

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

Otimização multiobjetivo para seleção de materiais de construção

Alemilson Fabiano Silva

JUIZ DE FORA
JANEIRO, 2026

Otimização multiobjetivo para seleção de materiais de construção

ALEMILSON FABIANO SILVA

Universidade Federal de Juiz de Fora

Instituto de Ciências Exatas

Departamento de ciência da computação

Bacharelado em Ciência Da Computação

Orientadora: Luciana Conceição Dias Campos

Coorientadora: Júlia Castro Mendes

Coorientador: Vitor Freitas Mendes

JUIZ DE FORA

JANEIRO, 2026

OTIMIZAÇÃO MULTIOBJETIVO PARA SELEÇÃO DE MATERIAIS DE CONSTRUÇÃO

Alemilson Fabiano Silva

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS
EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE INTE-
GRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE
BACHAREL EM CIÊNCIA DA COMPUTAÇÃO.

Aprovada por:

Luciana Conceição Dias Campos
Doutora em Engenharia Elétrica (PUC-Rio)

Júlia Castro Mendes
Doutora em Engenharia Civil (UFOP)

Vitor Freitas Mendes
Mestre em Engenharia Civil (UFOP)

Carlos Cristiano Hasenclever Borges
Doutor em Engenharia Civil (UFRJ)

Bruno Henriques Dias
Doutor em Engenharia Elétrica (PUC-Rio)

JUIZ DE FORA

22 DE JANEIRO, 2026

*Dedico esse trabalho aos meus pais por todo
apoio e incentivo.*

Resumo

A indústria da construção civil é um dos maiores contribuintes para às emissões de gases de efeito estufa (GEE) e consumo de recursos naturais. A seleção de materiais de construção é uma etapa crucial no ciclo de vida de uma edificação, impactando diretamente seu custo, desempenho energético e pegada de carbono. Este trabalho desenvolveu uma abordagem integrada para apoiar a seleção de sistemas construtivos com base em desempenho térmico, custo e emissões de CO₂ equivalente, combinando aprendizado de máquina e otimização multiobjetivo. A abordagem proposta visa simular combinações construtivas no EnergyPlus para alimentar um metamodelo baseado em XGBoost, o qual é integrado a um processo de otimização multiobjetivo via R-NSGA-III. Dessa forma, busca-se identificar as melhores combinações de sistemas de paredes, pisos e coberturas, considerando diferentes preferências de avaliação e compromisso entre os objetivos analisados. A utilização dos metamodelos permitiu avaliar mais de 28.224 combinações de paredes, pisos e coberturas. Foram considerados dois cenários de uso. No Cenário 1, 80% dos pesos foram atribuídos às métricas de conforto térmico. Já no Cenário 2, a priorização foi direcionada ao custo (40%) e ao consumo energético (35%). No Cenário 1, as soluções obtidas reduziram o desconforto térmico em até 17% e ampliaram em 7% as métricas associadas ao conforto, em comparação ao espaço amostral. No Cenário 2, observou-se maior convergência das soluções, com reduções no consumo energético entre 140 kWh e 180 kWh, considerando um consumo anual de referência de aproximadamente 2000 kWh. A análise de recorrência indicou padrões distintos entre os climas: maior variabilidade em Belém, convergência moderada em São Paulo e forte repetição em Curitiba. Conclui-se que a ferramenta proposta é promissora para apoiar decisões construtivas considerando cenários atuais e futuros, tornando análises complexas mais rápidas, acessíveis e alinhadas às demandas climáticas brasileiras.

Palavras-chave: Otimização multiobjetivo, seleção de materiais de construção, EnergyPlus, aprendizado de máquina, eficiência energética, mudanças climáticas.

Abstract

The construction industry is one of the largest contributors to greenhouse gas (GHG) emissions and natural resource consumption. The selection of building materials is a crucial step in the life cycle of a building, directly impacting its cost, energy performance, and carbon footprint. This work developed an integrated approach to support the selection of building systems based on thermal performance, cost, and CO₂ equivalent emissions, combining machine learning and multi-objective optimization. The proposed approach aims to simulate construction combinations in EnergyPlus to feed an XGBoost-based metamodel, which is integrated into a multi-objective optimization process via R-NSGA-III. In this way, the goal is to identify the best combinations of wall, floor, and roof systems, considering different evaluation preferences and trade-offs between the analyzed objectives. The use of metamodels allowed the evaluation of more than 28,224 combinations of walls, floors, and roofs. Two usage scenarios were considered. In Scenario 1, 80% of the weights were assigned to thermal comfort metrics. In Scenario 2, prioritization was directed towards cost (40%) and energy consumption (35%). In Scenario 1, the solutions obtained reduced thermal discomfort by up to 17% and increased comfort-related metrics by 7%, compared to the sample area. In Scenario 2, greater convergence of solutions was observed, with reductions in energy consumption between 140 kWh and 180 kWh, considering an annual reference consumption of approximately 2000 kWh. The recurrence analysis indicated distinct patterns between climates: greater variability in Belém, moderate convergence in São Paulo, and strong repetition in Curitiba. It is concluded that the proposed tool is promising for supporting constructive decisions considering current and future scenarios, making complex analyses faster, more accessible, and aligned with Brazilian climate demands.

Keywords: Multi-objective optimization, selection of building materials, EnergyPlus, machine learning, energy efficiency, climate change.

Agradecimentos

Agradeço profundamente a Deus, cuja presença sempre iluminou meu caminho. Expresso minha gratidão aos meus pais, Ivair e Maria, por todo apoio, incentivo, dedicação e confiança durante essa jornada acadêmica. À minha família, por todo incentivo e apoio.

Aos meus amigos que estiveram ao meu lado, pelas conversas, pelo companheirismo, pelo conhecimento compartilhado

Às minhas orientadoras, Júlia e Luciana, e ao meu coorientador, Vitor, deixo um agradecimento sincero pela orientação, pelo conhecimento, pelos conselhos e pela paciência.

Registro também minha gratidão ao Grupo de Pesquisa em Ciências de Dados Aplicadas à Engenharia (CIDENG - CNPq), pelos incentivos, ambiente de aprendizado e colaboração, e à Universidade Federal de Juiz de Fora, pela oportunidade de crescimento acadêmico e pessoal.

Por fim, agradeço o apoio das agências de fomento - CNPq, FINEP e FAPEMIG, cujo investimento e incentivo à pesquisa científica tornaram possível a realização deste estudo.

*“Não importa o quão profunda seja a noite,
no dia seguinte o sol irá brilhar nova-
mente”.*

Brook (One Piece)

Conteúdo

Lista de Figuras	8
Lista de Tabelas	9
Lista de Abreviações	10
1 Introdução	12
1.1 Objetivo geral	15
1.1.1 Objetivos específicos	15
2 Fundamentação Teórica	16
2.1 Avaliação Termoeenergética	16
2.1.1 Conceitos Fundamentais	16
2.1.2 Envoltória da Edificação	18
2.1.3 Métodos de avaliação por simulação energética	20
2.2 Aprendizado de Máquina	28
2.2.1 Aprendizado Não Supervisionado	30
2.2.2 Aprendizado Supervisionado	31
2.2.3 Árvores de Decisão	35
2.2.4 Extreme Gradient Boosting (XGBoost)	37
2.3 Otimização	39
2.3.1 Otimização multiobjetivo	42
2.3.2 Métricas de avaliação de desempenho em otimização multiobjetivo .	43
2.3.3 Otimização multiobjetivo baseada em pontos de referência	46
2.3.4 Estado da Arte	49
3 Abordagem Proposta	51
3.1 Sistemas Construtivos	55
3.2 Edificação e Climats Analisados	58
3.3 Modelo Substituto para Avaliação do Desempenho Térmico	59
3.4 Otimização Multiobjetivo	62
3.4.1 Seleção da representação dos indivíduos	63
3.4.2 Preferências do(a) usuário(a) e seleção da melhor combinação cons- trutiva	66
3.5 Análise dos Resultados	68
4 Experimentos e Resultados	70
4.1 Definição do melhor tipo de representação	70
4.2 Análise das melhores soluções	71
4.2.1 Análise de valores das melhores combinações	71
4.2.2 Análise de recorrência das melhores combinações	73
4.3 Melhores sistemas construtivos	77
5 Conclusão	90

A	Lista de materiais dos sistemas construtivos	93
A.1	Paredes	93
A.2	Pisos	96
A.3	Cobertura	99
B	Tabelas de calibração de hiperparâmetros	112
B.1	<i>Random search</i> na representação discreta	112
B.2	<i>Random search</i> na representação binária	113
B.3	<i>Random search</i> na representação <i>Gray Code</i>	115
	Bibliografia	117

Lista de Figuras

2.1	Fluxo de calor proveniente da radiação solar que incide em uma parede (esquerda) e uma janela (direita)	18
2.2	Esquema de funcionamento de Carga Térmica CT	22
2.3	Esquema de funcionamento de Graus-Hora (GH)	23
2.4	Método de Autonomia Térmica (AT)	25
2.5	Método de Resiliência Térmica (RT)	27
2.6	Banco de dados dividido em subconjuntos de treino e teste por meio do método k-fold para k=5	33
2.7	Exemplo de árvore de decisão para regressão. Os nós de decisão exibem a regra de divisão e uma métrica de erro (MSE); as folhas apresentam a previsão média \hat{y} e o número de amostras n	36
2.8	Esquema conceitual do funcionamento do XGBoost.	37
2.9	Fluxo de um Algoritmo Genético.	41
2.10	Método integrado	48
3.1	Fluxograma geral da metodologia da pesquisa	51
3.2	Dispersão dos sistemas construtivos por custo e emissão de CO ₂	56
3.3	Dispersão dos sistemas construtivos por resistência térmica (R) e capacidade térmica (Ct)	57
3.4	HIS 1 – Esquerda: maquete 3D. Meio: maquete humanizada. Direita: planta baixa.	58
3.5	Fluxo da etapa de avaliação por múltiplas soluções.	69
4.1	Melhores combinações no Cenário 1 com frequência maior ou igual a 2 para cada clima. Tons mais escuros representam maior frequência de seleção dos sistemas.	75
4.2	Melhores combinações no Cenário 2 com frequência maior ou igual a 2 para cada clima. Tons mais escuros representam maior frequência de seleção dos sistemas.	76
4.3	Materiais recorrentes para Curitiba. Tons mais escuros representam maior frequência de seleção dos sistemas.	78
4.4	Materiais recorrentes para São Paulo. Tons mais escuros representam maior frequência de seleção dos sistemas.	80
4.5	Materiais recorrentes para Belém. Tons mais escuros representam maior frequência de seleção dos sistemas.	82
4.6	Materiais recorrentes para Curitiba. Tons mais escuros representam maior frequência de seleção dos sistemas.	84
4.7	Materiais recorrentes para São Paulo. Tons mais escuros representam maior frequência de seleção dos sistemas.	87
4.8	Materiais recorrentes para Belém. Tons mais escuros representam maior frequência de seleção dos sistemas.	88

Lista de Tabelas

2.1	Propriedades termofísicas	19
3.1	Exemplos de sistemas construtivos analisados	55
3.2	Estatísticas dos parâmetros utilizados nas análises	57
3.3	Modelos de aprendizado de máquina desenvolvidos	59
3.4	Comparativo de desempenho dos modelos desenvolvidos por (OLIVEIRA, 2025) e neste trabalho	61
3.5	Pesos usados nos cenários de otimização multiobjetivo	67
4.1	Comparação das três representações segundo HV, IGD ⁺ e <i>Spacing</i> (10 execuções).	70
4.2	Comparação estatística entre soluções otimizadas e espaço amostral	71
4.3	Estatísticas do custo total (R\$) por localização: mínimo, mediana e máximo	76
4.4	Estatísticas das emissões totais de CO ₂ (kgCO ₂): mínimo, mediana e máximo	76
4.5	Melhores combinações por localização e cenário: custo total e emissões totais de CO ₂	77
A.1	Materiais e propriedades térmicas equivalentes dos sistemas de paredes . .	93
A.2	Materiais e propriedades térmicas equivalentes dos sistemas de pisos . . .	97
A.3	Materiais e propriedades térmicas equivalentes dos sistemas de cobertura .	99
B.1	Configurações gerais utilizadas no random search para a representação discreta.	112
B.2	Faixas de hiperparâmetros obtidas pelo <i>random search</i> (representação discreta).	112
B.3	Melhor conjunto de hiperparâmetros obtido pelo <i>Optuna</i> (representação discreta).	113
B.4	Configurações gerais utilizadas no <i>random search</i> para a representação binária.	113
B.5	Faixas de hiperparâmetros obtidas pelo <i>random search</i> (representação binária).114	
B.6	Melhor conjunto de hiperparâmetros obtido pelo <i>Optuna</i> (representação binária).	114
B.7	Configurações gerais utilizadas no <i>random search</i> para a representação <i>Gray Code</i>	115
B.8	Faixas de hiperparâmetros obtidas pelo <i>random search</i> (representação <i>Gray Code</i>).	115
B.9	Melhor conjunto de hiperparâmetros obtido pelo <i>Optuna</i> (representação <i>Gray Code</i>).	116

Lista de Abreviações

DCC	Departamento de Ciência da Computação
UFJF	Universidade Federal de Juiz de Fora
CIDENG	Grupo de Pesquisa em Ciências de Dados Aplicadas à Engenharia
ABNT	Associação Brasileira de Normas Técnicas
CT	Carga Térmica
CTa	Carga Térmica de Aquecimento
CTr	Carga Térmica de Resfriamento
GH	Graus Hora
GHa	Graus Hora de Aquecimento
GHr	Graus Hora de Resfriamento
AT	Autonomia Térmica
RT	Resiliência Térmica
AVAC	Aquecimento, Ventilação e Ar Condicionado
CO ₂	Dióxido de Carbono
IA	Inteligência Artificial
IGD+	<i>Inverted Generational Distance Plus</i>
HV	Hypervolume
R ²	Coefficiente de Determinação
RMSE	<i>Root Mean Squared Error</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
ML	<i>Machine Learning</i>
R	Resistência Térmica
U	Transmitância Térmica
Ct	Capacidade térmica
XGBoost	<i>Extreme Gradient Boosting</i>

AG	Algoritmo Genético
MOPS	<i>Multi-Optimization Problems</i>
EMO	<i>Multi-objective Evolutionary Optimization</i>
ZB	Zona Bioclimática

1 Introdução

Globalmente, o setor de edificações consome cerca de 30% de toda a energia final e é um dos principais emissores de gases de efeito estufa, destacando sua importância nas agendas de mitigação climática (UN Environment Programme; Global Alliance for Buildings and Construction (GlobalABC), 2023). A diversidade climática, agravada pelas mudanças ambientais, torna essencial a compreensão sobre como as construções se comportam em diferentes contextos climáticos, como é o caso do Brasil (KRELLING et al., 2024).

Projetar edificações que conciliem desempenho térmico e sustentabilidade, torna-se, portanto, uma prioridade estratégica tanto para o setor público quanto para o privado. O conforto térmico refere-se à percepção subjetiva de bem-estar dos ocupantes diante das condições ambientais internas (ABNT, 2024a). Por sua vez, desempenho térmico costuma ser tratado como a capacidade da edificação manter condições internas estáveis e agradáveis, independentemente das variações climáticas externas, sendo um parâmetro objetivo (ABNT, 2024b). Quando o conforto térmico é alcançado com baixo consumo de energia, obtém-se a eficiência energética, que se configura como um dos pilares da sustentabilidade no setor da construção civil (LAMBERTS et al., 2016).

Historicamente, a escolha de materiais de construção tem sido pautada por critérios econômicos, disponibilidade e tradição de uso, deixando em segundo plano aspectos como a questão térmica e o impacto ambiental. Essa abordagem, entretanto, mostra-se insustentável diante dos desafios contemporâneos impostos pelas mudanças climáticas. Projeções climáticas indicam o aumento da frequência e intensidade de eventos extremos, como ondas de calor e variações bruscas de temperatura, que representam um desafio significativo para o setor da construção civil (NTC Brasil, 2025). Nesse contexto, torna-se indispensável considerar o conceito de resiliência térmica no processo de concepção da edificação. A resiliência térmica é entendida como a capacidade das edificações de manter condições adequadas de habitabilidade, conforto e desempenho energético mesmo sob cenários climáticos futuros mais severos (IFSC Verifica, 2024).

O desempenho térmico e energético das edificações pode ser avaliado por dife-

rentes métricas, cada uma capturando aspectos complementares do desempenho térmico. Neste trabalho, são adotados quatro indicadores amplamente utilizados na literatura: a Carga Térmica (CT), associada ao consumo energético necessário para manter condições internas de conforto por meio de sistemas de climatização; os Graus Hora (GH), que quantificam a intensidade do desconforto térmico em condições de ventilação natural; a Autonomia Térmica (AT), que expressa a frequência com que a edificação permanece dentro da faixa de conforto sem o uso de sistemas ativos; e a Resiliência Térmica (RT), voltada à avaliação do desempenho da edificação sob condições climáticas extremas. O uso conjunto desses indicadores permite uma análise mais abrangente e representativa do desempenho térmico da envoltória.

Para isso, softwares de simulação energética, como o EnergyPlus, são amplamente utilizados para avaliar o comportamento térmico e energético das edificações em cenários presentes e futuros, em diferentes localizações e climas, considerando tanto as condições atuais quanto projeções futuras e as características específicas de cada projeto (OLIVEIRA, 2025). O EnergyPlus é um software de simulação termoenergética de edificações que utiliza como dados de entrada a geometria do edifício, propriedades termofísicas dos materiais, padrões de ocupação, cargas internas e arquivos climáticos específicos da localidade. A partir dessas informações, a ferramenta simula, em regime horário, o comportamento térmico das zonas internas e o consumo energético associado aos sistemas de climatização, permitindo avaliar o desempenho térmico e energético ao longo do tempo (U.S. Department of Energy, 2025). Entretanto, apesar de sua alta precisão, as simulações completas apresentam elevado custo computacional e tempo de processamento, especialmente quando aplicadas a problemas de larga escala que envolvem múltiplas combinações de materiais e configurações construtivas (MENDES, 2023).

Por essa razão, o uso de novas técnicas, surgem como uma alternativa viável para reduzir o tempo de análise, permitindo obter resultados com boa precisão. A inteligência artificial (IA) pode ser definida como o campo da ciência da computação que desenvolve sistemas capazes de executar tarefas que normalmente exigiriam raciocínio, percepção e aprendizado humano. Dentro desse campo, o aprendizado de máquina (*Machine Learning* – ML) é um subconjunto que permite que algoritmos aprendam automaticamente a partir

de dados, reconhecendo padrões e realizando previsões sem a necessidade de programação explícita (FACELI et al., 2011). No contexto da análise termoenergética de edificações, o ML pode ser utilizado para prever o desempenho térmico de diferentes soluções construtivas com base em dados simulados ou experimentais, reduzindo o tempo e o custo de análises complexas (OLIVEIRA, 2025; BAQER; RASHIDI-KHAZAEI, 2025; LI et al., 2025).

Por sua vez, a otimização multiobjetivo é uma abordagem matemática voltada para a resolução de problemas em que se busca equilibrar simultaneamente múltiplos critérios conflitantes (VESIKAR; DEB; BLANK, 2018). Aplicada à análise térmica de edificações, essa técnica permite identificar soluções de compromisso que conciliam desempenho térmico adequado e eficiência energética com viabilidade econômica e sustentabilidade ambiental, apoiando o processo decisório de projetistas e pesquisadores(as) (CURY; ALVES; ALVES, 2024; ROKA et al., 2024; ROKA et al., 2025).

Com base nesse cenário, este trabalho propõe o desenvolvimento de um modelo de otimização multiobjetivo, integrado a modelos preditivos de aprendizado de máquina, aplicado à seleção de materiais de envoltória (pisos, paredes e cobertura) em edificações residenciais. O método visa integrar o uso de técnicas de otimização multiobjetivo com modelos de ML, possibilitando identificar soluções de compromisso entre critérios conflitantes: custo, desempenho térmico e impacto ambiental. Diferentemente de abordagens convencionais, que geralmente consideram apenas um ou dois indicadores térmicos, este trabalho adota uma análise multimétrica, incorporando simultaneamente quatro métricas relevantes para a avaliação do desempenho passivo da edificação: CT, GH, AT e RT. A integração conjunta dessas métricas constitui uma contribuição inovadora do estudo, permitindo uma caracterização mais completa e realista do comportamento térmico da envoltória em cenários presentes e futuros. Além disso, o modelo proposto é orientado por preferências, permitindo que o usuário(a) (por exemplo, arquiteto(a) ou engenheiro(a)) direcione a busca para regiões específicas das soluções ótimas, conforme suas prioridades de projeto. Dessa forma, o processo de otimização se torna interativo e mais alinhado à prática profissional, fornecendo respostas personalizadas que conciliam desempenho e viabilidade econômica.

