimativa de geração fotovoltaica baseada em BIM e redes neurais feedforward. ENTAC 2026. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 21, 2026, Goiânia. Anais... Goiânia: ANTAC, 2026.

DOI: https://doi.org/10.46421/entac.v21i1.8335

Therefore, this study presents SolarisBIM.AI, a framework that integrates machine learning-based solar radiation forecasting with a routine developed in Dynamo, aiming to quantify solar energy production and avoided CO_2 emissions. For this purpose, a 49-year historical series of solar radiation data from six cities in Pernambuco was used, applied to the training of feedforward neural networks. Applied to a case study, SolarisBIM.AI estimated an annual production of 381,802 kWh for the year 2023, representing an overestimation of only 2% compared to the measured production of 374,204 kWh in the school building of the Center for Technology and Geosciences at the Federal University of Pernambuco. The results demonstrate that the proposed approach can assist architects, engineers, and planners in quantifying solar energy generation and evaluating the sustainable performance of buildings even in the design phase.

Keywords: Artificial intelligence. Sustainability. Photovoltaic energy. Deep learning. Building Information Modeling.

INTRODUÇÃO

O aumento da demanda global por energia, impulsionado pela urbanização e industrialização, intensificou a busca por soluções sustentáveis. Nesse cenário, os edifícios se destacam por representarem cerca de 40% do consumo energético e 33% das emissões globais [1]. Diante da baixa eficiência energética, os sistemas fotovoltaicos emergem como uma estratégia-chave para a transição para edificações mais sustentáveis e de baixo carbono [2]. O setor fotovoltaico tem crescido, representando cerca de 75% das novas instalações renováveis em 2024, com projeções de ultrapassar 4.600 TW até 2050. Esse avanço é impulsionado por políticas de incentivo, inovação tecnológica e maior conscientização climática [2].

Em paralelo, embora o BIM tenha sido amplamente adotado no setor do ambiente construído para projetos integrados de edificações, sua aplicação no planejamento de sistemas fotovoltaicos ainda é limitada [3]. As abordagens atuais dependem, em geral, de processos manuais, o que limita a otimização nas fases iniciais [2]. Nesse contexto, torna-se necessária a adoção de soluções automatizadas e orientadas por dados que incorporem análises preditivas ao ambiente BIM. A literatura revela um interesse crescente na previsão de energia fotovoltaica orientada por inteligência artificial (IA) [4], no entanto, ainda existe uma lacuna na aplicação dessas técnicas no planejamento de sistemas solares baseados em BIM [5].

Para suprir essa lacuna, o objetivo geral desta pesquisa é desenvolver o SolarisBIM.AI, um processo de projeto automatizado que integra a BIM a uma Rede Neural Feedforward (FNN) para estimar a geração fotovoltaica e os impactos ambientais evitados. Para alcançar este propósito, foram delineados os seguintes objetivos específicos: (1) treinar um modelo de aprendizado de máquina com dados de radiação solar dos postos de coleta disponíveis no estado de Pernambuco; (2) implementar um fluxo de trabalho em Dynamo e Revit para a extração automatizada da geometria da cobertura; e (3) analisar o framework por meio de um estudo de caso empírico, comparando os resultados simulados com dados reais de produção energética. Assim, investiga-se a integração entre aprendizado de máquina e BIM para estimar a geração fotovoltaica, combinando séries temporais de radiação solar e extração automatizada

de dados. Além disso, quantificam-se a energia produzida e as emissões de CO_2 evitadas com base nas previsões do modelo.

A problemática abordada neste artigo reside na fragmentação do processo de projeto de sistemas fotovoltaicos. Tradicionalmente, a concepção arquitetônica e o dimensionamento energético são conduzidos em etapas distintas e por especialistas distintos, o que resulta no uso de ferramentas de software isoladas. Enquanto a arquitetura emprega soluções como AutoCAD, Archicad e SketchUp, a engenharia fotovoltaica utiliza softwares específicos, como PVsyst e RETScreen, ou ferramentas dedicadas à análise de sombreamento e ao arranjo de módulos. Essa dependência de modelos implica que alterações realizadas em uma disciplina podem não ser sincronizadas automaticamente, o que exige retrabalho e dificulta a integração do projeto.

Nesse contexto, este artigo destaca que o BIM possibilita a criação de um modelo centralizado que pode evitar a desconexão entre as fases de projeto. Avançando nessa perspectiva, o presente estudo propõe um processo no qual os modelos BIM transcendem a mera representação espacial, atuando como repositórios de dados geométricos e de informações paramétricas. Esse repositório subsidia decisões estratégicas de projeto, ainda na fase de planejamento, e fornece parâmetros de entrada para modelos preditivos de inteligência artificial.

