

**UNIVERSIDADE FEDERAL DE JUIZ DE FORA
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO
ENGENHARIA COMPUTACIONAL**

Israel Louback Ribeiro Júnior

**Aprendizado de Máquina aplicado à análise de desempenho térmico de
edificações**

Juiz de Fora
2025

Israel Louback Ribeiro Júnior

Aprendizado de Máquina aplicado à análise de desempenho térmico de edificações

Trabalho de Conclusão de Curso
apresentado ao Programa de Graduação
em Engenharia Computacional da
Universidade Federal de Juiz de Fora
como requisito parcial à obtenção do título
de bacharel em Engenharia
Computacional

Data da aprovação: 20/08/2025

Orientadora: Profa. D.Sc. Júlia Castro Mendes – UFJF

Coorientador: Prof. Me. Vitor Freitas Mendes – IFMG

Juiz de Fora

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Júnior, Israel Louback Ribeiro.

Aprendizado de Máquina aplicado à análise de desempenho térmico de edificações / Israel Louback Ribeiro Júnior. -- 2025.
84 f. : il.

Orientadora: Júlia Castro Mendes


Coorientador: Vitor Freitas Mendes

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Engenharia, 2025.

1. Aprendizado de Máquina. 2. Desempenho Térmico. 3. Simulação Energética. 4. Carga Térmica. 5. Graus-hora. I. Mendes, Júlia Castro, orient. II. Mendes, Vitor Freitas, coorient. III. Título.

Concluídos os trabalhos de apresentação e argüição em sessão pública, o(a) aluno(a) Israel Louback Ribeiro Júnior foi aprovado pela banca examinadora.

Na forma regulamentar, foi lavrada a presente ata, que segue assinada pelos membros da banca examinadora e pelo respectivo aluno(a).



Juiz de Fora, 20 de Agosto de 2025.

Documento assinado digitalmente
gov.br ISRAEL LOUBACK RIBEIRO JUNIOR
Data: 21/08/2025 14:34:19-0300
Verifique em <https://validar.iti.gov.br>

Israel Louback Ribeiro Júnior
Aluno(a)

Documento assinado digitalmente
gov.br JULIA CASTRO MENDES
Data: 21/08/2025 10:52:30-0300
Verifique em <https://validar.iti.gov.br>

Júlia Castro Mendes
Orientador(a)

Documento assinado digitalmente
gov.br VITOR FREITAS MENDES
Data: 21/08/2025 11:07:49-0300
Verifique em <https://validar.iti.gov.br>

Vitor Freitas Mendes
Coorientador(a)

Documento assinado digitalmente
gov.br LUCIANA CONCEICAO DIAS CAMPOS
Data: 21/08/2025 17:34:30-0300
Verifique em <https://validar.iti.gov.br>

Luciana Conceição Dias Campos
1º Examinador(a)

Documento assinado digitalmente
gov.br ALDO RIBEIRO DE CARVALHO
Data: 21/08/2025 15:07:41-0300
Verifique em <https://validar.iti.gov.br>

Aldo Ribeiro Carvalho
2º Examinador(a)

Dedico este trabalho à memória dos meus avós,
Sra. Maria da Conceição Aparecida Ribeiro e Sr. Apolônio Louback,
cujas presenças permanecem vivas em minhas lembranças e conquistas.

AGRADECIMENTOS

Agradeço, primeiramente, a Deus e à Nossa Senhora por me abençoarem e me concederem força e saúde para concluir mais uma etapa importante da minha vida. Aos meus pais, Israel e Marta, por todo o apoio, amor e por nunca medirem esforços, mesmo nos momentos mais difíceis, para que eu pudesse chegar até aqui. Ao meu irmão, Caio, por todo o exemplo, parceria e incentivo. À minha namorada, Karen, pelo amor, paciência e ajuda incondicional, especialmente nos últimos tempos. À minha família por todo incentivo desde o início. Aos amigos do curso e da vida, que de alguma forma contribuíram nessa jornada. Ao saudoso Carlos Augusto e à sua família, pela generosidade e colaboração ao longo da minha caminhada. À minha orientadora, Júlia, e ao coorientador, Vitor, por toda orientação, paciência e ajuda.

Agradeço, também, ao Grupo de Pesquisa em Ciências de Dados Aplicadas à Engenharia (CIDENG – CNPq), pelos incentivos, e à Universidade Federal de Juiz de Fora, pela oportunidade de realizar a graduação.

RESUMO

A crescente demanda energética para o condicionamento térmico de edificações transcende a esfera ambiental, alcançando também dimensões sociais e econômicas, visto que a necessidade de manter um ambiente interno confortável acarreta custos financeiros significativos para famílias. É essencial priorizar o desempenho térmico das edificações, garantindo o menor consumo de energia possível e conforto dos usuários. Assim, o presente trabalho tem como objetivo desenvolver modelos de aprendizado de máquina (*Machine Learning* - ML) para prever o desempenho térmico de edificações com base nas propriedades termofísicas dos materiais utilizados em sua envoltória. Para tal, foram empregados modelos baseados em árvores de decisão aplicado a duas habitações de interesse social. Assim, foi construído um banco de dados com 35280 combinações de sistemas construtivos (35 tipos de paredes, 21 de pisos e 48 de coberturas). As avaliações do desempenho térmico foram conduzidas com as métricas de Carga Térmica (CT) e Graus-Hora (GH), a partir de simulações energéticas realizadas no *software* EnergyPlus, considerando o clima de três cidades: Curitiba, São Paulo e Belém. Inicialmente, utilizando todas as instâncias no treinamento do modelo, o desempenho foi satisfatório. Posteriormente, submetendo os modelos à previsão com combinações envolvendo sistemas construtivos inéditos, observou-se uma queda de desempenho nos resultados. Apesar disso, os resultados iniciais indicam uma boa capacidade de predição para combinações com sistemas conhecidos, o que reduz a necessidade de tantas simulações energéticas. Também foi explorada a técnica de *transfer learning*, para testar os modelos quando lidam com uma edificação distinta do treinamento. As métricas apresentaram uma queda significativa, evidenciando uma possível insuficiência de variáveis representativas, que permitissem uma melhor generalização por parte dos modelos. Conclui-se que o uso de técnicas de ML configura uma abordagem promissora para promover maior eficiência e eficácia no projeto de edificações, representando um campo com amplo potencial de desenvolvimento e aplicação.

Palavras-chave: Aprendizado de Máquina; Árvore de decisão; Regressão; Desempenho térmico; Eficiência energética; Carga Térmica; Graus-hora; Simulação energética.

ABSTRACT

The increasing energy demand for the thermal conditioning of buildings transcends the environmental sphere, also reaching social and economic dimensions, since the need to maintain a comfortable indoor environment entails significant financial costs for families. It is essential to prioritize the thermal performance of buildings, ensuring the lowest possible energy consumption and user comfort. Thus, the present work aims to develop machine learning (ML) models to predict the thermal performance of buildings based on the thermophysical properties of the materials used in their envelope. For this purpose, models based on decision trees were applied to two social housing units. A database with 35,280 combinations of construction systems was built (35 types of walls, 21 types of floors, and 48 types of roofs). Thermal performance assessments were conducted using the metrics of Cooling/Heating Load (CT) and Degree-Hours (GH), based on energy simulations performed in the EnergyPlus software, considering the climate of three cities: Curitiba, São Paulo, and Belém. Initially, using all instances for model training, the performance was satisfactory. Subsequently, when the models were tested with combinations involving new construction systems, a decrease in performance was observed. Despite this, the initial results indicate a good predictive capacity for combinations with known systems, which reduces the need for so many energy simulations. Transfer learning was also explored, to test the models when dealing with a building different from the training data. The metrics showed a significant decrease, highlighting a possible insufficiency of representative variables that could allow for better generalization by the models. It is concluded that the use of ML techniques constitutes a promising approach to promoting greater efficiency and effectiveness in building design, representing a field with wide potential for development and application.

Keywords: Machine learning; Decision tree; Regression; Thermal performance; Energy efficiency; Thermal load; Degree-hours; Energy simulation.

LISTA DE FIGURAS

Figura 1 – Principais variáveis que afetam o conforto térmico das edificações ..	19
Figura 2 – Fatores que afetam o desempenho térmico das edificações	20
Figura 3 – Fluxo de calor proveniente da radiação solar que incide em uma parede (esquerda) e uma janela (direita)	21
Figura 4 – Exemplo do método CT para um intervalo de temperatura operativa de 18 a 23°C	24
Figura 5 – Exemplo do Método GH para um intervalo de temperatura interna de 18 a 23°C	26
Figura 6 – Exemplo do desenvolvimento manual de um filtro de spam	28
Figura 7 – Exemplo de uma abordagem de filtro de spam usando ML	29
Figura 8 – Exemplo da automação de filtro de spam usando ML	30
Figura 9 – Aprendizado supervisionado para um problema de classificação de imagens	32
Figura 10 – Aprendizado supervisionado para um problema de regressão	33
Figura 11 – Exemplo de aplicação do aprendizado não supervisionado.	34
Figura 12 – Representação da arquitetura de um perceptron	37
Figura 13 – Representação de arquitetura de uma MLP com camada oculta e saída binária	38
Figura 14 – Exemplo de uma árvore de decisão	39
Figura 15 – Representação simplificada da estrutura do XGBoost	41
Figura 16 – Etapas para construção de um modelo para avaliação de desempenho térmico	43
Figura 17 – Panorama geral da pesquisa	48
Figura 18 – Edificação simulada 1 – 43,6 m ²	48
Figura 19 – Edificação simulada 2 – 39,6 m ²	49
Figura 20 – Zonas bioclimáticas e classificação climática das cidades selecionadas	50
Figura 21 – Processo de geração dos dados	52
Figura 22– Boxplot das propriedades dos sistemas construtivos	54
Figura 23– Esquematização da validação cruzada (<i>k-fold</i>)	56

Figura 24 – Gráfico de dispersão para duas saídas. Esquerda: Modelo com melhor R^2 (0,92), referente à Edif. 2 na ZB 1M e tendo CT como saída. Direita: Modelo com o pior R^2 (0,55), referente à Edif. 2 na ZB 6A, tendo GH como saída.62

LISTA DE TABELAS

Tabela 1 – Propriedades termofísicas	22
Tabela 2 – Classificação dos algoritmos de ML	30
Tabela 3 – Zonas bioclimáticas e classificação climática das cidades selecionadas	50
Tabela 4 – Configurações de simulação para o CT	51
Tabela 5 – Configurações de simulação para o GH.....	51
Tabela 6– Amostra do conjunto final dos dados de GH para 6 instâncias aleatórias	53
Tabela 7 – Estatísticas descritivas das propriedades dos sistemas construtivos..	54
Tabela 8 – Desempenho dos modelos com validação cruzada (<i>k-fold</i>).....	59
Tabela 9 – Métricas de avaliação dos modelos na nova divisão do conjunto de treino/teste.....	61
Tabela 10 – Métricas de avaliação dos modelos em outra edificação.	63

LISTA DE SIGLAS

AD – Árvore de decisão / *Decision Tree*

Ct – Capacidade térmica

CT – Carga térmica

U – Transmitância Térmica

GH – Graus-Horas

IA – Inteligência artificial

MAE – Erro médio absoluto

MAPE - Erro percentual absoluto médio

ML – Aprendizado de máquina / *Machine Learning*

XGBoost – Extreme Gradient Boosting

R^2 – Coeficiente de determinação

ZB – Zona Bioclimática

RNA – Rede Neural Artificial / Artificial Neural Network

SVR – Support Vector Regression / Regressão de Vetores de Suporte

SI – Sistema Internacional de Unidades

Sumário

1	Introdução	14
1.1	Objetivo	18
1.2	Objetivos específicos	18
2	Revisão Bibliográfica.....	19
2.1	Conceitos fundamentais da avaliação termoenergética.....	19
2.1.1	Envoltória da edificação	20
2.1.2	Métodos de avaliação por simulação energética.....	22
2.2	Aprendizado de máquina (<i>Machine Learning</i> - ML)	28
2.2.1	Tipos de Aprendizado de Máquina	30
2.2.2	Redes Neurais Artificiais e Árvores de Decisão	35
2.2.3	Métricas de avaliação de desempenho	41
2.2.4	Estado da arte	43
3	Metodologia	47
3.1	Panorama geral	47
3.2	Edificações e climas analisados	48
3.3	Coleta de dados.....	52
3.4	Dados das simulações energéticas	53
3.5	Implementação do ML	55
3.5.1	Divisões do conjunto de treino e teste	55
3.5.2	<i>Transfer learning</i>	57
3.5.3	Ajustes de hiperparâmetros	57
4	Resultados	59
4.1	Avaliação dos modelos com <i>k-fold</i>	59
4.2	Avaliação dos modelos com nova divisão do conjunto treino/teste	60

4.3	Avaliação dos modelos em outra edificação (<i>transfer learning</i>).....	62
5	Conclusão	64
	Referências.....	66
	Apêndice A – Lista de materiais dos sistemas construtivos	71
	A.1 Paredes.....	71
	A.2 Pisos	75
	A.3 Coberturas	77
	Apêndice B – Hiperparâmetros ajustados	83

1 INTRODUÇÃO

O setor da construção civil representa uma das principais fontes de emissões globais de gases de efeito estufa. Na edição mais recente do relatório publicado pelo Programa para o Meio Ambiente da ONU, em março de 2024, o setor foi apontado como responsável por 21% das emissões globais desses gases, e em 2022 foram responsáveis por 34% da demanda global de energia, e 37% das emissões de CO₂ (PROGRAMME, 2024). No Brasil, segundo o Balanço Energético Nacional de 2024, o consumo de eletricidade cresceu 9,1% no setor Residencial, representando um aumento de 14,1 terawatts-hora; ainda, de acordo com o Boletim Trimestral de Consumo de Eletricidade da Empresa de Pesquisa Energética, no primeiro trimestre de 2024, o consumo de energia elétrica das residências foi de 46.242 GWh, o maior valor num trimestre desde o início da série histórica em 2004 (Empresa de Pesquisa Energética, 2024). Uma parcela significativa do consumo energético é impulsionada por ondas de calor e temperaturas acima da média, devido às mudanças climáticas (G1, 2024). Assim, torna-se evidente a necessidade de aprimorar a eficiência energética das edificações, promovendo desempenho térmico à construção e conforto térmico aos ocupantes com o menor consumo possível de energia.

O conforto térmico envolve a satisfação bem-estar dos ocupantes de um ambiente, em uma percepção individual e subjetiva da temperatura, umidade relativa, velocidade do ar e outros fatores (Verma & Netam, 2020). O desempenho térmico se caracteriza como uma propriedade objetiva da edificação, se referindo à sua capacidade em manter condições de temperaturas adequadas em seu interior, levando em conta fatores como o isolamento térmico, ganho e perda de calor, ventilação, e sistemas de climatização (ABNT, 2024a). Edificações que asseguram condições adequadas de conforto térmico utilizando a menor quantidade possível de energia apresentam elevada eficiência energética. Existem duas abordagens principais para a avaliação do desempenho térmico de projetos: a simplificada e simulação computacional.

O método simplificado, adotado pela norma brasileira de desempenho de edificações, NBR 15575 (ABNT, 2024a), consiste, geralmente, em comparar as

propriedades termofísicas das envoltórias (ex: transmitância térmica (U) e capacidade térmica (Ct)) com valores-limite recomendados para cada região do país. Quando a avaliação dos componentes construtivos não é atendida pela norma, ou esses componentes devem ser alterados, ou a equipe de projeto pode avaliar mais detalhadamente o desempenho pelo método computacional.