1.1 Objetivo geral

Desenvolver e avaliar uma abordagem integrada baseada em metamodelos preditivos e otimização multiobjetivo para aprimorar a análise do desempenho térmico e energético de edificações, incluindo também aspectos de custo e impacto ambiental.

1.1.1 Objetivos específicos

Os objetivos específicos deste estudo são:

1. Determinar a viabilidade de um método de otimização multiobjetivo orientado por preferências capaz de explorar de forma eficiente os *trade offs* entre critérios de projeto relacionados ao desempenho térmico, energético, econômico e ambiental.
2. Investigar o impacto da otimização de parâmetros do algoritmo evolutivo para três formas distintas de representação da solução, discreta, binária e *Gray code* avaliando como essas escolhas influenciam a convergência, a diversidade e a qualidade final do conjunto de soluções.
3. Analisar e comparar o impacto das diferentes condições climáticas sobre o desempenho térmico, energético e a seleção ótima de sistemas construtivos, identificando padrões de recorrência, *trade offs* e estratégias de projeto mais adequadas para cada contexto climático.

2 Fundamentação Teórica

Aqui serão apresentados os principais fundamentos teóricos que sustentam este trabalho. Inicialmente, discutem-se os conceitos essenciais de avaliação termoenergética, estabelecendo definições, indicadores e métodos de cálculo relevantes ao desempenho térmico e energético. Na sequência, introduzem-se conceitos de aprendizado de máquina pertinentes ao estudo, com ênfase em modelos e procedimentos de treinamento/validação aplicáveis ao problema. Por fim, são expostos os princípios de otimização multiobjetivo, destacando a modelagem de funções-objetivo e restrições, bem como os critérios de Pareto, culminando na aplicação de um Algoritmo Genético como estratégia de busca para a solução do problema proposto.

2.1 Avaliação Termoenergética

2.1.1 Conceitos Fundamentais

O conforto térmico se refere à condição subjetiva de satisfação de um indivíduo em relação às condições climáticas do ambiente ao seu redor (LAMBERTS et al., 2016). Segundo Lamberts et al. (2016), as variáveis que condicionam o conforto térmico são classificadas em dois grupos principais:

1. Ambientais: como temperatura do ar, velocidade do vento, umidade relativa do ar, radiação solar, entre outros fatores físicos que atuam diretamente sobre o corpo humano.
2. Humanas: como nível de atividade metabólica, a resistência térmica das vestimentas, bem como características fisiológicas individuais, tais como sexo, idade, raça e estado de saúde.

O desempenho térmico, por sua vez, refere-se a uma característica objetiva e quantificável da edificação, representando sua capacidade de manter condições internas estáveis e agradáveis, independentemente das variações climáticas externas (ABNT,

2024b). Segundo ABNT (2024a), entre os principais fatores que influenciam o desempenho térmico estão:

1. Características construtivas: propriedades termofísicas da vedação, aberturas para ventilação, pé-direito¹, orientação solar e *layout*.
2. Características externas: incidência solar, umidade, topografia, poluição atmosférica, amplitude térmica, sombreamento, vegetação, urbanização e clima.
3. Fontes de calor: ocupação e aparelhos emissores de calor.

Por fim, eficiência energética é a capacidade da edificação entregar o desempenho e as funcionalidades requeridas com o menor consumo possível de energia (LAMBERTS; DUTRA; PEREIRA, 2014). Na prática, envolve estratégias de projeto e operação que reduzem custos e impactos ambientais, como adotar um projeto bioclimático integrado (orientação, *layout*, aberturas, ventilação e proteção solar), minimizar as cargas térmicas associadas às trocas de calor pela envoltória da edificação, especificar equipamentos e controles eficientes (BALARAS, 2021).

No âmbito da eficiência energética, são empregadas duas categorias principais de estratégias para controle climático: passivas e ativas. Estratégias passivas não gastam energia, são baseadas em projeto arquitetônico e ciência dos materiais, operam em harmonia com o clima local para reduzir a necessidade de intervenção mecânica (SADINENI; MADALA; BOEHM, 2011). Como exemplo, podem-se citar Gosain (2025) a orientação do edifício para controle de ganhos solares em regiões frias; o uso de inércia térmica (ex. concreto ou rocha) para absorver e liberar calor vagarosamente no ambiente; adotar altos níveis de isolamento na envoltória, a fim de tornar o interior mais independente do exterior; usar envidraçamentos de alto desempenho para modular o ganho de calor por radiação solar; e promover a ventilação natural efetiva para resfriar os ambientes.

Já as estratégias ativas empregam sistemas mecânicos e elétricos para gerenciar o ambiente interno, incluindo, por exemplo (GOSAIN, 2025): os sistemas de aquecimento, ventilação e ar-condicionado (AVAC); os controles e automação predial inteligentes para

¹Pé-direito: Distância vertical livre entre o piso acabado e a face inferior do teto (ou forro) de um compartimento.

regular o uso de energia de forma eficiente e manter as condições de conforto térmico; os sensores de presença ou ocupação para modular a iluminação e a temperatura; e as tecnologias de recuperação de energia, visando tratar a carga térmica remanescente com maior eficiência.

2.1.2 Envoltória da Edificação

Um dos principais fatores que influenciam o desempenho térmico das edificações é a envoltória (ou sistema de vedação), composta por pisos, paredes, coberturas e esquadrias (portas e janelas) (RIBAS, 2007). Como pode ser visto na Figura 2.1, esses elementos são responsáveis por controlar o fluxo de calor entre o ambiente interno e externo (ou o inverso) por condução, convecção e radiação térmica (LAMBERTS; DUTRA; PEREIRA, 2014). O bom desempenho da vedação da edificação contribui para manter o conforto térmico dos ocupantes e reduz a dependência de sistemas artificiais de climatização, melhorando a eficiência energética da construção (BACHRUN; ZHEN; GANI, 2019).

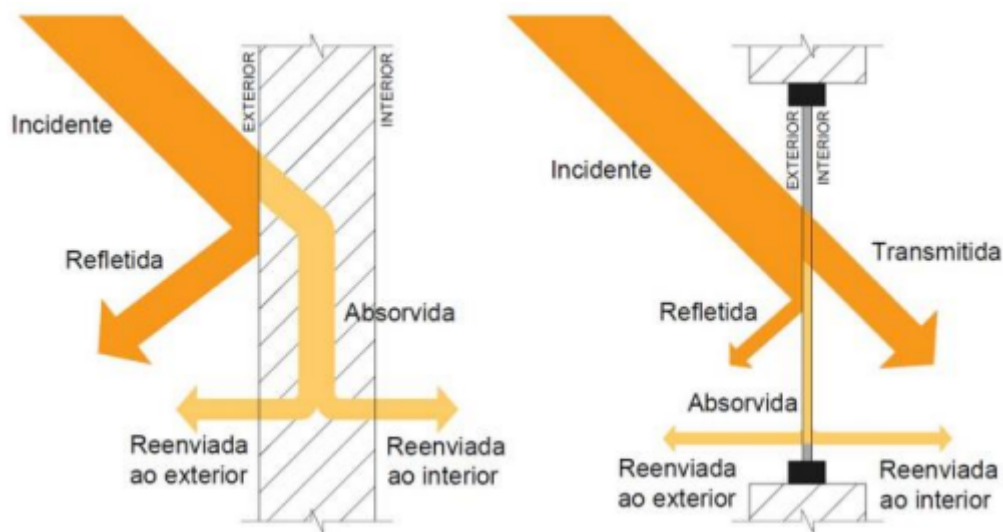


Figura 2.1: Fluxo de calor proveniente da radiação solar que incide em uma parede (esquerda) e uma janela (direita)

Fonte: (MENDES, 2021).

Nos elementos opacos da envoltória (paredes, pisos e coberturas), que não permitem a passagem direta de luz, o mecanismo dominante de troca térmica é a condução, acionada pela diferença entre as temperaturas interna e externa (LAMBERTS; DUTRA; PEREIRA, 2014). Já nos translúcidos (ex. janelas, fachadas de vidro e claraboias), que

permitem a entrada de luz, podem ocorrer trocas térmicas por condução e convecção, mas, principalmente, por radiação (LAMBERTS; DUTRA; PEREIRA, 2014).

As propriedades termofísicas dos materiais que compõem o sistema de vedação exercem influência significativa sobre esse fluxo de calor e, conseqüentemente, no desempenho térmico da edificação (ALMEIDA; BRASILEIRO; SILVOSO, 2018). Sua magnitude decorre de uma combinação complexa e inter-relacionada desses parâmetros, como condutividade, capacidade térmica e massa específica, ao longo das camadas (MENDES, 2023). A Tabela 2.1 apresenta as definições e efeitos das principais propriedades termofísicas dos materiais. Neste trabalho, o foco será sobre a transmitância térmica (U), e a capacidade térmica (C_t), que sintetiza grande parte da colaboração dos sistemas opacos do fechamento o desempenho térmico da edificação (ABNT, 2024b).

Tabela 2.1: Propriedades termofísicas

Propriedade	Definição	Efeito na edificação em dias quentes	Efeito na edificação em dias frios
Calor específico (c) [kJ/(kg·K)]	Facilidade do material em se aquecer ou resfriar quando recebe ou perde energia (INCROPERA et al., 2008). Sendo Q a quantidade de calor, m a massa e ΔT a variação de temperatura: $c = \frac{Q}{m \cdot \Delta T}$.	Alto c absorve mais energia até aquecerem, atrasando picos de temperatura interna. Porém, o material, uma vez aquecido, pode demorar a resfriar.	Alto c pode ajudar a reter calor interno por mais tempo, reduzindo variações bruscas de temperatura e tornando o ambiente mais estável.
Massa específica (ρ) [kg/m ³]	Relação entre a massa m e o volume V de um material: $\rho = \frac{m}{V}$.	Alta ρ tende a aumentar a capacidade térmica dos sistema (propriedade definida a seguir).	
Espessura (e) [m]	Dimensão associada à profundidade do elemento no que tange à transmissão de calor.	A e influencia na capacidade térmica, resistência térmica e transmitância térmica (propriedades definidas a seguir).	

Propriedade	Definição	Efeito na edificação em dias quentes	Efeito na edificação em dias frios
Capacidade térmica (C_t) [J/(m ² ·K)]	Potencial do elemento em variar sua temperatura frente a um aporte de calor (ABNT, 2024b). Para uma camada homogênea: $C_t = e \cdot \rho \cdot c$.	Alta C_t ajuda a retardar variações bruscas de temperatura, mas pode acumular calor excessivo em regiões de baixa amplitude térmica diária (quentes durante o dia e quentes durante a noite).	Alta C_t funciona como “reservatório” de calor, evitando oscilações bruscas de temperatura e mantendo o ambiente aquecido por mais tempo. Isso é especialmente útil em regiões de alta amplitude térmica diária (quentes durante o dia e frios durante a noite).
Resistência térmica (R) [(m ² ·K)/W]	Capacidade do elemento em reduzir a troca de calor por condução. Para camada homogênea: $R = \frac{e}{\lambda}$.	Alta R inibe a entrada de calor, evitando o superaquecimento da edificação.	Alta R impede a saída de calor, ajudando a manter o ambiente interno aquecido.
Transmitância térmica (U) [W/(m ² ·K)]	Taxa de transferência de calor induzida por diferença de temperatura entre superfícies (ABNT, 2024b). Para elementos planos: $U = \frac{1}{R}$.	Baixa U contribui para impedir a entrada de calor do exterior para o interior a edificação.	Baixa U contribui para reter calor na edificação.

Fonte: (MENDES, 2023), adaptado.

2.1.3 Métodos de avaliação por simulação energética

Os softwares de simulação computacional possibilitam a análise do desempenho termoe-nergético das edificações. Entre eles, o EnergyPlus destaca-se como o software gratuito mais amplamente utilizado no mundo (MENDES et al., 2024). Desenvolvido pelo De-partamento de Energia dos Estados Unidos, o programa tem como objetivo estimar as trocas térmicas, os níveis de iluminação e o consumo energético das edificações modeladas (LAMBERTS et al., 2010). Dessa forma, é possível realizar simulações para diferentes tipologias construtivas a partir da modelagem tridimensional do edifício, considerando

ainda as condições bioclimáticas locais por meio de arquivos meteorológicos específicos de cada cidade.

As simulações no EnergyPlus são realizadas através de arquivos de entrada previamente configurados com os parâmetros físicos e operacionais, como as propriedades dos sistemas construtivos, especificação das aberturas para ventilação natural (janelas e portas), o modelo geométrico da edificação, os padrões de ocupação, as condições de sombreamento, a divisão em zonas térmicas, configurações do sistemas de aquecimento, ventilação e ar-Condicionado (AVAC) entre outros fatores que influenciam o desempenho energético (EnergyPlus, 2025). O EnergyPlus possui diversas variáveis de saída, e cada método de avaliação possui *outputs* distintos. Dentre esses métodos, quatro se destacam: Carga Térmica (CT), Graus-hora (GH), Autonomia Térmica (AT) e Resiliência Térmica (RT).

O método da Carga Térmica (CT) mede a energia consumida pelo sistema AVAC para controle climático ativo da temperatura interna da edificação. Para isso é preciso definir os *setpoints* (temperaturas em que os(as) usuários(as) ligam ar condicionado ou aquecedor) de temperatura do sistema de AVAC, a partir de recomendações de normas ou preferências locais. Esses *setpoints* podem ser definidos pelo(a) usuário(a), pelos(as) projetistas ou por normas. Sempre que a temperatura interna excede o limite superior ou cai abaixo do inferior, o sistema AVAC é acionado para resfriar ou aquecer o ambiente e mantê-lo dentro da faixa estipulada. Assim, quanto menor a energia requerida para manter a temperatura no intervalo-alvo, menor o CT, melhor o desempenho térmico e maior a eficiência energética da edificação (HOYT; ARENS; ZHANG, 2015; WU et al., 2023). A Figura 2.2 apresenta um exemplo de aplicação do método. O intervalo *setpoint* foi configurado entre 21°C e 23°C , e as colunas em vermelho e azul, representam, respectivamente, a carga térmica de aquecimento (CTa) e de resfriamento (CTr), que se acumulam ao longo do ano de referência, somando toda vez que o aquecedor ou o ar condicionado são colocados em funcionamento.




Figura 2.2: Esquema de funcionamento de Carga Térmica CT

Fonte: (MENDES et al., 2024).

No geral, os estudos consideram *ambientes de longa permanência* da edificação (como quartos, salas) ao longo de um *ano de referência*, de modo a abranger todas as estações do ano, mantendo as janelas e portas permanentemente fechadas (somente com a infiltração do ar entre as frestas) (MENDES, 2023). Naturalmente, essa métrica exige que a edificação seja projetada com um sistema AVAC em mente. O cálculo do método segue a equação (2.1), que soma as cargas térmicas anuais de aquecimento e de resfriamento:

$$CT_{\text{total}} = \sum_{\text{ano de referência}} (CT_a + CT_r) \quad (2.1)$$

onde:

- CT_{total} é a soma das cargas térmicas de aquecimento e de resfriamento ao longo de um ano;
- CT_a é a carga térmica de aquecimento;
- CT_r é a carga térmica de resfriamento.

O método Graus-Hora (GH) considera o uso da ventilação natural como estratégia passiva de resfriamento no controle climático interno (sem uso do sistema AVAC). Ele

acumula a diferença entre a temperatura interna e os limites de conforto térmico (temperaturas operativas de referência) (MENDES et al., 2024). O Graus-Hora de aquecimento (GHa) se refere a uma necessidade de aquecer o ambiente, correspondendo à soma das diferenças entre a temperatura de conforto inferior e a temperatura interna sempre que esta se encontra abaixo do limite. Já o Graus-Hora de resfriamento (GHr) se refere à necessidade de resfriar o espaço, sendo obtido a partir das diferenças entre a temperatura interna e a temperatura de conforto superior quando o limite é excedido. Mais uma vez, os limites dos intervalos de conforto são definidos com base em normas locais ou conforme a convenção adotada pela equipe de pesquisa (MENDES et al., 2024). O GH também se dá pela análise do período de um ano, e também em ambientes de longa permanência.

A Figura 2.3 apresenta um exemplo de aplicação do método GH para um intervalo de temperatura entre 18°C e 26°C . e a equação (2.2) apresenta a sua formulação matemática. Assim como no CT, quanto menor o valor da métrica (GH, no caso), melhor o desempenho da edificação.




Figura 2.3: Esquema de funcionamento de Graus-Hora (GH)

Fonte: (MENDES et al., 2024).

$$GH = \sum_{\text{ano ref.}} \left[\max(0, T_o - T_{\max, \text{base}}) + \max(0, T_{\min, \text{base}} - T_o) \right]. \quad (2.2)$$

onde:

- GH : Graus hora ($^{\circ}\text{C}\cdot h$);
- GH_r : Graus hora de calor ($^{\circ}\text{C}\cdot h$);
- GH_a : Graus hora de frio ($^{\circ}\text{C}\cdot h$);
- T_o : temperatura operativa interna ($^{\circ}\text{C}$);
- $T_{\text{max,base}}$: limite superior de temperatura operativa ($^{\circ}\text{C}$);
- $T_{\text{min,base}}$: limite inferior de temperatura operativa ($^{\circ}\text{C}$).

No método da Autonomia Térmica (AT), calcula-se a porcentagem de horas de ocupação em que a temperatura interna da edificação se mantém dentro dos limites da faixa de conforto térmico definidos (MENDES et al., 2024). Esses limites de temperatura operativa podem ser estabelecidos com base em normas técnicas, recomendações da literatura ou definidos pela equipe de pesquisa e preferências do(da) usuário(a), conforme o contexto da análise. Por isso, esse método também é chamado de percentual de horas dentro da faixa de temperatura operativa (PHFT)(ABNT, 2024b). Ele está relacionado com o GH, ao passo em que se verifica o desempenho térmico da edificação com o uso de ventilação natural (sem uso de estratégias ativas) e se analisa o desempenho térmico por meio da comparação de temperaturas. Contudo, o GH está mais relacionado à intensidade de desconforto térmico proporcionada pela edificação, enquanto a AT está mais relacionada à frequência desse conforto térmico. A Figura 2.4 apresenta um exemplo de aplicação do método AT para um intervalo de 18°C e 26°C e a equação (2.3) apresenta a sua formulação matemática. Observe que, sempre que a temperatura operativa ultrapassa os limites estabelecidos, ocorre uma redução no valor da métrica, ao passo que, dentro da faixa de conforto térmico, o indicador permanece constante. Entende-se que, quanto maior for o PHFT obtido, melhor será o desempenho térmico da edificação.




Figura 2.4: Método de Autonomia Térmica (AT)

Fonte: (MENDES et al., 2024).