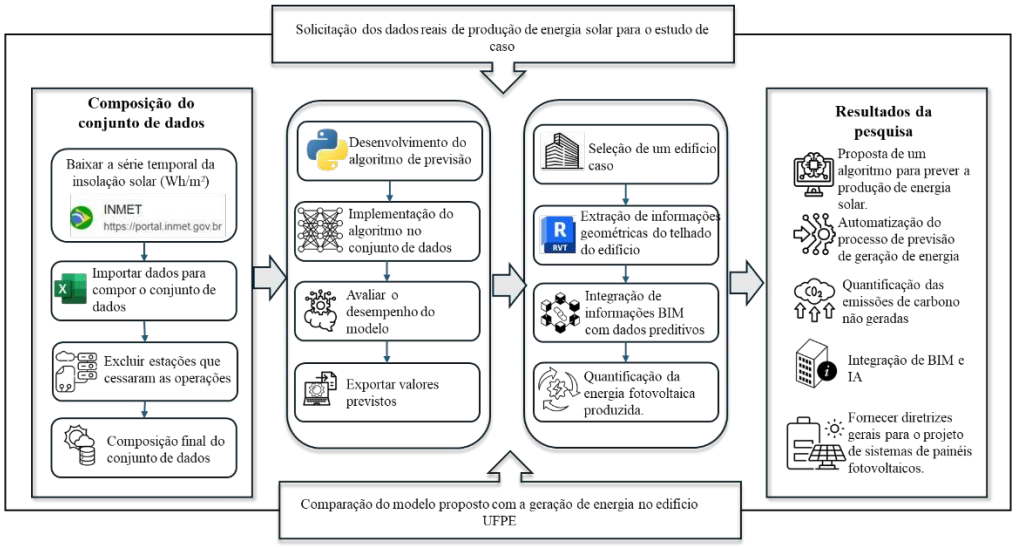
METODOLOGIA

Nesta pesquisa, as redes neurais *feedforward* (FNN) são empregadas para modelar séries temporais de radiação solar devido à sua capacidade de captar relações não lineares complexas entre variáveis climáticas. Além disso, apresentam bom desempenho preditivo quando treinadas com séries históricas extensas, como no caso deste estudo [6].

As previsões do modelo alimentam o cálculo da produção de energia fotovoltaica, que converte dados de radiação em estimativas de geração. Assim, este artigo desenvolve um banco de dados de radiação solar diária com dados de municípios de Pernambuco, Brasil. O fluxograma da pesquisa é apresentado na Figura 1, e cada etapa é descrita nas seções subsequentes. Esta pesquisa utilizou a linguagem de programação Python para desenvolver o algoritmo. O modelo 3D foi criado no Revit, e os dados de geometria do edifício foram extraídos com o Dynamo. O software QGIS foi utilizado para gerar mapas das mesorregiões da área de estudo.

DOI: https://doi.org/10.46421/entac.v21i1.8335

Figura 1. Fluxo de trabalho da pesquisa



Fonte: os autores.

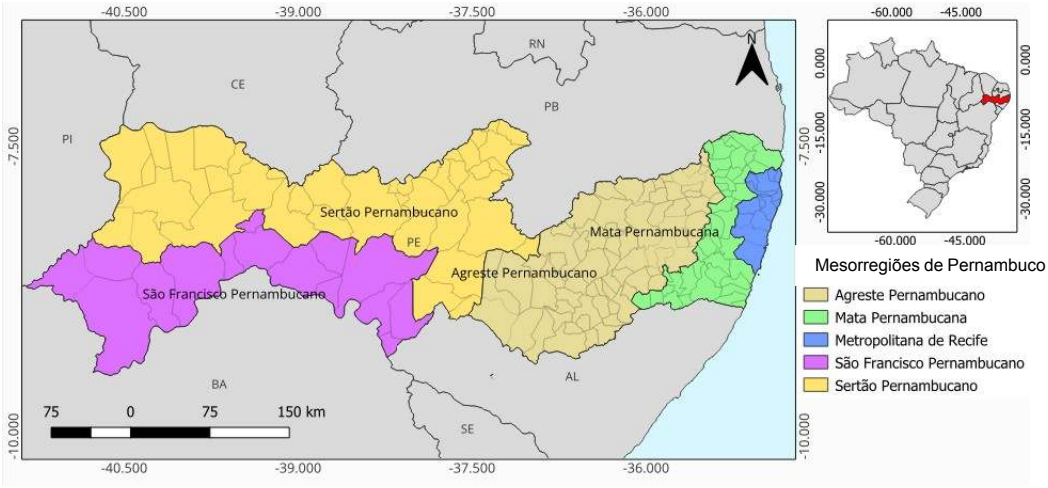
As seções subsequentes exploram a obtenção de dados históricos de radiação solar para o algoritmo preditivo desenvolvido em Python utilizando redes neurais *feedforward*, cuja precisão foi avaliada por meio de validação cruzada *walk-forward*. Desenvolveu-se um modelo 3D no Revit, acompanhado de uma rotina no Dynamo, responsável por extrair a área útil da cobertura. Por fim, o cruzamento das previsões de irradiação com os dados geométricos extraídos do ambiente BIM viabilizou a estimativa da produção de energia fotovoltaica e emissões de CO_2 evitadas.