O método computacional utiliza simulações energéticas para prever e avaliar o desempenho térmico da edificação de maneira eficaz (embora nem sempre eficiente). As simulações energéticas consistem em modelar a edificação em 3D em um *software* específico para este fim, como o EnergyPlus. Esses *softwares* computam os balanços de energia entre o ambiente interno e o externo (representado pelo arquivo climático de uma região, incluindo temperatura, umidade, vento, radiação solar e outros parâmetros, ao longo de um ano típico), para prever as condições dos ambientes internos da edificação, como temperatura e umidade internas.

As simulações energéticas para a avaliação do desempenho térmico são amplamente difundidas em estudos nacionais e internacionais, uma vez que oferecem diversas vantagens em relação aos métodos simplificados, como a possibilidade de explorar diferentes opções de *design*, variações nos *layouts* arquitetônicos, distintos componentes construtivos, viabilidade do projeto em múltiplos climas, além de uma avaliação global do comportamento dos sistemas da envoltória e do projeto arquitetônico (Oliveira, 2025). Por meio dessas simulações, busca-se avaliar o desempenho térmico das edificações com base em diferentes métricas ou indicadores, sendo os métodos da Carga Térmica (CT) e dos Graus-Horas (GH) os mais comumente empregados (Cruz et al., 2024).

A CT, como toda forma de energia conforme estabelecido pelo Sistema Internacional de Unidades (SI), deve ser expressa em joules (NIST, 2020). Ela representa a soma da energia necessária para manter a temperatura interna dentro de uma faixa de conforto térmico. Essa faixa é definida por limites inferior e superior, chamados de *setpoints* de temperatura de conforto, conforme especificado por normas técnicas ou critérios locais. Sempre que a temperatura ultrapassa esses limites, o sistema de Aquecimento, Ventilação e ar-condicionado (AVAC) é acionado para

aquecer ou resfriar o ambiente, restaurando as condições ideais de conforto. Quanto menor o valor do CT, melhor o desempenho da edificação, pois indica menor demanda energética para manter o conforto térmico interno.

Por sua vez, o GH, medido em graus, avalia o desempenho térmico independentemente do consumo direto de energia, baseando-se na diferença acumulada ao longo do tempo entre a temperatura interna e as temperaturas limites da zona de conforto. Quando a temperatura interna se encontra abaixo do limite inferior, somam-se os GH de aquecimento; quando excede o limite superior, acumulam-se os GH de resfriamento. Este método é particularmente utilizado na análise de edificações com ventilação natural, sem um sistema AVAC para conforto térmico. Assim como a CT, quanto menor for o valor de GH, melhor é o desempenho térmico da edificação, pois indica que a temperatura interna ultrapassou poucas vezes, e/ou em pouca intensidade, os limites de conforto estabelecidos.

Embora as simulações ofereçam vantagens significativas em relação aos métodos simplificados, é importante destacar que, dependendo do contexto e do volume de dados envolvidos, elas podem demandar elevado custo em termos de tempo de processamento e recursos computacionais. Diante desse panorama, o aprendizado de máquina (*Machine Learning* - ML) surge como uma abordagem promissora para a otimização desses processos.

O ML é um ramo da inteligência artificial (IA) que se ocupa do desenvolvimento de sistemas capazes de construir soluções baseadas em dados. Tais sistemas utilizam algoritmos que identificam padrões e extraem conhecimento a partir de conjuntos de dados, sem a necessidade de programação explícita para essa tarefa.

Nesse sentido, considerando os desafios relacionados ao alto custo computacional e ao tempo de execução de grandes volumes de simulações energéticas, o uso do ML torna-se uma alternativa eficiente e viável. Essa abordagem permite a criação de modelos preditivos mais rápidos e menos onerosos, capazes de estimar resultados com alta precisão. Com isso, é possível reduzir significativamente o tempo e os recursos tradicionalmente empregados em simulações individuais (Mendes et al., 2024). Estudos na área já apontam resultados promissores quanto ao uso do ML para predição térmica.

Quevedo, Geraldi e Melo (2023) empregaram três algoritmos de ML para a previsão do consumo energético em edificações universitárias. O modelo foi treinado com uma base de dados gerada por simulações no *software* EnergyPlus, considerando 23.256 cenários com distintas combinações de variáveis, como características da envoltória (transmitância e absorptância térmica), sistemas de climatização (tipo e eficiência), iluminação, sombreamento e condições climáticas. A variável de saída (predita pelo algoritmo) foi o consumo total de CT. O modelo final apresentou desempenho extremamente satisfatório, com o coeficiente de determinação (R^2) de 0,99.

No estudo de Hossein (2019), foram avaliados seis algoritmos de ML para prever a CT de aquecimento em edifícios energeticamente eficientes. O conjunto de dados abrangia 768 instâncias. As variáveis de entrada incluíram características geométricas e de orientação dos edifícios, como área de superfície, área das paredes e do telhado, altura total, orientação, área de envidraçamento e sua distribuição. Entre os modelos testados, o algoritmo *Random Forest* (RF) apresentou o melhor desempenho, com o R^2 de 0,9989.

Por sua vez, Westermann et al. (2021) utilizaram modelos de aprendizado profundo baseados em redes neurais convolucionais residuais (ResNet), treinados com dados provenientes de simulações no EnergyPlus. As variáveis de entrada consistiram em séries temporais de dados climáticos (como temperatura, umidade e radiação) e 13 parâmetros de projeto de edifícios. As variáveis de saída foram as cargas térmicas horárias de aquecimento e resfriamento. Os resultados obtidos mostram R^2 superiores a 0,93.

Diante do exposto, o presente estudo consiste em desenvolver modelos de ML supervisionados de regressão para previsão do desempenho térmico de edificações, por meio das métricas de CT e GH e através das propriedades termofísicas dos pisos, paredes e coberturas. Será desafiada a capacidade de predição desses modelos, variando o processo de separação dos conjuntos de treino/teste e reaproveitando um treinamento para prever resultados relativos a outra edificação (técnica de *transfer learning*). Para isso, serão consideradas duas edificações, cada uma em três diferentes regiões climáticas (fria, quente e amena). Com esse trabalho, busca-se não apenas

prever o desempenho térmico de edificações, mas também demonstrar que técnicas ML podem ser uma ferramenta valiosa no auxílio à otimização da escolha de materiais construtivos, contribuindo para o desenvolvimento de soluções mais sustentáveis no setor da construção civil.

1.1 Objetivo

O objetivo desse trabalho é construir e avaliar modelos de regressão supervisionado apto a estimar o desempenho térmico de edificações, por meio das métricas da CT e GH, considerando as propriedades termofísicas dos sistemas construtivos que compõem sua envoltória como variáveis de entrada.

1.2 Objetivos específicos

Os objetivos específicos deste estudo são:

- Investigar a viabilidade e a amplitude da aplicação de modelos preditivos em projetos de eficiência energética;
- Entender a influência das características climáticas regionais no desempenho dos modelos;
- Avaliar o desempenho de generalização de um modelo pré-treinado na transferência de aprendizado entre edificações distintas (*transfer learning*).

2 REVISÃO BIBLIOGRÁFICA

2.1 Conceitos fundamentais da avaliação termoenergética

O conforto térmico refere-se ao estado psicológico que expressa a sensação de satisfação de um indivíduo em relação às condições térmicas do ambiente ao seu redor (Lamberts, 2016). Ainda segundo o autor, as variáveis que influenciam o conforto térmico, são, geralmente, classificadas em dois grandes grupos: variáveis ambientais e variáveis humanas. As variáveis ambientais englobam elementos como a temperatura do ar, velocidade do vento, umidade relativa do ar, radiação solar, entre outros fatores físicos que atuam diretamente sobre o corpo humano, já as variáveis humanas incluem aspectos como o nível de atividade metabólica, a resistência térmica das vestimentas, bem como características fisiológicas individuais, tais como sexo, idade, raça e estado de saúde (Lamberts, 2016). A Figura 1 apresenta as principais variáveis que influenciam o conforto térmico.

Figura 1 – Principais variáveis que afetam o conforto térmico das edificações



Fonte: (Oliveira, 2025).

Já o desempenho térmico está relacionado à capacidade de uma edificação manter condições internas adequadas, considerando a interação entre o ambiente externo e as propriedades físicas da construção. Dentre os principais influenciadores

do desempenho térmico, estão os componentes construtivos (ex. paredes, coberturas e pisos), sombreamento, fontes de energia interna, entre outros fatores (ABNT, 2024a). A Figura 2 ilustra as principais variáveis que afetam o desempenho térmico das edificações.



Fonte: (Oliveira, 2025).

Por fim, a eficiência energética consiste na capacidade de uma construção utilizar a menor quantidade possível de energia para manter o conforto e as funcionalidades necessárias do ambiente. Ou seja, oferecer ambientes confortáveis otimizando o consumo de energia. Para isso, uma gama de tecnologias e práticas é empregada, visando, além de reduzir o custo operacional, reduzir os impactos ambientais.


2.1.1 Envoltória da edificação

Um dos principais elementos que afetam o desempenho térmico é o sistema de vedação da edificação, que compreende pisos, paredes e coberturas. Esses elementos atuam como barreiras à troca de calor entre os ambientes interno e externo,

por meio dos mecanismos de condução, convecção e radiação térmica (Lamberts et al., 2014). A eficiência desses sistemas de vedação é essencial para garantir conforto térmico aos ocupantes, reduzindo, inclusive, a dependência de sistemas artificiais de climatização.

Comumente, as envoltórias são classificadas em dois tipos principais: translúcidos e opacos. Em elementos opacos (paredes externas, pisos externos e coberturas), que não permitem a passagem direta da luz, ocorre a troca de calor predominantemente por condução, quando existe uma diferença entre a temperatura interna e externa (Lamberts et al., 2014). Já em sistemas translúcidos (janelas, fachadas de vidro, claraboias, entre outros) que permitem a entrada de luz, podem ocorrer os três tipos de trocas térmicas: condução, radiação e convecção (Lamberts et al., 2014).

Figura 3 – Fluxo de calor proveniente da radiação solar que incide em uma parede (esquerda) e uma janela (direita)



Fonte: (Mendes, 2021).

As propriedades termofísicas dos materiais presentes no sistema de vedação exercerão uma influência significativa no desempenho térmico da edificação, uma vez que a magnitude desse desempenho envolve uma combinação complexa e inter-relacionada destas (Mendes, 2023). O presente trabalho focará principalmente nas propriedades U e Ct dos materiais que compõem os sistemas construtivos das

envoltórias. A Tabela 1 apresenta as definições e efeitos das principais propriedades termofísicas dos materiais.

Tabela 1 – Propriedades termofísicas

Propriedade	Definição	Efeito do material/ elemento na edificação
Calor específico (c) [kJ/(kg·K)]	Facilidade do material em se aquecer, quando recebe energia, ou resfriar, quando perde energia (Incropera, Dewit, Bergman, & Lavine, 2008). Sendo Q a quantidade de calor, m a massa do material, ΔT a diferença de temperatura aferida no material: $c = \frac{Q}{m \cdot \Delta T}$	Um material com alto calor específico tende a aumentar a capacidade térmica do sistema (propriedade definida a seguir).
Massa específica (ρ) [kg/m³]	Propriedade do material que relaciona a massa de um material (m) com o seu volume (V). $\rho = \frac{m}{V}$	Um material com alta massa específica tende a aumentar a capacidade térmica do sistema (propriedade definida a seguir).
Espessura (e) [m]	Dimensão que diz respeito à profundidade do elemento no tocante à transmissão de calor.	A espessura influencia na capacidade térmica, resistência térmica e transmitância térmica (propriedades definidas a seguir).
Capacidade térmica (C _T) [J/(m²·K)]	Potencial do elemento em variar sua temperatura a partir do calor imposto a ele (ABNT, 2024a). $C_t = e \cdot \rho \cdot c$	Um material com alta capacidade térmica mantém o interior da edificação mais estável em relação às variações térmicas externas.
Resistência térmica (R) [(m²·K)/W]	Capacidade do elemento em reduzir a troca de calor por condução. $R = \frac{e}{\lambda}$	Um elemento com alta resistência térmica mantém o ambiente interno mais isolado termicamente frente ao exterior.
Transmitância térmica (U) [W/(m²·K)]	Taxa de transferência de calor de um certo elemento, induzida por uma diferença de temperatura imposta entre as superfícies (ABNT, 2024a). $U = \frac{1}{R}$	A transmitância térmica é o oposto da resistência térmica. Um elemento com alta transmitância térmica tende a deixar o ambiente interno mais suscetível ao clima externo.

Fonte: adaptado de (Mendes, 2023).

2.1.2 Métodos de avaliação por simulação energética

Os *softwares* de simulação computacional permitem a análise do comportamento termo energético das edificações. O EnergyPlus, *software* gratuito mais adotado do mundo (Mendes et al., 2024), foi desenvolvido pelo Departamento de Energia dos Estados Unidos, e tem como finalidade estimar trocas térmicas, os níveis de iluminação e consumo energético da edificação modelada (Pereira, 2010). Assim, é

possível realizar simulações para qualquer edificação, a partir da modelagem de seu *layout* 3D, e considerar diversas condições climáticas da região, utilizando arquivos climáticos específicos de cada cidade.

No EnergyPlus, as simulações são baseadas em arquivos de entrada previamente configurados, nos quais são definidos os parâmetros físicos e operacionais de interesse. Esses parâmetros incluem as propriedades termofísicas dos sistemas construtivos, a fração de abertura das janelas e portas para ventilação natural, o modelo geométrico da edificação, os padrões de ocupação, condições de sombreamento, a divisão em zonas térmicas, entre outros aspectos relevantes ao desempenho energético (EnergyPlus, 2025).

Entre as diversas variáveis de saída disponíveis, têm-se aquela que representa o CT necessário para manter as condições internas de conforto térmico — isto é, a energia exigida para aquecimento ou resfriamento de cada zona da edificação de acordo com os *setpoints* definidos, e as saídas referentes as temperaturas operativas de conforto térmico, na qual é utilizada no cálculo do GH. Há também saídas referentes a fluxos de ar e ventilação, ganhos solares e iluminação, consumos de sistemas AVAC, dentre várias outras. É necessária uma configuração prévia diferente para cada método e saída de interesse.

Os principais métodos de avaliação do desempenho térmico no procedimento computacional, em nível mundial, como observado por Mendes et al. (2024), são o CT e GH. Atualmente, a norma brasileira de desempenho térmico, NBR 15575, utiliza uma metodologia combinada se assemelhando aos métodos GH e CT (ABNT, 2024a).


2.1.2.1 Método de carga térmica (CT)

O método da carga térmica (CT) usa como base os limites de temperatura definidos pelo sistema de AVAC, chamados de *setpoints*, que variam conforme normas técnicas ou preferências locais. Esses limites devem representar uma faixa de temperatura capaz de garantir conforto térmico para a maioria dos ocupantes da edificação (Mendes et al., 2024). Sempre que a temperatura interna ultrapassa os limites inferior e superior, o sistema AVAC é acionado para aquecer ou resfriar o

ambiente e manter a temperatura no intervalo dentro da faixa de conforto térmico definida para os ocupantes. Deste modo, quanto menor a energia demandada para manter a temperatura interna dentro do intervalo ideal, maior é a eficiência energética da edificação. Sintetizando então, uma menor demanda de CT do sistema AVAC sugere que os elementos construtivos do edifício foram bem planejados para garantir o conforto interno.

A Figura 4 apresenta um exemplo de aplicação do método. Nesse caso, o intervalo de *setpoint* foi configurado entre 18 e 23 °C, e as colunas em vermelho e azul, representam, respectivamente, a energia gasta pelo acionamento do sistema AVAC para aquecer ou resfriar o ambiente.

