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.v21i1.8619

Aplicação de Aprendizado de Máquina na Simulação Energética de Edificações: Uma Revisão Sistemática de Literatura

Application of Machine Learning in Building Energy Simulation: A Systematic Literature Review

Clarisse de Souza Pinho
Universidade Federal do Espírito Santo| Vitória | Brasil | clarisse.pinho@edu.ufes.br
Luciana Aparecida Netto de Jesus
Universidade Federal do Espírito Santo| Vitória | Brasil | luciana.a.jesus@ufes.br
Saile Tomazelli
Universidade Federal do Espírito Santo| Vitória | Brasil | sailetomazelli@gmail.com
Raquel Rocha Cruz
Universidade Federal do Espírito Santo| Vitória | Brasil | rrcruz.egc@uesc.br

Resumo

Este estudo tem como objetivo analisar como técnicas de aprendizado de máquina vêm sendo integrados à modelagem energética de edificações e às simulações com *EnergyPlus®*, com foco na avaliação e melhoria da eficiência energética. A pesquisa foi conduzida por meio de uma Revisão Bibliográfica Sistemática, seguindo as diretrizes PRISMA. Um total de 300 artigos foram inicialmente identificados nas bases Scopus e Web of Science, considerando artigos publicados entre 2015 e 2025. Após o processo de seleção, 40 estudos foram analisados. Os resultados indicam que o *EnergyPlus®* é amplamente utilizado como modelo físico de referência para treinamento e validação de modelos preditivos, destacando-se o uso de modelos substitutos para redução do custo computacional, além da aplicação de algoritmos em análises de sensibilidade, *benchmarking energético* e modelagem de edificações. Observa-se também o avanço de técnicas de inteligência artificial explicável e a integração com dados de microclima urbano.
Palavras-chave: Eficiência Energética. EnergyPlus. Simulação termoenergética. Aprendizado de Máquina

Abstract

This study aims to analyze how algorithms and machine learning techniques have been integrated into building energy modeling and EnergyPlus® simulations, focusing on the evaluation and improvement of energy efficiency. The research was conducted through a Systematic Literature Review following PRISMA guidelines. A total of 300 papers were initially identified based on searches in the Scopus and Web of Science databases, considering articles published between 2015 and 2025. After the selection process, 40 studies were analyzed. The results indicate that EnergyPlus® is widely used as a reference physics-based model for training and validating predictive models, with emphasis on the use of surrogate models to reduce computational cost, as well as the application of algorithms in sensitivity analysis, energy benchmarking, and building energy modeling. The advancement of explainable artificial intelligence techniques and integration with urban microclimate data were also observed.
Keywords: Energy Efficiency. EnergyPlus. Thermal Energy Simulation. Machine Learning

PINHO, C. S.; JESUS, L. A. N.; TOMAZELLI, S.; CRUZ, R. R. Aplicação de Aprendizado de Máquina na Simulação Energética de Edificações: Uma Revisão Sistemática de Literatura. In: ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO, 21, 2026, Goiânia. **Anais**... Goiânia: ANTAC, 2026.

DOI: https://doi.org/10.46421/entac.v21i1.8619

INTRODUÇÃO

A crescente demanda por energia no setor da construção civil tem colocado as edificações no centro das discussões globais sobre sustentabilidade e mitigação das mudanças climáticas. Estima-se que os edifícios sejam responsáveis por aproximadamente 30% do consumo mundial de energia e 28% das emissões globais de dióxido de carbono (CO_2) [1]. No contexto brasileiro, esse impacto é ainda mais expressivo, uma vez que o setor responde por cerca de 52,5% do consumo total de energia do país [2]. Esse cenário decorre, principalmente, do crescimento contínuo da área construída, aliado ao uso intensivo de sistemas de climatização e iluminação artificial, frequentemente demandados devido ao baixo desempenho térmico de grande parte do ambiente construído.

Diante desse panorama, tornam-se fundamentais o desenvolvimento e a aplicação de estratégias voltadas à melhoria da eficiência energética das edificações, tanto na fase de projeto quanto ao longo de sua operação. Ainda, tais estratégias promovem a diminuição dos custos operacionais e a melhoria das condições de conforto térmico e ambiental dos usuários [3]. Nesse contexto, a simulação termoenergética, ou Building Energy Modeling (BEM), destaca-se como uma ferramenta essencial para a avaliação e a previsão do desempenho energético de edifícios, permitindo a análise de diferentes soluções construtivas, operacionais e tecnológicas antes de sua implementação [4].

