



DE HORAS PARA MILISSEGUNDOS: ANÁLISE DO DESEMPENHO TÉRMICO COM APRENDIZADO DE MÁQUINA

From hours to milliseconds: accelerating thermal performance with machine learning

Vítor Freitas Mendes

Instituto Federal de Minas Gerais | Santa Luzia, Minas Gerais | vitor.mendes@aluno.ufop.edu.br

Israel Louback Ribeiro Júnior

Universidade Federal de Juiz de Fora | Juiz de Fora, Minas Gerais | isaellouback@hotmail.com

Gabriela Oliveira Pessoa

Universidade Federal de Ouro Preto | Ouro Preto, Minas Gerais | gabriela.pessoa@aluno.ufop.edu.br

Júlia Castro Mendes

Universidade Federal de Juiz de Fora | Juiz de Fora, Minas Gerais | juliacaastro.mendes@ufff.br

Resumo

Este estudo desenvolveu modelos de Aprendizado de Máquina para prever o desempenho térmico de edificações, considerando Carga Térmica e Graus-Hora. Foram realizadas simulações energéticas no EnergyPlus para avaliar 35.280 combinações de paredes, pisos e coberturas em Curitiba, São Paulo e Belém, representando diferentes zonas bioclimáticas. Os modelos foram treinados com XGBoost, validados por validação cruzada (10-fold) e avaliados por R^2 , MAE e MAPE. Os resultados mostraram alta precisão ($R^2 > 0,99$, MAPE $< 6,1\%$), permitindo previsões rápidas em milissegundos. Mesmo com apenas 2% dos dados, o modelo manteve R^2 acima de 0,90, tornando-o uma alternativa eficiente às demoradas simulações energéticas. A abordagem possibilita análises térmicoenergéticas ágeis, reduz tempo e custo computacional e contribui para o desenvolvimento de edificações mais sustentáveis e resilientes.

Palavras-chave: Inteligência Artificial; Edificação; Simulação energética; Carga térmica; Graus-hora.

ABSTRACT

This study developed Machine Learning models to predict the thermal performance of buildings, considering Thermal Load and Degree-Hours. Energy simulations were conducted in EnergyPlus to evaluate 35,280 combinations of walls, floors, and roofs in Curitiba, São Paulo, and Belém, representing different bioclimatic zones. The models were trained using XGBoost, validated through 10-fold cross-validation, and assessed using R^2 , MAE, and MAPE. The results demonstrated high accuracy ($R^2 > 0.99$, MAPE $< 6.1\%$), enabling rapid predictions in milliseconds. Even with only 2% of the dataset, the model maintained R^2 above 0.90, making it an efficient alternative to time-consuming energy simulations. This approach enables fast thermal-energy analyses, reduces time and computational costs, and contributes to the development of more sustainable and resilient buildings.

Keywords: Artificial Intelligence; Building; Energy simulation; Thermal load; Degree-hour.

1 INTRODUÇÃO

As edificações são grandes consumidoras de energia e contribuem significativamente para as emissões de gases de efeito estufa (Ngo, 2019). Uma envoltória com adequado desempenho térmico reduz o consumo de energia para climatização, promove conforto térmico e garante resiliência (Lamberts, Dutra e Pereira, 2014). O desempenho térmico de uma edificação depende de fatores como *layout*, altura, sombreamento, orientação solar e ventilação, mas os materiais da envoltória são um dos principais influenciadores (Mendes *et al.*, 2022). Para avaliá-lo, normas internacionais utilizam simulações energéticas, sendo os métodos Grau-Hora (GH) e Carga Térmica (CT) os mais aplicados (Mendes *et al.*, 2024). O GH mede a intensidade do desconforto térmico ao comparar a temperatura interna com limites de conforto, enquanto a CT calcula a energia consumida por sistemas de climatização para manter temperaturas internas adequadas. Quanto menores os valores de GH e CT, melhor o desempenho térmico da edificação, reduzindo custos e impacto ambiental durante sua vida útil.