Figura 4 – Exemplo do método CT para um intervalo de temperatura operativa de 18 a 23°C



Fonte: (Mendes et al., 2024)

No geral, os estudos analisam os ambientes de longa permanência da edificação (como quartos, salas e escritórios) e no período de um ano-padrão, de modo a abranger todas as estações do ano (Mendes, 2023). O cálculo do método é como descrito na equação (1), que faz o somatório das cargas térmicas de aquecimento e resfriamento durante um ano.

$$CT_{total} = \sum_{1 \text{ ano de referência}} (CT_a + CT_r) \quad (1)$$

Onde:

CT_{total} é a soma das cargas térmica de aquecimento e resfriamento em um ano

CT_a é o CT de aquecimento

CT_r é o CT de resfriamento

2.1.2.2 Método de graus-hora (GH)

O método GH é parecido com o CT, mas, ao invés de somar o acumulado de energia gasta ao longo do ano, essa estratégia compara e soma acumuladamente a diferença entre a temperatura interna e as temperaturas operativas (temperaturas limite de conforto). Assim, os GH de aquecimento e resfriamento medem o desconforto térmico acumulado ao longo do tempo. O GH de aquecimento soma as diferenças entre a temperatura de conforto inferior e a interna quando esta está abaixo do limite, enquanto o GH de resfriamento soma as diferenças entre a interna e a temperatura de conforto superior quando esta é excedida (Mendes et al., 2024). Os limites dos intervalos de conforto, são, também, definidos perante normas locais ou convenção da equipe de pesquisa (Mendes et al., 2024).

A análise do GH também se dá, geralmente, em um período de um ano, e em ambientes de longa permanência, podendo ou não ser feita a partir da identificação do cômodo mais crítico. Similar ao CT, quanto menor o valor da métrica, maior o desempenho da edificação. A Figura 5 exemplifica o método GH em um intervalo de temperatura interna de 18 e 23 °C.

O método GH é calculado a partir da Equação (2):

$$GH_{total} = GH_{resfriamento} + GH_{aquecimento} = \sum_{1 \text{ ano de referência}} \max.(0; (T_o - T_{base})) + \sum_{1 \text{ ano de referência}} \max.(0; (T_{base} - T_o)) \quad (2)$$

Onde:

GH_{total} é a soma do GH de aquecimento e resfriamento


$GH_{aquecimento}$ é a diferença entre a temperatura interna e o limite inferior (T_{base}), quando esta ultrapassa o limite inferior.

$GH_{resfriamento}$ é a diferença entre o limite superior (T_{base}) e a temperatura interna, quando esta ultrapassa o limite superior.

T_o é a temperatura interna operativa

T_{base} são as temperaturas de base definida como o intervalo de conforto da edificação

Figura 5 – Exemplo do Método GH para um intervalo de temperatura interna de 18 a 23°C



Fonte: (Mendes et al., 2024)

A utilização do método GH é abordada no trabalho de Bisolo (2018), que realizou uma análise comparativa entre o método baseado em dias típicos, conforme a versão

antiga da NBR 15575, e o método GH, considerando faixas de conforto térmico entre 18 °C e 26 °C. O estudo foi aplicado a edificações residenciais em Santa Maria/RS, por meio de simulações computacionais no *software* EnergyPlus. Os autores concluíram que a avaliação contínua desse método, considerando todas as horas do ano, mostra-se mais adequada para subsidiar decisões de projeto e para a análise da eficiência energética das edificações, ao contrário de outros métodos, como o dos dias típicos, que pode gerar classificações inconsistentes pela seleção pontual de dias específicos. O método dos dias típicos teve sua prescrição descontinuada nas versões mais recentes da NBR 15575, sendo possíveis encontrar mais detalhes sobre ele no estudo de Mendes et al. (2024).

Já aplicando o método CT, o trabalho de Dos Santos et al. (2017) analisou a adequação dos aparelhos de ar-condicionado nas salas de aula do Instituto Federal Fluminense, utilizando duas metodologias de cálculo: ABNT NBR 5858:1983 e ABNT NBR 16401-1:2008, com simulações realizadas no *software* EnergyPlus. No estudo, foi constatado que nenhuma sala possuía equipamentos compatíveis com as cargas térmicas calculadas e que, pela avaliação conforme a NBR 16401-1:2008, as cargas apresentaram valores médios 0,82% superiores aos obtidos pela NBR 5858:1983. Os autores concluíram identificando falha no dimensionamento atual, sendo recomendado o uso de aparelhos de 30.000 BTU (British Thermal Unit – unidade térmica britânica, utilizada para expressar a potência de resfriamento dos condicionadores de ar) com classificação “A”, visando maior eficiência energética e conforto térmico.


Apesar das vantagens do uso de simulações em *softwares* computacionais frente aos métodos simplificados, sua utilização ainda apresenta desafios, como o tempo de processamento, que pode ultrapassar, em muitos casos, dois minutos por modelo (Mendes, 2023). Embora em simulações únicas o valor não seja muito alto, a depender da complexidade da análise envolvida, como a quantidade de zonas térmicas, nível de detalhamento construtivo e número de comparações avaliadas, o tempo total de simulação pode se tornar um entrave significativo, exigindo maior capacidade computacional e planejamento adequado para viabilizar estudos em larga

escala. Nesse sentido, o ML é uma estratégia que vem sendo aplicada para aumentar a eficiência das análises em larga escala.

2.2 Aprendizado de máquina (*Machine Learning* - ML)

O ML é o campo de estudo que desenvolve algoritmos com habilidade de aprender padrões sem serem explicitamente programados para isso. A Figura 6 apresenta uma possível abordagem tradicional de um filtro de *spam* para e-mails, onde seria necessário a uma pessoa ou equipe identificar as características de um *spam*, escrever um algoritmo de detecção que obedecesse às regras observadas, e repetir os passos anteriores até o programa ser suficientemente bom a ponto de ser utilizado. Além da possibilidade de certos padrões não serem detectados, essa abordagem apresenta baixa escalabilidade, pois, em cenários de maior complexidade, o sistema resultante se tornaria um conjunto extenso de regras complexas.

Figura 6 – Exemplo do desenvolvimento manual de um filtro de spam




Fonte: adaptado de (Géron, 2019).

Em contraste, a abordagem baseada em algoritmos de ML, mostrada na Figura 7, demonstra-se mais escalável, de fácil manutenção e potencialmente mais precisa (Géron, 2019). Isso ocorre, porque, ao ser treinado com um conjunto histórico de e-

mails rotulados, o modelo é capaz de identificar automaticamente padrões linguísticos e características recorrentes associadas a mensagens classificadas como *spam*. Dessa forma, o algoritmo pode realizar a distinção entre e-mails indesejados (*spam*) e mensagens legítimas (*ham*) de maneira eficiente e autônoma.


Além disso, caso remetentes de *spam* identifiquem que e-mails contendo um termo específico estão sendo bloqueados, eles podem modificar a sintaxe da palavra para contornar o filtro. Em uma abordagem tradicional, baseada em regras, seria necessário atualizar manualmente o sistema sempre que tal adaptação ocorresse, tornando o processo ineficiente e oneroso. Em contrapartida, em um modelo baseado ML, ao receber *feedback* do usuário indicando que as novas variantes ainda correspondem a *spam*, o algoritmo ajustaria seus parâmetros automaticamente, adaptando-se às mudanças sem necessidade de intervenção manual, como mostrado na Figura 8.

Figura 7 – Exemplo de uma abordagem de filtro de spam usando ML



Fonte: adaptado de (Géron, 2019).

Figura 8 – Exemplo da automação de filtro de spam usando ML



Fonte: adaptado de (Géron, 2019).

2.2.1 Tipos de Aprendizado de Máquina

A categorização dos algoritmos de ML pode ser estruturada com base em diferentes critérios, conforme citados na Tabela 2:

Tabela 2 – Classificação dos algoritmos de ML

Critério	Categoria	Descrição
Supervisão do Modelo	Supervisionado	Treinado com dados rotulados fornecidos por humanos.
	Não supervisionado	Identifica padrões nos dados sem a necessidade de rótulos.
	Aprendizado por reforço	Aprende por tentativa e erro, maximizando uma função de recompensa
Modo de aprendizado	<i>Online</i>	Atualiza seus parâmetros continuamente conforme novos dados são recebidos.
	<i>Batch</i> (em lote)	Os parâmetros são ajustados após o processamento de um conjunto completo de dados.
Estratégia de generalização	Baseado em instâncias	Armazena exemplos e compara novas instâncias com os dados previamente observados.
	Baseado em modelo	Constrói uma função preditiva a partir dos padrões extraídos durante o treinamento.

Fonte: autor.

A supervisão do treinamento se refere ao grau de intervenção humana no fornecimento de dados rotulados: modelos supervisionados exigem dados com rótulos

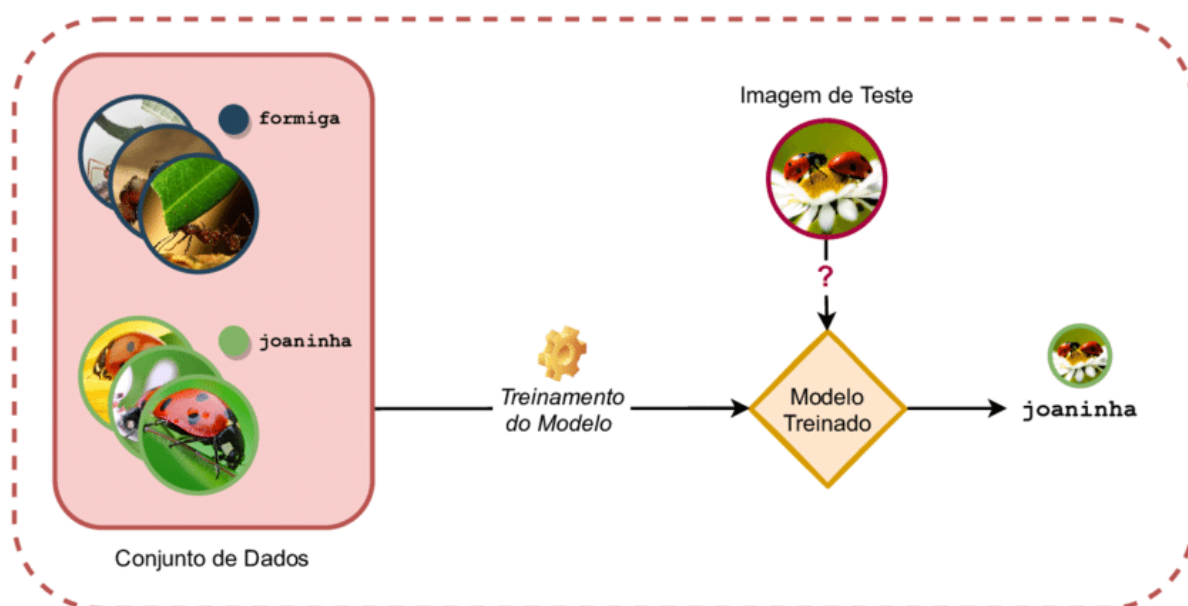
definidos, enquanto os não supervisionados extraem padrões sem essa necessidade; já os modelos baseados em reforço aprendem por meio de tentativa e erro, otimizando uma função de recompensa. Outro critério relevante é o modo de aprendizado, que pode ser do tipo *online*, no qual os parâmetros do modelo são atualizados continuamente à medida que novos dados são disponibilizados; ou *batch* (em lote), no qual as atualizações ocorrem apenas após o processamento de um conjunto completo de dados. Por fim, quanto à estratégia de generalização, os algoritmos podem ser baseados em instâncias, armazenando exemplos anteriores para realizar previsões por comparação; ou baseados em modelo, construindo uma função preditiva a partir de padrões identificados durante o treinamento. Esses critérios não são mutuamente exclusivos e podem ser combinados dependendo da abordagem e do objetivo do sistema de aprendizado.

No aprendizado supervisionado, cada instância do conjunto de dados de treinamento é associada a uma variável-alvo, conhecida como rótulo (*label*), que representa a saída que o modelo deve prever. Em problemas de classificação, essa variável assume valores discretos, categorizando as instâncias em classes distintas, como “baixo”, “médio” e “alto”. Já em problemas de regressão, a variável-alvo é representada por um valor contínuo (número). Assim, durante a fase de treinamento, o algoritmo ajusta seus parâmetros para capturar a relação estatística entre as variáveis independentes (*features*) e a variável-alvo (*label*) presente nos dados de treinamento (Akman et al., 2023). Esse processo permite que o modelo generalize o padrão aprendido, possibilitando a inferência precisa de rótulos para novas amostras não observadas previamente.

A Figura 9 ilustra, de forma simplificada, o funcionamento de um classificador. No lado esquerdo da imagem, vemos o conjunto de dados utilizado para o treinamento do modelo, composto por imagens previamente rotuladas como formiga (em azul escuro) e joaninha (em verde). Esse conjunto de dados é alimentado no processo de treinamento do modelo. Após essa etapa, obtém-se o modelo treinado. A imagem no topo da figura, identificada como “Imagem de Teste”, representa um novo dado que o modelo nunca viu antes. Ao processar essa imagem por meio do modelo treinado, o

classificador é capaz de identificar corretamente que se trata de uma joaninha, como mostrado na saída do lado direito da figura. Esse processo exemplifica como, a partir de exemplos rotulados, o modelo aprende padrões que permitem classificar novas instâncias com base no conhecimento adquirido. Um uso frequente desse tipo de aprendizado na engenharia é na área de Engenharia de Materiais, no qual são utilizados modelos de classificação que permite categorizar materiais em diferentes classes de acordo com suas propriedades (Schmidt et al., 2019).

Figura 9 – Aprendizado supervisionado para um problema de classificação de imagens




Fonte: (Do Rêgo, 2022).

Já os problemas de regressão funcionam como ilustrado na Figura 10. No gráfico, os círculos representam instâncias previamente observadas, cada uma com um valor numérico associado (eixo vertical) e uma *feature* (eixo horizontal). Durante o processo de treinamento, o modelo aprende a relação entre a *feature* 1 e o valor alvo, ajustando seus parâmetros para minimizar o erro entre os valores previstos e os reais. No centro inferior da figura, o símbolo "X" indica uma nova instância que ainda não foi avaliada. O objetivo do modelo é prever, com base nos padrões aprendidos, qual será o valor correspondente a essa nova entrada. Esse processo caracteriza um modelo de regressão, no qual o resultado esperado é um valor numérico contínuo. Uma aplicação

comum deste tipo de aprendizado em engenharia é a predição da resistência à compressão de concreto (Paixão, Penido, Cury, & Mendes, 2022).

Figura 10 – Aprendizado supervisionado para um problema de regressão



Fonte: adaptado de (Géron, 2019).


No aprendizado não supervisionado, o conjunto de dados é composto por instâncias sem rótulos pré-definidos, ou seja, não há variáveis de saída explicitamente mapeadas. Essa abordagem busca extrair padrões e estruturas latentes nos dados sem a necessidade de supervisão externa; por isso, o seu nome.

Dentre as principais tarefas associadas a essa categoria de aprendizado, destaca-se a clusterização (ou agrupamento), que consiste na segmentação de instâncias em grupos homogêneos com base em características semelhantes. Essa técnica é amplamente empregada em aplicações como segmentação de clientes, sistemas de recomendação, mecanismos de busca e diversas outras áreas que demandam a identificação de agrupamentos naturais nos dados (Géron, 2019). Na engenharia mecânica, por exemplo, a clusterização é estudada como ferramenta para reconhecimento de padrões aplicadas ao diagnóstico de falhas em rolamentos por meio da análise de vibração (Almeida, 2007).