Entre os softwares disponíveis, o *EnergyPlus®* tem se consolidado como uma das principais ferramentas de simulação energética de edificações, em função de sua robustez e capacidade de representar, com base em princípios físicos, os fenômenos térmicos e energéticos associados à envoltória, aos sistemas prediais e aos padrões de uso dos edifícios [5]. A ferramenta calcula métricas de iluminação, sombreamento e conforto visual, oferece suporte à configuração flexível de sistemas de climatização e simula em passos de tempo sub-horários para lidar com dinâmicas rápidas de sistemas e estratégias de controle [6]. A aplicação do *EnergyPlus®* tem possibilitado estimativas mais precisas do consumo energético e a identificação de estratégias capazes de reduzir o consumo em até 50% em novas edificações e cerca de 30% em edificações existentes submetidas a processos de *retrofit* [7].

De forma complementar, o *benchmarking* energético tem-se consolidado como uma abordagem relevante para a avaliação comparativa do desempenho energético de edificações pertencentes a uma mesma tipologia. Essa estratégia permite identificar padrões de consumo ineficientes, apoiar decisões relacionadas a intervenções de *retrofit* e orientar práticas operacionais mais eficientes [8]. No entanto, a aplicação do *benchmarking* enfrenta limitações

importantes, especialmente associadas à escassez de dados reais e confiáveis sobre o consumo energético, o que dificulta a realização de análises em larga escala em diversos países. Para contornar essa limitação, diversos estudos recorrem ao desenvolvimento de arquétipos, modelos simplificados que representam o estoque edificado de determinadas tipologias, viabilizando avaliações energéticas em nível regional ou urbano [9].

A construção de arquétipos energéticos, contudo, exige rigor metodológico, uma vez que sua representatividade influencia diretamente a confiabilidade dos resultados obtidos. Características como geometria, propriedades da envoltória, sistemas instalados e padrões de ocupação precisam ser cuidadosamente definidas, testadas e validadas a partir de edifícios reais, a fim de garantir que as simulações reproduzam adequadamente os comportamentos energéticos observados na prática [10]. Nesse cenário, o elevado custo computacional associado a simulações paramétricas extensas e a complexidade inerente aos modelos físicos detalhados tornam-se desafios adicionais, sobretudo quando se busca aplicar essas análises em larga escala [11].

Como resposta a essas limitações, observa-se um crescimento significativo da integração entre a modelagem energética de edificações e métodos baseados em algoritmos, técnicas de otimização e de aprendizado de máquina. Essas abordagens têm sido empregadas tanto para acelerar simulações por meio de modelos substitutos quanto para calibrar, otimizar e expandir a aplicação do *EnergyPlus*® em contextos urbanos e de *benchmarking* energético [12,13]. Apesar do avanço dessas pesquisas, a literatura ainda se encontra dispersa quanto às metodologias adotadas, aos tipos de algoritmos empregados e às formas de integração com o *EnergyPlus*®, evidenciando a necessidade de uma sistematização crítica do conhecimento produzido na última década.

Diante disso, este artigo tem como objetivo analisar, por meio de uma Revisão Bibliográfica Sistemática, de que maneira algoritmos e técnicas de aprendizado de máquina vêm sendo integrados à modelagem energética de edificações e às simulações com o *EnergyPlus*®, com foco na avaliação e na melhoria da eficiência energética.

METODOLOGIA

A presente pesquisa foi desenvolvida por meio de uma Revisão Bibliográfica Sistemática (RBS), conduzida segundo as diretrizes do *Preferred Reporting Items for Systematic Reviews and Meta-Analyses* (PRISMA), metodologia adotada em função de sua capacidade de assegurar rigor metodológico,

transparência e reprodutibilidade dos resultados [14]. O método PRISMA estrutura o processo de revisão desde a formulação da pergunta de pesquisa até a síntese dos resultados, contemplando as etapas de identificação, triagem, elegibilidade e inclusão final dos estudos analisados.

Inicialmente, foi definida a pergunta de revisão que norteou todo o desenvolvimento do estudo: "Qual o contexto da literatura sobre a aplicação de aprendizado de máquina na modelagem energética de edificações e às simulações com *EnergyPlus*® para avaliar ou melhorar a eficiência energética em edificações?". Essa questão orientou tanto a estratégia de busca quanto os critérios de inclusão e exclusão adotados ao longo do processo.

A pesquisa bibliográfica foi realizada nas bases de dados *Scopus* e *Web of Science*, selecionadas por seu amplo acervo de revistas revisadas por pares e por concentrarem publicações relevantes nas áreas de Engenharia. As buscas foram conduzidas até o final de 2025, utilizando as mesmas palavras-chave em ambas as bases, de modo a garantir consistência na recuperação dos estudos. A *string* de busca empregada foi: ('building' OR 'construction') AND 'energy efficiency' AND 'BEM' AND 'simulation' AND ('algorithm' OR 'machine learning') AND 'EnergyPlus'. Essa combinação permitiu focar especificamente em pesquisas que abordassem eficiência energética, modelagem energética de edificações, simulação computacional e métodos baseados em algoritmos ou em aprendizado de máquina aplicados ao *EnergyPlus®*.