No entanto, simulações energéticas exigem alto custo computacional e esforço humano (Forouzandeh *et al.*, 2023). O aprendizado de máquina (AM) surge como alternativa promissora por sua capacidade de processar grandes volumes de dados, identificar padrões e estimar resultados com rapidez e precisão (Ibarra-Vazquez *et al.*, 2023; García e Morilón, 2022). Assim, este estudo desenvolveu um modelo de AM para prever o desempenho térmico de edificações, considerando os métodos GH e CT, a fim de auxiliar na escolha de sistemas construtivos mais eficientes e sustentáveis.

Embora o AM já tenha sido aplicado com sucesso para prever a CT em etiquetagem energética e dimensionamento de ar-condicionado (Rackes, Melo e Lamberts, 2016; Machado *et al.*, 2023), este trabalho inova ao estimar também o método GH, ainda pouco explorado em pesquisas que utilizam AM. Além disso, analisa o impacto do tamanho do banco de dados sobre a precisão dos modelos desenvolvidos e oferece uma ferramenta treinada com base em uma ampla variedade de sistemas construtivos utilizados no Brasil. Ao aplicar o modelo em diferentes zonas bioclimáticas brasileiras, especificamente em Curitiba (ZB1M), São Paulo (ZB2M) e Belém (ZB6A), o estudo reforça sua aderência às temáticas de tecnologias e materiais de baixo carbono, uma vez que viabiliza avaliações rápidas e precisas do desempenho térmico. Essa metodologia proporciona análises eficientes com menor custo operacional, favorecendo decisões informadas para construções resilientes, energeticamente eficientes e ambientalmente sustentáveis.

2 METODOLOGIA

A Figura 1 apresenta uma visão geral da metodologia deste trabalho. Foram realizadas simulações energéticas no EnergyPlus v22.1 para avaliar o desempenho térmico de duas edificações. Como se observa na Figura 2, trata-se de residências térreas unifamiliares de pequeno porte, 40m², compostas por uma cozinha, uma sala, um banheiro e dois quartos, tendo seus *layouts* distintos. A análise foi feita para Curitiba, São Paulo e Belém, representantes das ZBs 1M (“muito fria com inverno moderado”), 3 (“fria com inverno moderado”) e 8 (“muito quente e úmida”) (ABNT, 2024), respectivamente. Para facilitar a compreensão os estudos, as cidades serão tratadas de forma relativa: Belém como cidade quente, São Paulo como amena e Curitiba como fria. Foram testados 35 tipos distintos de parede, 21 de piso e 48 de cobertura, totalizando 35.280 combinações construtivas.