Na Figura 11, observa-se um exemplo de aplicação de algoritmos de aprendizado não supervisionado de agrupamento. O objetivo é particionar o conjunto de dados em subconjuntos denominados *clusters*, de modo que as instâncias

pertencentes a um mesmo grupo apresentem alta similaridade entre si e, ao mesmo tempo, sejam significativamente diferentes das instâncias pertencentes a outros grupos. Para quantificar essa similaridade ou dissimilaridade, utilizam-se métricas de distância, sendo a distância euclidiana uma das mais comuns. Dentre os diversos algoritmos existentes, o *K-Means* é um dos mais utilizados pela sua simplicidade e eficiência. Ele funciona iterativamente, atribuindo inicialmente os dados a centróides escolhidos aleatoriamente, recalculando esses centróides com base na média dos pontos atribuídos a cada grupo, e repetindo esse processo até que a convergência seja atingida. O resultado são *clusters* bem definidos, com centróides que representam a posição média de cada grupo no espaço de características.

Figura 11 – Exemplo de aplicação do aprendizado não supervisionado.



Fonte: autor

Outra tarefa fundamental no aprendizado não supervisionado é a detecção de anomalias, o que consiste em aprender o comportamento normal dos dados a fim de identificar instâncias que desviam significativamente desse padrão. Essa abordagem é amplamente utilizada em monitoramento de processos industriais, onde desvios podem indicar falhas na linha de produção, e em sistemas de detecção de fraudes, como na identificação de transações atípicas em cartões de crédito, visando mitigar riscos e prevenir atividades fraudulentas (Géron, 2019). No contexto da engenharia

civil, destaca-se o Monitoramento da Saúde Estrutural (*Structural Health Monitoring*), que utiliza técnicas de detecção de anomalias para identificar alterações no comportamento dinâmico ou físico de estruturas, como pontes e edifícios, possibilitando a detecção precoce de danos ou degradações que comprometam a integridade e a segurança (Nunes, Amaral, Barbosa, & Cury, 2021).

No aprendizado por reforço, o processo envolve a interação entre um agente e um ambiente. O agente é responsável por selecionar e executar ações, recebendo recompensas ou penalidades em resposta às suas decisões. A partir dessas interações, ele ajusta seu comportamento de forma autônoma, aprendendo a otimizar sua estratégia — denominada política — com o objetivo de maximizar o retorno acumulado ao longo do tempo. Um exemplo desse tipo de aprendizado na engenharia é o controle autônomo de robôs móveis em ambientes industriais, nos quais o agente (robô) aprende a navegar por rotas seguras e eficientes dentro de uma planta fabril, desviando de obstáculos e priorizando pontos de inspeção, a fim de minimizar o tempo total da tarefa e evitar colisões (Liu et al., 2020).

2.2.2 Redes Neurais Artificiais e Árvores de Decisão


Há uma variedade de algoritmos e abordagens disponíveis para a análise de dados, cada um aplicando métodos distintos de modelagem. Não existe uma escolha universalmente ótima. Em vez disso, é uma prática comum treinar e avaliar múltiplos modelos para determinar aquele que proporciona o melhor equilíbrio entre desempenho e esforço computacional, o que, por sua vez, são proporcionais à quantidade e à complexidade dos dados. Entre os modelos mais simples e amplamente utilizados, destacam-se a Regressão Linear, a Regressão Ridge e a Regressão Lasso, que introduzem técnicas de regularização para controle de *overfitting* (ajuste excessivo aos dados de treinamento). Já os modelos baseados em árvores de decisão (AD) incluem a Árvore de Decisão para Regressão, o *Random Forest Regressor* (RF) e técnicas avançadas de *boosting*, como o *Extreme Gradient Boosting* (XGBoost), que aprimoram a precisão ao reduzir viés e variância por meio de aprendizado sequencial. No campo das Redes Neurais Artificiais (RNAs), modelos

como a *Perceptron* Multicamadas (MLP) são amplamente empregados em tarefas de regressão não linear, especialmente quando os dados apresentam relações complexas e de difícil modelagem por métodos tradicionais. Por fim, abordagens baseadas em processos estatísticos e métodos não paramétricos incluem o *Support Vector Regression* (SVR), que utiliza margens suaves para otimizar previsões, e os Processos Gaussianos para Regressão (GPR), que oferecem inferências probabilísticas, fornecendo não apenas previsões, mas também estimativas de incerteza. Dentre todos esses algoritmos abordados, detalharemos as RNAs e o XGBoost.

2.2.2.1 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais (RNA) foram inspiradas nas redes neurais cerebrais. Sua versatilidade, robustez e capacidade de escalabilidade as tornam particularmente adequadas para a execução de tarefas de ML de alta complexidade e grande escala, como a classificação de bilhões de imagens, exemplificada pelo Google Imagens (Géron, 2019). Uma das arquiteturas mais elementares de RNA é o *perceptron*, desenvolvido em 1957 por Frank Rosenblatt. Essa estrutura serviu de base para arquiteturas modernas amplamente utilizadas, como o *Perceptron* de Múltiplas Camadas (*Multi-Layer Perceptron* – MLP). O *perceptron* consiste em uma unidade lógica de limiar (*Threshold Logic Unit* – TLU), na qual tanto as entradas quanto a saída são representadas por valores numéricos. Além disso, um termo adicional denominado viés (bias) é incluído nesse cálculo, permitindo o deslocamento da função de ativação e, conseqüentemente, aumentando a flexibilidade do modelo para ajustar melhor os dados. O resultado da soma ponderada e do viés é então processado por uma função de ativação, a fim de gerar a saída final (Géron, 2019), conforme a Figura 12 e equação 6.

Figura 12 – Representação da arquitetura de um perceptron



Fonte: adaptado de (LUNGE, 2021)

$$z = \sum_{i=1}^n w_i x_i + b \quad (6)$$

Onde:

n é o número total de conexões de entrada,

w_i é o peso da i -ésima entrada,


x_i é o i -ésimo valor de entrada,

b é o viés

Para problemas de regressão, o MLP é uma das arquiteturas mais utilizadas (Jaiswal, 2025). Sua estrutura é composta por diversas camadas: uma camada de entrada, onde cada neurônio artificial representa uma característica dos dados de entrada; uma ou mais camadas ocultas formadas por neurônios artificiais, onde cada neurônio artificial recebe entrada de todos os neurônios artificiais da camada anterior; e uma camada de saída, também composta por neurônios artificiais. Cada camada inclui um peso sináptico e é totalmente conectada à camada subsequente. Os cálculos seguem os mesmos princípios do *perceptron* simples, com a diferença de que, na MLP, existem mais camadas até a saída. Em casos de problemas com saída univariada, é

necessário apenas um neurônio na camada de saída. Para problemas com saída multivariada, será necessário um neurônio de saída para cada dimensão da variável de saída, conforme ilustra a Figura 13.

Figura 13 – Representação de arquitetura de uma MLP com camada oculta e saída binária




Fonte: adaptado de (LUNGE, 2021)

2.2.2.2 Árvore de Decisão (AD)

Um dos algoritmos mais poderosos e utilizados é a Árvore de Decisão (AD) e suas variantes. Ela é capaz de se adaptar aos conjuntos de dados complexos e é bastante utilizada nas soluções de ML nos dias de hoje. A ideia de uma AD é bem simples, como no exemplo mostrado na Figura 14.

Figura 14 – Exemplo de uma árvore de decisão



Fonte: adaptado de (JAVATPOINT, 2021).

Os retângulos apresentados são denominados nós da árvore, enquanto os níveis em que esses nós se encontram correspondem à profundidade da árvore, iniciando-se pelo nó raiz, com profundidade igual a 0. Cada nó localizado um nível abaixo de seu predecessor é denominado nó filho daquele nó. Os nós situados na maior profundidade, sem descendentes, são denominados nós folha.

As ADs são amplamente empregadas como elementos fundamentais na construção de modelos baseados em técnicas de *ensemble*, as quais visam combinar múltiplos modelos — distintos ou variantes de um mesmo tipo — com o propósito de aumentar a precisão, a estabilidade e a capacidade de generalização das previsões. Estratégias como *Random Forest* e *Gradient Boosting*, por exemplo, dependem da agregação de diversas AD para compor modelos mais robustos e acurados do que seria possível com a utilização de uma única árvore isolada.

O *Extreme Gradient Boosting* (XGBoost) é um modelo de ML do tipo *ensemble*, fundamentado em AD. Métodos *ensemble*, também denominados métodos de agregação de preditores, consistem na combinação de múltiplos modelos base com o

objetivo de produzir uma previsão mais robusta, precisa e generalizável do que seria possível utilizando apenas um único modelo. O XGBoost também emprega a técnica de *boosting*, um processo sequencial no qual cada novo modelo é treinado para corrigir os erros cometidos por seus predecessores. Esse procedimento é aliado ao conceito de gradiente descendente, de modo que as correções são orientadas pela minimização de uma função de perda, utilizando as derivadas (gradientes) dessa função em relação às previsões anteriores (XGBoost Developers, 2025).

Sua função de predição é dada pela equação 7, onde $\hat{y}_i^{(t)}$ representa a predição do exemplo i na iteração t , x_i denota o vetor de características do exemplo i , $\mathcal{F}$ é o espaço funcional das árvores de regressão, e f_k corresponde à k -ésima árvore de decisão adicionada ao modelo.

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i), \quad f_k \in \mathcal{F} \quad (7)$$

Já a função objetivo, juntamente com o termo de regularização, é expressa conforme a equação 8, em que $l(y_i, \hat{y}_i)$ representa a função de perda adotada, que comumente, em problemas de regressão se trata do erro quadrático médio. Para viabilizar a otimização, essa função é expandida por meio de uma aproximação de Taylor de segunda ordem. O termo de regularização $\Omega(f)$ é composto por uma penalização proporcional ao número de folhas da árvore, dada por γT , onde γ é um hiperparâmetro para controlar o número de folhas e T o número total de folhas, acrescida de outro termo de regularização dos pesos baseado na norma L2, dos pesos das folhas (w), conforme apresentado na equação 9.

$$\mathcal{L}^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t)}) + \sum_{k=1}^t \Omega(f_k) \quad (8)$$


Onde:

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (9)$$

Deste modo, durante a construção das árvores, o algoritmo avalia o ganho proporcionado por cada possível divisão de um nó. Esse ganho é calculado com base nas somas dos gradientes (G_L, G_R) e hessianos (H_L, H_R) de cada lado da divisão, considerando também os parâmetros de regularização. A divisão é aceita se o ganho líquido, após subtrair o custo de adicionar uma nova folha, for positivo, garantindo assim um equilíbrio entre ajuste e simplicidade do modelo, como em (11).

$$\text{Gain} = \frac{1}{2} \left[\frac{G_L^2}{H_L + \lambda} + \frac{G_R^2}{H_R + \lambda} - \frac{(G_L + G_R)^2}{H_L + H_R + \lambda} \right] - \gamma \quad (11)$$

Figura 15 – Representação simplificada da estrutura do XGBoost



Fonte: adaptado de (Oztornaci, Ata, & Kartal, 2024)

2.2.3 Métricas de avaliação de desempenho

As principais métricas de validação utilizadas em problemas de regressão baseiam-se na diferença entre os valores observados (“reais”) e os valores estimados (previstos) pelo modelo. Cada uma delas proporciona uma perspectiva distinta sobre

sua performance. Neste trabalho, foram empregados três métricas quantitativas para avaliar o desempenho do modelo: coeficiente de determinação (R^2), o Erro Médio Absoluto (*Mean Absolute Error* - MAE) e o Erro Percentual Absoluto Médio (*Mean Absoute Percentage Error* - MAPE).

O R^2 quantifica a proporção da variância total dos dados que é explicada pelo modelo de regressão. Seu valor varia entre 0 e 1, sendo que valores mais próximos de 1 indicam maior capacidade explicativa do modelo. Seu cálculo é feito conforme mostrado na equação 3, onde y é o valor real, $\hat{y}$ é o valor predito e $\bar{y}$ é a média dos valores reais. Em determinadas situações, R^2 pode assumir valores negativos. Isso ocorre quando o modelo apresenta desempenho inferior ao de uma abordagem ingênua que consiste em prever, para todas as observações, a média dos valores reais.

$$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (3)$$

Já o MAE quantifica a média das diferenças absolutas entre o valor real (y) e predito ($\hat{y}$), conforme expresso na equação 4. Trata-se de uma métrica menos sensível a valores discrepantes (*outliers*), pois não eleva os erros ao quadrado, diferentemente de outras métricas. O resultado do MAE é expresso na mesma unidade de medida dos dados, o que facilita sua interpretação direta. Por se tratar de uma métrica de erro, valores mais baixos indicam melhor desempenho do modelo preditivo.

$$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4)$$

Por fim, o MAPE é uma métrica que expressa o erro médio das previsões em termos percentuais em relação aos valores observados. Se parece com o MAE, mas com acréscimo de uma divisão por $|y|$, como mostrado na equação 5. Para evitar divisão por zero, especialmente quando o valor de y é zero, é comumente utilizado


um pequeno valor constante ϵ no denominador. O MAPE é amplamente adotado na avaliação de modelos de regressão por fornecer uma interpretação direta do desempenho em termos percentuais, indicando, em média, qual a proporção do valor real que o modelo tende a errar.

$$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{\max(\epsilon, |y_i|)} \quad (5)$$

2.2.4 Estado da arte

Para a predição de desempenho térmico de edificações, em que o objetivo geralmente é estimar as cargas térmicas necessárias para atingir condições de conforto térmico, geralmente usa-se o ML do tipo supervisionado, de regressão, e as etapas para a construção de um modelo deste tipo são resumidamente ilustradas na Figura 16.

Figura 16 – Etapas para construção de um modelo para avaliação de desempenho térmico



Fonte: autor.

O processo se inicia com a realização de simulações em um *software* de simulação energética, configurado conforme as características arquitetônicas, construtivas e operacionais da edificação de interesse. Essas simulações geram um banco de dados contendo informações, como temperaturas internas, consumo total de energia, níveis de umidade, requisitos de iluminação, emissões de CO2 entre outros, que são utilizadas para a avaliação de desempenho térmico. No caso de uma avaliação por meio do método CT, utiliza-se dados de consumo de energia com equipamentos AVAC. Já para o método GH, se utiliza dados da temperatura interna. Com essas informações e outros parâmetros estipulados por normas ou pela equipe de pesquisa, avalia-se o desempenho térmico das edificações, obtendo valores de CT

e GH. Mais uma vez, destaca-se que cada método, cada edificação, cada clima, exige uma determinada configuração de simulação energética.

Em seguida, os dados são organizados e passam por uma etapa de pré-processamento, que pode incluir limpeza, normalização, seleção de características e transformação de variáveis, com o objetivo de preparar os dados para alimentar algoritmos de ML. Com os dados tratados, inicia-se o treinamento do modelo, no qual técnicas de ML são utilizadas para aprender padrões e relações entre as variáveis de entrada e o desempenho térmico da edificação. Por fim, o modelo é avaliado com base em métricas de avaliação, como R^2 , MAE e MAPE, utilizando dados de validação para garantir sua capacidade de generalização. Essa etapa permite verificar a precisão e a robustez do modelo, antes de sua aplicação prática na previsão do comportamento térmico de novas edificações ou cenários simulados.