O cálculo do método segue a equação (2.3):

$$PHFT = \frac{\sum_{\text{ano de ref.}} \delta(T_{\min, \text{base}} \leq T_o \leq T_{\max, \text{base}})}{\text{total de horas ocupadas}} \times 100 \quad (2.3)$$

$$\delta = \begin{cases} 1, & \text{se } T_o \text{ está dentro da faixa } [T_{\min, \text{base}}, T_{\max, \text{base}}] \\ 0, & \text{caso contrário} \end{cases} \quad (2.4)$$

onde:

- $PHFT$: percentual de horas de ocupação dentro de uma faixa de temperatura operacional (%);
- T_o : temperatura operacional interna (°C);
- $T_{\min, \text{base}}$: limite inferior de temperatura operacional (°C);
- $T_{\max, \text{base}}$: limite superior de temperatura operacional (°C);

Por fim, a Resiliência Térmica (RT) de uma edificação pode ser definida como a capacidade de manter ou recuperar condições internas adequadas perante variações térmicas extremas (por exemplo, ondas de calor ou frio intenso) e, por consequência,

pode ser medida de diversas formas (APOLONIO; CALLEJAS; ROSETA, 2024). Uma delas é a partir do indicador Graus-Hora SET (GH SET) (ASHRAE, 2020). Essa métrica também se espelha no método GH, pois se contabiliza o acumulado da diferença de temperatura nas ocasiões de desconforto térmico (APOLONIO; CALLEJAS; ROSETA, 2024). Contudo, a faixa de temperatura de controle é referente à temperatura efetiva padrão (*Standard Effective Temperature*, i.e., SET). SET é um índice que considera a temperatura do ar, temperatura radiante, umidade, velocidade do ar e fatores do ocupante, como o metabolismo e a vestimenta (GAGGE; NISHI; GONZALEZ, 1972). No cálculo do GH SET, a condição térmica interna da edificação é representada pela temperatura operativa interna (T_o), que corresponde à sensação térmica percebida pelo ocupante. Essa variável considera não apenas a temperatura do ar, mas também o calor trocado com as superfícies do ambiente, como paredes, piso e cobertura, que podem estar mais quentes ou mais frias e influenciar diretamente o conforto térmico. Nesse método, avalia-se o desempenho térmico da edificação sob condições extremas, como apagões prolongados ou escassez de combustível para climatização de uma edificação projetada para o uso de estratégias ativas de controle climático (AVAC). A análise é feita para temporadas de extremo frio ou extremo calor na dada região, considerando os sete dias mais críticos do ano (de frio ou calor).

A Figura 2.5 apresenta um exemplo de aplicação do método, com intervalo de temperatura SET configurado entre 12°C e 30°C . Já a equação (2.5) apresenta o cálculo embutido no método. Entende-se que, quanto menor o valor de GH SET calculado, melhor o desempenho térmico e a resiliência térmica da edificação. O sistema *Leadership in Energy and Environmental Design* (LEED) determina uma faixa de temperatura SET entre 12°C e 30°C , sendo que, em edificações residenciais, os valores de GH SET não devem ultrapassar $120^{\circ}\text{C h SET}$.




Figura 2.5: Método de Resiliência Térmica (RT)

Fonte: (MENDES et al., 2024).

$$\begin{aligned}
 GH_{\text{SET}} &= \sum_{\text{semana crítica}} (GH_{c,\text{SET}} + GH_{f,\text{SET}}) \\
 &= \sum_{\text{semana crítica}} [\max(0, T_o - T_{\text{max,base}}) + \max(0, T_{\text{min,base}} - T_o)].
 \end{aligned} \tag{2.5}$$

onde:

- GH_{SET} : Graus-Hora SET total ($^{\circ}\text{C} \cdot h \text{ SET}$);
- $GH_{r,\text{SET}}$: Graus-Hora SET de calor ($^{\circ}\text{C} \cdot h \text{ SET}$);
- $GH_{a,\text{SET}}$: Graus-Hora SET de frio ($^{\circ}\text{C} \cdot h \text{ SET}$);
- T_o : temperatura operativa interna ($^{\circ}\text{C}$);
- $T_{\text{max,base}}$: limite superior de temperatura efetiva ($^{\circ}\text{C}$);
- $T_{\text{min,base}}$: limite inferior de temperatura efetiva ($^{\circ}\text{C}$).

A precisão dos resultados e a ampla aceitação da comunidade científica consolidam softwares de simulação energética, como o EnergyPlus, como referência no campo da

simulação termoeenergética de edifícios (MUSLIM, 2021). Contudo, sua aplicação ainda impõe desafios práticos, sobretudo o tempo de processamento, que pode ultrapassar, em muitos casos, vários minutos por modelo (MENDES, 2023). Em avaliações isoladas esse tempo pode parecer modesto, porém, em estudos de otimização o tempo pode ser uma limitação, devido à quantidade de simulações requeridas, que podem chegar à casa das dezenas ou centenas de milhares (KUBWIMANA; NAJAFI, 2023).

Nesses cenários, o tempo total de execução torna-se um gargalo relevante, exigindo maior capacidade computacional (CPU/GPU, paralelização, filas de *jobs*) e um planejamento rigoroso do experimento para viabilizar análises de grande escala. Diante disso, métodos de aprendizado de máquina (*Machine Learning*, ML) têm sido adotados. Cada vez mais, torna-se comum a utilização de metamodelos que emulam a resposta de softwares de simulação energética (CRUZ et al., 2024). Esses métodos, aliados a outras ferramentas de inteligência artificial (IA), permitem varrer espaços de projeto amplos, realizar otimização e quantificação de incertezas com menos custo computacional, sem abrir mão do suporte do modelo físico subjacente.

2.2 Aprendizado de Máquina

A IA é um campo da ciência da computação dedicado ao desenvolvimento de sistemas capazes de realizar tarefas que, tradicionalmente, exigiriam inteligência humana. Esses sistemas buscam reproduzir aspectos do raciocínio, da percepção e da aprendizagem, permitindo que máquinas tomem decisões de forma autônoma com base em dados e padrões observados no ambiente (RUSSELL; NORVIG, 2020).

No contexto computacional, a IA difere dos sistemas convencionais por não depender de regras fixas programadas manualmente. Em vez de depender exclusivamente da codificação manual do conhecimento humano, os algoritmos de aprendizado de máquina são capazes de extrair automaticamente relações complexas entre variáveis, tornando-se especialmente úteis em domínios nos quais o comportamento do sistema é dinâmico, incerto ou difícil de modelar por meio de regras explícitas. Em vez disso, baseia-se em modelos capazes de “aprender” com experiências passadas e melhorar seu desempenho progressivamente (FACELI et al., 2011). Essa capacidade de aprendizado é o que funda-

menta o subcampo conhecido como aprendizado de máquina, em inglês, *Machine Learning* (ML), responsável por permitir que os sistemas ajustem seus comportamentos com base em dados empíricos (RUSSELL; NORVIG, 2016).

O ML pode ser entendido como o conjunto de métodos e algoritmos que permitem que um sistema melhore automaticamente seu desempenho em determinada tarefa por meio da experiência (RUSSELL; NORVIG, 2016). Em outras palavras, o computador não é explicitamente programado para realizar cada ação, mas sim treinado a partir de dados que representam o comportamento esperado. Essa abordagem tem se mostrado fundamental em aplicações como reconhecimento facial, análise de sentimentos, diagnóstico médico, sistemas de recomendação e previsão de demanda energética (GÉRON, 2019).

Géron (2019), define que um programa é considerado capaz de aprendizado de máquina quando seu desempenho em uma tarefa T melhora com a experiência E , medida por uma métrica de desempenho P . Essa formulação, embora datada, continua sendo útil porque explicita o caráter iterativo do processo de aprendizado: o modelo é sucessivamente exposto a pares de entrada e saída esperada e, cada iteração, ajusta seus parâmetros interno para reduzir o erro e, assim, ampliar sua capacidade preditiva. É justamente esse princípio que permanece na base dos algoritmos contemporâneos de ML. De forma complementar, Russell e Norvig (2016), ressaltam que o ML constitui a espinha dorsal das aplicações modernas de IA, pois oferece os mecanismos necessários para transformar grandes volumes de dados em conhecimento.

No âmbito do aprendizado de máquina, os métodos podem ser classificados, de forma geral, de acordo com a natureza dos dados disponíveis e do tipo de tarefa envolvida. As abordagens mais difundidas incluem o aprendizado supervisionado, no qual o modelo é treinado a partir de exemplos rotulados, isto é, pares de entrada e saída desejada; o aprendizado não supervisionado, que busca identificar padrões, estruturas ou agrupamentos em dados não rotulados; e, em menor escala, o aprendizado por reforço, baseado na interação contínua com o ambiente por meio de recompensas e penalidades (FACELI et al., 2011; GÉRON, 2019). Essa distinção é fundamental para compreender o escopo e as limitações de cada técnica, bem como o tipo de problema ao qual elas se aplicam.

O foco desta seção recai sobre o *Extreme Gradient Boosting* (XGBoost), modelo

preditivo adotado nas análises, pertencente à classe dos algoritmos de ML supervisionado baseados em árvores de decisão. A seguir, apresentam-se seus fundamentos teóricos e os principais elementos necessários à sua aplicação no contexto deste estudo.

2.2.1 Aprendizado Não Supervisionado

No aprendizado não supervisionado, o modelo é treinado a partir de um conjunto de dados não rotulado, isto é, as amostras de entrada não estão associadas a saídas ou rótulos previamente definidos. Nesse contexto, o objetivo principal não é realizar previsões diretas, mas identificar padrões, agrupamentos ou regularidades presentes nos dados, explorando exclusivamente as relações internas entre as variáveis de entrada (ALPAYDIN, 2020; FACELI et al., 2011).

Diferentemente do aprendizado supervisionado, em que existe uma variável alvo explícita, o aprendizado não supervisionado busca compreender a organização intrínseca do conjunto de dados. Essa abordagem é particularmente útil em situações nas quais o processo de rotulagem é inviável, custoso ou subjetivo, bem como em etapas exploratórias de análise de dados, redução de dimensionalidade e segmentação de amostras (GÉRON, 2022).

Entre as principais categorias de aprendizado não supervisionado destacam-se os métodos de agrupamento (*clustering*), que têm como objetivo particionar o conjunto de dados em grupos de amostras semelhantes entre si e distintas das demais, segundo algum critério de similaridade ou distância (RUSSELL; NORVIG, 2016). Nesses métodos, espera-se que amostras pertencentes a um mesmo grupo compartilhem características comuns, enquanto amostras de grupos diferentes apresentem maior dissimilaridade.

Um dos algoritmos de agrupamento mais amplamente utilizados na literatura é o *k-means*. Esse algoritmo visa particionar o conjunto de dados em k grupos previamente definidos, denominados *clusters*, de modo a minimizar a soma das distâncias quadráticas entre cada amostra e o centroide do grupo ao qual ela foi atribuída (AHMED; SERAJ; ISLAM, 2020). Formalmente, o *k-means* busca minimizar a variância intra-cluster, promovendo agrupamentos compactos e bem definidos no espaço de atributos.

O funcionamento do *k-means* ocorre de forma iterativa. Inicialmente, são seleci-

onados k centroides, que podem ser definidos aleatoriamente ou por métodos específicos de inicialização. Em seguida, cada amostra do conjunto de dados é atribuída ao cluster cujo centroide apresenta a menor distância, geralmente medida pela distância euclidiana. Após essa etapa de atribuição, os centroides são recalculados como a média das amostras pertencentes a cada cluster. Esse processo de atribuição e atualização é repetido até que não haja mais mudanças significativas nos centroides ou nas associações das amostras (GÉRON, 2022).

Apesar de sua simplicidade e eficiência computacional, o *k-means* apresenta algumas limitações relevantes. O número de clusters k deve ser definido previamente, o que nem sempre é trivial e pode influenciar significativamente os resultados. Além disso, o algoritmo é sensível à inicialização dos centroides e à presença de outliers, podendo convergir para mínimos locais (FACELI et al., 2011). Ainda assim, devido à sua interpretabilidade e baixo custo computacional, o *k-means* é amplamente empregado em diversas áreas, como segmentação de clientes, análise exploratória de dados, agrupamento de materiais, identificação de padrões climáticos e organização de grandes bases de dados multidimensionais.

2.2.2 Aprendizado Supervisionado

No aprendizado supervisionado o modelo é treinado a partir de um conjunto de dados rotulado, no qual cada amostra de entrada está associada a uma saída desejada. O objetivo é aprender uma função capaz de generalizar o relacionamento entre variáveis de entrada (*features*) e saídas (*targets*), de modo que o modelo consiga realizar previsões precisas quando exposto a novos dados (ALPAYDIN, 2020).

De forma geral, os problemas supervisionados podem ser divididos em duas grandes categorias: classificação e regressão. A classificação é empregada quando a variável de saída é discreta, representando classes ou categorias. O objetivo, nesse caso, é atribuir uma classe correta a cada nova amostra com base em padrões aprendidos durante o treinamento (RUSSELL; NORVIG, 2016; LITJENS et al., 2017; PHUA et al., 2010; LESSMANN et al., 2015). Exemplos típicos incluem o reconhecimento de imagens, a detecção de fraudes bancárias, a identificação de doenças em exames médicos e a previsão

de aprovação de crédito. Em todos esses casos, o modelo deve distinguir entre categorias distintas, como “fraude” ou “não fraude”, “positivo” ou “negativo”, “baixo risco” ou “alto risco”.

Por outro lado, a regressão é aplicada quando a variável de saída é contínua, ou seja, assume valores numéricos dentro de um intervalo (RUSSELL; NORVIG, 2016). Nesses casos, o modelo busca prever quantidades, tendências ou intensidades com base nas características de entrada. Exemplos incluem a previsão de preços de imóveis, o consumo de energia, a temperatura ambiente, a resistência de um concreto, a produção agrícola e a carga térmica de uma edificação (GÉRON, 2022). A regressão, portanto, é essencial em estudos que envolvem estimativas quantitativas e relações físicas ou econômicas entre variáveis.

Em termos genéricos, os modelos de regressão supervisionada aprendem a minimizar o erro entre os valores previstos e os valores reais, utilizando métricas de avaliação que quantificam o desempenho do modelo (Elastic, 2025). Quanto menor for o erro obtido durante o treinamento e a validação, mais adequado tende a ser o modelo de ML ao problema em análise. No entanto, é preciso cautela quanto ao sobreajuste (*overfitting*), situação em que o modelo apresenta desempenho aparentemente excelente nos dados de treinamento, mas baixa capacidade de generalização ao ser aplicado a novos casos (FACELI et al., 2011). Para mitigar esse efeito, recomenda-se a divisão do conjunto de dados em amostras distintas de treinamento, validação e teste. Entretanto, essa estratégia só é efetiva quando os subconjuntos são representativos da distribuição dos dados e não excessivamente homogêneos, uma vez que conjuntos enviesados podem conduzir ao sobreajuste e a uma avaliação excessivamente otimista do desempenho do modelo (ALPAYDIN, 2020; FACELI et al., 2011). Nessa estrutura, o conjunto de treinamento é usado para ajustar os parâmetros do modelo, o de validação serve para calibrar hiperparâmetros e prevenir o sobreajuste, e o de teste é reservado para avaliar a capacidade de generalização (ALPAYDIN, 2020).

Outra abordagem amplamente empregada é a validação cruzada (*cross-validation*), em que o conjunto de dados é dividido em múltiplas partições (ou *folds*), alternando-se as amostras utilizadas para treino e validação a cada iteração (ALPAYDIN, 2020; FA-

CELI et al., 2011). Em aplicações práticas, é comum realizar previamente uma separação do conjunto de dados em duas partes: uma parcela destinada ao conjunto de teste, tipicamente correspondente a 20% das amostras, mantida isolada durante o processo de treinamento, e a parcela restante (80%), utilizada na etapa de validação cruzada. Esse procedimento permite estimar de forma mais confiável o desempenho médio do modelo, reduzindo a dependência de uma única divisão dos dados e mitigando possíveis vieses amostrais (ALPAYDIN, 2020). A Figura 2.6 apresenta o funcionamento do método *k fold cross-validation*, com $k = 5$, sendo reiterado 5 vezes de modo que, em cada iteração, um *fold* diferente é utilizado para validação e os demais 4 folds compõem o conjunto de treinamento. Ao final das 5 execuções, obtém-se uma estimativa média mais estável do desempenho do modelo, reduzindo sua sensibilidade a uma única divisão dos dados e mitigando potenciais vieses amostrais.




Figura 2.6: Banco de dados dividido em subconjuntos de treino e teste por meio do método k-fold para $k=5$

Fonte: (MENDES et al., 2025)

Entre as métricas mais utilizadas em problemas de regressão estão o erro absoluto médio (*Mean Absolute Error*, MAE), o erro percentual absoluto médio (*Mean Absolute Percentage Error*, MAPE), o erro quadrático médio (*Root Mean Squared Error*, RMSE), e o coeficiente de determinação (R^2) (MENDES et al., 2025).

O erro absoluto médio (*Mean Absolute Error*, MAE), calcula a média das dife-

renças absolutas entre os valores previstos (\hat{y}_i) e os valores observados (y_i) na quantidade de dados analisados, sendo expressa na equação (2.6):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.6)$$

O MAE é expresso na mesma unidade da variável de interesse, uma vez que representa a média das diferenças absolutas entre valores observados e previstos. Quanto menor o valor do MAE, melhor o desempenho do modelo, pois menores são, em média, os desvios entre as previsões e os valores reais.

O erro percentual absoluto médio (*Mean Absolute Percentage Error*, MAPE) representa o erro relativo em termos percentuais, permitindo avaliar o desvio médio proporcional entre as previsões e os valores reais, sendo expressa na equação (2.7):

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.7)$$

O MAPE é uma métrica adimensional, expressa em termos percentuais, o que facilita a interpretação do erro de forma relativa à magnitude dos valores observados. Valores mais baixos de MAPE indicam maior precisão preditiva do modelo. Contudo, essa métrica pode apresentar limitações quando os valores observados y_i se aproximam de zero, situação na qual o erro percentual tende a ser amplificado.

Já o erro quadrático médio (*Root Mean Squared Error*, RMSE) dá maior peso a erros mais altos, sendo amplamente empregado quando grandes desvios têm maior impacto no desempenho do modelo, sendo expressa na Eq. (2.8):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.8)$$

O RMSE é expresso na mesma unidade da variável de interesse, assim como o MAE, porém atribui maior penalização a erros de maior magnitude devido à elevação ao quadrado das diferenças. Dessa forma, valores menores de RMSE indicam melhor desempenho do modelo, sendo essa métrica especialmente adequada quando grandes desvios entre valores previstos e observados são indesejáveis.

Por fim, o coeficiente de determinação (*Coefficient of Determination*, R^2) mede

a proporção da variabilidade dos dados que é explicada pelo modelo, indicando sua qualidade de ajuste, sendo expressa na Eq. (2.9):

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.9)$$

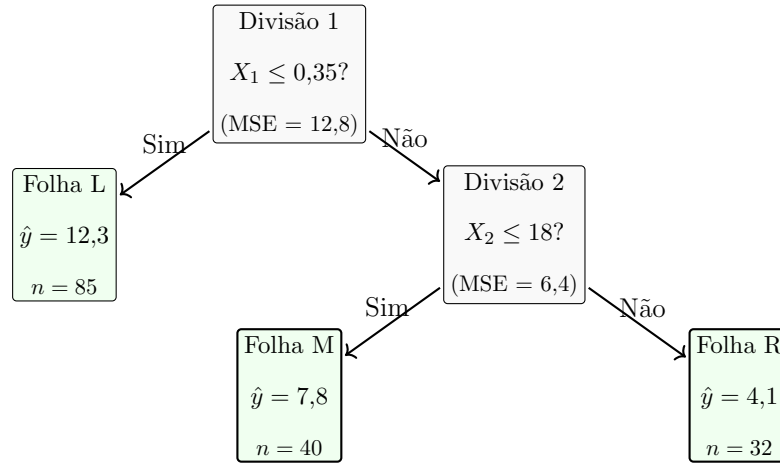
O coeficiente de determinação R^2 é uma métrica adimensional que pode assumir valores variando de $-\infty$ a 1. Valores próximos de 1 indicam que o modelo explica grande parte da variabilidade dos dados observados, enquanto valores próximos de zero indicam desempenho semelhante ao de um modelo que utiliza apenas a média dos dados como predição. Valores negativos de R^2 indicam que o modelo apresenta desempenho inferior a esse preditor médio, caracterizando um ajuste inadequado.

Essas métricas permitem quantificar a precisão e a robustez dos modelos preditivos, sendo ferramentas fundamentais para a comparação de diferentes algoritmos e o refinamento de seus hiperparâmetros.

2.2.3 Árvores de Decisão

As árvores de decisão (*Decision Trees*, em inglês) constituem um dos modelos mais intuitivos e amplamente utilizados no aprendizado supervisionado, tanto para tarefas de classificação quanto de regressão (ABDULQADER; ABDULAZEEZ, 2024). Sua popularidade advém da simplicidade conceitual e da capacidade de representar relações não lineares entre variáveis de entrada e saída de maneira interpretável.