COMPOSIÇÃO DA BASE DE DADOS

Os dados de radiação solar foram obtidos do Instituto Nacional de Meteorologia (INMET), expressos em kWh/m². Pernambuco foi selecionado devido ao seu elevado potencial solar e à disponibilidade de dados reais de geração fotovoltaica da Universidade Federal de Pernambuco (UFPE), utilizados para validação do modelo. Conforme mostrado na Figura 2, o estado apresenta cinco mesorregiões com características distintas: o Sertão Pernambucano, de clima semiárido; o Agreste, com transição climática e atividades agroindustriais; a Mata Pernambucana, tradicional na produção canavieira; a Região Metropolitana do Recife, altamente urbanizada e centro econômico; e o São Francisco Pernambucano, com destaque para a agricultura irrigada [7].

DOI: https://doi.org/10.46421/entac.v21i1.8335

Figura 2. Mesorregiões de Pernambuco



Fonte: os autores.

Para garantir a capacidade de generalização do modelo preditivo frente a diferentes zonas bioclimáticas, a base de dados incluiu municípios representativos das diversas mesorregiões do estado. Em Pernambuco, das 16 estações do INMET, apenas seis (Arcoverde, Cabrobó, Garanhuns, Petrolina, Recife e Surubim) possuem dados utilizáveis, abrangendo o período de 01/01/1975 a 31/12/2023 (17.896 dias, 49 anos) [3]. Valores ausentes foram preenchidos com a média das estações do mesmo dia. A análise de sensibilidade, comparando imputação por média, preenchimento direto e interpolação linear, mostrou diferenças insignificantes na média global (+0,019% e +0,010%) e na variância (+0,105% e +0,041%), confirmando a adequação do método adotado.

Os dados foram divididos de acordo com estes índices: 80% foram utilizados para o treinamento do modelo, 10% para a validação e os últimos 10% para o teste e a avaliação final do desempenho.

REDE NEURAL FEEDFORWARD (FNN)

Avanços recentes na literatura estabeleceram a base teórica para a capacidade das redes *feedforward*. Nessa arquitetura, os neurônios são organizados em camadas, permitindo a transmissão de informações de forma hierárquica e sequencial. A FNN utiliza a biblioteca *TensorFlow Keras*. Inicialmente, o modelo é configurado para prever uma variável temporal específica com uma janela de observação de 1 dia (*look_back*=1), o que significa que o valor atual é previsto com base no valor imediatamente anterior. A função *create_dataset* organiza os dados de treinamento, validação e teste, gerando as variáveis X e y adequadas para a modelagem de séries temporais. A arquitetura do algoritmo é mostrada no Algoritmo 1.

Algoritmo 1: Definindo e treinando o modelo FNN

Passo 1. Para cada sequência de entrada $\{x_t\}$ com janela de tempo L

$X_t = \{x_{t-L+1}, \ldots, x_{t-1}, x_t\}$ e

$y_{t+1} = x_{t+1}$

X é a matriz de características

y é o vetor de valores alvo

Passo 2. Camada de entrada com n_1 neurônios, onde n_1=10

$h^{(1)}$=f $(W^{(1)} * X + b^{(1)})$

W $^{(1)}$ e b $^{(1)}$ são os pesos e vieses da camada de entrada

f é a função de ativação ReLU

$h^{(1)}$ é a ativação da primeira camada oculta

$h^{(2)}$ é a ativação da segunda camada oculta

Camada oculta com n_2=10 neurônios

$h^{(2)}$=f $(W^{(2)} * h^{(1)} + b^{(2)})$

Passo 3. Camada de saída com um único neurônio, que fornece a previsão $\hat{y}$

$\hat{y}=W^{(3)} * h^{(2)} + b^{(3)}$

Fim

A arquitetura da rede neural foi definida com base na literatura e nas características dos dados. Utilizou-se ativação ReLU para evitar o desaparecimento do gradiente e o otimizador Adam para ajuste adaptativo da taxa de aprendizado. A modelagem de séries temporais adotou um *look-back* de 1, considerando o valor do dia anterior como principal preditor. A rede, implementada em *Keras*, consiste em um *perceptron* multicamada com duas camadas ocultas de 10 neurônios cada e saída linear. O treinamento foi realizado por 100 épocas, com lote de 32 e taxa de aprendizado de 10^{-3}.