Para avaliar o estado da arte no presente tema, foram considerados como estudos correlatos aqueles que desenvolveram ou empregaram modelagens preditivas com ênfase na avaliação do desempenho térmico ou da eficiência energética de edificações. Inicialmente, cita-se Quevedo et al. (2023), que propuseram a criação de um *benchmarking* energético de edificações universitárias no Brasil usando simulações paramétricas com EnergyPlus. Com base em 23.256 cenários simulados, os autores utilizaram regressão linear múltipla (*Multiple Linear Regression* – MLR), RNA e SVM. O modelo SVM demonstrou o melhor desempenho ($R^2 = 0,97$), evidenciando sua robustez frente à complexidade não linear dos dados. Posteriormente, com base na diferença entre os cenários simulados extremos, os edifícios foram classificados em três faixas de eficiência energética: "eficientes", "típicos" ou "ineficientes", estabelecendo uma escala aplicável a edificações universitárias em todo o território nacional. A abordagem destacou-se por sua escalabilidade e por permitir diagnósticos energéticos mesmo em contextos de escassez de dados reais de consumo.

Seyedzadeh (2019) investigou a eficiência de modelos de ML na predição de CT de aquecimento e resfriamento em edifícios, com ênfase na otimização de hiperparâmetros (*tuning*). Os autores aplicaram técnicas como busca em grade (*grid-*

search) combinada com validação cruzada *k-fold* para ajustar os parâmetros de seis modelos: RNA, XGBoost, SVM, Processos Gaussianos (*Gaussian Process* – GP), RF e Árvores de Regressão por Gradiente (*Gradient Boosted Regression Trees* – GBRT). Como resultado, os autores observaram que ao aplicar técnicas adequadas de ajuste de hiperparâmetros, os modelos de aprendizado de máquina podem prever com alta precisão as CTs, superando significativamente os resultados obtidos em trabalhos anteriores. Entre os modelos testados, o XGBoost e o GBRT se destacaram com os menores erros (RMSE) e altos coeficientes de determinação ($R^2 > 0.98$), combinando precisão e desempenho computacional.

Ngo (2019) propôs um modelo para prever cargas térmicas de resfriamento em edifícios de escritórios ainda na fase inicial de projeto. Para isso, foram utilizados dados de simulações energéticas de 243 edifícios com diferentes características construtivas e operacionais. As variáveis de entrada incluíam informações como: número de pavimentos, área de piso, relação janela-parede, densidades de iluminação, equipamentos e ocupação, localização climática, entre outros. Foram treinados e comparados quatro modelos de ML individuais — RNAs, SVR, Regressão Linear e Árvores de Regressão (CART) — além de 23 modelos *ensemble* baseados em diferentes técnicas de combinação de modelos. A validação foi feita por validação cruzada *10-fold* e os modelos foram avaliados com base em métricas como R^2 , RMSE, MAE e MAPE. Os resultados mostraram que o modelo de *ensemble* com RNAs apresentou o melhor desempenho geral, com $R^2 = 0,99$ e MAPE = 6,17%, superando os demais modelos também quanto ao tempo de execução. O autor conclui que modelos de ML, especialmente *ensembles* com RNAs, são promissores para substituir ou complementar simulações físicas na fase preliminar do projeto de edifícios, contribuindo para decisões mais rápidas e eficazes voltadas à eficiência energética.

Sauer et al. (2022) propuseram um modelo, para prever CT de aquecimento e resfriamento em edificações residenciais. O objetivo foi melhorar a acurácia e estabilidade preditiva do modelo frente a abordagens tradicionais. Para isso, utilizaram um conjunto de 768 simulações energéticas de edifícios geradas no *software* Ecotect. As variáveis de entrada incluíam características geométricas e construtivas da

edificação (como área de parede, altura, orientação, área de vidro etc.). O modelo XGBoost foi treinado para mapear as variáveis de entrada às saídas, e seus hiperparâmetros foram otimizados usando o mJaya, uma metaheurística baseada na ideia de aproximar-se das melhores soluções e afastar-se das piores. O desempenho foi avaliado por validação cruzada 10-*fold*, com foco em métricas como RMSE, R^2 e MAE. Os resultados mostraram que esse modelo superou outras nove metaheurísticas testadas, obtendo RMSE de 0,381 e R^2 de 0,998 para aquecimento, e RMSE de 0,976 e R^2 de 0,989 para resfriamento.

Westermann et al. (2021) apresentam a plataforma web "buildingenergy.ninja", que utiliza redes neurais convolucionais (*Convolutional Neural Networks* – CNNs) como modelos substitutos para estimativa rápida de séries temporais horárias de CT de edifícios. O modelo foi treinado com 20.000 simulações realizadas no EnergyPlus cobrindo 120 climas distintos, permitindo prever cargas horárias de aquecimento e resfriamento para qualquer localização geográfica. A arquitetura baseada em CNNs do tipo ResNet mostrou elevada acurácia ($R^2 > 0,93$) e baixa margem de erro (MAE < 0,28 kWh). O sistema permite exploração interativa de parâmetros de projeto e clima, com resposta quase instantânea. No entanto, os autores alertaram para limitações, como a necessidade de retreinamento para novos climas ou tipologias não contempladas no treinamento original e a incerteza epistêmica presente em previsões para condições fora da distribuição.

O R^2 foi amplamente adotado nos cinco trabalhos como métrica principal de ajuste dos modelos, servindo como indicador da variabilidade explicada pelo modelo. Uma semelhança significativa entre os trabalhos é o uso do EnergyPlus como ferramenta de simulação energética os dados para treinar ou avaliar modelos de ML. Tanto Quevedo et al. (2023) quanto Westermann et al. (2021) fizeram uso da ferramenta para realizar as simulações energéticas e consequentemente gerar os dados para treinamento do modelo. Isso indica que a combinação do EnergyPlus com estratégias de ML é uma estratégia promissora para deixar mais eficiente e eficaz o projeto de edificações com melhor desempenho térmico.

3 METODOLOGIA


3.1 Panorama geral

A metodologia adotada neste estudo consistiu na variação sistemática de características de elementos construtivos, utilizados como dados de entrada para um modelo de ML com o objetivo de prever o desempenho térmico final de edificações com base em duas abordagens principais: o CT e o GH. Além disso, o estudo avaliou a capacidade de generalização do modelo em função da técnica de *transfer learning*.

Entre as variáveis de entrada do banco de dados, foram avaliadas duas propriedades térmicas, CT e GH, para três sistemas construtivos principais: paredes, piso e cobertura. Variando os materiais de cada sistema, sua composição e espessura, obtivemos 21 sistemas de piso, 35 de parede e 48 de cobertura, totalizando 35.280 combinações possíveis, disponíveis no Apêndice A. Esses sistemas foram aplicados a dois tipos de habitações de pequeno porte, sendo cada configuração simulada em três diferentes zonas bioclimáticas. As faixas de temperatura de conforto térmico adotadas foram definidas conforme a norma ABNT NBR 15575 (2024a): de 21 °C a 23 °C para o Método CT e de 18 °C a 26 °C para o Método GH. Os dados utilizados foram gerados e pré-processados pela equipe de pesquisa por meio do *software* de simulação energética EnergyPlus.

Com base em testes preliminares com diferentes algoritmos e em uma revisão da literatura, optou-se pela utilização do algoritmo XGBoost, que se trata de um modelo baseado em AD com otimização sequencial. Foram empregados, dentre outros, procedimentos de validação cruzada e otimização de hiperparâmetros com o intuito de maximizar o desempenho do modelo, conforme será mais bem detalhado nas seções a seguir. A Figura 17 sintetiza o panorama geral da presente pesquisa.

Figura 17 – Panorama geral da pesquisa



Fonte: autor

3.2 Edificações e climas analisados

Para o presente trabalho, foram utilizadas duas residências de interesse social. Cada edificação é composta por uma sala, um banheiro social e dois quartos, totalizando uma área aproximada de 40 m². As Figuras 18 e 19 apresentam, para cada edificação, a maquete 3D à esquerda, a maquete humanizada ao centro e a planta baixa à direita.

Figura 18 – Edificação simulada 1 – 43,6 m²



Fonte: (Oliveira, 2025).

Figura 19 – Edificação simulada 2 – 39,6 m²




Fonte: (Oliveira, 2025).

Embora as edificações possuam áreas totais semelhantes e a mesma quantidade de cômodos, elas diferem na forma como esses ambientes estão dispostos. A Edificação 1 é favorecida pela incidência solar, principalmente nos quartos e na sala, uma vez que suas aberturas estão voltadas para o norte, conforme ilustrado na planta da Figura 18. Já a Edificação 2 apresenta a disposição dos cômodos voltada para o sul, o que resulta em menor aproveitamento da radiação solar direta ao longo do dia.

Com o objetivo de realizar as simulações energéticas, foram selecionadas três cidades brasileiras que representam diferentes condições climáticas predominantes no território nacional. As cidades escolhidas foram: Curitiba, caracterizada por clima frio; São Paulo, com clima relativamente ameno; e Belém, com clima quente. Cada uma dessas cidades está inserida em uma zona bioclimática distinta (ZB), sendo elas, respectivamente, as zonas 1M, 2M e 6A, conforme definido pela norma ABNT NBR 15220 (2024b) e ilustrado na Figura 20.

A Tabela 3 apresenta as cidades selecionadas e suas respectivas zonas bioclimáticas, além da classificação climática segundo o sistema Köppen-Geiger, método amplamente utilizado para identificar os diferentes tipos de clima no mundo. Ele se baseia em dados de temperatura e chuva, relacionando os padrões climáticos com a vegetação típica de cada região. O sistema utiliza códigos com letras para indicar as principais características do clima, como o nível de umidade, o padrão das chuvas e as faixas de temperatura mais comuns.

Figura 20 – Zonas bioclimáticas e classificação climática das cidades selecionadas



Fonte: autor

Tabela 3 – Zonas bioclimáticas e classificação climática das cidades selecionadas

Cidade	Zona Bioclimática	Classificação Köppen-Geiger
Curitiba	1M	CFB (Clima temperado úmido com verão fresco)
São Paulo	2M	CWA (Clima temperado com inverno seco e verão quente)
Belém	6A	AF (Clima equatorial úmido)

Fonte: autor.

As tabelas 4 e 5 trazem as configurações de simulações para os métodos utilizados, CT e GH.

Tabela 4 – Configurações de simulação para o CT

Ganhos internos de calor			
Sistema de iluminação			
Densidade de potência instalada (DPI)	5 W/m ²	Padrão de uso	
Fração radiante	0,32	Quartos	6h-8h e 22h-00h
Fração visível	0,23	Sala	16h-22h
Ocupação			
Calor produzido por pessoa		Padrão de ocupação	
Quartos	81 W	Quartos	22h-8h
Sala	108 W	Sala	14h-18h (50%)
Fração radiante	0,30		18h-22h (100%)
Equipamentos elétricos			
Sala	120 W	Padrão de uso	
Fração radiante	0,30	Sala	14h-22h
Fonte: autor			

Tabela 5 – Configurações de simulação para o GH

Ganhos internos de calor			
Sistema de iluminação			
Densidade de potência instalada (DPI)	5 W/m ²	Padrão de uso	
Fração radiante	0,32	Quartos	6h-8h e 22h-00h
Fração visível	0,23	Sala	16h-22h
Ocupação			
Calor produzido por pessoa		Padrão de ocupação	
Quartos	81 W	Quartos	22h-8h
Sala	108 W	Sala	14h-18h (50%)
Fração radiante	0,30		18h-22h (100%)
Equipamentos elétricos			
Sala	120 W	Padrão de uso	
Fração radiante	0,30	Sala	14h-22h
Ventilação Natural			
Fração de abertura		Padrão de abertura	
Janela (50%) Portas (100%)	50%	Temperatura interna ≥ 19°C	
Coeficiente de descarga de abertura (C _d)	0,60		
Fonte: autor			

Nota-se que a análise da CT e do GH foi direcionada aos ambientes de longa permanência (sala de estar e quartos), os quais foram simulados ao longo de um ano climático de referência. Para CT, considerou-se o sistema AVAC (*setpoints* de 21°C e 23°C) operando conforme os horários estipulados pelo padrão de ocupação da ABNT NBR 15575 (ABNT, 2024a). O valor de CT total foi obtido por meio da média ponderada das áreas dos cômodos analisados. Já para o GH foi calculado com base no intervalo de temperatura de conforto entre 18 °C e 26 °C, sendo contabilizada, para cada hora do ano, a diferença entre a temperatura interna de bulbo seco e os limites de conforto sempre que estes fossem excedidos, independentemente da ocupação. O valor final do GH também considerou a média ponderada das áreas dos ambientes de longa permanência.

3.3 Coleta de dados

Os dados foram gerados pela equipe de pesquisa, em um esquema conforme ilustrado na Figura 21. Após a configuração dos arquivos de entrada com os materiais especificados, bem como a configuração do arquivo climático com as características da ZB referida, foram realizadas as simulações energéticas no *software* EnergyPlus (versão 22.1.0). Os arquivos foram simulados de forma simultânea, por meio da funcionalidade de agrupamento e execução paralela de simulações disponibilizada pelo programa. Os arquivos climáticos utilizados durante as simulações, e que representam o clima de cada ZB, se baseiam nos dados do Instituto Nacional de Meteorologia e estão em conformidade e estão disponibilizados na própria norma ABNT NBR 15575 (2024a).

Figura 21 – Processo de geração dos dados



Fonte: autor

Ao término das simulações, o EnergyPlus gerou arquivos no formato CSV para cada instância simulada, contendo os valores de CT de resfriamento e aquecimento para cada ambiente da edificação, as temperaturas operativas — necessárias para o cálculo do GH —dentre outros dados de saída. Esses arquivos foram posteriormente processados por um *script* em Python, responsável por extrair e tratar as informações referentes aos valores de CT e GH (provindos de simulações distintas).

Por fim, conforme exemplo exposto na Tabela 6, os dados extraídos foram organizados em uma planilha consolidada juntamente com as propriedades das envoltórias dos materiais utilizados, constituindo assim o conjunto de dados utilizados no processo de modelagem.

Tabela 6— Amostra do conjunto final dos dados de GH para 6 instâncias aleatórias

INSTÂNCIA	U_ PAREDE	CT_ PAREDE	U_ COBERTURA	CT_ COBERTURA	U_PISO	CT_PISO	GH_ COOLING (C)	GH_ HEATING (C)	GH_ TOTAL (C)
1	4,72	111,86	4,05	296,60	12,84	180,50	2384,85	1662,53	4047,38
3417	4,36	255,70	4,81	36,79	2,14	411,08	2138,01	816,36	2954,37
9188	2,59	175,27	2,19	222,61	9,94	327,50	1000,00	957,02	1957,02
11003	2,54	194,77	2,26	236,04	2,14	437,76	862,59	531,32	1393,91
20599	5,53	190,89	4,02	147,19	2,17	308,23	2329,29	998,11	3327,40
24946	6,57	184,42	1,69	183,60	2,17	308,23	1414,63	809,39	2224,03

Fonte: autor.

3.4 Dados das simulações energéticas

Os dados foram gerados considerando uma absorptância solar fixa de 0,325. Como o estudo envolve duas variáveis de saída — CT e GH —, aplicadas a duas edificações distintas (Edificação 1 e Edificação 2) em três ZBs, foram desenvolvidos ao todo 12 configurações diferentes. Além disso, foram consideradas as variações nos sistemas construtivos de piso (21), parede (35) e cobertura (48), listados no Apêndice A.

A Tabela 7 e a Figura 22 apresentam algumas estatísticas descritivas dos dados de entrada, que representam as propriedades U e Ct destes sistemas construtivos. No EnergyPlus, entretanto, os materiais são definidos por suas propriedades individuais — espessura, condutividade térmica, massa específica e calor específico — e não diretamente pelos valores de U e Ct. Como mostrado na Tabela 1, esses valores de


U e Ct resultam de formulações matemáticas baseadas nas demais propriedades dos materiais. Mais adiante, será demonstrado o uso de U e Ct como variáveis de entrada nos modelos de ML desenvolvidos, decisão adotada para viabilizar o trabalho, considerando sistemas com diferentes tipos e quantidades de materiais.