A Figura 2.7 ilustra uma árvore de decisão para resolver um problema de regressão. A construção da árvore segue uma abordagem de cima para baixo, em que o nó raiz contém todo o conjunto de dados. A cada iteração, as divisões são realizadas até que se atinja um critério de parada, como a profundidade máxima, o número mínimo de amostras por nó ou a ausência de ganho informacional significativo. O resultado final é uma estrutura hierárquica composta por nós de decisão e nós folha, nos quais cada folha representa uma previsão ou valor médio associado às amostras pertencentes àquele subconjunto.



Nós de decisão: regra de divisão (X_j e limiar).

Folhas: previsão do nó (\hat{y}) e tamanho da amostra (n).

Figura 2.7: Exemplo de árvore de decisão para regressão. Os nós de decisão exibem a regra de divisão e uma métrica de erro (MSE); as folhas apresentam a previsão média \hat{y} e o número de amostras n .

Fonte: Baseado em (STANKEVIX, 2020).

Nota-se que o funcionamento de uma árvore de decisão baseia-se na divisão recursiva do conjunto de dados em subconjuntos progressivamente mais homogêneos, segundo critérios de decisão definidos por métricas estatísticas (BLOCKHEEL et al., 2023). Em cada nó da árvore, escolhe-se uma variável e um ponto de divisão que melhor separam as amostras de acordo com o objetivo de previsão. Para problemas de classificação, medidas como a impureza de Gini e a entropia são comumente utilizadas para avaliar a qualidade das divisões (BLOCKHEEL et al., 2023). Já em problemas de regressão, o critério mais adotado é a minimização do erro quadrático médio (*Mean Squared Error*, MSE) entre os valores previstos e observados (BLOCKHEEL et al., 2023).

Uma das principais vantagens das árvores de decisão é a facilidade de interpretação. A estrutura hierárquica permite compreender de forma direta como o modelo chega a uma decisão (ABDULQADER; ABDULAZEEZ, 2024). Essas características são úteis em aplicações que demandam transparência, como diagnósticos médicos, crédito bancário ou avaliação de desempenho energético de edificações. No entanto, árvores individuais tendem a apresentar limitações em termos de generalização, podendo sofrer de sobreajuste (*overfitting*) quando o modelo se torna excessivamente complexo e ajustado aos dados de treinamento (ZHANG, 2024), fazendo valer a etapa de validação e teste do

modelo para avaliar esse problema.

Para contornar essas limitações de *overfitting*, surgiram os chamados métodos de *ensemble*, que combinam modelos em que múltiplas árvores que são treinadas de forma sequencial, como o *Random Forest* e o *Gradient Boosting*, que combinam múltiplas árvores para aumentar a precisão e a robustez do modelo (ABDULQADER; ABDULAZEEZ, 2024). Dentre esses métodos, destaca-se o *Extreme Gradient Boosting* (XGBoost), que é apresentado na subseção seguinte.

2.2.4 Extreme Gradient Boosting (XGBoost)

O *Extreme Gradient Boosting* (XGBoost) é um modelo de aprendizado supervisionado baseado em árvores de decisão que utiliza o princípio do *boosting de gradiente* para aprimorar progressivamente a capacidade preditiva do modelo (XGBoost Developers, 2025). Desenvolvido por Chen e Guestrin (2016), ele é amplamente reconhecido por sua alta eficiência computacional, desempenho preditivo robusto e flexibilidade de aplicação em problemas de regressão e classificação (CHEN; GUESTIN, 2016).

O *boosting* é uma técnica de aprendizado por conjunto (*ensemble*) na qual múltiplos modelos, tipicamente árvores de decisão, são treinados de forma sequencial (CHEN; GUESTIN, 2016). A cada iteração, o modelo corrige os erros residuais das previsões realizadas nas árvores antecessoras, de modo que o modelo final seja uma soma ponderada de todas essas árvores construídas (CHEN; GUESTIN, 2016). Essa abordagem permite que o XGBoost capture relações complexas entre variáveis e reduza o viés e a variância do modelo (CHEN; GUESTIN, 2016). A Figura 2.8 ilustra esse funcionamento conceitual, evidenciando a sequência de treinamento e correção dos resíduos ao longo das iterações.




Figura 2.8: Esquema conceitual do funcionamento do XGBoost.

Fonte: Baseado em (XGBoost Developers, 2025).

O processo de aprendizagem do XGBoost busca minimizar uma função objetivo

$(L(\phi))$ composta por dois termos: a função de perda (l), que mede o erro entre as previsões (\hat{y}_i) e os valores reais (y_i), e um termo de regularização ($\Omega(f)$), que penaliza a complexidade do modelo, prevenindo *overfitting*. Essa função objetivo é expressa na equação (2.10).

$$\mathcal{L}(\phi) = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{k=1}^K \Omega(f_k) \quad (2.10)$$

A função de perda (l) costuma ser o erro MSE. Já o termo de regularização ($\Omega(f)$) é uma função do número de folhas da árvore (T), peso de cada folha (w_j^2), e hiperparâmetros que controlam a penalização de complexidade (γ e λ), como se verifica na equação (2.11).

$$\Omega(f) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T w_j^2 \quad (2.11)$$

O processo de aprendizado do XGBoost ocorre de forma aditiva e sequencial, em que cada árvore é treinada para corrigir os erros residuais gerados pelas previsões anteriores. Dessa maneira, o modelo final resulta da soma ponderada de todas as árvores, aprimorando gradualmente o ajuste às observações reais sem perder capacidade de generalização.

Entre as principais características do XGBoost destacam-se sua regularização explícita, que incorpora penalizações L1 e L2 que reduzem o sobreajuste, e o suporte à paralelização, que permite o particionamento eficiente de dados e acelera o treinamento (CHEN; GUESTRIN, 2016). Além disso, também se destacam a capacidade de manejar dados ausentes, identificando automaticamente os caminhos ideais para amostras com valores faltantes, e o controle de aprendizado, realizando por meio do parâmetro *learning rate* (η), que equilibra a velocidade e a estabilidade de convergência (XGBoost Developers, 2025). Por fim, mas não menos importante, tem-se a análise de importância das variáveis, que fornece medidas interpretáveis de contribuição de cada atributo na predição (XGBoost Developers, 2025).

Embora os modelos preditivos baseados em ML, como o XGBoost, sejam capazes de estimar com alta precisão o desempenho termoenergético das edificações, sua

aplicação isolada não é capaz de apoiar suficientemente as decisões complexas de projeto, envolvendo múltiplos critérios que devem ser equilibrados simultaneamente (CRUZ et al., 2024). Projetos arquitetônicos e construtivos envolvem, por natureza, *trade-offs* entre variáveis como desempenho térmico, consumo energético, custo de materiais e impacto ambiental (TRIANA et al., 2023). Assim, a busca por soluções que conciliem desempenho e sustentabilidade requer uma abordagem sistemática que vá além da simples previsão de resultados (CRUZ et al., 2024). Nesse contexto, a integração entre modelos preditivos e métodos de otimização multiobjetivo torna-se uma estratégia poderosa (KUBWIMANA; NAJAFI, 2023; COELLO et al., 2020). O modelo preditivo atua como um metamodelo (ou modelo substituto), capaz de estimar rapidamente o desempenho de diferentes combinações de variáveis, reduzindo o custo computacional associado a simulações termo-energéticas completas (BARBARESI et al., 2022). Já o algoritmo de otimização, como será discorrido na seção 2.3, é responsável por explorar o espaço de soluções, identificando os conjuntos de alternativas mais promissores de acordo com os objetivos definidos (COELLO et al., 2020).

2.3 Otimização

De modo geral, a otimização, no contexto de pesquisa operacional, consiste em encontrar, entre todas as soluções possíveis de um problema, aquela (ou aquelas) que melhor satisfaçam determinado critério de desempenho (HILLIER; LIEBERMAN, 2015). Esse tipo de problema está presente em diversas áreas do conhecimento, sempre que há a necessidade de maximizar ou minimizar alguma variável de interesse, como eficiência, custo, tempo ou desempenho. Em sua forma mais simples, um problema de otimização busca identificar o vetor de variáveis de decisão que minimize (ou maximize) uma função objetivo $f(x)$ sujeita a restrições, como mostrado na equação (2.12), juntamente com as restrições de desigualdade - equação (2.13) e igualdade - equação (2.14). O vetor x corresponde às variáveis de decisão do modelo, definido na equação (2.15).

$$\min_{x \in \mathbb{R}^n} f(x) \quad (2.12)$$

$$\text{sujeito a } g_i(x) \leq 0, \quad i = 1, 2, \dots, m \quad (2.13)$$

$$h_j(x) = 0, \quad j = 1, 2, \dots, p \quad (2.14)$$

$$x = [x_1, x_2, \dots, x_n]^T \quad (2.15)$$

Na prática, muitos problemas de engenharia, inclusive os relacionados ao desempenho termoenergético de edificações, apresentam natureza não linear, múltiplos mínimos locais e variáveis interdependentes (COELLO et al., 2020). Nessas situações, métodos analíticos tradicionais se tornam inviáveis, exigindo o uso de abordagens numéricas e heurísticas (COELLO et al., 2020). As abordagens numéricas são técnicas matemáticas que buscam soluções aproximadas por meio de cálculos iterativos (CHAPRA; CANALE, 2015). Já as heurísticas são estratégias baseadas em regras empíricas ou inspiradas em fenômenos naturais, usadas quando o problema é tão complexo que não há uma solução exata viável (COELLO et al., 2020). Indo além, temos abordagens meta-heurísticas evolutivas, em especial, inspiradas em processos naturais que, têm se mostrado particularmente eficientes em lidar com tais desafios, oferecendo soluções robustas em espaços de busca complexos e de alta dimensionalidade (COELLO et al., 2020; DEB et al., 2002).

Entre as meta-heurísticas mais conhecidas, destaca-se o algoritmo genético (*Genetic Algorithm*, GA), introduzido por Holland na década de 1970 (COELLO et al., 2020).

Inspirado nos princípios da seleção natural e da genética biológica, o GA simula a evolução de uma população de soluções potenciais ao longo de várias gerações (EIBEN; SMITH, 2015). Cada indivíduo representa uma possível solução codificada (normalmente em forma de vetor ou cadeia binária), e seu desempenho é avaliado por uma função de aptidão (*fitness*) (EIBEN; SMITH, 2015). Os indivíduos mais aptos têm maior probabilidade de serem selecionados para reprodução, onde operadores genéticos, como cruzamento (*crossover*) e mutação, são aplicados para gerar novas soluções (EIBEN; SMITH, 2015). Esse processo iterativo promove a exploração e a diversificação do espaço de busca, permitindo que o algoritmo evolua gradualmente em direção a soluções cada vez melhores

(EIBEN; SMITH, 2015). A Figura 2.9 ilustra o procedimento.



Figura 2.9: Fluxo de um Algoritmo Genético.

Fonte: Baseado em (GONTIJO, 2020).

Em problemas com múltiplos critérios de desempenho, no entanto, a aplicação de um único GA tradicional é limitada, pois ele tende a convergir para uma única solução ótima (DEB et al., 2002). Para lidar com cenários onde há mais de um objetivo a ser otimizado simultaneamente, surgiram os chamados algoritmos genéticos multiobjetivo (*Multi-Objective Genetic Algorithms*, MOGAs) (COELLO et al., 2020). Esses métodos estendem os princípios do GA clássico para trabalhar com múltiplas funções objetivo em paralelo, buscando não uma única resposta, mas um conjunto de soluções de compromisso conhecidas como soluções de Pareto (DEB et al., 2002). Assim, em vez de escolher arbitrariamente uma métrica de desempenho agregada, os MOGAs exploram o equilíbrio natural entre objetivos conflitantes, oferecendo à projetista um leque de alternativas com diferentes compensações entre custo, eficiência e outros critérios relevantes (WIERZBICKI, 1980).

Entre as abordagens mais notáveis de MOGAs estão o algoritmo genético de ordenação não dominada II (*Non-dominated Sorting Genetic Algorithm II*, NSGA-II) e sua extensão NSGA-III (DEB et al., 2002). Esses métodos são particularmente úteis em problemas de engenharia, onde decisões de projeto frequentemente envolvem múltiplos objetivos interdependentes, como, no presente caso, desempenho térmico, consumo de energia, impacto ambiental e custo construtivo.

2.3.1 Otimização multiobjetivo

No mundo real, existem inúmeros problemas com dois ou mais objetivos, muitas vezes conflitantes, aos quais buscamos otimizar simultaneamente. Por exemplo, ao desenvolver um carro elétrico, uma empresa pode precisar equilibrar: maximizar a autonomia, minimizar o custo de produção e reduzir o tempo de recarga. Aumentar a autonomia pode elevar custos e ampliar o tempo de recarga, enquanto reduzir o tempo de recarga pode exigir tecnologias mais caras ou menos eficientes. Esse equilíbrio entre metas opostas caracteriza um típico problema de otimização multiobjetivo. Esses problemas são conhecidos como problemas de otimização multiobjetivo (*Multi-Optimization Problems*, MOPs) (COELLO et al., 2020).

Devido ao conflito entre objetivos, a resolução de um MOP resulta em um conjunto de soluções que representam os melhores compromissos possíveis entre os objetivos (ou seja, soluções nas quais um objetivo não pode ser melhorado sem piorar outro) (COELLO et al., 2020). Tais soluções constituem o conjunto soluções de compromisso, e a imagem desse conjunto (isto é, os valores das funções objetivo correspondentes) forma a chamada frente ou fronteira de Pareto (FONSECA; FLEMING, 1999).

Matematicamente, um MOP resolve como o exemplo exposto na equação (2.16):

$$\begin{aligned} \text{minimizar} \quad & f(x) := [f_1(x), f_2(x), \dots, f_k(x)] \\ \text{sujeito a} \quad & g_i(x) \leq 0, \quad i = 1, 2, \dots, m, \\ & h_j(x) = 0, \quad j = 1, 2, \dots, p. \end{aligned} \tag{2.16}$$

Onde:

$x = [x_1, x_2, \dots, x_n]^T$ é o vetor de variáveis de decisão,

$f_i : \mathbb{R}^n \rightarrow \mathbb{R}$, para $i = 1, \dots, k$, são as funções objetivo.

g_i e $h_j : \mathbb{R}^n \rightarrow \mathbb{R}$ são as funções de restrição do problema.

Além disso, para introduzir a noção de otimalidade usada em um MOP, é necessário entender alguns pontos (WIERZBICKI, 1980):

1. Dados dois vetores $x, y \in \mathbb{R}^k$, diz-se que $x \leq y$ se $x_i \leq y_i$ para $i = 1, \dots, k$, e que x domina y (denotado por $x \prec y$) se $x \not\leq y$.

2. Diz-se que um vetor de variáveis de decisão $x \in X \subset \mathbb{R}^n$ é não dominado com respeito a X se não existe outro $x' \in X$ tal que $f(x') \prec f(x)$.
3. Diz-se que um vetor de variáveis de decisão $x^* \in F \subset \mathbb{R}^n$ (sendo F a região viável) é ótimo de Pareto se for não dominado com respeito a F .
4. O conjunto ótimo de Pareto (P^*) é definido conforme a Eq. (2.17):

$$P^* = \{x \in F \mid x \text{ é ótimo de Pareto}\} \quad (2.17)$$

5. A frente de Pareto (PF^*) é definida conforme a equação (2.18):

$$PF^* = \{f(x) \in \mathbb{R}^k \mid x \in P^*\} \quad (2.18)$$

Nota-se que, o objetivo é obter o conjunto ótimo de Pareto a partir do conjunto F de todos os vetores de variáveis de decisão que satisfazem as restrições do problema. No entanto, na prática, nem todo o conjunto ótimo de Pareto é desejável ou alcançável. Em alguns casos, os tomadores e tomadoras de decisão tendem a preferir certos tipos de soluções ou regiões específicas da frente de Pareto, como é discutido na subseção seguinte.

2.3.2 Métricas de avaliação de desempenho em otimização multiobjetivo

Na prática, algoritmos de otimização multiobjetivo não fornecem exatamente a frente de Pareto ótima teórica, mas sim uma aproximação composta por um conjunto finito de soluções. Dessa forma, torna-se necessário empregar métricas quantitativas capazes de avaliar a qualidade dessas soluções aproximadas.

Entre as métricas mais utilizadas na literatura destacam-se o *Hypervolume* (HV), o *Inverted Generational Distance Plus* (IGD⁺) e o *Spacing*, cada uma associada a um critério distinto de qualidade da frente de Pareto obtida (COELLO; LAMONT; VELDHUIZEN, 2007; DEB, 2001).

Considere $P = \{p_1, p_2, \dots, p_N\}$ o conjunto de soluções obtidas por um algoritmo

de otimização multiobjetivo, $R = \{r_1, r_2, \dots, r_M\}$ uma frente de Pareto de referência e $f(p) = (f_1(p), \dots, f_k(p))$ o vetor de valores das funções objetivo associado a uma solução p .

Hypervolume (HV)

O *Hypervolume* mede o volume do espaço de objetivos dominado pelas soluções obtidas, considerando um ponto de referência z^{ref} previamente definido, o qual deve ser pior do que todas as soluções em todos os objetivos (ZITZLER; BROCKHOFF; THIELE, 2007). Matematicamente, o HV é definido como pode ser visto na equação (2.19):

$$HV(P) = \lambda \left(\bigcup_{p \in P} [f_1(p), z_1^{\text{ref}}] \times \dots \times [f_k(p), z_k^{\text{ref}}] \right), \quad (2.19)$$

onde $\lambda(\cdot)$ representa a medida de *Lebesgue* no espaço dos objetivos.

De forma intuitiva, essa métrica indica simultaneamente o quão próximas as soluções estão da região ideal e o quanto elas cobrem essa região. Valores mais elevados de HV indicam frentes de Pareto mais desejáveis, pois refletem melhor desempenho global e maior diversidade das soluções. Por essa razão, o HV é amplamente adotado como uma métrica consolidada na avaliação de algoritmos de otimização multiobjetivo.

Inverted Generational Distance Plus (IGD⁺)

O IGD⁺ é uma métrica baseada em distância que avalia a proximidade entre a frente de Pareto aproximada e uma frente de referência que representa a solução ideal do problema (ZITZLER et al., 2003). Diferentemente do IGD tradicional, o IGD⁺ considera apenas distâncias que violam a dominância de Pareto, penalizando soluções que estejam piores do que a frente de referência.

A distância IGD⁺ entre um ponto de referência $r \in R$ e uma solução $p \in P$ é definida na equação (2.20):

$$d^+(r, p) = \sqrt{\sum_{i=1}^k (\max\{f_i(p) - f_i(r), 0\})^2}. \quad (2.20)$$

Com base nessa distância, o IGD⁺ é calculado conforme pode ser visto na equação

(2.21):

$$IGD^+(P, R) = \frac{1}{|R|} \sum_{r \in R} \min_{p \in P} d^+(r, p). \quad (2.21)$$

Com isso, o IGD^+ evita penalizar indevidamente soluções que dominam pontos da frente de referência, tornando a métrica mais consistente com o conceito de dominância de Pareto. Valores menores de IGD^+ indicam melhor convergência da frente aproximada em relação à frente ideal. De forma intuitiva, essa métrica mede o quão distante a frente obtida está da frente ideal, considerando apenas os desvios realmente indesejáveis do ponto de vista da otimização multiobjetivo.

Spacing

A métrica *Spacing* avalia a uniformidade da distribuição das soluções ao longo da frente de Pareto (DEB, 2001). Inicialmente, define-se a distância mínima entre cada solução $p_i \in P$ e as demais soluções da frente como demonstra a equação (2.22):

$$d_i = \min_{j \neq i} \sum_{m=1}^k |f_m(p_i) - f_m(p_j)|. \quad (2.22)$$

Em seguida, o *Spacing* é calculado como o desvio padrão dessas distâncias, conforme pode ser visto na equação (2.23):

$$S = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (d_i - \bar{d})^2}, \quad (2.23)$$

onde \bar{d} representa a média das distâncias d_i .

Valores menores de *Spacing* indicam soluções mais uniformemente distribuídas, enquanto valores elevados apontam para aglomerações ou lacunas na frente aproximada, comprometendo a diversidade das soluções.