Figura 1: Metodologia da pesquisa

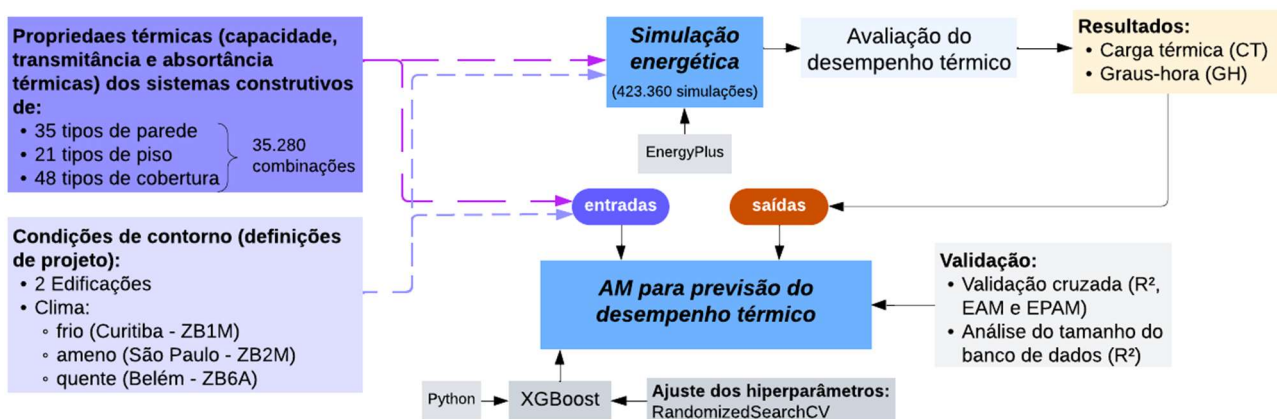


Figura 2: Edificações analisadas

Edificação 1



Edificação 2



As configurações de parâmetros da simulação energética, que impactam no desempenho térmico, como ocupação, iluminação e temperatura operativa das edificações seguiram recomendações da NBR 15575 (ABNT, 2024). O desempenho térmico foi avaliado sob os métodos da Carga Térmica (CT) e Graus-Hora (GH), seguindo as definições de Mendes *et al.* (2024). A CT foi avaliada a partir da energia demandada pelo sistema mecânico de climatização funcionando, quando a edificação estivesse ocupada e com temperaturas internas fora da faixa operativa (21-23°C). Mesmo em locais onde a norma não exige a avaliação de carga térmica para aquecimento (CTa), como São Paulo e Belém, essa análise foi realizada juntamente com a carga térmica de resfriamento (CTr), garantindo uma avaliação completa o desempenho térmica da edificação, prezando pelo conforto térmico dos habitantes, melhoria da eficiência energética e uniformidade metodológica da pesquisa para todos os cenários avaliados.

Os resultados de GH foram extraídos continuamente, com foco no número de graus que excediam os limites da faixa operativa (18–26 °C) a cada hora, considerando apenas a ventilação natural da edificação, sem estratégia ativa de garantia do conforto térmico interno. Foram calculados os graus-hora de calor (GHc) e de frio (GHf), que representam a intensidade de desconforto anual devido ao calor e ao frio, respectivamente. Os valores obtidos para cada cômodo de longa permanência (sala e quartos) foram ponderados pela área de cada um, resultando em um valor específico para GHc e GHf, assim como para CTa e CTr.

Cruz *et al.* (2024) realizaram uma revisão sistemática de estudos que utilizaram AM para prever o desempenho térmico de edificações, tendo identificado o algoritmo XGBoost como um dos mais utilizados na literatura especializada e, por isso, decidiu-se por adotá-lo neste estudo. Os modelos foram criados em Python, tendo seus hiperparâmetros ajustados via *RandomizedSearchCV* e sendo submetidos a uma validação cruzada *K-fold* ($k = 10$). Como entrada, foram utilizados os valores das propriedades termofísicas dos sistemas (parede, piso e cobertura) de cada combinação construtiva, e a saída prevista foi o desempenho térmico (CTa, CTr, GHc e GHf). A lista completa dos materiais, suas propriedades termofísicas (transmitância e capacidade térmica) para cada sistema construtivo e os valores dos hiperparâmetros otimizados em cada modelo está disponível para acesso neste [link](#). As propriedades termofísicas, como massa específica, calor específico e condutividade térmica, seguiram conformidades da NBR 15220 (ABNT, 2005), além da transmitância e capacidade térmica serem calculadas de acordo com suas diretrizes. Para materiais não contemplados na norma, as propriedades foram baseadas nos dados de Clarke (2001).

O desempenho dos modelos de AM foi avaliado pelo coeficiente de determinação (R^2), Erro Absoluto Médio (MAE) e Erro Percentual Absoluto Médio (MAPE). Também foi analisado o impacto da quantidade de amostras de treino na previsão do desempenho térmico. Para isso, o banco de dados foi dividido em proporções de treino de 1% a 10%. Em cada caso, o modelo foi treinado com a porcentagem definida e testado no restante. O desempenho foi medido pela média do R^2 em 100 repetições, reduzindo variações aleatórias.

3 RESULTADOS E ANÁLISE

A Tabela 1 apresenta a alta precisão obtida nos modelos de AM criados. Não se verifica diferenças significativas entre os desempenhos para os diferentes climas nem para as diferentes edificações analisadas. Os modelos obtiveram R^2 acima de 0,99 e MAPE abaixo de 6,1%, sendo inferior a 1,1% na maioria dos casos. Esses resultados corroboram pesquisas anteriores, como Seyedzadeh *et al.* (2019), que encontraram R^2 de 0,986 para CT de resfriamento e 0,982 para aquecimento, e Sauer *et al.* (2022), que reportaram R^2 de 0,998 para aquecimento e 0,989 para resfriamento.