Tabela 7 – Estatísticas descritivas das propriedades dos sistemas construtivos

ESTATÍSTICAS DESCRITIVAS	PROPRIEDADES DAS ENVOLTÓRIAS					
	U_PAREDE (W/m ² .K)	Ct_PAREDE (kJ/ m ² .K)	U_COBERTURA (W/m ² .K)	Ct_COBERTURA (kJ/ m ² .K)	U_PISO (W/ m ² .K)	Ct_PISO (kJ/ m ² .K)
MÍNIMO	1,67	53,36	1,83	12,42	1,94	58,50
MÉDIA	4,45	167,26	3,47	157,87	7,36	266,19
MEDIANA	4,36	175,27	3,41	187,26	7,41	307,65
MÁXIMO	9,52	334,73	11,42	315,02	23,00	437,76

Fonte: autor.

Figura 22– Boxplot das propriedades dos sistemas construtivos



Fonte: autor.

No geral, nota-se que as propriedades da cobertura apresentaram distribuições mais próximas de uma assimetria positiva, as propriedades Ct_COBERTURA e U_PISO apresentaram maior variabilidade nos dados, enquanto as propriedades da parede estão mais uniformemente distribuídas.

3.5 Implementação do ML


Os modelos de ML foram desenvolvidos utilizando a linguagem Python (versão 3.11.7), com o auxílio de diversas bibliotecas. A biblioteca Pandas foi empregada para a análise e manipulação do conjunto de dados; a Scikit-learn foi utilizada por oferecer uma ampla variedade de algoritmos de ML, bem como ferramentas para validação e otimização dos modelos; a XGBoost foi incorporada por disponibilizar o algoritmo de *gradient boosting* utilizado no presente trabalho; e a NumPy foi utilizada para operações numéricas e manipulação eficiente de vetores multidimensionais. Essas ferramentas em conjunto permitiram a construção, treinamento e avaliação do modelo proposto de forma eficiente e robusta.

Como os dados utilizados foram gerados pela própria equipe de pesquisa, não foi necessário realizar procedimentos de imputação de valores ausentes nem a remoção de registros duplicados. Ademais, em virtude da natureza do algoritmo empregado — baseado em AD —, não se fez necessário aplicar técnicas de normalização ou padronização dos dados.

3.5.1 Divisões do conjunto de treino e teste

Inicialmente, os modelos foram treinados utilizando a técnica de validação cruzada (*k-fold*). Tal técnica consiste em dividir aleatoriamente o conjunto de dados, em “k” subconjuntos distintos, chamado “*folds*”, onde o modelo é treinado k vezes, escolhendo sempre um subconjunto diferente para avaliação enquanto os outros k-1 *folds* são usados no treinamento, conforme ilustrado na Figura 23. Essa estratégia visou reduzir possíveis vieses de amostragem que podem surgir numa divisão simples de treino e teste. Tratando-se da técnica de *k-fold*, não existe um valor único ou exato de “k” que seja considerado ideal para todos os casos. O valor de k pode variar conforme a natureza do problema e o tamanho do conjunto de dados. No entanto, é comum a adoção de valores entre 5 e 10 em muitas aplicações práticas. Seguindo essa prática, e assim como feito por Sauer (2022), neste estudo foi utilizado $k = 10$.

Figura 23– Esquematização da validação cruzada (k-fold)



Fonte: autor

Como será visto na seção 4.1, essa primeira avaliação resultou em um desempenho muito elevado ($R^2 > 0,99$). Entretanto, tal desempenho pôde ser parcialmente atribuído a uma possível similaridade entre instâncias – por exemplo, uma combinação no conjunto de testes pode possuir as mesmas propriedades de piso e parede que uma combinação no conjunto de treino, com apenas pequenas diferenças na propriedade de cobertura.

Por isso, numa segunda etapa, visando avaliar uma maior capacidade de generalização do modelo, os conjuntos de piso, parede e cobertura foram integralmente separados em 5 subconjuntos ou *folds*. O treinamento foi feito com 4 desses subconjuntos (80%), combinados entre si (~18.300 instâncias), e o teste, com o 5º *fold* (20%) (~280 instâncias). A diferença para o treinamento delineado anteriormente é que, nessa avaliação, os sistemas de piso, parede e cobertura foram

integralmente separados antes de serem combinados, de modo que nenhum dos valores de treino entrou nas combinações construtivas usadas para teste. Essa avaliação foi repetida 5 vezes, para mitigar vieses de amostragem na separação, e os resultados mostram a média das métricas obtidas. Ademais, em ambas as estratégias de divisão de dados para treinamento, os modelos foram avaliados pelas métricas R^2 , MAE e MAPE.

3.5.2 *Transfer learning*

O *transfer learning* é uma técnica de ML que consiste em reutilizar um modelo previamente treinado em uma determinada tarefa como ponto de partida para uma nova tarefa. Essa abordagem permite uma adaptação ao novo problema, acelerando o processo de aprendizado. O *transfer learning* se destaca como uma solução eficaz em cenários com dados limitados ou de difícil obtenção, reduzindo significativamente o tempo e os custos de aquisição de novos dados. Isso se deve ao fato de que o modelo pré-treinado já incorporou conhecimento a partir de um grande volume de dados. Além disso, essa técnica oferece alta adaptabilidade, possibilitando ajustes específicos para a nova tarefa de forma mais rápida e eficiente. Neste trabalho, essa técnica foi empregada para aproveitar um modelo previamente treinado com dados simulados de uma edificação visando realizar previsões de CT e GH em outra edificação. Essa abordagem permitiu explorar o conhecimento já consolidado no modelo original, facilitando sua aplicação em um novo cenário com características distintas.

3.5.3 Ajustes de hiperparâmetros

O ajuste de parâmetros é uma etapa essencial para alcançar um bom desempenho de um modelo de ML. Um ajuste adequado permite equilibrar o viés e a variância do modelo, reduzindo o risco de *overfitting* (incapacidade de generalização) ou *underfitting* (incapacidade de capturar padrões relevantes, baixo desempenho de reconhecimento de padrões). Ao ajustar valores de parâmetros, podemos controlar a

complexidade, regularização e taxa de aprendizado do algoritmo de ML, o que pode melhorar a capacidade do modelo na generalização para novos dados.

Para isso, existem diversas técnicas de busca de hiperparâmetros com o objetivo de alcançar uma configuração otimizada do modelo. Neste trabalho, adotou-se o método de otimização bayesiana, implementado pela biblioteca Optuna. Essa abordagem realiza uma exploração inteligente do espaço de busca previamente definido, utilizando informações de avaliações deste espaço para propor novas combinações de hiperparâmetros mais promissoras a cada iteração. Os hiperparâmetros ajustados foram: “*max_depth*”, que define a profundidade máxima das árvores e influencia diretamente a complexidade do modelo; “*min_child_weight*”, que determina o peso mínimo necessário para a criação de nós filhos e regula a robustez da divisão das árvores; *subsample*, que especifica a fração de amostras utilizada em cada árvore para evitar *overfitting*; “*learning rate*”, representando a taxa de aprendizado a cada passo, responsável por controlar o impacto de cada árvore na atualização do modelo final; e “*colsample_bytree*”, que define a proporção de variáveis utilizadas na construção de cada árvore, promovendo diversidade e reduzindo a correlação entre árvores. Os valores para cada um desses parâmetros em cada um dos modelos foram listados no Apêndice B.

4 RESULTADOS

4.1 Avaliação dos modelos com *k-fold*

Os modelos foram inicialmente treinados utilizando validação cruzada com 10 divisões, sem restrições ao banco de dados. Essa análise buscou avaliar se o modelo é capaz de substituir parcialmente as simulações energéticas, reduzindo o tempo necessário para a avaliação de múltiplas combinações de sistemas construtivos. Os resultados das métricas de avaliação estão apresentados na Tabela 8.

Tabela 8 – Desempenho dos modelos com validação cruzada (*k-fold*)

SAÍDA	EDIFICAÇÃO	ZONA BIOCLIMÁTICA								
		ZB 1M - CURITIBA			ZB 2M - SÃO PAULO			ZB 6A - BELÉM		
		MAE	MAPE (%)	R ²	MAE	MAPE (%)	R ²	MAE	MAPE (%)	R ²
CT (MJ)	EDIF 1	6,01	0,12	0,99991	7,21	0,15	0,99993	12,32	0,05	0,99995
	EDIF 2	1,56	0,06	0,99996	1,76	0,06	0,99994	2,13	0,02	0,99998
GH (°C)	EDIF 1	12,78	0,41	0,99977	13,04	0,69	0,99979	59,21	0,39	0,99980
	EDIF 2	4,40	0,12	0,99995	4,06	0,32	0,99993	5,92	0,02	0,99994

Fonte: autor.

Observa-se que os modelos apresentam estatísticas de desempenho satisfatórias: $R^2 > 0,999$ e $MAPE < 1\%$. Os resultados estão de acordo com os encontrados por Ngo (2019), que, ao utilizar 243 edificações em simulações energéticas e testar modelos do tipo ensemble, obteve um $R^2 = 0,99$ e um MAPE inferior a 7% para a previsão das cargas térmicas de resfriamento. Da mesma forma, Sauer et al. (2022), ao comparar modelos preditivos com abordagens tradicionais para prever as CT de aquecimento e resfriamento, encontrou R^2 de 0,99 e 0,989, respectivamente. Por fim, Westermann et al. (2021) utilizando redes neurais convolucionais e um banco de dados com 20 mil instâncias simuladas, obteve um $R^2 > 0,93$ e um MAE próximo a 1 mega joule.

Os resultados deste estudo estão relacionados principalmente à forma como o banco de dados foi construído — por meio de combinações entre sistemas construtivos de piso, parede e cobertura. Entre as 35.280 instâncias, algumas envolveram materiais com propriedades muito semelhantes. Por esse motivo, mesmo com a aplicação da validação cruzada, é provável que instâncias com propriedades

muito próximas estejam presentes simultaneamente nos conjuntos de treino e de teste.

Assim, o modelo tende a se apoiar em padrões muito similares aos já observados no treinamento. Como consequência, obtêm-se previsões com acurácia elevada, refletindo um bom ajuste ao desempenho térmico real das edificações a partir das combinações de sistemas construtivos. Esses achados mostram que o uso de ML em análises térmoenergéticas pode reduzir substancialmente a necessidade de milhares de simulações energéticas, que seriam exigidas para avaliar todas as combinações possíveis de sistemas de piso, parede e cobertura. Em processos de otimização, por exemplo, em que seria necessário simular um grande número de combinações para encontrar a configuração mais eficiente, o modelo treinado pode substituir essas simulações computacionalmente custosas. Uma vez ajustado, ele é capaz de fornecer novos resultados ao algoritmo de otimização em questão de segundos, permitindo avaliar rapidamente múltiplas alternativas e acelerar de forma significativa a busca por soluções com melhor desempenho térmico.

4.2 Avaliação dos modelos com nova divisão do conjunto treino/teste

Para endereçar essa questão e conferir maior robustez ao estudo, optou-se por não utilizar os mesmos sistemas construtivos no conjunto de treino para o de teste. Diferentemente da abordagem anterior, que utilizava todas as combinações possíveis, nesta nova estratégia selecionamos aleatoriamente 80% dos sistemas construtivos de cada componente da envoltória (paredes, coberturas e pisos), que, após combinarem entre si, integraram o conjunto de treino. Os 20% restantes foram combinados entre si e reservados exclusivamente para a formação do conjunto de teste. Essa separação garante que não haja qualquer interseção entre os conjuntos em relação aos sistemas construtivos utilizados em cada envoltória, permitindo assim uma avaliação mais fiel da capacidade de generalização dos modelos. A Tabela 9 apresenta o resultado das métricas após a divisão dos dados.

Tabela 9 – Métricas de avaliação dos modelos na nova divisão do conjunto de treino/teste

SAÍDA	EDIFICAÇÃO	ZONA BIOCLIMÁTICA								
		ZB 1M - CURITIBA			ZB 2M - SÃO PAULO			ZB 6A - BELÉM		
		MAE	MAPE (%)	R ²	MAE	MAPE (%)	R ²	MAE	MAPE (%)	R ²
CT (MJ)	EDIF 1	348,16	7,05	0,72	328,69	7,00	0,73	880,15	3,97	0,66
	EDIF 2	88,78	1,15	0,92	71,64	2,39	0,91	109,2	2,80	0,84
GH (°C)	EDIF 1	374,96	10,90	0,85	463,84	23,86	0,78	2401,03	15,28	0,65
	EDIF 2	392,51	12,41	0,65	233,66	13,89	0,84	1010,49	2,34	0,55

Fonte: autor.


É possível então perceber, que, após essa divisão, as métricas diminuem consideravelmente, mostrando que, embora o modelo atue bem com combinações de materiais conhecidos, sua habilidade de generalização para novos materiais não é tão boa.

No geral, as métricas referentes as saídas para CT foram ligeiramente melhores que as métricas de GH. Embora não se possa relacionar o MAE das duas saídas, por se tratar de grandezas distintas, se analisarmos o MAPE, percebemos que o erro foi menor para a saída de CT. Observa-se, ainda, que as métricas obtidas para a ZB6A foram inferiores em comparação às demais ZBs. Isso se deve, em grande parte, à maior temperatura média anual da região, o que acarreta uma maior variação nos valores de CT e GH em função dos diferentes sistemas construtivos. Esse comportamento evidencia a influência significativa dos materiais na eficiência energética das edificações, ressaltando a importância de uma seleção criteriosa de componentes construtivos que favoreçam o conforto térmico e o desempenho energético (Lamberts, 2016).

Além disso, a diferença dos erros médios entre as edificações (MAE e MAPE), possivelmente se dá pelas características de orientação solar e layout da edificação 1, que possui uma área maior de longa permanência e uma orientação solar que favorece uma maior incidência de radiação solar, resultando em uma variabilidade no desempenho térmico, e, portanto, uma variabilidade nos erros de aprendizagem dos modelos.

A Figura 24 apresenta o gráfico de dispersão que relaciona os valores reais e previstos para as saídas com o melhor e o pior desempenho, com base na métrica R^2 dos resultados. É possível observar que, no gráfico à esquerda, os pontos estão bem alinhados à linha de tendência ideal, o que indica um bom desempenho preditivo do modelo, com baixa dispersão dos erros. Por outro lado, no gráfico à direita, nota-se uma maior dispersão dos dados em relação à linha, especialmente nos valores mais altos, o que evidencia uma precisão reduzida do modelo e sugere a presença de um viés sistemático de subestimação — ou seja, o modelo tende a prever valores consistentemente menores do que os reais.

Figura 24 – Gráfico de dispersão para duas saídas. Esquerda: Modelo com melhor R^2 (0,92), referente à Edif. 2 na ZB 1M e tendo CT como saída. Direita: Modelo com o pior R^2 (0,55), referente à Edif. 2 na ZB 6A, tendo GH como saída.



Fonte: autor.

4.3 Avaliação dos modelos em outra edificação (*transfer learning*)

A fim de entender a capacidade de generalização do nosso modelo, testamos adotar o modelo treinado na edificação 1 para prever os resultados da edificação 2 e vice-versa (técnica de *transfer learning*). Essa estratégia busca avaliar se o modelo é capaz de se adaptar a uma edificação diferente daquela usada no treinamento. A Tabela 10 apresenta os resultados obtidos, por meio do MAE, MAPE e R^2 .

Tabela 10 – Métricas de avaliação dos modelos em outra edificação.