Em conjunto, essas métricas permitem uma avaliação abrangente das soluções obtidas, considerando convergência, diversidade e qualidade global da frente de Pareto (COELLO; LAMONT; VELDHUIZEN, 2007).

2.3.3 Otimização multiobjetivo baseada em pontos de referência

Com os recentes avanços na otimização evolutiva multiobjetivo (*multi-objective evolutionary optimization*, EMO), é possível encontrar diversas soluções de compromisso (*trade-off*) em problemas com quatro ou mais objetivos (VESIKAR; DEB; BLANK, 2018). Porém, de acordo com Vesikar, Deb e Blank (2018), há ao menos duas razões pelas quais os(as) usuários(as), em algumas ocasiões, podem estar interessados em encontrar apenas uma parte da fronteira ótima de Pareto. Primeiro, após analisar as soluções obtidas por algum algoritmo EMO, o(a) usuário(a) pode desejar se concentrar em uma região preferencial específica da fronteira de Pareto, seja para obter soluções adicionais na região de interesse ou para investigar a natureza das soluções naquela área. Segundo, o(a) usuário(a) pode já ter uma preferência bem articulada entre os objetivos e estar interessado apenas em soluções alinhadas a essas preferências ou podem existir restrições externas, como físicas, de custo e de projeto.

Existem diversas variantes de algoritmos EMO aplicáveis à busca por partes específicas da fronteira ótima de Pareto. Dentre eles, destaca-se o R-NSGA-II (DEB; SUNDAR, 2006), no qual as preferências dos tomadores e tomadoras de decisão são fornecidas por um ou mais pontos de referência, seguindo uma abordagem de tomada de decisão multicritério originalmente proposta por Wierzbicki (WIERZBICKI, 1980). Esse algoritmo permite incorporar explicitamente as preferências dos tomadores de decisão no processo evolutivo, direcionando a busca para regiões da fronteira de Pareto consideradas mais relevantes. No entanto, por ser derivado do NSGA-II, o R-NSGA-II herda também suas limitações, especialmente a dificuldade de manter uma boa distribuição das soluções quando o número de objetivos aumenta, devido à perda de eficácia do mecanismo de *crowding distance* em espaços objetivo de alta dimensionalidade (DEB et al., 2002). Esse fator restringe sua aplicação em MOPs com muitos objetivos, motivando o desenvolvimento de extensões mais robustas.

Em particular, o NSGA II seleciona soluções na última frente usando o *crowding distance*, que estima a densidade local no espaço objetivo para promover diversidade (DEB et al., 2002). Já o NSGA III substitui esse critério por um mecanismo de *niching* guiado por pontos de referência, no qual os objetivos são normalizados e cada solução

é associada ao ponto mais próximo, priorizando nichos menos ocupados para garantir melhor cobertura da fronteira (DEB; SUNDAR, 2006). Essa mudança torna o controle de diversidade mais robusto em problemas com muitos objetivos, onde o *crowding distance* tende a perder poder discriminativo (DEB et al., 2002; DEB; SUNDAR, 2006).

O R-NSGA-III supera as limitações de seus predecessores ao combinar o mecanismo de pontos de referência do R-NSGA-II com a estrutura do NSGA-III, concebida especificamente para lidar com problemas de muitos objetivos. Dessa forma, o algoritmo mantém a capacidade de incorporar preferências explícitas dos tomadores e tomadoras de decisão por meio de pontos de referência personalizados, ao mesmo tempo que se beneficia da distribuição estruturada de soluções característica do NSGA-III, favorecendo maior diversidade em espaços objetivo de alta dimensionalidade (DEB; SUNDAR, 2006; VESIKAR; DEB; BLANK, 2018).

Essa integração torna o R-NSGA-III mais eficiente e adequado a aplicações práticas, nas quais os tomadores e tomadoras de decisão estão interessados em regiões específicas da fronteira de Pareto, permitindo direcionar a busca conforme preferências sem comprometer a diversidade das soluções (VESIKAR; DEB; BLANK, 2018).

A Figura 2.10 apresenta, de forma esquemática, um método híbrido. Inicialmente, um modelo de avaliação do sistema é empregado para gerar uma base de dados que relaciona variáveis de entrada e respostas de interesse. Em seguida, técnicas de aprendizado de máquina são utilizadas para construir um modelo preditivo capaz de aproximar o comportamento do sistema, o qual é validado por procedimentos de amostragem e ajuste de parâmetros. Por fim, um algoritmo de otimização multiobjetivo explora o espaço de soluções com base nesse modelo preditivo, incorporando preferências do tomador e tomadora de decisão, assim resultando em um conjunto de soluções de compromisso para análise de *trade-offs* entre os objetivos considerados.

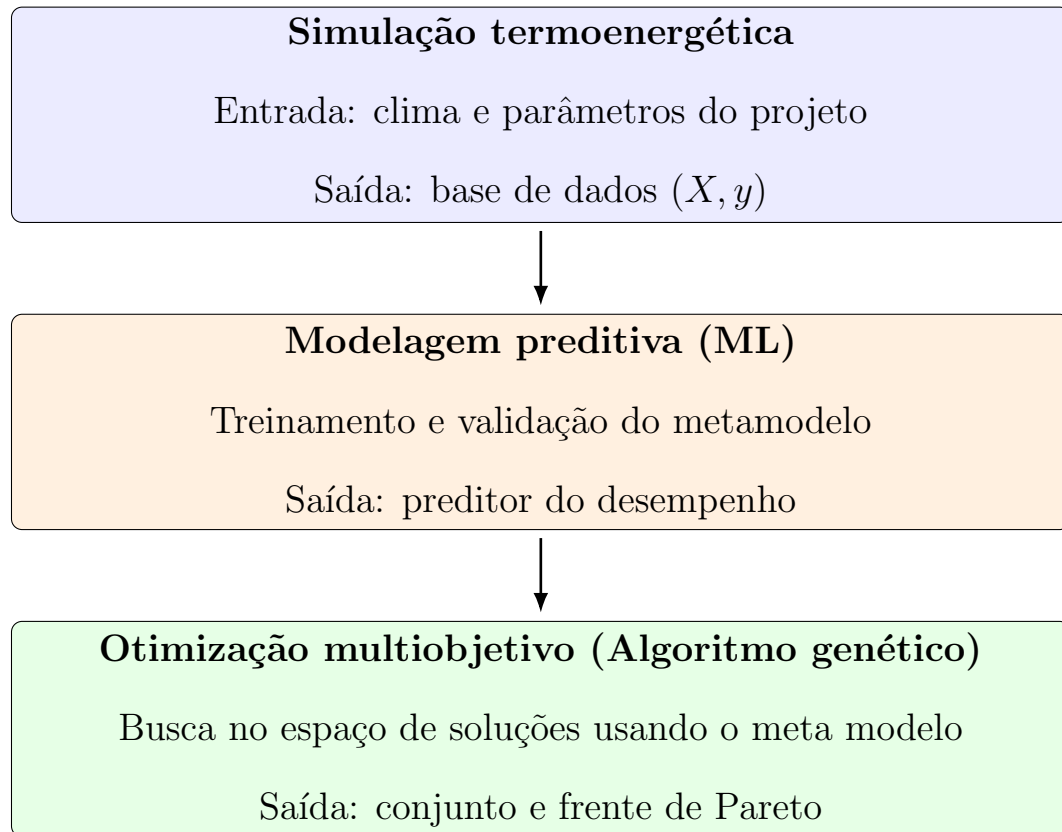


Figura 2.10: Método integrado

Fonte: Elaborado pelo autor.

Enquanto o modelo preditivo é responsável por estimar, com elevada eficiência, o desempenho do sistema sob diferentes configurações de projeto, o algoritmo de otimização atua como um mecanismo de busca inteligente sobre essas estimativas, otimizando simultaneamente múltiplos objetivos potencialmente conflitantes. Dessa forma, o modelo preditivo passa a desempenhar o papel de um metamodelo (ou modelo substituto) do modelo de avaliação original, possibilitando que o processo de otimização explore um grande número de soluções potenciais em um tempo computacional significativamente inferior ao requerido por avaliações diretas do sistema. Essa integração não apenas reduz o tempo de processamento das análises, mas também amplia a capacidade de exploração de cenários, contribuindo para o desenvolvimento de projetos mais eficientes, sustentáveis e resilientes frente às mudanças climáticas (CRUZ et al., 2024).

2.3.4 Estado da Arte

O desempenho termoenergético de edificações tem sido amplamente estudado nas últimas décadas, impulsionado pela crescente preocupação com a eficiência energética e a sustentabilidade no setor da construção civil. Esse campo multidisciplinar integra conhecimentos de arquitetura bioclimática, ciências dos materiais, termodinâmica e ciência de dados, com o objetivo de reduzir o consumo energético e as emissões de gases de efeito estufa associadas à construção e operação dos edifícios (BALARAS et al., 2024).

Historicamente, os primeiros estudos do desempenho térmico se concentraram em métodos empíricos e análises simplificadas baseadas em balanços térmicos (LAMBERTS et al., 2010). A partir da década de 1990, o avanço dos recursos computacionais viabilizou o uso de simulações termoenergéticas detalhadas, com destaque para ferramentas como *EnergyPlus* e *TRNSYS*, que permitiram representar com maior precisão o comportamento dinâmico das edificações (CRAWLEY et al., 2001; MUSLIM, 2021). Esses modelos baseados em física continuam sendo a principal referência para análises de eficiência, embora apresentem desafios relacionados ao tempo de processamento e à calibração dos parâmetros de entrada (MENDES et al., 2024).

Nos últimos anos, a convergência entre técnicas de modelagem física e métodos de ML tem impulsionado uma nova geração de abordagens híbridas (KUBWIMANA; NAJAFI, 2023). De acordo com Balaras et al. (2024), essa integração permite superar limitações computacionais e aumentar a capacidade preditiva, utilizando dados simulados ou empíricos para treinar modelos capazes de estimar o desempenho térmico e energético de forma rápida e precisa. Conforme as revisões da literatura realizadas por Balaras et al. (2024), Coello et al. (2020) e Cruz et al. (2024), verifica-se que os estudos mais recentes agrupam-se em três grandes eixos: (i) modelos de previsão de consumo e cargas térmicas, que aplicam regressões lineares, redes neurais e gradient boosting para estimar demandas energéticas; (ii) modelos de controle e otimização operacional, voltados ao ajuste dinâmico de sistemas de climatização e iluminação; e (iii) modelos de otimização de projeto, que integram algoritmos evolutivos multiobjetivo com meta-modelos para explorar soluções construtivas de melhor desempenho.

Entre as abordagens de otimização, destacam-se os algoritmos genéticos, o NSGA-

II e suas extensões, amplamente utilizados na busca de soluções de compromisso entre variáveis conflitantes, como custo, consumo e conforto térmico (CRUZ et al., 2024). Esses algoritmos têm sido aplicados em conjunto com metamodelos baseados em aprendizado supervisionado, como Rede Neural Artificial, *Random Forest*, *Support Vector Regression* e *XGBoost*, para reduzir o número de simulações necessárias, mantendo boa precisão (BARBARESI et al., 2022). A literatura recente evidencia que essa combinação híbrida oferece ganhos significativos de eficiência, tornando viável a aplicação de métodos de otimização em larga escala e em diferentes zonas climáticas (CRUZ et al., 2024).

Apesar dos avanços, algumas lacunas permanecem. Muitos estudos ainda se concentram em condições de operação estáticas, negligenciando a variabilidade climática futura, devido às mudanças climáticas, e o conceito de *resiliência térmica*, que se torna crucial frente às projeções de aumento de temperaturas médias globais (HONG et al., 2023). Outro ponto crítico é a escassez de bases de dados padronizadas e abertas, o que dificulta a reprodutibilidade e comparação entre estudos (TIAN et al., 2021).

Além das lacunas relacionadas à variabilidade climática futura e à resiliência térmica, observa-se que a maior parte dos estudos concentra-se predominantemente em métricas associadas ao consumo energético, como CT, enquanto análises voltadas a edificações naturalmente ventiladas, baseadas em indicadores de conforto térmico como GH e AT, ainda são relativamente escassas. Essa assimetria limita a compreensão do desempenho térmico em contextos nos quais estratégias passivas desempenham papel central, especialmente em climas quentes ou mistos. Diante desse cenário, torna-se relevante o desenvolvimento de abordagens integradas que considerem simultaneamente múltiplas métricas de desempenho, como CT, GH, AT e RT, avaliadas tanto sob condições climáticas atuais quanto sob cenários futuros. Ademais, a incorporação de pontos de referência no processo decisório desponta como uma estratégia promissora para explicitar preferências do tomador de decisão na análise de soluções de compromisso. Nesse contexto, a integração entre modelos preditivos baseados em aprendizado de máquina e técnicas de otimização multiobjetivo apresenta-se como um caminho potencial para viabilizar a exploração eficiente do espaço de soluções e a análise sistemática dos *trade-offs* entre desempenho térmico, conforto e eficiência.

3 Abordagem Proposta

A abordagem proposta neste trabalho integra simulações termoenergéticas, modelagem preditiva e otimização multiobjetivo para identificar combinações construtivas que conciliem conforto térmico, eficiência energética, custo de materiais e emissões de CO₂. A metodologia foi organizada para possibilitar a análise de um grande número de alternativas de projeto sob condições climáticas atuais e futuras, considerando três cidades brasileiras com climas distintos: São Paulo, Belém e Curitiba. Também incorpora as preferências de tomadores e tomadoras de decisão por meio da atribuição de pesos aos critérios de otimização e da seleção de regiões específicas da fronteira de Pareto conforme diferentes prioridades. A Figura 3.1 apresenta uma visão geral do método adotado.

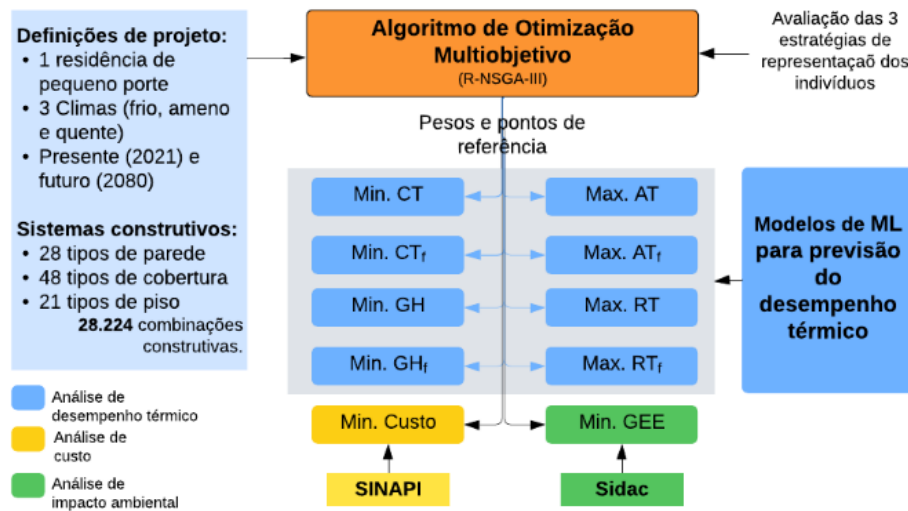


Figura 3.1: Fluxograma geral da metodologia da pesquisa

Fonte: Elaborado pelo autor.

Com base nas métricas de desempenho termoenergético, econômico e ambiental apresentadas anteriormente, este trabalho formula um problema de otimização multiobjetivo para apoiar a seleção de sistemas construtivos de edificações residenciais. O objetivo é identificar combinações de sistemas de paredes, pisos e coberturas que apresentem soluções de compromisso entre desempenho térmico, custo e emissões de dióxido de carbono, considerando simultaneamente cenários de clima presente e futuro.

O problema é caracterizado por um espaço de decisão, composto por um conjunto finito de alternativas construtivas para cada elemento da envoltória da edificação. Para cada combinação candidata, as funções objetivo são avaliadas a partir dos modelos computacionais desenvolvidos, permitindo quantificar o impacto da escolha dos sistemas construtivos sobre o desempenho global da edificação.

Adota-se uma abordagem de otimização multiobjetivo, na qual não se busca uma única solução ótima, mas sim um conjunto de soluções não dominadas que aproximam a frente de Pareto do problema. Dessa forma, a formulação proposta possibilita analisar explicitamente os conflitos existentes entre os diferentes objetivos, fornecendo subsídios quantitativos para a tomada de decisão em projetos de edificações sob a perspectiva de eficiência energética, viabilidade econômica e sustentabilidade ambiental. As equações (3.1) até a (3.3) apresentam a formulação matemática do problema de otimização multiobjetivo considerado neste trabalho, definindo o vetor de funções objetivo, o vetor de variáveis de decisão e o espaço de busca associado.

$$\begin{aligned} \min_{\mathbf{x}} \mathbf{F}(\mathbf{x}) = & \left[CT^{\text{pres}}(\mathbf{x}), CT^{\text{fut}}(\mathbf{x}), GH^{\text{pres}}(\mathbf{x}), GH^{\text{fut}}(\mathbf{x}), \right. \\ & (1 - AT^{\text{pres}}(\mathbf{x})), (1 - AT^{\text{fut}}(\mathbf{x})), RT^{\text{pres}}(\mathbf{x}), RT^{\text{fut}}(\mathbf{x}), \\ & \left. \text{Custo}(\mathbf{x}), CO2(\mathbf{x}) \right] \end{aligned} \quad (3.1)$$

$$\mathbf{x} = (x_{pa}, x_{pi}, x_{co}) \quad (3.2)$$

$$x_{pa} \in \mathcal{P}, \quad x_{pi} \in \mathcal{J}, \quad x_{co} \in \mathcal{C} \implies \mathbf{x} \in \mathcal{X} = \mathcal{P} \times \mathcal{J} \times \mathcal{C} \quad (3.3)$$

onde:

- $\mathbf{F}(\mathbf{x})$ é o vetor de funções objetivo do problema, conforme a equação (3.1).
- \mathbf{x} é o vetor de variáveis de decisão, composto por três escolhas: x_{pa} (sistema de parede), x_{pi} (sistema de piso) e x_{co} (sistema de cobertura), conforme a equação (3.2).

- \mathcal{P} é o conjunto finito de alternativas disponíveis para sistemas de parede. Cada elemento de \mathcal{P} corresponde a uma composição construtiva candidata de parede considerada neste trabalho.
- \mathcal{J} é o conjunto finito de alternativas disponíveis para sistemas de piso. Cada elemento de \mathcal{J} corresponde a uma composição construtiva candidata de piso considerada neste trabalho.
- \mathcal{C} é o conjunto finito de alternativas disponíveis para sistemas de cobertura. Cada elemento de \mathcal{C} corresponde a uma composição construtiva candidata de cobertura considerada neste trabalho.
- \mathcal{X} é o espaço de busca do problema, isto é, o conjunto de todas as combinações possíveis entre paredes, pisos e coberturas consideradas: $\mathcal{X} = \mathcal{P} \times \mathcal{J} \times \mathcal{C}$, conforme a equação (3.3).
- O sobrescrito **pres** indica avaliação no cenário de **clima presente** (ano de referência), enquanto **fut** indica avaliação no cenário de **clima futuro**. Em ambos os casos, as métricas são calculadas a partir das séries simuladas para a edificação e para o modelo de ocupação adotado.

Descrição das funções objetivo:

1. $CT^{\text{pres}}(\mathbf{x})$ e $CT^{\text{fut}}(\mathbf{x})$ representam a carga térmica anual total, definida como a soma das cargas de aquecimento e de resfriamento associadas à solução \mathbf{x} , para os cenários de clima presente e futuro, respectivamente. Tipicamente, CT é expresso em energia anual, por exemplo em kWh/ano.
2. $GH^{\text{pres}}(\mathbf{x})$ e $GH^{\text{fut}}(\mathbf{x})$ representam o indicador de Graus-Hora associado ao desconforto térmico para a solução \mathbf{x} , nos cenários de clima presente e futuro, respectivamente. O GH é usualmente expresso em °C·h.
3. $AT^{\text{pres}}(\mathbf{x})$ e $AT^{\text{fut}}(\mathbf{x})$ representam a Autonomia Térmica, definida como o percentual de horas ocupadas em que a temperatura operativa interna permanece dentro da

faixa de conforto térmico. Por se tratar de uma métrica de maximização, a Autonomia Térmica foi convertida para minimização por meio das funções $(1 - AT^{\text{pres}}(\mathbf{x}))$ e $(1 - AT^{\text{fut}}(\mathbf{x}))$. A AT é adimensional e pode ser apresentada em fração (0 a 1) ou em percentual (%).