Tabela 1: Desempenho dos modelos de AM

Métrica	Edif.	Curitiba (ZB1M)			São Paulo (ZB2M)			Belém (ZB6A)		
		R^2	MAE	MAPE	R^2	MAE	MAPE	R^2	MAE	MAPE
CTr	1	0,9993	7,69 MJ	0,35%	0,9997	4,29 MJ	0,03%	0,9994	21,21 MJ	0,09%
	2	0,9998	1,81 MJ	0,14%	0,9998	2,24 MJ	0,10%	0,9997	4,44 MJ	0,03%
CTa	1	0,9998	3,74 MJ	0,14%	0,9998	2,76 MJ	0,20%	-	-	-
	2	0,9999	1,19 MJ	0,08%	0,9999	0,72 MJ	0,10%	-	-	-
GHc	1	0,9992	10,67 °C·h	1,10%	0,9995	13,68 °C·h	2,20%	0,9992	8,45 °C·h	0,03%
	2	0,9997	1,84 °C·h	6,02%	0,9998	3,92 °C·h	1,10%	0,9995	7,92 °C·h	0,02%
GHf	1	0,9999	4,39 °C·h	0,12%	0,9997	3,32 °C·h	0,30%	-	-	-
	2	0,9999	4,39 °C·h	0,12%	0,9998	3,27 °C·h	0,40%	-	-	-

Belém não apresentou valores para CTa e GHf, pois as temperaturas nunca ficaram abaixo dos limites de conforto térmico, comportamento esperado para seu clima bastante quente (ZB6A) (ABNT, 2024). O MAPE do GH foi geralmente maior que o do CT, pois a simulação de CT considera a operação do HVAC apenas no período de ocupação (14h às 8h), enquanto o GH avalia 24 horas com ventilação aberta, tornando-se mais sensível às trocas térmicas. Além disso, o GH soma linearmente as diferenças de temperatura, enquanto o CT contabiliza a energia consumida, considerando fatores como umidade e eficiência do sistema (Mendes *et al.*, 2024).

O modelo desenvolvido demonstrou alta eficiência, levando menos de 2 segundos para prever CT e GH na edificação 1 e menos de 5 segundos na edificação 2, incluindo treinamento, validação cruzada e cálculo das métricas para todas as 35.280 combinações construtivas, para cada região climática analisada. Isso representa um avanço significativo, pois a previsão de novos cenários agora ocorre em milissegundos, sem a necessidade de executar simulações energéticas demoradas para cada nova combinação de materiais ou condições climáticas.

Quanto à influência do tamanho do banco de dados no desempenho dos modelos de AM, as Figura 3 e 4 apresentam os valores de R^2 para amostragens de teste entre 1% e 10% do banco de dados original, comparando-os com a validação cruzada (10-fold) de todo o banco de dados (100%). Mesmo com redução no conjunto de dados, o modelo manteve R^2 acima de 0,81 com apenas 1% dos dados e acima de 0,90 a partir de 2%, com baixa dispersão. O maior desvio padrão (encontrado nos modelos com 1% do banco de dados) foi inferior a 1% em todos os casos.

Figura 3: Influência da redução do tamanho do banco de dados nos modelos desenvolvidos -1