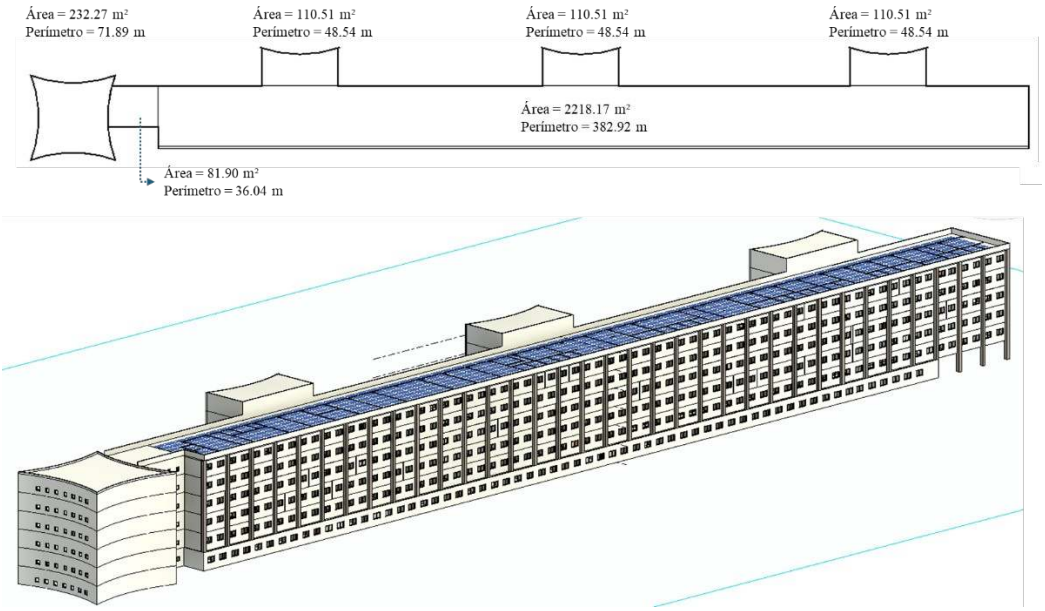
MÉTRICAS DE AVALIAÇÃO

O modelo foi avaliado com base nas métricas Erro Absoluto Médio (MAE) e Erro Percentual Absoluto Médio (MAPE). Para garantir uma avaliação robusta, utilizou-se a validação cruzada do tipo *walk-forward*, na qual o modelo é treinado progressivamente com dados históricos e validado em blocos subsequentes, respeitando a ordem temporal. A partir das iterações, foram calculados o erro médio, o desvio padrão e os intervalos P5–P95, além das métricas Raiz do Erro Quadrático Médio (RMSE), que indica a magnitude dos erros, e R^2, que mede a capacidade do modelo de explicar a variabilidade dos dados [8].

MODELO BIM PARA O ESTUDO DE CASO

O edifício do Centro de Tecnologia e Geociências da UFPE (CTG-UFPE) foi selecionado para modelagem e simulação da produção fotovoltaica, por possuir módulos solares instalados em sua cobertura. Isso permitiu comparar os resultados simulados com a geração real. O prédio conta com seis pavimentos e abriga salas de aula, gabinetes de professores, laboratórios e auditórios destinados a diversos cursos de engenharia. A planta da cobertura e o modelo 3D desenvolvido no Revit são apresentados na Figura 3.

Figura 3. Representação do telhado e modelo 3D gerado no Revit.



Fonte: os autores.

Para a análise, foi implementada uma rotina no Dynamo para extrair automaticamente a área útil do telhado. Em seguida, foram inseridas as dimensões e a eficiência dos módulos fotovoltaicos para determinar a quantidade de painéis instalados. Esses dados alimentaram o modelo SolarisBIM.AI para estimativa da geração de energia.

QUANTIFICAÇÃO DA PRODUÇÃO DE ENERGIA FOTOVOLTAICA

Os algoritmos de aprendizado profundo (DL) fornecem a radiação solar em kWh/m² para o(s) dia(s) desejado(s). O manual do fabricante fornece a eficiência média de conversão dos módulos, tipicamente entre 15% e 22% (ou 0,15 a 0,22). A área necessária para o cálculo é extraída do modelo BIM 3D. O cálculo é realizado utilizando a Equação 1. O número de módulos solares ($Nº_{MS}$) é obtido pela divisão da área total do telhado do edifício ($A_{coberta}$) pela área de um módulo solar (A_{MS}). A produção diária de energia fotovoltaica (P_{EF}) é calculada multiplicando-se o número de módulos solares pela radiação solar média diária por metro quadrado ($RS_{média}$) e pela eficiência dos módulos (E). A produção anual de energia fotovoltaica (PV_{anual}) é então obtida multiplicando-se a produção diária de energia por 366 dias, considerando os anos bissextos. Essa estimativa fornece um método simples para avaliar a geração de energia fotovoltaica com base nas especificações dos módulos e nas condições solares locais. Vale ressaltar que este modelo desconsidera as perdas da etapa de conversão do sistema fotovoltaico (inversor).