4. $RT^{\text{pres}}(\mathbf{x})$ e $RT^{\text{fut}}(\mathbf{x})$ representam a Resiliência Térmica associada à solução \mathbf{x} , calculada para os cenários de clima presente e futuro. Neste trabalho, a Resiliência Térmica é quantificada por meio da unidade $^{\circ}\text{C h SET}$. Por se tratar de uma métrica associada à intensidade do desconforto térmico em condições críticas, RT é tratada como uma função objetivo de minimização, conforme a definição do indicador adotada.
5. $\text{Custo}(\mathbf{x})$ representa o custo associado à solução \mathbf{x} , calculado a partir da composição de materiais e dos critérios econômicos definidos. O custo é expresso em moeda corrente (R\$), conforme o escopo econômico adotado.
6. $\text{CO}_2(\mathbf{x})$ representa a emissão de dióxido de carbono associada à solução \mathbf{x} , conforme o escopo considerado. Essa métrica representa emissões incorporadas, sendo usualmente expressa em kgCO_2 .

Adicionalmente, este trabalho considera a aplicação de pesos para refletir a importância relativa de cada função objetivo. Para isso, os valores das funções objetivo são previamente normalizados por meio da normalização Min-Max, de modo a torná-los comparáveis em uma escala adimensional comum. A equação (3.4) demonstra a normalização Min-Max.

$$\hat{f}_i(\mathbf{x}) = \frac{f_i(\mathbf{x}) - f_i^{\min}}{f_i^{\max} - f_i^{\min}}, \quad i = 1, \dots, m \quad (3.4)$$

onde f_i^{\min} e f_i^{\max} representam, respectivamente, os menores e maiores valores observados para o objetivo i , e m é o número total de funções objetivo.

Assim, o problema busca identificar soluções de compromisso que conciliem desempenho termoenergético no clima presente e futuro, redução de custo e redução das emissões de dióxido de carbono.

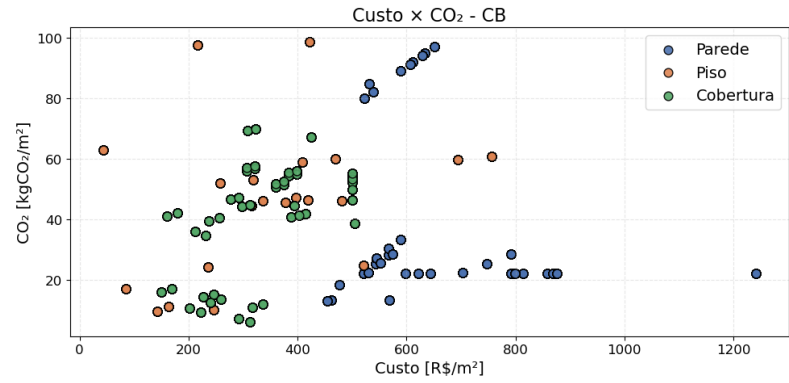
3.1 Sistemas Construtivos

Em estudos preliminares desta equipe de pesquisa, foram catalogados materiais que compõem 28 tipos de parede, 21 tipos de pisos e 48 tipos de coberturas, totalizando 28.224 combinações construtivas (MENDES et al., 2025). No Apêndice A, lista-se cada um desses sistemas construtivos, onde também foram incluídas propriedades termofísicas, como resistência térmica (R) e a capacidade térmica (Ct) de cada sistema. Também é listado o custo de construção e instalação de cada um deles, bem como o seu respectivo impacto ambiental (em emissões de kgCO₂). Esses dados foram retirados do estudo de Arcanjo et al. (2025), que realizou o levantamento com base na Tabela do Sistema Nacional de Pesquisa de Custos e Índices da Construção Civil (SINAPI) e no Sistema de Informação do Desempenho Ambiental da Construção (Sidac). A Figura 3.2 apresenta a dispersão dos sistemas construtivos analisados, quanto ao custo e emissão de CO₂. Por sua vez, a Figura 3.3 apresenta essa dispersão, em relação às propriedades termofísicas (R e Ct). A Tabela 3.1 ilustra 3 exemplos da base de dados.


Tabela 3.1: Exemplos de sistemas construtivos analisados

Sistema	Tipo	Camadas	Espessura total (m)	R (m²K/W)	Ct (kJ/m²K)
co48	Cobertura	Reboco + Laje treliçada de EPS + Impermeabilizante	0.143	0.31	181.21
pi01	Piso	Contrapiso + Argamassa colante + Porcelanato	0.045	0.04	86.00
pa04	Parede	Reboco isolante + Bloco cerâmico + Reboco isolante	0.140	0.44	131.36

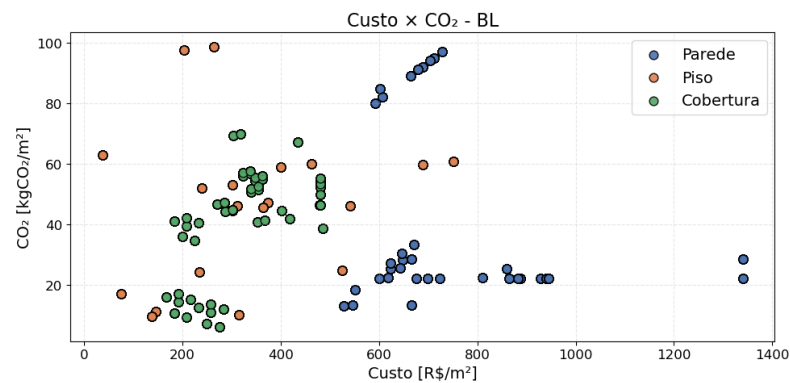
Fonte: Elaborado pelo autor.



(a) Curitiba



(b) São Paulo



(c) Belém

Figura 3.2: Dispersão dos sistemas construtivos por custo e emissão de CO_2 *Fonte: Elaborado pelo autor.*




Figura 3.3: Dispersão dos sistemas construtivos por resistência térmica (R) e capacidade térmica (C_t)

Fonte: Elaborado pelo autor.

Como as combinações construtivas não apresentam distribuição contínua ou uniforme, a comparação direta com valores extremos não seria estatisticamente representativa. Assim, adotou-se uma abordagem baseada em medidas robustas de posição: o quartil inferior (Q_1), a mediana (Md) e o quartil superior (Q_3). Nesse contexto, Q_1 e Q_3 delimitam a faixa central da distribuição, correspondendo, respectivamente, aos valores abaixo dos quais estão 25% e 75% dos resultados. Já a Md representa o ponto central dessa distribuição, dividindo os valores em duas metades iguais. A Tabela 3.2 apresenta as estatísticas dos parâmetros utilizados nas análises.

Tabela 3.2: Estatísticas dos parâmetros utilizados nas análises

Parâmetro	Q1	Mediana	Q3
$R \text{ (m}^2 \cdot \text{K)/W}$	0.22	0.29	0.39
$C_t \text{ (kJ/(m}^2 \cdot \text{K))}$	114.07	197.94	265.88
Custo Curitiba (R\$)	81170.7	89838.8	103024.8
Custo São Paulo (R\$)	77204.6	85955.5	99575.0
Custo Belém (R\$)	88443.0	97318.0	111409.8
$\text{CO}_2 \text{ (kgCO}_2\text{)}$	5248.7	6411.4	10170.2

Fonte: Elaborado pelo autor.

3.2 Edificação e Climats Analisados

Neste trabalho, foi analisada uma habitação de interesse social de pequeno porte, com área total de 40 m², conforme representado na Figura 3.4. A edificação é térrea, unifamiliar e possui uma configuração funcional simples, composta por sala, banheiro e dois dormitórios.

Para representar diferentes condições climáticas do território brasileiro, foram selecionadas três cidades localizadas em distintas zonas bioclimáticas brasileiras (ZBs), conforme a NBR 15220 (ABNT, 2024b): Curitiba (ZB 1M), São Paulo (ZB 2M) e Belém (ZB 6A). Ao longo do texto, essas cidades serão tratadas de forma relativa como clima frio, ameno e quente, respectivamente, de modo a facilitar a interpretação dos resultados.



Figura 3.4: HIS 1 – Esquerda: maquete 3D. Meio: maquete humanizada. Direita: planta baixa.

Fonte: (OLIVEIRA, 2025)

Além do clima atual (ABNT, 2024b), o presente trabalho também utiliza arquivos climáticos projetados para o ano de 2080, permitindo avaliar o desempenho térmico das edificações em cenários de mudança climática. Essa decisão é fundamentada na ABNT (2024b), que estabelece requisitos de desempenho associados à vida útil de projeto, de modo que a análise não se restringe às condições climáticas presentes, mas considera a manutenção do desempenho ao longo do tempo. Assim, o horizonte de 2080 é adotado como um cenário representativo de longo prazo, possibilitando verificar se as soluções avaliadas permanecem adequadas diante de condições climáticas futuras. Esses arquivos foram desenvolvidos por Vaz et al. (2024) por meio do *Future Weather Generator* (FWG), utilizando o cenário SSP2-4.5 do CMIP-6, que representa um futuro intermediário, marcado por esforços moderados de mitigação de emissões. Trata-se de um cenário ampla-

mente empregado em pesquisas de planejamento urbano e resiliência térmica por oferecer projeções consistentes e realistas para análises de adaptação e mitigação climática (USTA; TEYMOURI; CHATTERJEE, 2022).

3.3 Modelo Substituto para Avaliação do Desempenho Térmico

Como se verifica na Tabela 3.3, foi desenvolvido um modelo específico para prever cada métrica de desempenho térmico, abrangendo Carga Térmica (CT), Graus-Hora (GH), Autonomia Térmica (AT) e Resiliência Térmica (RT). Cada métrica também possui uma versão para o presente e outra para o futuro, identificadas pelo subíndice f . Todos os modelos foram treinados utilizando o conjunto completo de variáveis de entrada, composto pelos valores de resistência térmica (R) e capacidade térmica (Ct) das paredes, do piso e da cobertura sendo os subíndices p , pi e c empregados para identificar, respectivamente, parede, piso e cobertura.

Tabela 3.3: Modelos de aprendizado de máquina desenvolvidos

#	Métrica prevista	Variáveis de entrada
1	CT	$R_p, Ct_p, R_{pi}, Ct_{pi}, R_c, Ct_c$
2	CT_f	
3	GH	
4	GH_f	
5	AT	
6	AT_f	
7	RT	
8	RT_f	

Fonte: Elaborado pelo autor.

Para a elaboração dos modelos de ML, este trabalho se baseou nos estudos anteriores de Mendes et al. (2025), Louback (2025) e Oliveira (2025). Esses estudos desenvolveram um modelo de ML para prever o desempenho térmico de edificações a partir das métricas de CT e GH no clima presente, com o mesmo banco de dados analisado

neste trabalho. Para isso, foram realizadas simulações no EnergyPlus, avaliando todas as permutações de conjuntos de parede, piso e cobertura, aplicadas a duas residências unifamiliares de 40 m² em Curitiba (frio), São Paulo (ameno) e Belém (quente). As simulações seguiram as configurações da NBR 15575 e geraram valores de CT e GH utilizados como variáveis-alvo para treinar modelos XGBoost. As propriedades termofísicas de cada combinação construtiva (R e Ct) foram empregadas como variáveis de entrada, e os modelos foram avaliados por meio de validação cruzada (k-fold; k=10) e das métricas R², MAE e MAPE.

Os resultados evidenciaram alta precisão. Em todos os cenários analisados, os modelos apresentaram R² superior a 0,99 e MAPE inferior a 6,1%, frequentemente abaixo de 1,1%. Exemplos incluem o modelo de CTr em Curitiba, que atingiu R² de 0,9993 e MAPE de apenas 0,35%, e o modelo de GHc em São Paulo, com R² de 0,9995 (OLIVEIRA, 2025).

Adicionalmente, um dos achados mais relevantes de Mendes et al. (2025) foi a demonstração da eficácia da redução do banco de dados. Para testar essa hipótese, o conjunto completo de instâncias foi gradualmente reduzido para treinos contendo apenas 1% a 10% das amostras, enquanto o restante do banco (99% a 90%) foi utilizado como teste. Em cada caso, foram realizadas 100 repetições para reduzir o efeito de variações aleatórias. Mesmo com apenas 1% do banco de dados usados para treinamento, os modelos mantiveram R² acima de 0,81. A partir de 2% das instâncias, o R² superou 0,90 em todos os testes, apresentando baixa dispersão e desvios-padrão inferiores a 1%. Esses resultados demonstraram que não é necessário treinar modelos com a totalidade das simulações energéticas: simular apenas 2% do banco no EnergyPlus (procedimento que leva aproximadamente uma hora em um computador básico) já permite treinar modelos suficientemente precisos para aplicações profissionais.

Esse procedimento foi tratado como uma prova de conceito. Para verificar sua capacidade de generalização, em cenários em que não foi simulado o banco de dados completo, simulou-se apenas 10% das combinações totais e, posteriormente, essas instâncias foram utilizadas no treinamento do ML. Essa abordagem foi escolhida por ser conservadora e, ainda assim, reduzir cerca de 90% do custo operacional associado à construção de

modelos treinados com 100% das instâncias. A eficácia desses modelos foi avaliada com mil instâncias aleatórias e independentes do treinamento, que também foram simuladas. Mais detalhes podem ser consultados em Mendes et al. (2025), Oliveira (2025) e Louback (2025).

No presente trabalho, foi mantido o uso de 10% do banco de dados para o treinamento do modelo, mas aprimorou-se a seleção das instâncias de treino por meio de agrupamento não supervisionado a partir dos valores de R e Ct de cada sistema construtivo. O objetivo dessa etapa foi garantir maior diversidade estrutural no conjunto de treinamento, evitando que o modelo fosse ajustado apenas com combinações muito semelhantes entre si. Para isso, aplicou-se o algoritmo de agrupamento k-means sobre todas as instâncias disponíveis. Do total de grupos definidos (correspondentes a 10% do total de instâncias), cada grupo representa um subconjunto de combinações construtivas com características termofísicas semelhantes. Em seguida, foi selecionada apenas uma instância por grupo, garantindo que instâncias muito similares não fossem simultaneamente escolhidas. Essa abordagem reduz redundâncias e melhora a representatividade do conjunto utilizado no treinamento. Além disso, para o presente trabalho, foram ampliadas as métricas de avaliação do desempenho térmico, incorporando também AT e RT, além de projeções de desempenho térmico para o futuro (2080).A Tabela 3.4 apresenta os resultados comparativos entre a formulação adotada por Oliveira (2025) e a adotada neste trabalho. Verifica-se uma melhoria no clima ameno e uma aproximação dos resultados nos demais climas. Adicionalmente, o presente trabalho estende os modelos por meio da inclusão de métricas complementares.

Tabela 3.4: Comparativo de desempenho dos modelos desenvolvidos por (OLIVEIRA, 2025) e neste trabalho

Cidade	Métrica prevista	R ²		MAE		MAPE(%)		RMSE	
		Oliveira (2024)	Pres. trab.	Oliveira (2024)	Pres. trab.	Oliveira (2024)	Pres. trab.	Oliveira (2024)	Pres. trab.
Curitiba (frio)	CT (MJ)	0,994	0,997	23,659	24,30	0,630	0,377	–	36,381
	GH (°C·h)	0,978	0,977	98,343	62,936	1,404	0,423	–	91,18
	RT (°C·h SET)	–	0,990	–	1,652	–	2,158	–	2,211
	AT (%)	–	0,994	–	0,002	–	0,402	–	0,002

(continuação) Comparativo de desempenho dos modelos

Cidade	Métrica prevista	R ²		MAE		MAPE(%)		RMSE	
		Oliveira (2024)	Pres. trab.	Oliveira (2024)	Pres. trab.	Oliveira (2024)	Pres. trab.	Oliveira (2024)	Pres. trab.
	CTf (MJ)	–	1,000	–	6,263	–	0,125	–	97,123
	GHf (°C·h)	–	0,997	–	49,979	–	0,855	–	69,246
	RTf (%)	–	0,994	–	1,607	–	2,669	–	2,369
	ATf (%)	–	0,998	–	0,001	–	0,131	–	0,001
São Paulo (ameno)	CT (MJ)	0,982	0,996	25,994	22,181	0,978	0,496	–	31,507
	GH (°C·h)	0,988	0,979	62,252	52,205	1,500	0,653	–	78,605
	RT (°C·h SET)	–	0,949	–	0,065	–	313,0	–	0,118
	AT (%)	–	0,993	–	0,002	–	0,351	–	0,003
	CTf (MJ)	–	0,999	–	0,986	–	0,147	–	141,000
	GHf (°C·h)	–	0,996	–	74,710	–	0,912	–	105,280
	RTf (%)	–	0,995	–	1,728	–	3,545	–	2,516
	ATf (%)	–	0,994	–	0,001	–	0,101	–	0,001
Belém (quente)	CT (MJ)	0,997	0,992	20,379	27,590	0,191	0,263	–	31,16
	GH (°C·h)	0,995	0,979	65,696	52,205	0,374	0,653	–	78,605
	RT (°C·h SET)	–	0,995	–	1,312	–	1,312	–	1,915
	AT (%)	–	0,993	–	0,002	–	0,351	–	0,003
	CTf (MJ)	–	0,997	–	35,852	–	0,185	–	47,70
	GHf (°C·h)	–	0,927	–	108,045	–	0,228	–	277,116
	RTf (%)	–	0,994	–	1,697	–	0,370	–	2,375
	ATf (%)	–	0,992	–	0,003	–	0,194	–	0,004

Fonte: Elaborado pelo autor.

3.4 Otimização Multiobjetivo

Na etapa de otimização multiobjetivo, os parâmetros de desempenho térmico (CT, GH, AT e RT) foram avaliados por meio dos modelos de ML desenvolvidos neste estudo, enquanto os critérios de impacto ambiental e custo dos materiais foram obtidos a partir do banco de dados compilado por Arcanjo et al. (2025). Para não enviesar esses objetivos, dada suas diferenças de escala, inicialmente, esses dados foram normalizados com o método básico “min-max” (equação (3.5))

$$f'(x) = \frac{f(x) - f_{\min}}{f_{\max} - f_{\min}} \quad (3.5)$$

Esses critérios, no entanto, apresentam conflitos naturais entre si, como já discutido na literatura (Cruz et al., 2024b; Mendes et al., 2024b). Por exemplo, uma combinação construtiva que reduz significativamente CT pode exigir materiais de maior isolamento, o que normalmente eleva o custo e aumentando as emissões de CO₂ associadas à produção desses materiais isolantes. De forma semelhante, uma alternativa muito barata pode apresentar pior desempenho térmico e maior desconforto ao longo do ano. Para lidar com essas contradições e permitir que a ferramenta reflita preferências específicas de quem toma a decisão, optou-se pelo uso do algoritmo *Reference-point based Non-dominated Sorting Genetic Algorithm III* (R-NSGA-III), amplamente reconhecido por sua capacidade de explorar de forma eficiente regiões de interesse da fronteira de Pareto de acordo com os pesos e os pontos de referência definidos pelo usuário. A implementação foi realizada com o suporte da biblioteca Pymoo, em Python (BLANK; DEB, 2020).

3.4.1 Seleção da representação dos indivíduos

O problema de seleção de sistemas construtivos é de natureza discreta, pois cada parede, piso e cobertura deve ser escolhida dentro de um conjunto finito de alternativas. Para aumentar a robustez do modelo de otimização, foram avaliadas três estratégias de representação dos indivíduos da população: inteira, binária e *Gray Code* (SHASTRI; FRACHTENBERG, 2020; ROTHLAUF, 2006). Cada esquema determina como os genes são estruturados e manipulados pelos operadores evolutivos, influenciando a capacidade do algoritmo de explorar o espaço de busca e de refinar soluções localmente (YIQUN; XIANRUI, 2018). A comparação entre essas representações é essencial, uma vez que escolhas inadequadas de codificação podem levar à perda de diversidade, convergência prematura ou dificuldade no refinamento da fronteira de Pareto (YIQUN; XIANRUI, 2018).