SAÍDA	EDIFICAÇÃO	ZONA BIOCLIMÁTICA								
		ZB 1 - CURITIBA			ZB 3 - SÃO PAULO			ZB 8 - BELÉM		
		MAE	MAPE (%)	R ²	MAE	MAPE (%)	R ²	MAE	MAPE (%)	R ²
CT (MJ)	EDIF 1	2273,85	82,01	0,09	2119,72	72,77	0,13	9092,88	65,94	0,11
	EDIF 2	2184,97	43,66	0,19	1957,61	39,46	0,04	8288,80	37,07	0,20
GH (°C)	EDIF 1	692,08	19,34	0,23	606,78	44,36	0,27	11775,00	35,61	0,22
	EDIF 2	767,78	26,08	0,38	689,83	22,61	0,44	13260,61	87,52	0,003

Fonte: autor.

Observa-se uma maior queda no desempenho dos modelos, não conseguindo generalizar o aprendizado para diferentes edificações. A principal causa para esse resultado é provavelmente a insuficiência de características (*features*) relevantes, já que um conjunto mais abrangente de variáveis permitiria representar cenários construtivos distintos e, portanto, melhorar a capacidade de generalização do modelo. Para ampliar sua capacidade de generalização, seria necessário treinar os modelos com diferentes edificações, contemplando *layouts* variados e incorporando características específicas no processo de treinamento (como orientação solar, área de aberturas e área total). Esse tipo de abordagem permitiria ao modelo abranger uma maior diversidade de padrões térmicos presentes em diferentes projetos de edificações, sendo recomendada para trabalhos futuros.

5 CONCLUSÃO

Este trabalho teve como objetivo desenvolver e avaliar modelos preditivos de desempenho térmico em diferentes edificações e condições climáticas, por meio da aplicação de técnicas de ML e com base em simulações energéticas. Após o levantamento dos materiais e a definição dos sistemas construtivos, foi utilizado o *software* de simulação energética EnergyPlus para a construção de um banco de dados. Esse banco reuniu informações sobre as propriedades térmicas dos materiais, bem como o CT e GH de duas edificações simuladas em três diferentes climas brasileiros. A partir dessas simulações, foram desenvolvidos modelos de ML, avaliando a sua capacidade de predição com alterações na divisão do conjunto de dados para treino e teste, bem como com a técnica de *transfer learning*.

Inicialmente, com os modelos treinados e avaliados por meio de validação cruzada (*k-fold*). Os resultados indicaram valores de R^2 superiores a 0,99, além de EPAM inferiores a 1% para todas as variáveis de saída, ZBs e edificações. Esse desempenho elevado reflete a forma de construção do banco de dados, no qual combinações de sistemas construtivos incluíram materiais com propriedades semelhantes, possivelmente presentes tanto nos conjuntos de treino quanto de teste. Essa configuração favorece bons resultados e indica que modelos desse tipo podem ser úteis para substituir grande parte das simulações energéticas necessárias à avaliação do desempenho térmico de combinações com sistemas construtivos já conhecidos.

Para avaliar a capacidade de generalização, a divisão dos dados foi reestruturada, de modo que determinados materiais fossem utilizados exclusivamente nas combinações do conjunto de teste. Nessa configuração, observou-se uma queda na capacidade preditiva: os EPAM permaneceram inferiores a 16% e os valores de R^2 ficaram acima de 0,7, mas abaixo de 0,9 na maioria dos cenários.

Por fim, no que se refere à aplicação do *transfer learning*, verificou-se uma redução acentuada no desempenho. Em situações mais extremas, o EPAM chegou a aproximadamente 80% e o R^2 permaneceu abaixo de 0,4 em todos os casos, evidenciando a baixa capacidade do modelo em explicar a variância dos dados. Esses

resultados mostram que os padrões de correlação entre variáveis de entrada e saída não se mantêm ao aplicar o modelo a edificações diferentes daquelas utilizadas no treinamento. Isso sugere a necessidade de incluir variáveis explicativas que representem características específicas das edificações, além de ampliar a diversidade de tipologias no conjunto de treinamento, de modo a melhorar a capacidade de generalização.

Em suma, os resultados obtidos, apesar das limitações observadas, evidenciam contribuições relevantes ao demonstrar o potencial de técnicas de ML como ferramenta eficaz de apoio à seleção de materiais de construção com foco no desempenho térmico. Dessa forma, o estudo oferece uma base sólida para avanços futuros, indicando caminhos para ampliar a generalização e explorar plenamente o potencial de modelos de ML no apoio à seleção de materiais de construção com foco no desempenho térmico.

REFERÊNCIAS

- ABNT. (2024a). *NBR 15575 - Edificações habitacionais - Desempenho*. Associação Brasileira de Normas Técnicas, Rio de Janeiro.
- ABNT. (2024b). *NBR 15220 - Desempenho térmico em edificações*. Rio de Janeiro.
- Abrahão et al. (2021). A hybrid learning strategy for structural damage detection. *Structural Health Monitoring*, 20, pp. 2143-2160.
- Akman, G. et al. (2023). Assessing innovation capabilities of manufacturing companies by combination of unsupervised and supervised machine learning approaches. *Applied Soft Computing.*, 147, p. 110735.
- Akmann, G. et al. (2023). Assessing innovation capabilities of manufacturing companies by combination of unsupervised and supervised machine learning approaches. *Applied Soft Computing.*, p. 110735.
- Almeida, F. (2007). *Análises estatísticas e reconhecimento de padrão aplicados em diagnósticos de defeitos em rolamentos através da análise de vibração*. Tese de doutorado, UNIFEI, Itajubá.
- Bisolo, G. (2018). *Análise do desempenho térmico em edifícios residenciais: estudo comparativo entre métodos de avaliação para a zona bioclimática 2*. São Leopoldo.
- Cruz et al. (2024). MULTI-OBJECTIVE OPTIMIZATION BASED ON SURROGATE MODELS FOR SUSTAINABLE BUILDING DESIGN: A SYSTEMATIC LITERATURE REVIEW. *Building and Environment*, p. 266.
- Do Rêgo, L. G. (2022). *Uso de Meta-Learning em Tarefas de Aprendizado Profundo*. Búzios.
- dos Santos, W. I., & Junior, M. E. (2017). Dimensionamento da carga térmica de resfriamento de ambientes como estratégia para melhoria da eficiência energética em instituições de ensino. *Revista Vértices*, 19, pp. 211-236. doi:10.19180/1809-2667.v19n32017p211-236

- Empresa de Pesquisa Energética. (2024). *Boletim Trimestral de Consumo de Eletricidade – Ano V, Nº 20*. Rio de Janeiro. Acesso em 10 de Fevereiro de 2025, disponível em EPE – Empresa de Pesquisa Energética: https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-483/topico-717/Boletim%20Trimestral%20de%20Consumo%20de%20Eletricidade%20A%20N%C2%BA20_GF.pdf
- EnergyPlus, U. S. (2025). *EnergyPlus Documentation*. Acesso em 15 de Maio de 2025, disponível em EnergyPlus: <https://energyplus.net/documentation>
- G1. (2024). *Onda de calor: Brasil registra novo recorde de demanda de energia elétrica, diz ONS*. Fonte: G1: <https://g1.globo.com/economia/noticia/2024/03/17/onda-de-calor-brasil-registra-novo-recorde-de-demanda-de-energia-eletrica-diz-ons.ghtml>
- Géron, A. (2019). *Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow*. O'Reilly Media.
- Himmetoğlu, S., Delice, Y., Kızılkaya Aydoğan, E., & Uzal, B. (2022). Green building envelope designs in different climate and seismic zones: Multi-objective ANN-based genetic algorithm. *Sustainable Energy Technologies and Assessments*, 53. doi:10.1016/J.SETA.2022.102505
- Hossein et al. (2019). Predicting Heating Load in Energy-Efficient Buildings Through Machine Learning Techniques. *Applied Sciences*, 9, p. 4338.
- Incropera, F. P., Dewit, D. P., Bergman, T. L., & Lavine, A. S. (2008). *Fundamentos da Transferência de Calor e Massa*. LTC. Rio de Janeiro: LTC.
- Jaiswal, S. (2025). *Perceptrons multicamadas em aprendizado de máquina: um guia abrangente*. Acesso em 12 de Maio de 2025, disponível em Datacamp: <https://www.datacamp.com/tutorial/multilayer-perceptrons-in-machine-learning>

- JAVATPOINT. (2021). *Algoritmo de classificação de árvore de decisão*. Fonte: JavaTPoint: <https://www.javatpoint.com/machine-learning-decision-tree-classification-algorithm>
- Lamberts et al. (2014). *Eficiência energética na arquitetura*. (3 ed.). Rio de Janeiro: Eletrobras/Procel.
- Lamberts, R. e. (2016). *Apostila da disciplina ECV5161 – Eficiência Energética em Edificações*. Acesso em 10 de Abril de 2025, disponível em LabEEE – UFSC: https://labeee.ufsc.br/sites/default/files/disciplinas/ApostilaECV5161_v2016.pdf
- Liu et al. (2020). Reinforcement Learning-Based Autonomous Navigation for Mobile Robots in Industrial. *IEEE Access*, 8, pp. 156823-156832. doi:<https://doi.org/10.1109/ACCESS.2020.3018203>
- LUNGE, N. (27 de Janeiro de 2021). *A deep architecture – Multi-layer Perceptron*. Acesso em 14 de Abril de 2025, disponível em Medium: <https://medium.com/@nlunge786/a-deep-architecture-multi-layer-perceptron-164bc5ff3842>
- Mendes et al. (2024). A systematic review of methods for evaluating the thermal performance of buildings through energy simulations. *Renewable and Sustainable Energy Reviews*, 189, p. 113875.
- Mendes, V. (2021). *Novo Método de avaliação do isolamento térmico do fechamento de edificações: análise de sensibilidade das propriedades termofísicas de argamassas de revestimento*. Universidade Federal de Ouro Preto. Ouro Preto: Universidade Federal de Ouro Preto (dissertação de mestrado).
- Mendes, V. (2023). *Métodos para avaliação de desempenho térmico de edificações envolvendo simulações energéticas*. Universidade Federal de Ouro Preto, Ouro Preto.
- Ngo, N.-T. (2019). Early predicting cooling loads for energy-efficient design in office buildings by machine learning. *Energy and Buildings*, 182, pp. 264-273.

- NIST. (2020). *SI Base Units Relationships Poster*. Acesso em 22 de Julho de 2025, disponível em National Institute of Standards and Technology.
- Oliveira, G. (2025). *Desenvolvimento de modelos de aprendizado de máquina para prever o desempenho térmico de edificações e converter carga térmica em graus-hora*. Dissertação, Universidade Federal de Ouro Preto, Ouro Preto.
- ONEBUILDING. (2024). *Arquivos climáticos EPW – Brasil*. Acesso em 24 de 07 de 2025, disponível em OneBuilding: https://climate.onebuilding.org/WMO_Region_3_South_America/BRA_Brazil/index.html#IDSP_Sao_Paulo-
- Oztornaci, B., Ata, B., & Kartal, S. (2024). Analysing Household Food Consumption in Turkey Using Machine Learning Techniques. *Agris on-line Papers in Economics and Informatics*.
- Paixão, R. C., Penido, R. E.-K., Cury, A. A., & Mendes, J. C. (2022). Comparison of machine learning techniques to predict the compressive strength of concrete and considerations on model generalization. *Revista IBRACON de Estruturas e Materiais*, 15, e15503.
- Pereira, C. (2010). *Casa eficiente: simulação computacional do desempenho termo-energético*. Florianópolis.
- PROGRAMME, U. N. (2024). *Global Status Report for Buildings and Construction: Beyond foundations: mainstreaming sustainable solutions to cut emissions from the buildings sector*. Nairobi: UNEP. doi:<https://doi.org/10.59117/20.500.11822/45095>
- Quevedo, T. C., Geraldi, M. S., & Melo, A. P. (2023). Applying machine learning to develop energy benchmarking for university buildings in Brazil. *Journal of Building Engineering*, 63, p. 105468.
- Sauer, J. et al. (2022). Extreme gradient boosting model based on improved Jaya optimizer applied to forecasting energy consumption in residential buildings. *Evolving Systems*, 13, pp. 577-588.

- Schmidt et al. (2019). Recent advances and applications of machine learning in solid-state materials science. *Computational Materials*, 5, p. 83.
- Seyedzadeh, S. et al. (2019). Tuning machine learning models for prediction of building energy loads. *Sustainable Cities and Society*, 47, p. 101484.
- Verma, P. K., & Netam, N. (2020). A case study on thermal comfort analysis of school building. *Materials Today: Proceedings*, v. 28, pp. p. 2501-2504. doi:10.1016/J.MATPR.2020.04.829
- Westermann, P., Rousseau, G., & Evins, R. (2021). Buildingenergy. ninja: A web-based surrogate model for instant building energy time series for any climate. *Journal of Physics: Conference Series*, p. 012012.
- XGBoost Developers. (2025). *XGBoost documentation*. Fonte: XGBoost.readthedocs.io: <https://xgboost.readthedocs.io/en/stable/>

APÊNDICE A – LISTA DE MATERIAIS DOS SISTEMAS CONSTRUTIVOS

A.1 Paredes

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
1	Reboco	0,0150	1,1500	1950,0000	1000,0000	4,7213	111,8647
	Bloco Cerâmico	0,0900	0,4846	860,0833	689,4000		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		
2	Reboco	0,0200	1,1500	1950,0000	1000,0000	4,5351	131,3647
	Bloco Cerâmico	0,0900	0,4846	860,0833	689,4000		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
3	Reboco	0,0250	1,1500	1950,0000	1000,0000	4,3630	150,8647
	Bloco Cerâmico	0,0900	0,4846	860,0833	689,4000		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
4	Reboco isolante	0,0250	0,200	1560,00	1000,0000	2,295	131,365
	Bloco Cerâmico	0,0900	0,4846	860,0833	689,4000		
	Reboco isolante	0,0250	0,200	1560,00	1000,0000		
5	Reboco	0,0150	1,1500	1950,0000	1000,0000	4,1984	114,0717
	Bloco Cerâmico	0,1150	0,5422	806,5978	599,1000		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		
6	Reboco	0,0200	1,1500	1950,0000	1000,0000	4,0505	133,5717
	Bloco Cerâmico	0,1150	0,5422	806,5978	599,1000		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
7	Reboco	0,0250	1,1500	1950,0000	1000,0000	3,9127	153,0717
	Bloco Cerâmico	0,1150	0,5422	806,5978	599,1000		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
8	Reboco isolante	0,0250	0,200	1560,00	1000,0000	2,164	133,572
	Bloco Cerâmico	0,1150	0,5422	806,5978	599,1000		
	Reboco isolante	0,0250	0,200	1560,00	1000,0000		
9	Reboco	0,0150	1,1500	1950,0000	1000,0000	2,6549	155,7660