$$Nº_{MS} = \frac{A_{coberta}}{A_{MS}} \quad (1.1)$$

$$P_{EF}\ (kWh) = Nº_{MS} \times (RS_{média}) \times E \quad (1.2)$$

$$PV_{anual} = D_{PV} * 366 \quad (1.3)$$

(1)

A produção de energia fotovoltaica em kWh foi comparada ao fator de emissão de CO_2 para determinar a quantidade de CO_2 evitada. A fórmula é apresentada na Equação 2. No Brasil, o Ministério da Ciência, Tecnologia e Inovações (MCTI) informa que o Fator Médio de Emissão anual (tCO_2/kWh) é de 0,0000467 tCO_2/kWh [9].

$$CO_{2evitado} = PV_{anual}\ (kWh) \times CO_{2\ fator}\ (tCO_2/kWh) \quad (2)$$

RESULTADOS

Os resultados mostrados na Tabela 1 da FNN indicam desempenho consistente e boa capacidade de generalização entre as diferentes cidades, com valores de MAE próximos entre treino e validação (≈2,06 a 2,32), sugerindo ausência de *overfitting*. As cidades do Sertão, como Arcoverde, Cabrobó e Petrolina, apresentaram os melhores resultados, com MAPE em torno de 26% e baixa variabilidade (desvios-padrão reduzidos e intervalos P5–P95 estreitos), o que reflete maior estabilidade climática e, consequentemente, maior previsibilidade da radiação solar. Em contrapartida, Garanhuns e Recife apresentaram erros mais elevados (MAPE de 35,97% e 33,28%, respectivamente) e maior dispersão, o que pode ser atribuído à maior variabilidade climática dessas regiões — Garanhuns, por sua condição de transição no Agreste, e Recife, pela forte influência oceânica. Os valores de RMSE (≈2,59–2,77) reforçam a estabilidade do modelo, enquanto os coeficientes de determinação (R^2 entre 0,14 e 0,26) indicam que, embora a FNN capture tendências gerais da série, ainda há limitações na capacidade de explicar a variabilidade dos dados.

Tabela 1. Métricas de avaliação do modelo com validação *Walk-Forward*

Etapa	Métricas	Arcoverde	Cabrobó	Garanhuns	Petrolina	Recife	Surubim
FNN							
Treino	MAE	2.07	2.09	2.29	2.11	2.32	2.14
	MAPE	26.63	26.90	35.97	26.24	33.28	28.82
Validação	MAE [mean ± SD]	2.06 ± 0.08	2.10 ± 0.05	2.25 ± 0.18	2.10 ± 0.07	2.25 ± 0.13	2.11 ± 0.11
	RMSE [mean ± SD]	2.59 ± 0.10	2.61 ± 0.05	2.76 ± 0.21	2.63 ± 0.08	2.77 ± 0.17	2.64 ± 0.10
	R^2 [mean ± SD]	0.22 ± 0.03	0.21 ± 0.01	0.26 ± 0.06	0.17 ± 0.02	0.14 ± 0.05	0.17 ± 0.03
	MAE [P5–P95]	[1.98 – 2.16]	[2.05 – 2.15]	[2.03 – 2.43]	[2.03 – 2.18]	[2.10 – 2.39]	[1.99 – 2.20]
	RMSE [P5–P95]	[2.49 – 2.71]	[2.55 – 2.66]	[2.49 – 2.97]	[2.54 – 2.71]	[2.55 – 2.94]	[2.53 – 2.75]
	R^2 [P5–P95]	[0.20 – 0.25]	[0.20 – 0.23]	[0.22 – 0.34]	[0.15 – 0.20]	[0.10 – 0.19]	[0.12 – 0.19]

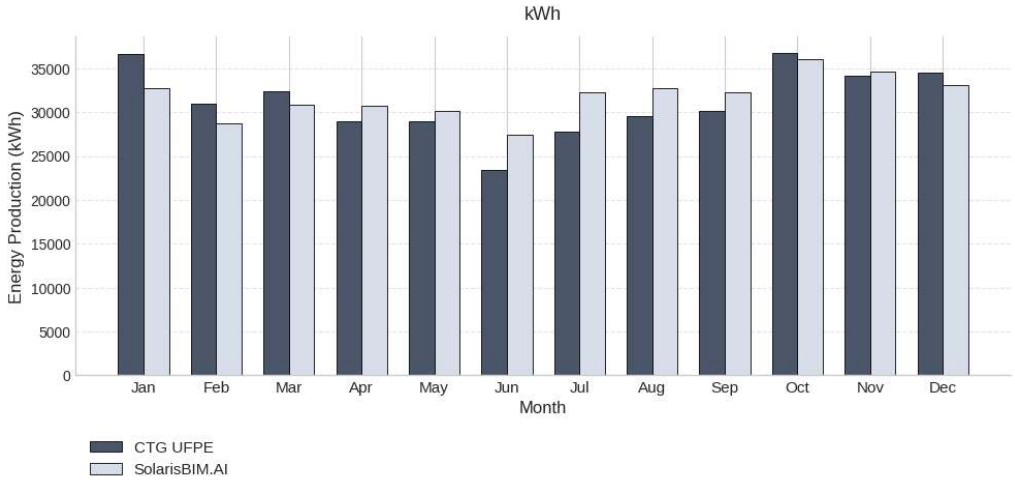
Fonte: os autores.