Na representação inteira, cada indivíduo é descrito por um vetor composto por três variáveis inteiras, que indicam os índices da parede, do piso e da cobertura selecionados. Por exemplo, o indivíduo (2, 8, 5) representa a terceira parede da lista (índice 2), o nono piso (índice 8) e a sexta cobertura (índice 5). A partir desse triplo construtivo,

são extraídos os valores de transmitância térmica (U), capacidade térmica (Ct) e custos, que servem como entrada nos modelos de ML, resultando nas previsões das métricas CT, GH, AT e RT para os cenários presente e futuro.

Embora o problema seja discreto, a representação inteira foi integrada a operadores tradicionalmente aplicados em espaços contínuos, devidamente adaptados ao domínio inteiro (BLANK; DEB, 2020). A população inicial foi gerada pelo método *IntegerRandomSampling*, que sorteia cada gene dentro dos limites válidos de cada categoria (BLANK; DEB, 2020). No cruzamento, empregou-se o operador SBX, no qual os descendentes são obtidos como combinações intermediárias entre dois pais; os valores contínuos gerados são posteriormente arredondados e reparados para garantir coerência com os índices disponíveis (DEB; SUNDAR, 2006). A mutação foi implementada por meio da mutação polinomial, que introduz pequenas perturbações contínuas sobre os genes inteiros, também submetidas a arredondamento e reparo para assegurar a validade das soluções (BLANK; DEB, 2020).

Na representação binária, cada alternativa é codificada por um bloco de bits, cujo tamanho corresponde ao número mínimo necessário para representar todas as opções disponíveis (SHASTRI; FRACHTENBERG, 2020). $n_{\text{parede}} = 28$, $n_{\text{piso}} = 21$ e $n_{\text{cobertura}} = 48$ os blocos possuem 5, 5 e 6 bits, respectivamente, totalizando 16 bits por indivíduo. Cada indivíduo é, portanto, um vetor binário formado pela concatenação desses três blocos. Por exemplo, o bloco (1, 0, 1, 1, 0) referente à parede é interpretado como o número decimal 22, que é convertido em um índice válido pela operação de divisão inteira (SHASTRI; FRACHTENBERG, 2020). Os operadores evolutivos atuam diretamente sobre os bits: a população inicial é gerada por *BinaryRandomSampling*, o cruzamento é feito por *one-point crossover* e a mutação emprega *bit flip* com baixa probabilidade, invertendo *bits* individuais e gerando novas combinações construtivas (BLANK; DEB, 2020).

Na representação Gray Code, cada alternativa também é codificada por blocos de bits, porém utilizando um esquema em que números consecutivos diferem por apenas um *bit* (ROTHLAUF, 2006). Essa característica promove transições mais suaves no espaço de busca, reduzindo saltos abruptos e favorecendo a exploração de vizinhanças estruturadas. Por exemplo, enquanto o número 2 é representado como 010 no binário comum, em Gray

Code torna-se 011, e o número 3 torna-se 010 (apenas um *bit* muda entre eles). Cada indivíduo é formado pela concatenação dos blocos de parede, piso e cobertura codificados em Gray Code, que depois são decodificados novamente para inteiros antes da avaliação. Os operadores evolutivos atuam da mesma forma que na representação binária: o cruzamento é realizado por *one-point crossover*, enquanto a mutação aplica *bit flip* com baixa probabilidade, gerando alterações graduais nos valores inteiros correspondentes (SHASTRI; FRACHTENBERG, 2020). Após a decodificação, padrões que produzam índices fora dos limites de cada conjunto de alternativas são considerados não mapeados e, portanto, descartados e substituídos por novas amostras, garantindo que apenas soluções válidas sejam avaliadas.

A definição dos hiperparâmetros do algoritmo R-NSGA-III (i.e., tamanho da população, taxa de cruzamento, taxa de mutação, operador de cruzamento, operador de mutação, parâmetro η e número de gerações) foi realizada em duas etapas complementares. Inicialmente, empregou-se um *random search*, que avaliou diversas combinações desses hiperparâmetros com base no hipervolume das fronteiras de Pareto geradas (BERGSTRA; BENGIO; RACHMAD, 2012). Em seguida, os melhores conjuntos foram refinados por meio do Optuna, que utiliza amostragem eficiente orientada por otimização bayesiana (AKIBA et al., 2019). Essa abordagem reduziu o custo computacional e permitiu concentrar a busca em regiões promissoras do espaço de hiperparâmetros. Cada representação (inteira, binária e Gray Code) teve seu próprio conjunto final de hiperparâmetros ajustado antes da comparação entre elas e seus valores estão apresentados no Apêndice B.

Após a etapa de otimização dos hiperparâmetros para cada uma das três representações de solução avaliadas, tornou-se necessário identificar qual delas apresentava o melhor desempenho global na resolução do problema multiobjetivo. Para isso, foi conduzida uma análise comparativa fundamentada em métricas amplamente consolidadas na literatura de otimização evolutiva multiobjetivo (YIQUN; XIANRUI, 2018).

Cada representação foi executada 10 vezes de forma independente. A repetição das execuções permitiu capturar a variabilidade intrínseca aos algoritmos evolutivos, possibilitando avaliar a robustez estatística associada a cada forma de representação. A comparação entre as representações considerou três indicadores de qualidade da fronteira

de Pareto obtida:

1. HV (*Hypervolume*)
2. IGD⁺
3. *Spacing*

3.4.2 Preferências do(a) usuário(a) e seleção da melhor combinação construtiva

Apesar da normalização inicial das funções objetivo, os valores das combinações ótimas na fronteira de Pareto foram propositalmente desbalanceados por meio da aplicação de pesos que refletem as preferências dos usuários. Essa estratégia permite resultados mais personalizados a diferentes cenários de projeto e uso da edificação, ajustando a importância relativa de cada critério. Os pesos adotados nesta etapa foram definidos de forma hipotética para ilustrar dois possíveis cenários. Além disso, foram estabelecidos pontos de referência para algumas métricas, utilizados exclusivamente durante a execução do algoritmo com o objetivo de direcionar a busca para regiões específicas da fronteira de Pareto. Já os pesos foram aplicados apenas posteriormente, durante a análise da fronteira, para apoiar a seleção da solução construtiva mais adequada em cada cenário.

Como se observa na Tabela 3.5, o Cenário 1 atribui maior peso às métricas de desempenho passivo (GH, AT e RT, presentes e futuras) e ao CO₂, refletindo uma situação em que o(a) usuário(a) prioriza ventilação natural, conforto sem climatização e sustentabilidade. Esse cenário representa edificações destinadas a reduzir a dependência de ar-condicionado, valorizando soluções bioclimáticas e maior resiliência térmica ao longo do tempo.

Já o Cenário 2 concentra maior peso em custo inicial e nas métricas de carga térmica (CT e CTf), correspondendo a um(a) usuário(a) que busca minimizar gastos de construção e custo de utilização da edificação (na forma de energia para o sistema AVAC), tanto no presente quanto no futuro. As métricas passivas permanecem no modelo, porém com menor relevância, alinhando-se a um perfil de decisão mais orientado por eficiência econômica do que por desempenho passivo. Nesse caso, os pontos de referência

fixados para CT e CTf (3500 kWh e 5500 kWh, respectivamente) orientam o algoritmo a privilegiar combinações com desempenho energético dentro desses limites, aproximando a otimização de uma visão mais pragmática e econômico-energética.

Tabela 3.5: Pesos usados nos cenários de otimização multiobjetivo

Métrica	Cenário 1	Cenário 2
CT	0,03	0,20
GH	0,18	0,03
RT	0,09	0,02
AT	0,13	0,03
CTf	0,03	0,15
GHf	0,18	0,03
RTf	0,09	0,02
ATf	0,13	0,03
Custo	0,06	0,40
CO ₂	0,08	0,09

Fonte: Elaborado pelo autor.

A seleção da melhor combinação construtiva em cada cenário foi realizada mediante o cálculo da distância euclidiana ponderada em relação ao ponto ideal, composta pelos melhores valores obtidos para cada função objetivo na fronteira de Pareto. Para cada alternativa, avaliou-se o afastamento entre seus valores normalizados e o ponto ideal, ponderando-se essa diferença pelos pesos atribuídos a cada métrica no respectivo cenário. Esse procedimento permite quantificar o quão próxima cada solução está do desempenho ótimo teórico, de modo que a alternativa associada ao menor valor de distância é considerada a mais adequada dentro das preferências do usuário. O cálculo adotado é apresentado a na equação (3.6).

$$D = \sqrt{\sum w_i (f_i - f_i^{ideal})^2} \quad (3.6)$$

onde

- f_i valor normalizado da função objetivo i para a solução avaliada

- f_i^* melhor valor obtido para a função objetivo i (ponto ideal)
- w_i peso atribuído à função objetivo i no cenário considerado
- n número total de métricas avaliadas

3.5 Análise dos Resultados

Após a obtenção das soluções ótimas, realizou-se uma etapa específica de análise destinada a avaliar a consistência e a robustez dos resultados. Para cada combinação de tipologia de edificação, clima e cenário, o algoritmo de otimização foi executado 100 vezes de forma independente, com sementes de inicialização distintas, evitando que as soluções dependessem de um único caminho de busca (EIBEN; SMITH, 2003). Ao final de cada execução, selecionou-se a solução com maior valor de hipervolume, resultando em um conjunto de 100 soluções ótimas por caso analisado. A partir desse conjunto, foram construídos histogramas de frequência que permitiram identificar quais sistemas de parede, piso e cobertura, bem como quais combinações completas, surgiram com maior recorrência entre as melhores soluções.

Essa etapa é fundamental porque permite transformar um conjunto amplo de soluções em informações claras sobre padrões de preferência do algoritmo. Soluções que aparecem repetidamente entre as 50 execuções tendem a ser mais robustas, pois mantêm desempenho elevado mesmo diante das variações estocásticas internas do processo de otimização (MANUEL; BRANKE; PAQUETE, 2021). A Figura 3.5 representa um fluxograma ilustrando a análise adotada.

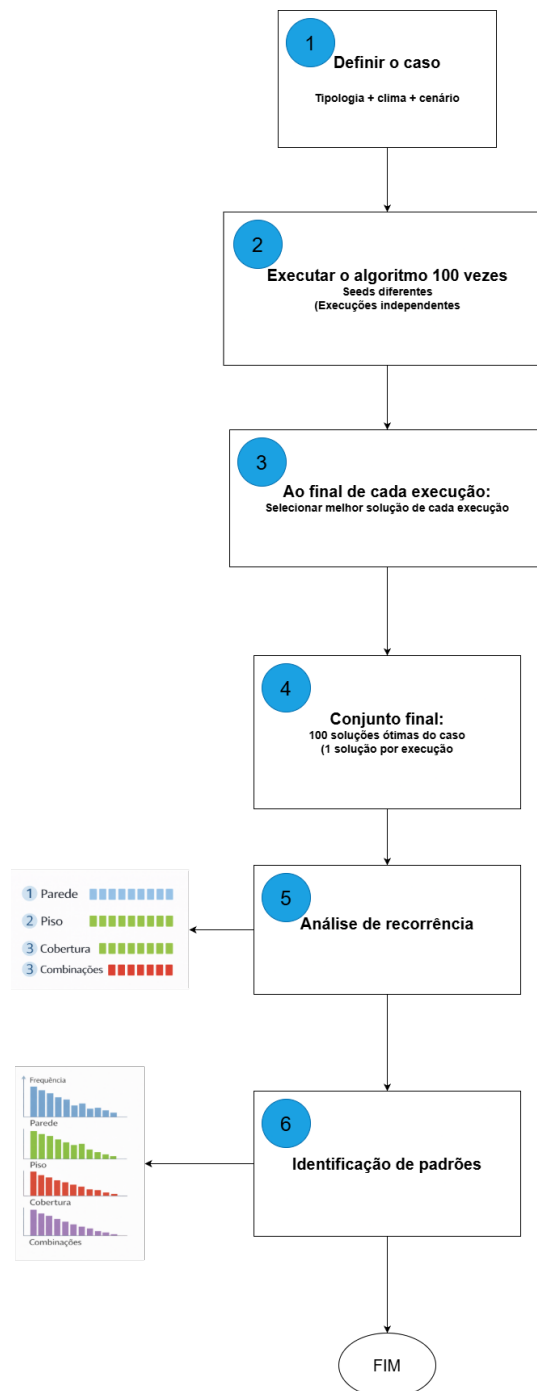


Figura 3.5: Fluxo da etapa de avaliação por múltiplas soluções.

Fonte: Elaborado pelo autor.

4 Experimentos e Resultados

4.1 Definição do melhor tipo de representação

Como apresentado na Tabela 4.1, a comparação entre as três representações avaliadas (discreta (inteira), binária e *Gray Code*) evidencia diferenças significativas no desempenho do algoritmo de otimização, considerando os indicadores HV, IGD^+ e *Spacing*, calculados ao longo de 10 execuções independentes.

Tabela 4.1: Comparação das três representações segundo HV, IGD^+ e *Spacing* (10 execuções).

Representação	HV (média \pm desvio)	IGD^+ (média \pm desvio)	<i>Spacing</i> (média \pm desvio)
Discreta (inteira)	0.959858 ± 0.000156	0.013501 ± 0.001420	0.101037 ± 0.000201
Binária	0.944149 ± 0.000013	0.018073 ± 0.000196	0.114499 ± 0.000230
<i>Gray Code</i>	0.964505 ± 0.000143	0.014643 ± 0.002470	0.095300 ± 0.000155

Fonte: Elaborado pelo autor.

Entre elas, a representação *Gray Code* obteve o melhor desempenho global, apresentando o maior valor médio de HV ($0,964505 \pm 0,000143$), o que indica maior aproximação da fronteira de Pareto ideal e melhor cobertura do espaço de soluções. Além disso, seu valor de *Spacing* ($0,095300 \pm 0,000155$) foi o menor dentre as representações analisadas, sugerindo uma distribuição mais uniforme das soluções ao longo da fronteira, característica desejável em algoritmos multiobjetivo (ZITZLER; DEB; THIELE, 2000).

Embora a representação discreta (inteira) tenha apresentado o menor valor de IGD^+ ($0,013501 \pm 0,001420$), indicando menor distância média entre sua fronteira e a fronteira de referência, esse benefício foi acompanhado de maior irregularidade na distribuição das soluções (*Spacing* = $0,101037 \pm 0,000201$), o que reduz a diversidade da fronteira obtida (YIQUN; XIANRUI, 2018). Já a representação binária apresentou os piores resultados em todas as métricas avaliadas, com destaque para o menor HV ($0,944149 \pm 0,000013$) e o maior *Spacing* ($0,114499 \pm 0,000230$), indicando frentes menos diversas, mais distantes da ideal e menos estáveis entre execuções (YIQUN; XIANRUI, 2018).

Esses resultados são coerentes com o comportamento esperado de cada esquema

de codificação. A representação *Gray Code*, ao garantir que números consecutivos diferem por apenas um bit, promove transições mais suaves no espaço de busca e reduz flutuações bruscas decorrentes da mutação (ROTHLAUF, 2006). Isso favorece uma exploração mais estruturada do espaço discreto e contribuindo para a geração de frentes mais consistentes e equilibradas. Em contraste, o esquema binário tradicional tende a produzir saltos abruptos no espaço de busca, o que pode prejudicar tanto a convergência quanto a diversidade, especialmente em problemas discretos e com alta correlação entre variáveis, como o observado neste estudo (EIBEN; SMITH, 2015).

A atuação dos esquemas de codificação foi coerente com o esperado na literatura. A *Gray Code* apresentou o melhor desempenho global, com maior HV e menor *Spacing*, resultado associado à sua maior localidade, que reduz saltos fenotípicos e favorece transições suaves no espaço de busca (ROTHLAUF, 2006).

Considerando o desempenho numérico obtido, a estabilidade entre execuções e a coerência teórica com o comportamento esperado das representações, o *Gray Code* foi selecionado como representação definitiva para os demais experimentos realizados neste trabalho.

4.2 Análise das melhores soluções

4.2.1 Análise de valores das melhores combinações

Com a representação definida, foram analisadas as melhores soluções construtivas para Curitiba, São Paulo e Belém, considerando 100 execuções do algoritmo em dois cenários distintos. A Tabela 4.2 apresenta um resumo desses resultados, comparando o desempenho das soluções otimizadas e relacionando-os ao comportamento global do espaço amostral completo (todas combinações possíveis avaliadas pelo algoritmo), o que permite avaliar o grau de melhoria obtido em relação às combinações possíveis.

Tabela 4.2: Comparação estatística entre soluções otimizadas e espaço amostral

Cidade	Métrica	Espaço amostral completo			Otimização do Cenário 1			Otimização do Cenário 2		
		Q1	Md	Q3	Q1	Md	Q3	Q1	Md	Q3
Curitiba	CT [kWh]	1681.2	1868.7	1917.3	1460.3	1474.6	1495.6	1358.7	1460.1	1470.5
	GH [°C h]	14702.3	14995.0	15352.0	13849.0	13907.1	14103.0	13849.4	13849.4	13877.6
	AT [%]	40	40	40	50	50	50	50	50	50

Continua na próxima página

Cidade	Métrica	Espaço amostral completo			Otimização do Cenário 1			Otimização do Cenário 2		
		Q1	Md	Q3	Q1	Md	Q3	Q1	Md	Q3
	RT	77.5	93.7	103.6	45.0	50.5	60.9	34.8	44.1	47.6
	[°C h SET]									
	CT _f	1341.34	1513.4	1542.9	1207.8	1211.3	1235.4	1111.3	1208.0	1210.7
	[kWh]									
	GH _f	5259.8	6198.6	6689.6	3488.7	3557.6	3912.5	3272.9	3480.2	3534.1
	[°C h]									
	AT _f	70	70	70	70	80	80	80	80	80
São Paulo	[%]									
	RT _f	47.0	74.2	89.8	15.7	18.4	25.5	10.8	15.1	17.1
	[°C h SET]									
	Custo	81170.7	89838.8	103024.8	70336.9	73685.5	79480.4	69370.6	72828.9	74634.9
	[R\$]									
	CO ₂	5248.7	6411.4	10170.2	3440.8	4296.4	7265.5	2948.0	9154.9	9570.0
	[kgCO ₂]									
Belém	CT	1185.5	1320.3	1358.8	928.0	949.7	1021.7	928.3	950.4	1049.3
	[kWh]									
	GH	7728.4	7990.0	8338.1	7084.6	7117.6	7348.5	7078.0	7105.5	7360.4
	[°C h]									
	AT	60	60	60	60	60	60	60	60	60
	[%]									
	RT _f	0.0	0.1	0.5	0	0	0	0	0	0
	[°C h SET]									
	CT _f	1787.9	1987.5	2007.6	1546.1	1547.8	1673.3	1547.0	1551.8	1695.4
	[kWh]									
	GH _f	7369.1	8629.8	9282.9	4558.6	4629.6	5278.6	4585.6	4688.1	5351.5
	[°C h]									
	AT _f	70	70	70	70	70	70	70	70	70
	[%]									
	RT _f	46.2	72.9	89.4	2.6	3.0	8.1	2.7	3.8	9.8
	[°C h SET]									
	Custo	77204.6	85955.5	99575.0	63869.1	65544.1	69604.1	63962.1	67417.4	72528.7
	[R\$]									
	CO ₂	5248.7	6411.4	10170.2	4871.1	9422.8	10001.6	3046.7	9114.0	9477.8
	[kgCO ₂]									
	CT	2830.9	2918.1	2984.3	2822.5	2917.7	2951.0	2769.8	2817.2	2949.8
	[kWh]									
	GH	7728.4	7990.0	8338.1	7570.2	7937.8	8416.4	7381.3	7558.1	7905.1
	[°C h]									
	AT	60	60	60	60	60	60	60	60	60
	[%]									
	RT _f	44.3	61.6	74.7	22.4	34.5	73.8	5.5	13.9	28.9
	[°C h SET]									
	CT _f	5224.2	5455.4	5546.7	5127.9	5373.6	5464.3	5004.8	5107.6	5288.8
	[kWh]									
	GH _f	46852.9	47847.1	48131.0	45937.9	46504.6	47961.9	45535.1	45834.0	45904.1
	[°C h]									
	AT _f	0	0	0	0	0	0	0	0	0
	[%]									
	RT _f	452.4	479.1	487.5	423.6	452.4	485.1	410.3	420.8	425.4
	[°C h SET]									
	Custo	88443.0	97318.0	111409.8	81670.1	92146.3	100320.6	69363.1	76757.5	81351.4
	[R\$]									
	CO ₂	5248.7	6411.4	10170.2	4655.6	5968.2	8706.0	2719.2	4032.0	5721.2
	[kgCO ₂]									

Fonte: Elaborado pelo autor.