Foram considerados elegíveis apenas artigos científicos revisados por pares publicados em revistas indexadas, redigidos em inglês, com data de publicação entre janeiro de 2015 e dezembro de 2025 e classificados em periódicos Q1 ou Q2. Os critérios de inclusão abrangeram estudos que apresentassem integração de algoritmos, técnicas de otimização ou métodos de aprendizado de máquina aos processos de modelagem energética, utilizando o *EnergyPlus*® como ferramenta principal ou integrada, com foco na avaliação e na melhoria da eficiência energética em edificações. Foram excluídos artigos de conferência, capítulos de livros, pré-prints, artigos de revisão, estudos conceituais sem aplicação metodológica, bem como trabalhos que não utilizassem algoritmos ou aprendizado de máquina aplicados ao BEM.

O processo de seleção teve início com a identificação de 300 registros, que foram importados em formato Bibtex para o Mendeley. Após a remoção de duplicatas com auxílio do Mendeley e a análise dos títulos e resumos, 109 estudos foram mantidos para avaliação subsequente. Desses, foi possível obter acesso integral ao texto de 100 artigos, dos quais, após a leitura, 40 atenderam

à pergunta de revisão. A síntese desse processo encontra-se no fluxograma da Figura 1.

Figura 1- Fluxograma PRISMA

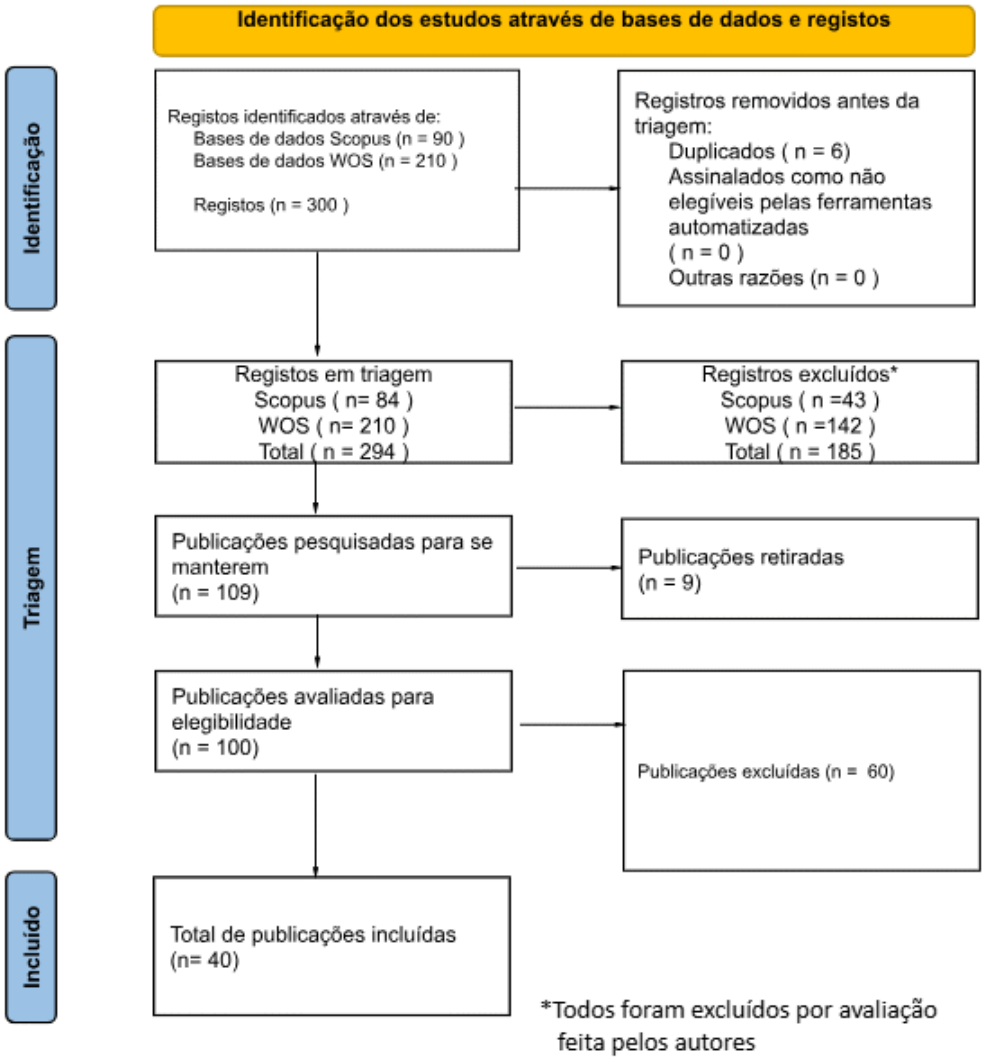

Fonte: Adaptado do fluxograma PRISMA 2020

RESULTADOS

REVISÃO BIBLIOMÉTRICA

Finalizado o fluxograma, foi feita a categorização dos artigos e foram identificados dados do ano de publicação, presentes na Figura 2, país de origem do autor principal, presente na Figura 3, e as revistas em que os artigos foram publicados, presentes na Figura 4.

Figura 2- Número de Publicações por ano

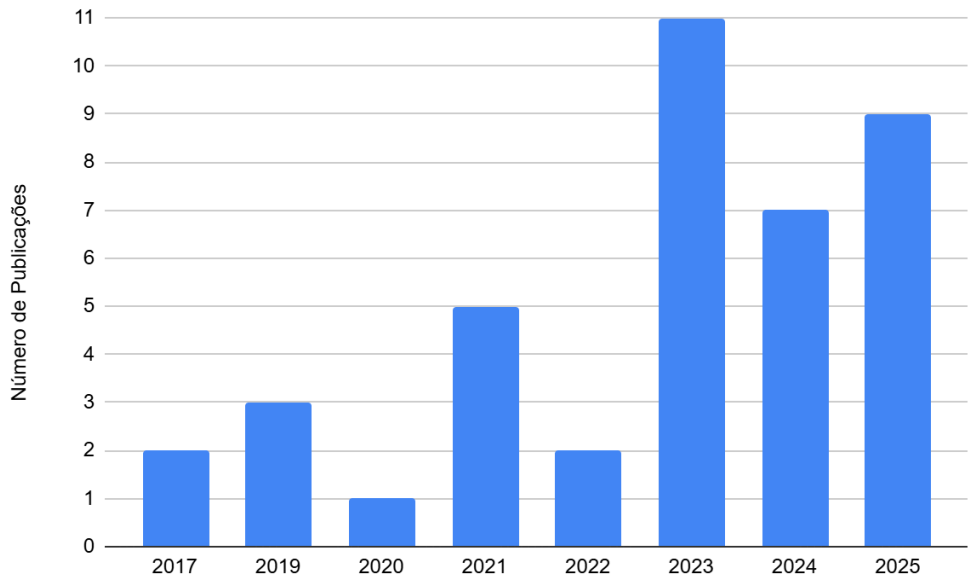

Fonte: Os autores

Percebe-se um crescimento em relação às publicações sobre o tema a partir de 2023, sendo este, ainda, um ano de “pico” de publicações, que pode ter ocorrido devido à maturação de técnicas de aprendizado de máquina juntamente com a popularização do uso da inteligência artificial, seguido de 2025 e 2024, respectivamente.

Figura 3- Número de Publicações por País do Autor Principal

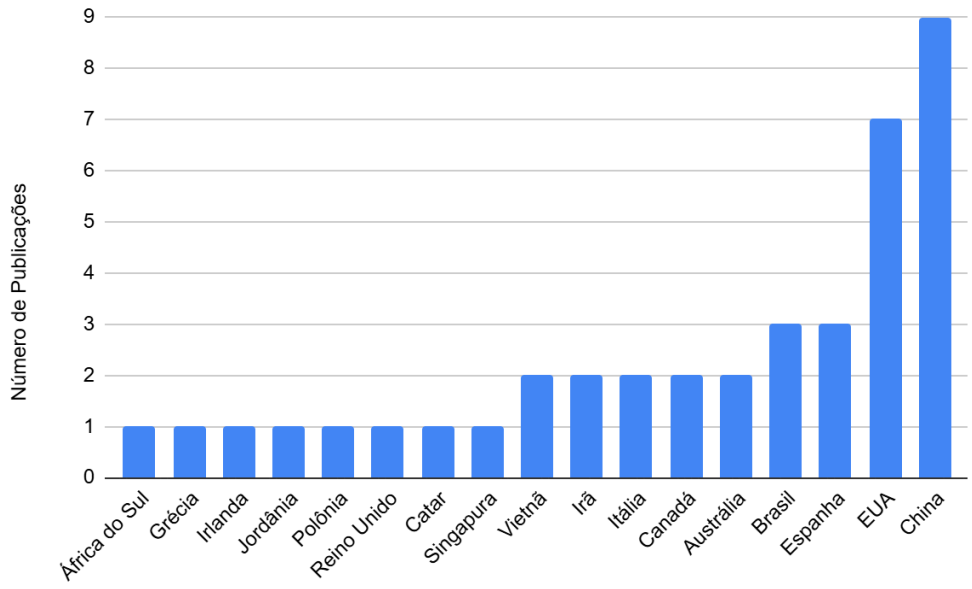

Fonte: Os autores

Levando em consideração as informações presentes na Figura 2, nota-se que os dados apontam a China como principal produtora científica nesta linha de pesquisa, devido