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
	Bloco cerâmico 9cm deitado	0,1900	0,5420	968,4167	528,6220		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		
10	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,5949	175,2660
	Bloco cerâmico 9cm deitado	0,1900	0,5420	968,4167	528,6220		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
11	Reboco	0,0250	1,1500	1950,0000	1000,0000	2,5377	194,7660
	Bloco cerâmico 9cm deitado	0,1900	0,5420	968,4167	528,6220		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
12	Reboco isolante	0,0250	0,200	1560,00	1000,0000	1,665	175,266
	Bloco cerâmico 9cm deitado	0,1900	0,5420	968,4167	528,6220		
	Reboco isolante	0,0250	0,200	1560,00	1000,0000		
13	Reboco	0,0150	1,1500	1950,0000	1000,0000	2,7212	156,3134
	Bloco cerâmico 11,5cm deitado	0,1900	0,5565	870,1685	591,6180		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		
14	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,6583	175,8134
	Bloco cerâmico 11,5cm deitado	0,1900	0,5565	870,1685	591,6180		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
15	Reboco	0,0250	1,1500	1950,0000	1000,0000	2,5982	195,3134
	Bloco cerâmico 11,5cm deitado	0,1900	0,5565	870,1685	591,6180		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
16	Reboco isolante	0,0250	0,200	1560,00	1000,0000	1,691	175,813
	Bloco cerâmico 11,5cm deitado	0,1900	0,5565	870,1685	591,6180		
	Reboco isolante	0,0250	0,200	1560,00	1000,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
17	Reboco	0,0150	1,1500	1950,0000	1000,0000	7,6245	205,3581
	Tijolo maciço	0,1000	0,9518	1592,8570	921,9790		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		
18	Reboco	0,0200	1,1500	1950,0000	1000,0000	7,1504	224,8581
	Tijolo maciço	0,1000	0,9518	1592,8570	921,9790		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
19	Reboco	0,0250	1,1500	1950,0000	1000,0000	6,7318	244,3581
	Tijolo maciço	0,1000	0,9518	1592,8570	921,9790		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
20	Reboco isolante	0,0250	0,200	1560,00	1000,0000	2,816	224,858
	Tijolo maciço	0,1000	0,9518	1592,8570	921,9790		
	Reboco isolante	0,0250	0,200	1560,00	1000,0000		
21	Reboco	0,0150	1,1500	1950,0000	1000,0000	5,5314	190,8870
	Bloco de Concreto	0,1400	0,9050	1166,0803	810,9400		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		
22	Reboco	0,0200	1,1500	1950,0000	1000,0000	5,2775	210,3870
	Bloco de Concreto	0,1400	0,9050	1166,0803	810,9400		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
23	Reboco	0,0250	1,1500	1950,0000	1000,0000	5,0460	229,8870
	Bloco de Concreto	0,1400	0,9050	1166,0803	810,9400		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
24	Reboco isolante	0,0250	1,1500	2023,4000	2000,0000	5,0460	334,7270
	Bloco de Concreto	0,1400	0,9050	1166,0803	810,9400		
	Reboco isolante	0,0250	1,1500	2023,4000	2000,0000		
25	Reboco	0,0150	1,1500	1950,0000	1000,0000	6,5665	184,4178
	Bloco de Concreto	0,0900	0,7132	1506,4027	928,7600		
	Reboco	0,0150	1,1500	1950,0000	1000,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
26	Reboco	0,0200	1,1500	1950,0000	1000,0000	6,2118	203,9178
	Bloco de Concreto	0,0900	0,7132	1506,4027	928,7600		
	Reboco	0,0200	1,1500	1950,0000	1000,0000		
27	Reboco	0,0250	1,1500	1950,0000	1000,0000	5,8935	223,4178
	Bloco de Concreto	0,0900	0,7132	1506,4027	928,7600		
	Reboco	0,0250	1,1500	1950,0000	1000,0000		
28	Reboco isolante	0,0250	0,200	1560,00	1000,0000	2,658	203,918
	Bloco de Concreto	0,0900	0,7132	1506,4027	928,7600		
	Reboco isolante	0,0250	0,200	1560,00	1000,0000		
29	Tijolo maciço	0,1000	0,9518	1592,8570	921,9790	9,5175	146,8581
30	Bloco de Concreto	0,1400	0,9050	1166,0803	810,9400	6,4641	132,3870
31	Bloco de Concreto	0,0900	0,7132	1506,4027	928,7600	7,9239	125,9178
32	Bloco Cerâmico	0,0900	0,4846	860,0833	689,4000	5,3844	53,3647
33	Bloco Cerâmico	0,1150	0,5422	806,5978	599,1000	4,7148	55,5718
34	Bloco cerâmico 9cm deitado	0,1900	0,5420	968,4167	528,6220	2,8524	97,2660
35	Bloco cerâmico 11,5cm deitado	0,1900	0,5565	870,1685	591,6180	2,9291	97,8134

Fonte: autor.

A.2 Pisos

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U equivalente (W/m².K)	Ct equivalente (kJ/m².K)
1	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	12,8372	180,5000
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Porcelanato	0,0100	1,2000	2000,0000	850,0000		
2	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	10,5205	58,5000
	Taco de madeira	0,0200	0,2900	900,0000	1340,0000		
3	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	7,9310	58,5000
	Vinil	0,0400	0,4000	1300,0000	960,0000		
4	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	23,0000	58,5000
	Cimento queimado	0,0200	1,1500	1950,0000	1000,0000		
5	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	14,0673	58,5000
	Madeira laminada	0,0090	0,2000	925,0000	2300,0000		
6	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	13,1179	207,1800
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Granito	0,0200	3,0000	2600,0000	840,0000		
7	Contrapiso	0,0300	1,1500	1950,0000	1000,0000	9,1391	60,5000
	Carpete	0,0050	0,0600	160,0000	2500,0000		
8	Laje	0,1000	1,7500	2300,0000	1000,0000	7,4051	410,5000
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Porcelanato	0,0100	1,2000	2000,0000	850,0000		
9	Laje	0,1000	1,7500	2300,0000	1000,0000	5,1106	417,6200
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Taco de madeira	0,0200	0,2900	900,0000	1340,0000		
10	Laje	0,1000	1,7500	2300,0000	1000,0000	5,4576	338,4200
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Vinil	0,0400	0,4000	1300,0000	960,0000		
11	Laje	0,1000	1,7500	2300,0000	1000,0000	9,9383	327,5000
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Cimento queimado	0,0200	1,1500	1950,0000	1000,0000		
12	Laje	0,1000	1,7500	2300,0000	1000,0000	7,7985	307,6475
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Madeira laminada	0,0090	0,2000	925,0000	2300,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U equivalente (W/m².K)	Ct equivalente (kJ/m².K)
13	Laje	0,1000	1,7500	2300,0000	1000,0000	7,4977	437,1800
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Granito	0,0200	3,0000	2600,0000	840,0000		
14	Laje	0,1000	1,7500	2300,0000	1000,0000	6,0037	290,5000
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Carpete	0,0050	0,0600	160,0000	2500,0000		
15	Laje	0,1000	1,7500	2300,0000	1000,0000	2,1350	411,0775
	Manta lã de vidro	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Porcelanato	0,0100	1,2000	2000,0000	850,0000		
16	Laje	0,1000	1,7500	2300,0000	1000,0000	2,0596	313,1975
	Manta termoacústica	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Taco de madeira	0,0200	0,2900	900,0000	1340,0000		
17	Laje	0,1000	1,7500	2300,0000	1000,0000	1,9359	289,0775
	Manta termoacústica	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Vinil	0,0400	0,4000	1300,0000	960,0000		
18	Laje	0,1000	1,7500	2300,0000	1000,0000	2,3044	328,0775
	Manta termoacústica	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Cimento queimado	0,0200	1,1500	1950,0000	1000,0000		
19	Laje	0,1000	1,7500	2300,0000	1000,0000	2,1666	308,2250
	Manta termoacústica	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Madeira laminada	0,0090	0,2000	925,0000	2300,0000		
20	Laje	0,1000	1,7500	2300,0000	1000,0000	2,1427	437,7575
	Manta termoacústica	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Argamassa Colante	0,0500	1,1500	2100,0000	1000,0000		
	Granito	0,0200	3,0000	2600,0000	840,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U equivalente (W/m².K)	Ct equivalente (kJ/m².K)
21	Laje	0,1000	1,7500	2300,0000	1000,0000	2,0004	291,0775
	Manta termoacústica	0,0150	0,0450	55,0000	700,0000		
	Contrapiso	0,0300	1,1500	1950,0000	1000,0000		
	Carpete	0,0050	0,0600	160,0000	2500,0000		

Fonte: autor.

A.3 Coberturas

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U equivalente (W/m².K)	Ct equivalente (kJ/m².K)
1	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,646	296,6000
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Caixa de ar	0,1500	-	-	-		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
2	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,918	247,4645
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Caixa de ar	0,200	-	-	-		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
3	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,017	204,2113
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Caixa de ar	0,200	-	-	-		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
4	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,796	315,0000
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Caixa de ar	0,200	-	-	-		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
5	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,013	265,8645
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Caixa de ar	0,1500	-	-	-		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
6	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,062	222,6113
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Caixa de ar	0,200	-	-	-		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
7	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,871	278,072
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Caixa de ar	0,200	-	-	-		
	Telha de fibrocimento	0,006	0,9500	1800,0000	840,0000		
8	Reboco	0,020	1,1500	1950,0000	1000,0000	3,061	228,936
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Caixa de ar	0,0200	-	-	-		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
9	Reboco	0,020	1,1500	1950,0000	1000,0000	2,084	185,683
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Caixa de ar	0,200					
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
10	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,084	296,620
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
11	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,547	247,485
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
12	Reboco	0,0200	1,1500	1950,0000	1000,0000	1,832	204,232
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
13	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,190	315,020
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
14	Reboco	0,2000	1,1500	1950,0000	1000,0000	2,619	265,885
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
15	Reboco	0,0200	1,1500	1950,0000	1000,0000	1,869	222,632
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Caixa de ar	0,1500	-	-	-		
16	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,243	278,092
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
17	Reboco	0,0200	1,1500	1950,0000	1000,0000	2,654	228,957
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
18	Reboco	0,0200	1,1500	1950,0000	1000,0000	1,887	185,704
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
19	Painel de gesso	0,0125	0,3500	875,0000	840,0000	4,247	36,7875
	Caixa de ar	0,200	-	-	-		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
20	Painel de gesso	0,0125	0,3500	875,0000	840,0000	4,452	55,1875
	Caixa de ar	0,200	-	-	-		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
21	Painel de gesso	0,0125	0,3500	875,0000	840,0000	4,555	22,988
	Caixa de ar	0,200	-	-	-		
	Telha de fibrocimento	0,0060	0,9500	2300,0000	1000,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m3)	c (J/kg.K)	U equivalente (W/m².K)	Ct equivalente (kJ/m².K)
22	Painel de gesso	0,0125	0,3500	875,0000	840,0000	3,503	36,8077
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
23	Painel de gesso	0,0125	0,3500	875,0000	840,0000	3,641	55,2077
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
24	Painel de gesso	0,0125	0,3500	875,0000	840,0000	3,710	18,280
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
25	Forro de PVC	0,0100	0,200	1300,0000	960,0000	3,359	247,079
	Caixa de ar	0,200	-	-	-		
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
26	Forro de PVC	0,0100	0,2000	1300,0000	960,0000	2,732	197,943
	Caixa de ar	0,200	-	-	-		
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
27	Forro de PVC	0,0100	0,2000	1300,0000	960,0000	1,926	154,690
	Caixa de ar	0,200	-	-	-		
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
28	Forro de PVC	0,0100	0,200	1300,0000	960,000	4,004	40,080
	Caixa de ar	0,200	-	-	-		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
29	Forro de PVC	0,0100	0,2000	1300,0000	960,000	4,185	58,480
	Caixa de ar	0,200	-	-	-		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
30	Forro de PVC	0,0100	0,2000	1300,0000	960,000	4,277	21,552
	Caixa de ar	0,200	-	-	-		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
31	Forro de PVC	0,0100	0,200	1300,0000	960,000	3,336	40,100
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
32	Forro de PVC	0,0100	0,200	1300,0000	960,0000	3,461	58,500
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
33	Forro de PVC	0,0100	0,200	1300,0000	960,000	3,523	21,572
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		
34	Forro de madeira	0,0050	0,1500	500,0000	1340,00	3,558	234,602
	Caixa de ar	0,200	-	-	-		
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
35	Forro de madeira	0,0050	0,1500	500,0000	1340,00	2,862	188,813
	Caixa de ar	0,200	-	-	-		
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
36	Forro de madeira	0,0050	0,1500	500,0000	1340,00	1,990	145,560
	Caixa de ar	0,200	-	-	-		
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
37	Forro de madeira	0,0050	0,1500	500,0000	1340,00	4,291	30,950
	Caixa de ar	0,200	-	-	-		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
38	Forro de madeira	0,0050	0,1500	500,0000	1340,00	4,499	49,350
	Caixa de ar	0,200	-	-	-		
	Telha de Concreto	0,0200	1,7500	2300,0000	1000,0000		
39	Forro de madeira	0,0050	0,1500	500,0000	1340,00	4,605	12,422
	Caixa de ar	0,200	-	-	-		
	Telha de fibrocimento	0,0060	0,9500	1800,0000	840,0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U equivalente (W/m ² .K)	Ct equivalente (kJ/m ² .K)
40	Forro de madeira	0,0050	0,1500	500,0000	1340,00	3,533	30,970
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,0400	12,0000	840,0000		
	Telha de cerâmica	0,0200	0,9000	1500,0000	920,0000		
41	Forro de madeira	0,0050	0,1500	500,0000	1340,00	3,673	49,370
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,002	0,040	12,000	840,000		
	Telha de Concreto	0,020	1,7500	2300,000	1000,000		
42	Forro de madeira	0,005	0,1500	500,000	1340,00	3,743	12,442
	Caixa de ar	0,200	-	-	-		
	Manta termoacústica	0,0020	0,040	12,000	840,000		
	Telha de fibrocimento	0,006	0,950	1800,000	840,000		
43	Painel de gesso	0,0125	0,3500	875,0000	840,0000	3,529	243,787
	Caixa de ar	0,200	-	-	-		
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
44	Painel de gesso	0,0125	0,3500	875,0000	840,0000	2,843	194,651
	Caixa de ar	0,200	-	-	-		
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,800		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
45	Painel de gesso	0,0125	0,3500	875,0000	840,0000	1,980	151,398
	Caixa de ar	0,200	-	-	-		
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
46	Reboco	0,0200	1,1500	1950,0000	1000,0000	11,418	273,599
	Laje de Concreto	0,1000	1,7500	2300,0000	1000,0000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
47	Reboco	0,0200	1,1500	1950,0000	1000,0000	6,411	224,463
	Laje treliçada de cerâmica	0,1200	0,9559	1629,7620	924,8000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		
48	Reboco	0,0200	1,1500	1950,0000	1000,0000	3,235	181,210
	Laje treliçada de EPS	0,1200	0,4305	1289,8000	889,1000		
	Impermeabilizante	0,0030	0,2300	1050,0000	1460,0000		

Fonte: autor.

APÊNDICE B – HIPERPARÂMETROS AJUSTADOS

	Hiperparâmetro	learning_rate	max_depth	subsample	coolsample_bytree	min_child_weight
ZB	Função	Representa a taxa de aprendizado de cada árvore.	Representa a profundidade máxima de cada árvore.	Representa a quantidade, em porcentagem, de amostras aleatorias presentes para treinar cada árvore.	Representa a quantidade, em porcentagem, de features a serem consideradas em cada árvore.	Representa o peso mínimo necessário para criar um novo nó,
ZB 1M	Edificação 1 CT	0,096	10	1,0	1,0	5
	Edificação 2 CT	0,088	10	0,8	1,0	3
	Edificação 1 GH	0,082	10	0,8	1,0	1
	Edificação 2 GH	0,092	10	0,8	0,9	3
ZB 2M	Edificação 1 CT	0,098	10	1,0	0,9	1
	Edificação 2 CT	0,099	10	0,8	1,0	3
	Edificação 1 GH	0,099	10	0,9	1,0	9
	Edificação 2 GH	0,073	5	1,0	0,7	4
ZB 6A	Edificação 1 CT	0,099	10	1,0	0,7	6
	Edificação 2 CT	0,098	10	0,8	0,8	1
	Edificação 1 GH	0,079	10	0,7	0,9	3
	Edificação 2 GH	0,098	10	1,0	0,9	2

Fonte: autor.