Além disso, a validação cruzada do tipo *walk-forward* reforçou esses resultados, com MAE variando de 2,03 a 2,43, RMSE entre 2,49 e 2,97 e coeficiente de determinação (R^2) entre 0,10 e 0,34, evidenciando capacidade de capturar padrões temporais com dispersão de erro controlada entre as iterações. Além disso, o modelo apresentou estabilidade entre as dobras de validação, sugerindo boa capacidade de generalização. Esses resultados confirmam a adequação da FNN para aplicações preditivas em séries temporais de radiação solar, sendo, portanto, utilizada como base para o processo de quantificação da geração fotovoltaica no framework proposto, denominado SolarisBIM.AI.

VALIDAÇÃO DO MODELO: O CASO DO PRÉDIO ESCOLAR DO CTG UFPE

Os dados diários de produção de energia solar do CTG UFPE referentes a 2023 foram coletados para comparação com os dados de produção previstos pelo SolarisBIM.AI para o mesmo ano. O módulo solar do CTG UFPE é o Astronergy CHSM6612P/HV-345, com eficiência de 18%. O CTG UFPE possui 792 módulos distribuídos no telhado do edifício. Portanto, como mostra a Figura 4, os valores previstos pelo SolarisBIM.AI estão muito próximos dos valores reais do CTG UFPE. Em 2023, a produção real de energia solar do UFPE foi de 374.204,50 kWh, enquanto o valor previsto pelo SolarisBIM.AI foi de 381.802,31 kWh, o que representa uma diferença de 2% entre o valor real e a previsão.

Figura 4. Produção real de energia solar na CTG UFPE versus produção prevista pelo SolarisBIM.AI

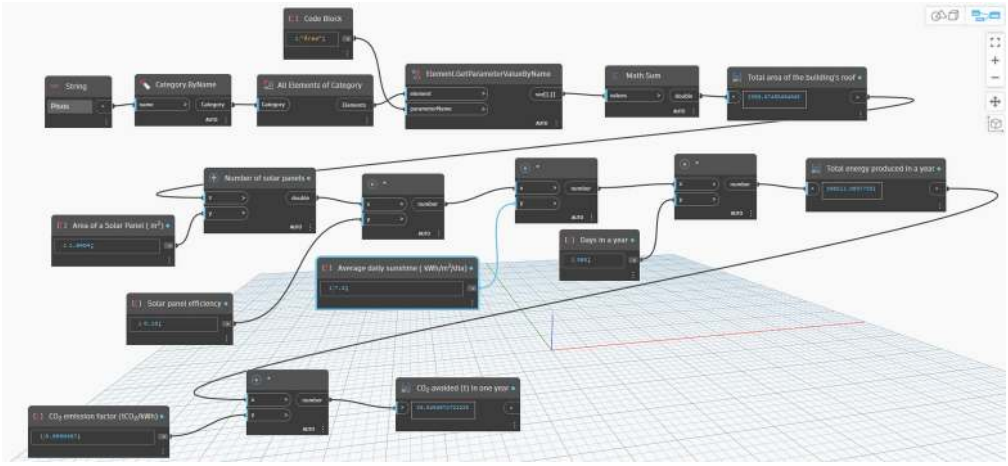


Fonte: os autores.

Pesquisas anteriores desenvolveram um modelo FNN com seis parâmetros de construção, dois parâmetros meteorológicos e cinco parâmetros climáticos como entradas para prever a iluminância da luz natural, e obtiveram um erro médio de 2,2% [10]. Essas descobertas corroboram hipóteses investigadas em pesquisas, como a de [11].

Para quantificar a produção de energia solar e o CO_2, foram aplicados parâmetros como o modelo do módulo solar, a área do telhado, a eficiência do módulo e o fator de emissão de CO_2 (0,0000467 tCO_2/kWh) à rotina do Dynamo, que extrai a área total da cobertura (Figura 5).

Figure 5. Rotina no Dynamo



Fonte: os autores.

O modelo Astronergy CHSM6612P/HV-345 foi adotado para a simulação em um telhado de 2.300,07 m², resultando em aproximadamente 1.185 módulos (área unitária de 1,9404 m²) com eficiência de 18%. Utilizou-se um fator de emissão de 0,0000467 tCO_2/kWh para estimar as emissões evitadas. A geração diária variou de 1.468,79 kWh (Garanhuns) a 1.757,23 kWh (Petrolina), com maior potencial no Sertão. Em termos de CO_2 evitado, Petrolina apresentou o maior valor anual (29,95 t), seguida por Arcoverde (27,46 t), enquanto Garanhuns e Surubim registraram menores reduções, de 25,04 t e 26,41 t, respectivamente. Esses resultados estão resumidos na Tabela 2.