ao grande crescimento científico na China nas áreas de engenharia, seguida pelos Estados Unidos, o que pode ser justificado pelo fato de o EnergyPlus ter sido criado pelo departamento de energia do país.

Figura 4- Número de Publicações por revista

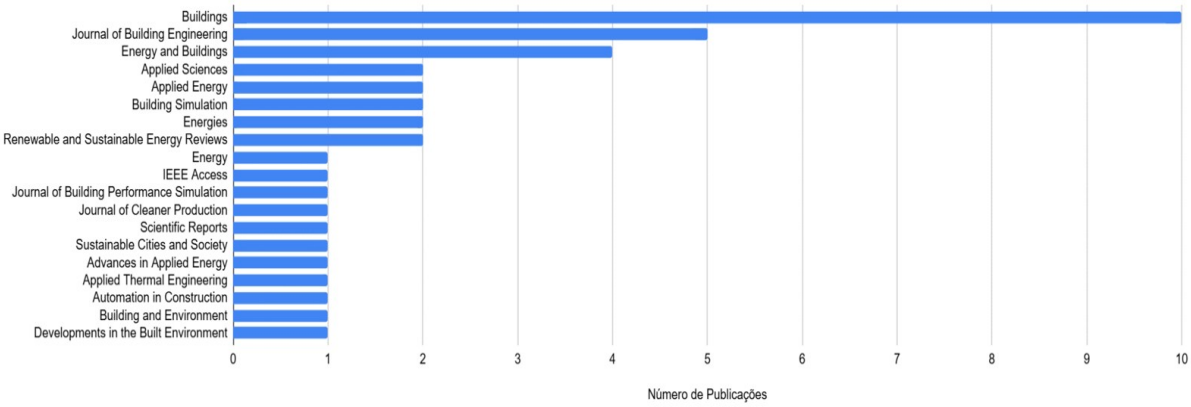

Fonte: Os autores

Nota-se que a revista com maior número de publicações é a *Buildings* (Q1), seguida da *Journal of Building Engineering* (Q1) e *Energy and Buildings* (Q1).

REVISÃO SISTEMÁTICA

De modo geral, observa-se que o EnergyPlus® é amplamente empregado como o modelo de referência "caixa-branca", caracterizado pela possibilidade de acesso à lógica interna, baseado em princípios físicos [12,15]. Seus resultados são fundamentais para treinar, calibrar ou validar modelos orientados por dados de entrada e saída, conhecidos como modelos "caixa-preta", permitindo que algoritmos aprendam padrões complexos de transferência de calor e de consumo energético [16,17].

Uma das abordagens mais recorrentes na literatura é o desenvolvimento de modelos substitutos (*surrogate models*), cujo principal objetivo é reduzir o elevado custo computacional associado a simulações paramétricas extensas e otimizações de projetos [18,19]. Nessa estratégia, o EnergyPlus® é utilizado para gerar grandes bancos de dados sintéticos por meio de variações sistemáticas de parâmetros. Esses dados alimentam algoritmos de aprendizado de máquina, como *Artificial Neural Network* (ANN), *Support Vector Machines* (SVM) e *Random Forest*, que passam a reproduzir as respostas do modelo físico com alta precisão e tempos de processamento significativamente reduzidos [15,19,20].

Outra vertente identificada refere-se à análise de sensibilidade e à avaliação do impacto da resolução dos dados de entrada. Estudos demonstram que nem todos os parâmetros exigem o mesmo nível de detalhamento; enquanto simplificações em janelas e sombreamentos podem ter baixo impacto no erro final, variáveis como agendas de ocupação e configurações de sistemas de climatização (HVAC) exercem

influência crítica sobre a precisão dos resultados [5]. Essa abordagem busca evitar complexidade desnecessária que aumente o tempo de simulação sem ganhos proporcionais em precisão.

Além da escala do edifício individual, a literatura avança para a Modelagem de Energia Urbana (UBEM) por meio de modelos preditivos baseados em dados reais de consumo. Algoritmos treinados a partir de bases de *benchmarking* demonstram que variáveis relacionadas ao uso, dimensão e idade das edificações configuram preditores robustos do consumo de eletricidade, permitindo diagnósticos em larga escala [8,20].