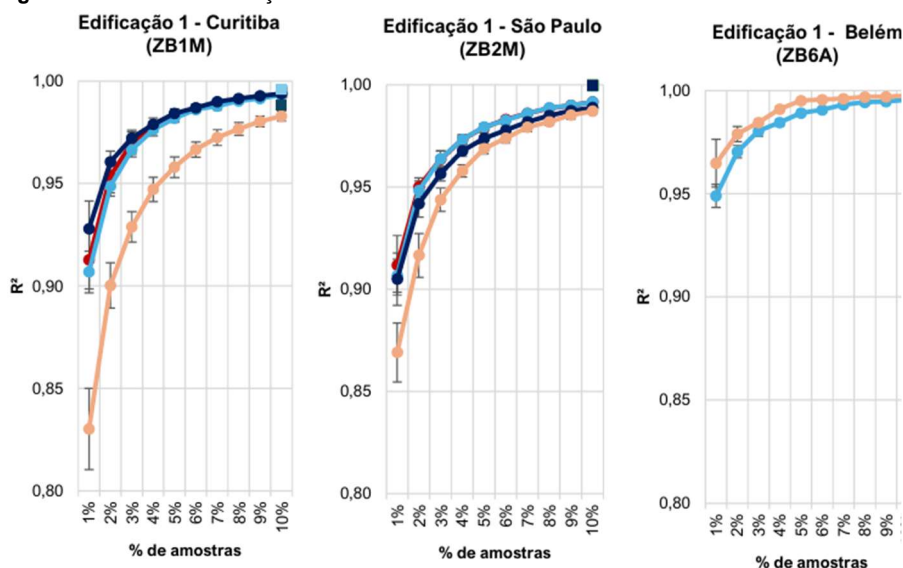
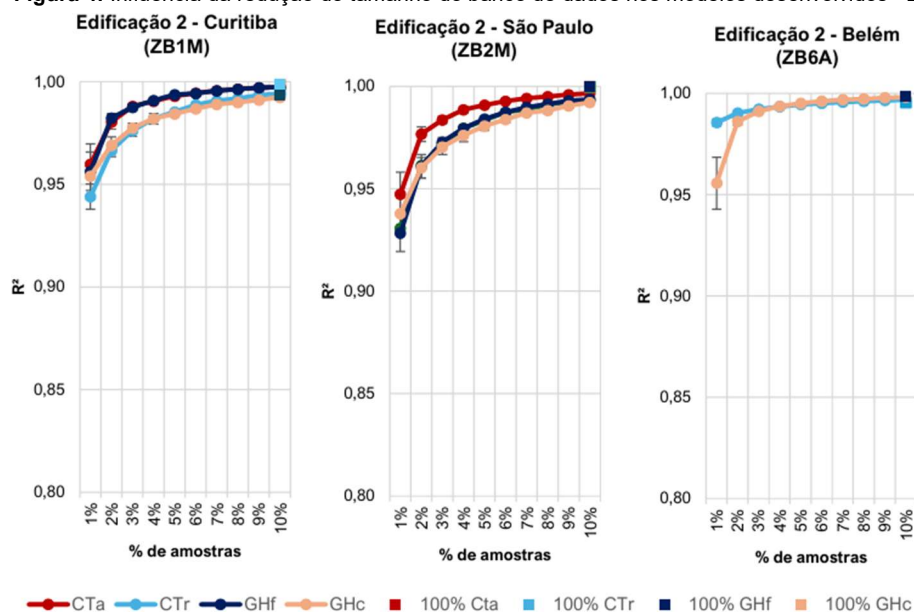


Figura 4: Influência da redução do tamanho do banco de dados nos modelos desenvolvidos - 2



Fonte: os autores.

A fase de simulações energéticas deste trabalho mostrou que rodar apenas 2% do banco de dados no EnergyPlus leva cerca de 1 hora em um computador básico, tornando a abordagem acessível para pesquisadores, projetistas e empresas do ramo de projetos de edificações.

4 CONCLUSÃO

Este estudo desenvolveu modelos de AM para prever o desempenho térmico de edificações, considerando CT e GH. Foram realizadas simulações energéticas no EnergyPlus para avaliar 35.280 combinações de paredes, pisos e coberturas em Curitiba, São Paulo e Belém, representando diferentes zonas bioclimáticas do Brasil. Os modelos foram treinados com XGBoost, validados por validação cruzada (10-fold) e avaliados por R^2 , MAE e MAPE. Os resultados demonstraram alta precisão, com R^2 superior a 0,99 e MAPE abaixo de 6,1%, sendo menor que 1,1% na maioria dos casos. O modelo também foi testado com diferentes tamanhos de amostra e manteve R^2 acima de 0,81 com apenas 1% dos dados de treino, atingindo 0,90 a partir de 2%.

A principal contribuição deste trabalho é a capacidade do modelo de substituir simulações energéticas demoradas por previsões rápidas e precisas, feitas em milissegundos. Isso permite avaliar rapidamente o desempenho térmico de novos materiais e sistemas construtivos, tornando a ferramenta útil para projetistas, pesquisadores e engenheiros. Além de reduzir o tempo e custo computacional, o modelo possibilita uma análise térmica eficiente para melhorar a escolha de sistemas construtivos, contribuindo para edificações mais resilientes e sustentáveis.