Tabela 2: Simulação da produção anual de energia solar e da redução das emissões de CO_2

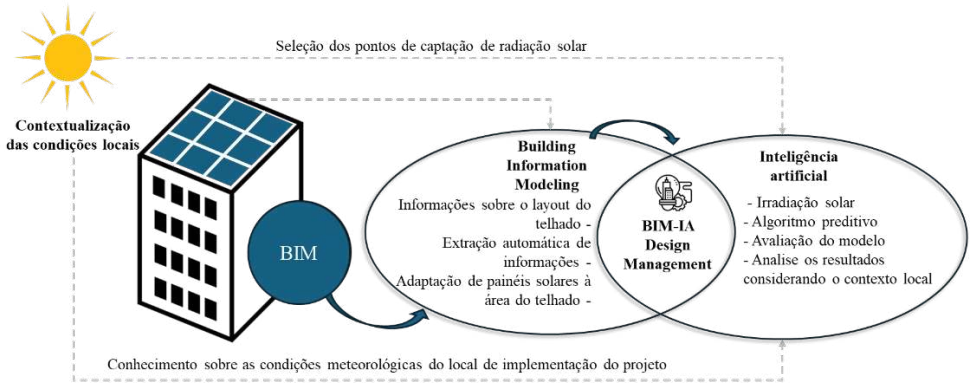
Resultados	Arcoverde	Cabrobó	Garanhuns	Petrolina	Surubim	Recife
Energia diária (kWh)	1,611.19	1,627.08	1,468.79	1,757.23	1,549.19	1,565.26
Energia anual (kWh)	588,082.77	593,884.27	536,109.17	641,389.23	565,455.11	571,319.09
CO_2 evitado (t)	27.46	27.73	25.04	29.95	26.41	26.68

Fonte: os autores.

Discussão

Este artigo estabelece um processo automatizado para prever e quantificar a produção de energia solar, destacando o papel do BIM e do planejamento de projetos na fase de projeto. A Figura 6 destaca que a fase de projeto é essencial para o funcionamento adequado de um sistema fotovoltaico em telhado. O uso do BIM desde os estágios iniciais da construção do projeto contribui para a otimização da gestão da informação, facilitando o processo de projeto e a colaboração multidisciplinar entre as diferentes etapas do projeto [12]. A aplicação de dados de radiação solar e informações BIM na fase de projeto ajuda os projetistas a otimizar usinas fotovoltaicas adaptadas às condições climáticas e regionais locais.

Figura 6. Planejamento inteligente de edifícios sustentáveis, com estimativa de produção solar baseada em BIM, utilizando previsões de radiação por aprendizado profundo



Fonte: os autores.

Do ponto de vista teórico, este estudo contribui para a pesquisa em sustentabilidade no ambiente construído ao articular suas implicações em diferentes escalas: micro, meso e macro. Na escala micro, o framework SolarisBIM.AI atua no nível de projetos individuais para a estimativa automatizada da geração fotovoltaica e das emissões de CO_2 evitadas diretamente a partir de modelos BIM, o que possibilita a otimização de estratégias energéticas ainda na fase inicial de projeto.

Na escala meso, o modelo apoia práticas profissionais em escritórios de arquitetura e engenharia ao integrar técnicas de inteligência artificial aos fluxos de trabalho de projeto. Já na escala macro, a abordagem contribui para agendas urbanas e políticas públicas, ao viabilizar a quantificação do impacto ambiental de alternativas de projeto, apoiando estratégias de planejamento municipal, programas de resiliência energética e metas de neutralidade de carbono [5].

CONCLUSÃO

O processo de projeto desenvolvido nesta pesquisa evidencia que a integração de tecnologias digitais na fase inicial pode aprimorar o planejamento do uso de energia solar em edificações, considerando as características específicas de localização e contexto. Os resultados demonstram o potencial da integração entre modelos de aprendizado profundo e ferramentas de automação BIM para apoiar o planejamento de sistemas fotovoltaicos e a avaliação do desempenho energético ainda nas etapas iniciais do projeto. Essa abordagem permite estimar a produção de energia antes da construção.

Os achados também ressaltam o papel da automação e da integração de dados no processo de projeto, indicando que o uso de séries temporais de radiação solar, aliado ao BIM, constitui uma estratégia para aumentar a sustentabilidade e a viabilidade econômica de sistemas fotovoltaicos. Do ponto de vista teórico e gerencial, a pesquisa propõe um processo baseado em BIM e inteligência artificial para a extração automatizada de dados e a quantificação preditiva da geração de energia, ampliando a aplicação de técnicas de aprendizado profundo em séries temporais no ambiente construído. A aplicação prática do modelo, incluindo a estimativa da energia gerada e

do CO_2 evitado, reforça o potencial dessas tecnologias no apoio à transição para edificações mais sustentáveis.