Quando dados reais de consumo são limitados, estratégias baseadas na geração de dados sintéticos a partir de arquétipos são empregadas para estabelecer *benchmarks* de eficiência [13]. Adicionalmente, técnicas de aprendizado de máquina permitem integrar aspectos subjetivos, como a satisfação térmica dos ocupantes, em métodos de *benchmarking* baseados em dados, garantindo que a eficiência energética não comprometa o conforto humano [21].

Com o aumento da complexidade dos modelos, cresce a necessidade de interpretabilidade. Métodos de Inteligência Artificial Explicável (XAI) passam a ser incorporados para converter modelos "caixa-preta" em sistemas transparentes [11]. Essas técnicas permitem identificar os principais fatores que impulsionam o consumo e apoiar a proposição de medidas de *retrofit* de forma clara para os tomadores de decisão.

Finalmente, uma frente emergente foca na integração entre simulações energéticas e microclima urbano. Estudos utilizam algoritmos para aproximar resultados de simulações de Dinâmica dos Fluidos Computacional (CFD), como campos de vento e temperatura, que são posteriormente utilizados como entradas dinâmicas mais realistas no EnergyPlus®. Essa integração mitiga incertezas causadas pelo uso de dados climáticos estáticos e genéricos [17].

Do ponto de vista técnico, destaca-se o uso recorrente da linguagem Python como elemento central de integração entre as diferentes etapas do processo de modelagem e análise de dados [4,18]. Python é amplamente empregado para automatizar a geração de modelos e a entrada de dados no EnergyPlus®, frequentemente utilizando a biblioteca Eppy [18], o que permite a criação de centenas de variações de projeto de forma iterativa e computacionalmente barata [15,18]. A linguagem também é utilizada para monitorar o uso de hardware (CPU) durante as simulações [4], fundamentar o treinamento de modelos de aprendizado de máquina [15] e conduzir processos de otimização global, como Algoritmos Genéticos e Otimização Bayesiana [18].

Quadro 1- Técnicas de Aprendizado de Máquina mais utilizadas

Técnica de Aprendizado de Máquina	Descrição de uso	Autores que utilizaram
Redes Neurais Artificiais (ANN)	Redes que emulam o processamento cerebral para identificar relações complexas nos dados. Atuam como modelos substitutos que reproduzem simulações físicas detalhadas de forma quase instantânea.	[15], [18], [19]
Máquinas de Vetores de Suporte (SVM)	Algoritmos que utilizam fronteiras matemáticas (hiperplanos) para organizar e prever informações. São ideais para criar modelos de referência (benchmarking) que classificam a eficiência de grandes estoques edificados.	[15],[16]
Random Forest	Sistema que combina múltiplas árvores de decisão para gerar resultados mais estáveis. É aplicado em modelos de escala urbana (UBEM) para estimar o consumo de energia com base em dados históricos.	[16], [20]
Agrupamento (Clustering - K-means)	Ferramenta que organiza edifícios com propriedades similares em grupos distintos. Isso facilita a criação de arquétipos para diagnósticos energéticos regionais.	[20]
Inteligência Artificial Explicável (XAI)	Métodos que trazem transparência a modelos complexos ("caixas-pretas"), revelando a lógica das previsões. Ajuda a identificar os principais fatores de consumo.	[11]
Redes Bayesianas	Modelos que utilizam probabilidades para representar relações de causa e efeito. São úteis para incluir variáveis subjetivas, como a percepção de satisfação térmica dos usuários, nas avaliações de desempenho.	[21]
Algoritmos Genéticos e Otimização Bayesiana	Procedimentos automatizados que testam repetidamente milhares de combinações de projeto. Permitem descobrir a configuração ideal de forma muito mais rápida e barata do que simulações tradicionais.	[18]

Fonte: os autores

Embora o Python prevaleça na automação e ciência de dados, a literatura aponta o uso de outras linguagens para finalidades específicas. A linguagem Ruby é o alicerce de ferramentas avançadas de *Urban Energy Modeling* (UBEM), como o *AutoBPS*, que opera sobre os motores do *OpenStudio* e *EnergyPlus* para simulações em escala urbana [22]. O *MATLAB* e o seu ambiente *Simulink* são citados como interfaces de integração fundamentais para simulações que conectam modelos energéticos de edifícios a outros algoritmos e sistemas de controle [12,17].