5 AGRADECIMENTOS

Os autores agradecem o apoio financeiro das agências de fomento CAPES (Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Código Financeiro 001 – bolsa de doutorado para Vítor Mendes e de mestrado para Gabriela Oliveira) e CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico pela bolsa de iniciação científica de Israel Louback e pelo projeto 305818/2023-6 de Júlia Mendes). Os autores também agradecem ao CIDENG-CNPq, Grupo de Pesquisa em Ciência de Dados aplicado à Engenharia, pela colaboração.

REFERÊNCIAS

ABNT. **NBR 15220** - Desempenho térmico em edificações. Associação Brasileira de Normas Técnicas. Rio de Janeiro. 2005.

- ABNT. **NBR 15220** - Desempenho térmico em edificações. Associação Brasileira de Normas Técnicas. Rio de Janeiro. 2024.
- ABNT. **NBR 15575** - Edifícios Residenciais - Desempenho Térmico. Associação Brasileira de Normas Técnicas. Rio de Janeiro. 2024.
- CLARKE, J. A. **Energy Simulation in Building Design**. 2. ed. [S.I.]: Butterworth-Heinemann, 2001.
- CRUZ, A. S. et al. Multi-objective optimization based on surrogate models for sustainable building design: A systematic literature review. **Building and Environment**, v. 266, p. 112147, 2024. <https://doi.org/10.1016/j.buildenv.2024.112147>
- FOROUZANDEH, N. et al. Room energy demand and thermal comfort predictions in early stages of design based on the Machine Learning methods. **Intelligent Buildings International**, 15, 2023. 3-20. <https://doi.org/10.1080/17508975.2022.2049190>
- GARCÍA, I. K.; MORILÓN, D. G. ANNEXE: An open-source building energy design optimisation framework using artificial neural networks and genetic algorithms. **Journal of Cleaner Production**, 371, 2022. <https://doi.org/10.1016/j.jclepro.2022.133500>
- IBARRA-VAZQUEZ, G. et al. Predicting open education competency level: A machine learning approach. **Heliyon**, 9, 2023. <https://doi.org/10.1016/j.heliyon.2023.e20597>
- LAMBERTS, R.; DUTRA, L.; PEREIRA, F. O. R. **Eficiência energética na arquitetura**. 3ª. ed. Rio de Janeiro: ELETROBRAS/PROCEL, 2014.
- MACHADO, R. M. E. S. et al. Metamodel to predict annual cooling thermal load for commercial, services and public buildings: A country-level approach to support energy efficiency regulation. **Energy and Buildings**, 301, 2023. <https://doi.org/10.1016/j.enbuild.2023.113690>
- MENDES, V. F. et al. Sensitivity analysis of coating mortars according to their specific heat, specific gravity, thermal conductivity, and thickness in contribution to the global thermal performance of buildings. **Sustainable Materials and Technologies**, v. 31, p. e00381, 2022. <https://doi.org/10.1016/j.susmat.2021.e00381>
- MENDES, V. F. et al. A systematic review of methods for evaluating the thermal performance of buildings through energy simulations. **Renewable and Sustainable Energy Reviews**, 189, 2024. <https://doi.org/10.1016/j.rser.2023.113875>
- NGO, N.-T. Early predicting cooling loads for energy-efficient design in office buildings by machine learning. **Energy e Buildings**, 182, 2019. 264-273. <https://doi.org/10.1016/j.enbuild.2018.10.004>
- RACKES, A.; MELO, A. P.; LAMBERTS, R. Naturally comfortable and sustainable: Informed design guidance and performance labeling for passive commercial buildings in hot climates. **Applied Energy**, 174, 2016. 256-274. <https://doi.org/10.1016/j.apenergy.2016.04.081>
- SEYEDZADEH, S. et al. Tuning machine learning models for prediction of building energy loads. **Sustainable Cities and Society**, 47, 2019. <https://doi.org/10.1016/j.scs.2019.101484>