Entretanto, o estudo apresenta limitações relacionadas à disponibilidade de dados meteorológicos, uma vez que a precisão das previsões depende da cobertura e qualidade das estações de monitoramento. Outro aspecto relevante é que a estimativa de geração foi baseada na área horizontal da cobertura e na radiação solar, sem considerar fatores como o sombreamento, a inclinação e a orientação dos módulos. Como perspectivas futuras, recomenda-se a incorporação de análises de sombreamento e de variáveis geométricas no ambiente BIM, bem como o uso de tecnologias como LiDAR e ortoimagens para automatizar a identificação de superfícies aptas à instalação de sistemas fotovoltaicos.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Declaração

Os autores declaram que não utilizaram IA generativa nem tecnologias assistidas por IA no processo de preparação do manuscrito.

REFERÊNCIAS

[1] ASIF, M.; NAEEM, G.; KHALID, M. **Digitalization for sustainable buildings: Technologies, applications, potential, and challenges.** J. Clean. Prod., v. 450, p. 141814, 2024. DOI: 10.1016/j.jclepro.2024.141814.

[2] WANG, Y.; WANG, S.; ZHAO, Q. **Experimental investigation on fire propagation characteristics and influencing factors in rooftop photovoltaic modules.** Journal of Building Engineering, v. 110, p. 113063, 2025. DOI: 10.1016/j.jobe.2025.113063.

[3] ALVES, J. L.; ALMEIDA FILHO, A. T. de; BRADASCHIA, F.; PALHA, R. P. **SolarisBIM.AI: Smart Sustainable Building Planning with BIM-Based Solar-Production Estimation Using Machine-Learning Radiation Forecasts.** J. Constr. Eng. Manag., v. 152, n. 6, 2026. DOI: 10.1061/JCEMD4.COENG-17897.

[4] TAO, H. et al. **Data driven insights for parabolic trough solar collectors: Artificial intelligence-based energy and exergy performance analysis.** J. Clean. Prod., v. 443, p. 141069, 2024. DOI: 10.1016/j.jclepro.2024.141069.

[5] ALVES, J. L.; PALHA, R. P.; ALMEIDA FILHO, A. T. de. **Towards an integrative framework for BIM and artificial intelligence capabilities in smart architecture, engineering, construction, and operations projects.** Autom. Constr., v. 174, n. 106168, p. 1–22, 2025. DOI: 10.1016/j.autcon.2025.106168.

[6] TIAN, J.; OOKA, R.; LEE, D. **Multi-scale solar radiation and photovoltaic power forecasting with machine learning algorithms in urban environment: A state-of-the-art review.** J. Clean. Prod., v. 426, p. 139040, 2023. DOI: 10.1016/j.jclepro.2023.139040.

[7] IBGE. **IBGE Cidades.** Disponível em: https://cidades.ibge.gov.br/brasil/pe/panorama. Acesso em: 05 nov. 2024.

[8] ALTALHONI, A.; LIU, H.; ABUDAYYEH, O.; KWIGIZILE, V.; HUANG, W.-C.; KIRKPATRICK, K. **Robust Forecasting Models for Highway Construction Cost Indices during Pandemic-Era Inflation.** J. Constr. Eng. Manag., v. 151, n. 8, 2025. DOI: 10.1061/JCEMD4.COENG-16622.

[9] MCTI. **Fatores de emissão de CO2 pela geração de energia elétrica no Sistema Interligado Nacional do Brasil - Ano Base 2023.** Disponível em: https://www.gov.br/mcti/pt-br/acompanhe-o-mcti/sirene/dados-e-ferramentas/fatores-de-emissao.

[10] KAZANASMAZ, T.; GÜNAYDIN, M.; BINOL, S. **Artificial neural networks to predict daylight illuminance in office buildings.** Build. Environ., v. 44, n. 8, p. 1751–1757, 2009. DOI: 10.1016/j.buildenv.2008.11.012.

[11] LIU, Q.; CHEN, Y.; LIU, Y.; LEI, Y.; WANG, Y.; HU, P. **A review and guide on selecting and optimizing machine learning algorithms for daylight prediction.** Build. Environ., v. 244, p. 110822, 2023. DOI: 10.1016/j.buildenv.2023.110822.

[12] DI GIOVANNI, G.; ROTILIO, M.; GIUSTI, L.; EHTSHAM, M. **Exploiting building information modeling and machine learning for optimizing rooftop photovoltaic systems.** Energy Build., v. 313, p. 114250, 2024. DOI: 10.1016/j.enbuild.2024.114250.