Adicionalmente, linguagens como *Modelica* são destacadas pela sua flexibilidade na simulação dinâmica de sistemas de controle de climatização (HVAC) e co-simulação

[12,17]. Por fim, as linguagens C e C++ aparecem como interfaces de script e APIs de alto desempenho essenciais para invocar simulações e desenvolver ferramentas de integração [17]. Essa diversidade de linguagens permite a construção de fluxos de trabalho integrados, reproduzíveis e eficientes, conectando modelos físicos a algoritmos de decisão avançados.

CONCLUSÃO

O estudo demonstrou que as abordagens identificadas na literatura concentram-se, primordialmente, no desenvolvimento de modelos substitutos (*surrogate models*) para a redução drástica do custo computacional, permitindo otimizações globais que seriam inviáveis via simulação física direta. Destaca-se também a relevância da análise de sensibilidade para identificar parâmetros críticos, como agendas de ocupação e configurações de HVAC, que impactam a fidelidade do modelo, em contraposição a parâmetros geométricos que admitem maior simplificação. A ampliação da modelagem energética para a escala urbana consolidou-se como uma tendência central, apoiada tanto por dados reais de *benchmarking* e leis de transparência energética quanto pela geração de grandes bases de dados sintéticas a partir de arquétipos simulados no *EnergyPlus*®.

Apesar dos avanços, a literatura evidencia limitações estruturais que balizam as lacunas de pesquisa. Persiste a necessidade de uma validação mais robusta frente ao "*gap* de desempenho", confrontando modelos com dados medidos de edificações reais para mitigar incertezas de entrada. Observa-se que a aplicação dos métodos ainda carece de maior diversidade tipológica, uma vez que arquétipos simplificados muitas vezes falham em representar a complexidade de grandes campi universitários ou edifícios multifuncionais. Além disso, a incorporação de dados comportamentais dinâmicos e do microclima urbano (via integração BEM-CFD) é imperativa para mitigar erros causados por dados meteorológicos estáticos e não representativos. Para o contexto brasileiro, o grande desafio reside na escassez de dados reais de consumo para validação de arquétipos nacionais. Futuras pesquisas devem focar na criação de bases de benchmarking públicas integradas a dados climáticos regionais de modo a melhorar a qualidade dos resultados.

Por fim, a ausência de fluxos de trabalho padronizados e a crescente opacidade dos modelos "caixa-preta" indicam que o avanço da área depende da adoção de métodos de Explainable Artificial Intelligence (XAI). Tais métodos conferem a transparência necessária para identificar os *drivers* de consumo, tornando a integração entre simulação e aprendizado de máquina uma ferramenta replicável e confiável de apoio à tomada de decisão em políticas de eficiência energética e *retrofit* em diferentes contextos urbanos.

AGRADECIMENTOS

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio concedido ao primeiro autor.

DECLARAÇÃO

Durante a preparação deste artigo, o primeiro autor utilizou o NotebookLM para organizar as informações do Quadro 1. Após a utilização da ferramenta, os autores revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo do artigo publicado

REFERÊNCIAS

[1] UNITED NATIONS ENVIRONMENT PROGRAMME. 2022 Global Status Report for Buildings and Construction: Towards a Zero-emission, Efficient and Resilient Buildings and Construction Sector. 2022. Disponível em: https://wedocs.unep.org/20.500.11822/41133. Acesso em: 31 maio 2025.

[2] EMPRESA DE PESQUISA ENERGÉTICA (EPE). **Anuário estatístico de energia elétrica 2024: ano base 2023. Rio de Janeiro: EPE**, 2024. Disponível em: https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/anuario-estatistico-de-energia-eletrica. Acesso em: 31 de maio de 2025.

[3] JARADAT, M.; AL MAJALI, H.; BENDEA, C. et al. Enhancing Energy Efficiency in Buildings through PCM Integration: A Study across Different Climatic Regions. **Buildings**,[S.l.], v. 14, n. 1,40, 2024. DOI: https://doi.org/10.3390/buildings14010040.

[4] KONG, D. et al. Evaluation of the Impact of Input-Data Resolution on Building-Energy Simulation Accuracy and Computational Load—A Case Study of a Low-Rise Office Building. **Buildings**, v. 13, n. 4, p. 861, 2023. DOI: https://doi.org/10.3390/buildings13040861.

[5] WOLKART, Isabella Cardoso. Abordagem BIM-BEM-LCA: Análise da interoperabilidade de software BIM para análise de desempenho termoenergético e da emissão de carbono no ciclo de vida de edificações. 2025. 150 f. Dissertação (Mestrado em Engenharia Civil), Universidade Federal do Espírito Santo, Vitória, 2025.

[6] U.S. DEPARTMENT OF ENERGY. EnergyPlus. [S. l.]: Energy.gov, 2014. Disponível em: https://www.energy.gov/cmei/buildings/articles/energyplus. Acesso em: 16 abr. 2026

[7] PROCEL. Centro Brasileiro de Informação de Eficiência Energética. Disponível em: http://www.procelinfo.com.br/main.asp?TeamID=%7B82BBD82C-FB89-48CA-98A9-620D5F9DBD04%7D. Acesso em: 31 maio 2025.

[8] BURMAN, E.; HONG, S.; PATERSON, G.; KIMPIAN, J. A comparative study of benchmarking approaches for non-domestic buildings: Part 2 – Bottom-up approach.

International Journal of Sustainable Built Environment, v. 3, n. 2, p. 247–261, 2014. DOI: 10.1016/j.ijsbe.2014.12.001.

[9] HEESEN, F.; MADLENER, R. Consumer behavior in energy-efficient homes: the limited merits of energy performance ratings as benchmarks. **Energy and Buildings**, v. 172, p. 405–413, 2018. DOI: 10.1016/j.enbuild.2018.04.039.

[10] LI, U.; SHAMSI, M. H.; HOARE, C.; MANGINA, E.; O'DONNELL, J. A data-driven approach for multi-scale building archetypes development. **Energy and Buildings**, v. 202, 2019. DOI: https://doi.org/10.1016/j.enbuild.2019.109364.

[11] DARVISHVAND, L. et al. A systematic review of explainable artificial intelligence in urban building energy modeling: methods, applications, and future directions. **Sustainable Cities and Society**, v. 128, p. 106492, 2025. DOI: https://doi.org/10.1016/j.scs.2025.106492.

[12] PAN, Y. et al. Building energy simulation and its application for building performance optimization: A review of methods, tools, and case studies. **Advances in Applied Energy**, v. 10, p. 100135, 2023. DOI: https://doi.org/10.1016/j.adapen.2023.100135.

[13] CHONG, A.; YAN, D.; SUN, K. et al. Ten questions concerning calibrating building energy simulation models. **Building and Environment**, v. 284, 113404, 2025. DOI: https://doi.org/10.1016/j.buildenv.2025.113404.

[14] PAGE, M. J. et al. **The PRISMA 2020 statement: an updated guideline for reporting systematic reviews.** *BMJ*, v. 372, n. 71, 2021. DOI: https://doi.org/10.1136/bmj.n71.

[15] QUEVEDO, T. C.; GERALDI, M. S.; MELO, A. P. Applying machine learning to develop energy benchmarking for university buildings in Brazil. **Journal of Building Engineering**, v. 63, p. 105468, 2023. DOI: https://doi.org/10.1016/j.jobe.2022.105468.

[16] KONTOKOSTA, Constantine E.; TULL, Christopher. A data-driven predictive model of city-scale energy use in buildings. **Applied Energy**, v. 197, p. 303–317, 2017. DOI: https://doi.org/10.1016/j.apenergy.2017.04.005.

[17] HUANG, W. et al. Urban multi-scale building energy modeling (BEM) and computational fluid dynamics (CFD) integration: Tools, strategies and accuracy for energy microclimate analysis. **Journal of Building Engineering**, v. 103, p. 112041, 2025. DOI: https://doi.org/10.1016/j.jobe.2025.112041.

[18] KUBWIMANA, B.; NAJAFI, H. A Novel Approach for Optimizing Building Energy Models Using Machine Learning Algorithms. **Energies**, v. 16, n. 3, p. 1033, 2023. DOI: https://doi.org/10.3390/en16031033.

[19] PITTARELLO, Marco et al. Artificial Neural Networks to Optimize Zero Energy Building (ZEB) Projects from the Early Design Stages. **Applied Sciences**, [S. l.], v. 11, n. 12, 5377, 2021. DOI: https://doi.org/10.3390/app11125377.

[20] NAGANATHAN, H.; CHONG, W. O.; CHEN, X. Building energy modeling (BEM) using clustering algorithms and semi-supervised machine learning approaches. **Automation**

in Construction, v. 72, p. 202–213, 2016. DOI: https://doi.org/10.1016/j.autcon.2016.07.001.

[21] GERALDI, M. S.; GHISI, E. Integrating evidence-based thermal satisfaction in energy benchmarking: A data-driven approach for a whole-building evaluation. **Energy**, v. 244, p. 123161, 2022. DOI: https://doi.org/10.1016/j.energy.2022.123161.

[22] XI, H.; ZHANG, Q.; REN, Z.; LI, G.; CHEN, Y. Urban Building Energy Modeling with Parameterized Geometry and Detailed Thermal Zones for Complex Building Types. **Buildings**, [S.l.], v. 13, n. 11, 2675, 2023. DOI: https://doi.org/10.3390/buildings13112675.