No Cenário 1, os pesos atribuídos priorizaram as métricas associadas ao conforto térmico passivo, com maior influência de GH e AT, incluindo suas projeções futuras. Como consequência, observa-se que a mediana das soluções otimizadas aproxima-se dos valores mínimos do espaço amostral para GH e GH_f, e dos valores máximos para AT e AT_f, com diferenças percentuais variando, em média, entre 3% e 25%, mas São Paulo tendo garantindo a maior variação (entre 13% e 20%). Esse comportamento indica que o algoritmo favoreceu configurações capazes de aumentar o número de horas em conforto térmico e reduzir a intensidade do desconforto nos períodos em que a edificação não atende às condições ideais, atendendo ao objetivo central de aprimorar o desempenho térmico passivo.

Em contraste, os valores de CT e CT_f apresentam desvios mais acentuados entre a mediana dos valores otimizados com os menores valores de todo campo amostral (en-

tre 12% e 20%), o que evidencia sua menor relevância relativa na função objetivo desse cenário. Ainda assim, o impacto não é negligenciável: a mediana das soluções otimizadas diferiu 255,03 kWh para CT e 274,53 kWh para CTf em relação à mediana do espaço amostral completo, considerando 1 ano de referência. Considerando que a maior tarifa de energia elétrica é no Pará, com R\$ 0,93/kWh (ENERGIA, 2025), e a menor é em Curitiba, com R\$ 0,62/kWh (ENERGIA, 2025), essa diferença pode representar relativas implicações financeiras ao longo de toda a vida útil da edificação. O conjunto desses resultados confirma o comportamento esperado em funções multiobjetivo baseadas em pesos. Critérios com maior importância atribuída tendem a apresentar soluções otimizadas mais próximas dos valores desejáveis, enquanto métricas menos priorizadas exibem maior variação e afastamento em relação ao desempenho ideal.

No Cenário 2, observou-se o comportamento oposto ao do Cenário 1. Os pesos foram propositalmente concentrados em custo da construção, CT e CTf, de modo a representar um cenário de uso consciente de sistemas de climatização (AVAC). Para orientar o processo de otimização, foram definidos pontos de referência para consumo energético: 2000 kWh para CT e 3000 kWh para CTf. Os resultados mostram a proximidade das medianas das soluções otimizadas aos pontos de referência de CT (87%) e CTf (87%). Quanto ao custo, é verificado desvios entre 22,9% e 47,5% entre a mediana dos valores otimizados com os menores valores de todo campo amostral, destacando a magnitude do peso que foi dada a esse critério.

Como os pesos atribuídos às métricas permanecem semelhantes entre o período atual e o futuro dentro de cada cenário, as soluções otimizadas resultam em respostas equivalentes para ambos os horizontes temporais. Assim, as análises apresentadas já refletem simultaneamente os dois momentos, garantindo que as melhorias observadas sejam válidas tanto para as condições presentes quanto para as projetadas.

4.2.2 Análise de recorrência das melhores combinações

A Figura 4.1 apresenta as combinações construtivas recorrentes (≥ 2 ocorrências) entre as 100 soluções finais obtidas no Cenário 1. Observa-se uma menor variabilidade em São Paulo, onde uma única combinação (pa34-pi4-co28) foi selecionada em 15 execuções, indi-

cando forte predominância dessa solução e sugerindo maior estabilidade da configuração ideal nesse clima. Em Curitiba, a dispersão é maior: duas combinações (pa34-pi4-co19 e pa34-pi4-co28) apresentaram recorrência moderada (5 aparições cada), enquanto o restante das soluções apresentou distribuição pulverizada ao longo das execuções. Já em Belém, apenas quatro combinações se repetiram, sendo a pa33-pi10-co20 a mais frequente, com três aparições. As outras três ocorreram apenas duas vezes, reforçando o caráter altamente distribuído das soluções.

Esse comportamento evidencia diferenças no grau de convergência das soluções entre os climas. Em cenários como São Paulo (e parcialmente Curitiba) a maior recorrência sugere que a otimização identifica um caminho construtivo mais consistente, indicando que pequenas variações nos materiais tendem a impactar menos significativamente o desempenho térmico. Por outro lado, em Belém, a baixa repetibilidade pode refletir dois fenômenos de forma separada ou integrada: (i) maior flexibilidade projetual, em que múltiplas combinações apresentam desempenho semelhante, ou (ii) menor influência isolada da envoltória no conforto térmico passivo, dada a predominância de condições externas adversas em clima quente e úmido.

Essa hipótese é reforçada pela observação de que, em Belém (e, em menor escala, em Curitiba) pequenas mudanças nos componentes construtivos resultam em variações discretas nos indicadores GH e AT (para presente e futuro). Isso reduz a dominância de uma solução única na otimização e sugere que, nesses contextos, estratégias complementares de projeto passivo, como sombreamento, ventilação cruzada, orientação solar e modulação de aberturas, podem exercer papel tão ou mais relevante que o ajuste isolado dos materiais da envoltória.




Figura 4.1: Melhores combinações no Cenário 1 com frequência maior ou igual a 2 para cada clima. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

A Figura 4.2 apresenta o mesmo mapeamento para o Cenário 2. Nesse caso, observou-se maior convergência dos resultados para São Paulo e Curitiba. Em Curitiba, a combinação pa34-pi4-co28 foi registrada 20 vezes (o maior valor de recorrência entre combinações construtivas de todo o estudo) indicando um forte consenso computacional sobre sua adequação quando consideradas as ponderações do segundo cenário. Em São Paulo, uma única, e a mesma solução do Cenário 1, concentrou a maior parte das ocorrências (pa34-pi1-co28), desta vez em 14 execuções. Já Belém apresentou comportamento semelhante ao observado no Cenário 1, com soluções variadas. Nesse cenário, houve somente uma combinação (pa1-pi10-co16) com frequência ≥ 1 , sendo igual a 2, demonstrando novamente baixa convergência.

A frequência por si só não garante que uma combinação seja competitiva em termos absolutos. Por isso, as Tabelas 4.3 e 4.4 apresentam estatísticas descritivas do espaço avaliado, permitindo posicionar as melhores soluções em relação ao mínimo, à mediana e ao máximo observados para custo total e emissões totais de CO₂.

Em termos de custo, as melhores combinações em Curitiba e São Paulo permanecem claramente abaixo das medianas de suas respectivas localizações, ficando mais próximas dos mínimos do que do centro da distribuição, o que caracteriza soluções economicamente competitivas dentro do conjunto analisado. Em Belém, a melhor solução do Cenário 1 aproxima-se da mediana, enquanto a do Cenário 2 desloca-se para uma faixa intermediária entre o mínimo e a mediana, reduzindo o custo total em relação ao Cenário 1. Para as emissões, observa-se que os valores das melhores combinações permanecem

distantes do máximo global, com destaque para Belém no Cenário 2, cuja emissão total (5654,6 kgCO₂) fica abaixo da mediana (6411,4 kgCO₂). Já Curitiba e São Paulo apresentam emissões acima da mediana, porém ainda em patamar moderado frente ao limite superior observado.

Assim, a Tabela 4.5 consolida as combinações escolhidas por localização e cenário, ao passo que as estatísticas fornecem o referencial necessário para interpretar o quão próximas essas soluções estão dos melhores valores observados no conjunto, evidenciando o equilíbrio entre custo total e CO₂ total em cada contexto climático.




Figura 4.2: Melhores combinações no Cenário 2 com frequência maior ou igual a 2 para cada clima. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

Tabela 4.3: Estatísticas do custo total (R\$) por localização: mínimo, mediana e máximo

Localização	Mínimo (R\$)	Mediana (R\$)	Máximo (R\$)
BL	62469.79	97318.01	186965.97
CB	54405.05	89838.85	177862.87
SP	50507.83	85955.53	176672.73

Tabela 4.4: Estatísticas das emissões totais de CO₂ (kgCO₂): mínimo, mediana e máximo

Mínimo (kgCO ₂)	Mediana (kgCO ₂)	Máximo (kgCO ₂)
2000.0	6411.4	16663.2

Tabela 4.5: Melhores combinações por localização e cenário: custo total e emissões totais de CO₂

Localização	Cenário	Combinação	Custo total (R\$)	CO ₂ total (kgCO ₂)
Curitiba	1	pa34pi04co19	66470.29	10472.40
Curitiba	2	pa34pi04co28	66067.96	9477.80
São Paulo	1	pa34pi04co28	65876.33	9248.02
São Paulo	2	pa34pi01co28	63034.24	9477.80
Belém	1	pa33pi10co20	96663.75	6814.50
Belém	2	pa01pi10co16	80501.06	5654.60

Embora essa distribuição heterogênea sugira a ausência de uma solução universalmente dominante, a seção seguinte (Seção 4.3) aprofunda e organiza os padrões observados, destacando os sistemas construtivos que mais se sobressaíram ao longo das execuções. Com isso, torna-se possível uma interpretação mais objetiva, comparativa e integrada dos resultados.


4.3 Melhores sistemas construtivos

A interpretação dos resultados deve considerar que o comportamento das soluções otimizadas está diretamente associado às prioridades definidas na função objetivo. Como já visto, a distribuição dos pesos resulta em diferenças marcantes entre os dois cenários. No Cenário 1, as métricas térmicas relacionadas a GH, AT, RT e suas projeções futuras representaram 80% da influência total, enquanto o custo e o consumo energético (CT + CTf) tiveram participação marginal, ambos com apenas 6%. Em contraste, o Cenário 2 apresenta um perfil quase inverso. O peso atribuído às métricas térmicas para condicionamento passivo do ambiente interno foi reduzido para 13%, enquanto CT + CTf alcançaram 35% e o custo tornou-se o critério dominante, com 40% de influência.


Cenário 1

Curitiba

A Figura 4.3 apresenta as frequências (≥ 2) dos sistemas construtivos das melhores combinações construtivas apontadas pelo algoritmo de otimização para o Cenário 1, em Curitiba. Segundo a ABNT (2024a) trata-se de uma cidade localizada na ZB 1M ("muito fria com inverno moderado").



(a) Recorrência ≥ 2 dos sistemas construtivos nas soluções otimizadas para o Cenário 1 em Curitiba.



(b) R vs Ct dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 1 em Curitiba.

Figura 4.3: Materiais recorrentes para Curitiba. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

No Cenário 1, a pa30 foi a solução mais recorrente, com 59 aparições, composta por bloco de concreto de 14 cm sem revestimento, apresentando baixa resistência térmica ($R = 0,15 \text{ (m}^2\cdot\text{K)/W}$) e baixa capacidade térmica ($Ct = 132,39 \text{ kJ/(m}^2\cdot\text{K)}$). A combinação desses valores relativamente baixos de resistência e capacidade térmica resultou em uma envoltória leve e pouco inercial, permitindo resposta mais rápida às condições internas consideradas e reduzindo o tempo em desconforto por frio segundo o indicador AT e a intensidade desse frio, avaliado por GH, métricas priorizadas no Cenário 1.

A segunda parede mais frequente foi a pa34, presente em 24 soluções finais, composta por bloco cerâmico assentado na posição deitado, com 9 cm, resultando em uma resistência térmica mais alta ($R = 0,35 \text{ (m}^2\cdot\text{K)/W}$) e capacidade térmica mais baixa ($C_t = 97,27 \text{ kJ/(m}^2\cdot\text{K)}$). Em climas frios, como Curitiba, classificada como ZB 1M (muito frio com inverno moderado) (ABNT, 2005), maior resistência térmica reduz perdas de calor para o ambiente externo e contribui para estabilidade térmica interna (LAMBERTS et al., 2016). Desta forma, enquanto a pa30 atua acelerando o aquecimento interno, a pa34 o faz minimizando sua dissipação, caracterizando duas estratégias térmicas distintas, porém equivalentes em desempenho segundo os critérios otimizados.

A recorrência do piso pi4, contabilizando 36 aparições, reforça esse padrão. Esse sistema, composto por contrapiso sem laje com acabamento em cimento queimado, apresenta $R = 0,04 \text{ (m}^2\cdot\text{K)/W}$ e $C_t = 97,5 \text{ kJ/(m}^2\cdot\text{K)}$, favorecendo o acoplamento térmico com o solo, que tanto em climas frios quanto quentes, tende a apresentar menor variação térmica ao longo do tempo e atuar como moderador natural. A baixa massa térmica desse sistema evita atraso térmico excessivo e favorece estabilização mais rápida da temperatura interna.


A cobertura mais frequente foi co28, composta por telha cerâmica com forro de PVC e ausência de laje, apresentando $R = 0,25 \text{ (m}^2\cdot\text{K)/W}$ e $C_t = 40,08 \text{ kJ/(m}^2\cdot\text{K)}$. Assim como as demais soluções predominantes, trata-se de um sistema leve, cuja rápida resposta térmica permitiu aproveitar os ganhos solares diurnos e reduzir o desconforto por frio. A ausência de casos recorrentes de superaquecimento nas simulações reforça a adequação dessa escolha no clima analisado.

A interpretação conjunta dos resultados revela um comportamento consistente: a maior parte das soluções selecionadas apresenta baixos valores de R e C_t , indicando preferência do algoritmo por envoltórias leves e responsivas, capazes de aproveitar ganhos solares e ajustar a temperatura interna rapidamente. No entanto, a recorrência, ainda que menor, de sistemas com propriedades térmicas mais elevadas, como o piso pi8 ($C_t = 316,0 \text{ kJ/(m}^2\cdot\text{K)}$), a cobertura co3 ($R = 0,50 \text{ (m}^2\cdot\text{K)/W}$) e a cobertura co1 ($C_t = 296,60 \text{ kJ/(m}^2\cdot\text{K)}$), indica que o processo de otimização também identificou cenários nos quais maior isolamento ou maior amortecimento térmico se mostraram vantajosos. Assim, a


seleção final não reflete uma única abordagem térmica dominante, mas sim um equilíbrio adaptativo entre rápida resposta ao ambiente e maior estabilidade térmica interna, condicionado pelas características climáticas, pela interação entre os demais componentes da envoltória e pelos pesos atribuídos aos critérios de análise.

São Paulo

A Figura 4.4 apresenta as frequências superior a 1 dos sistemas construtivos das melhores combinações construtivas em São Paulo para o Cenário 1. Segundo a ABNT (2024a), São Paulo é uma cidade pertencente à ZB 2M (“fria com inverno moderado”).



(a) Recorrência ≥ 2 dos sistemas construtivos nas soluções otimizadas para o Cenário 1 em São Paulo.



(b) R vs C_t dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 1 em São Paulo.

Figura 4.4: Materiais recorrentes para São Paulo. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

A parede pa34 e a cobertura co28 também se destacaram em São Paulo, com 75 e 35 recorrências, respectivamente, demonstrando desempenho ainda mais expressivo do que em Curitiba. Esse resultado reforça a capacidade desse conjunto construtivo em atender aos critérios priorizados no Cenário 1, pelos mesmos mecanismos previamente


discutidos: barreira térmica eficiente devido à maior resistência (no caso da pa34) e rápida resposta térmica devido à baixa capacidade térmica (no caso da co28). Além disso, a baixa capacidade térmica reduz o risco de superaquecimento, pois limita o armazenamento de calor ao longo do dia e facilita o resfriamento noturno (LAMBERTS et al., 2016).

O comportamento observado no piso acompanha essa tendência. O sistema predominante em São Paulo consiste em contrapiso revestido com porcelanato (pi1), resultando em valores de $R = 0,04 \text{ (m}^2\cdot\text{K)/W}$ e $C_t = 86,00 \text{ kJ/(m}^2\cdot\text{K)}$, muito próximos aos observados para o piso pi4, solução mais frequente em Curitiba e segunda mais recorrente em São Paulo, com 37 aparições. Assim como no clima mais frio, trata-se de um componente leve e sem laje, o que favorece rápida adaptação térmica interna com a temperatura amena do solo, sem induzir atraso térmico significativo.


A recorrência semelhante das soluções entre Curitiba e São Paulo sugere forte influência do regime climático no processo de otimização. Embora os dois locais apresentem intensidades distintas de frio, ambos são classificados como regiões de predominância térmica fria segundo a (ABNT, 2024a), o que pode explicar a similaridade das soluções predominantes. No entanto, em São Paulo a variabilidade observada em Curitiba é menos evidente: as soluções se concentram essencialmente em uma única região dos gráficos R versus C_t , indicando menor necessidade de estratégias térmicas distintas para atender aos critérios otimizados. Essa maior convergência pode estar associada à menor severidade térmica e à amplitude diária mais moderada, que reduzem os benefícios adicionais de soluções mais isolantes ou com maior massa térmica e tornam mais eficiente a adoção de sistemas com baixa inércia térmica.

Belém

A Figura 4.5 apresenta apenas os sistemas construtivos que se repetiram ao menos duas vezes entre as melhores combinações obtidas para Belém no Cenário 1. Segundo a (ABNT, 2024a), essa cidade está localizada na ZB 6A (“muito quente e úmida”).



(a) Recorrência ≥ 2 dos sistemas construtivos nas soluções otimizadas para o Cenário 1 em Belém.



(b) R vs Ct dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 1 em Belém.

Figura 4.5: Materiais recorrentes para Belém. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

A parede pa33 apresentou 21 recorrências em Belém no Cenário 1. Trata-se de uma alvenaria simples de bloco cerâmico de 11,5 cm, sem reboco, com $R = 0,21 \text{ (m}^2\cdot\text{K)/W}$ e $Ct = 55,57 \text{ kJ/(m}^2\cdot\text{K)}$, valores relativamente baixos dentro do conjunto analisado. Esse comportamento favorece uma resposta térmica mais rápida e contribui para dissipar calor acumulado sempre que há possibilidade de resfriamento natural, o que é desejável em clima quente e úmido, onde as cargas térmicas tendem a ser predominantemente positivas. Nos demais componentes da envoltória, a ausência de predominância de uma única solução reforça a interpretação de que diferentes sistemas apresentaram desempenhos muito próximos, indicando que, em Belém, a envoltória isoladamente exerce influência limitada no conforto térmico passivo devido à forte predominância das condições externas. Essa tendência é evidente, por exemplo, ao comparar o pi7 com o pi21, que tiveram 13 e 10 recorrências, respectivamente. O pi7 tem $R = 0,11 \text{ (m}^2\cdot\text{K)/W}$ e $Ct = 60,50 \text{ kJ/(m}^2\cdot\text{K)}$, enquanto o pi21, tem valores significativamente maiores ($R = 0,50 \text{ (m}^2\cdot\text{K)/W}$ e $Ct =$


291,08 kJ/(m²·K)), sugerindo que tanto soluções leves quanto mais isoladas alcançaram desempenho semelhante sob as prioridades estabelecidas no Cenário 1.

Em Belém, as soluções recorrentes distribuem-se por uma faixa ampla de valores de R e Ct, indicando ausência de uma estratégia dominante. Esse comportamento é consistente com a baixa repetibilidade observada anteriormente na análise das combinações construtivas, sugerindo que múltiplas combinações alcançaram desempenho semelhante e que a influência isolada da envoltória é limitada no clima quente-úmido.


Cenário 2

Curitiba


A Figura 4.6 apresenta apenas os sistemas construtivos recorrentes (≥ 2 ocorrências) entre as combinações selecionadas como melhores pelo algoritmo no Cenário 2, para o caso de Curitiba.



(a) Recorrência ≥ 2 dos sistemas construtivos nas soluções otimizadas para o Cenário 2 em Curitiba.



(b) Custo dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 2 em Curitiba.



(c) R vs Ct dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 2 em Curitiba.

Figura 4.6: Materiais recorrentes para Curitiba. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

No Cenário 2, a parede pa34 apresentou 81 recorrências em Curitiba, constituindo o maior número registrado em todo o estudo. Como descrito anteriormente, trata-se de uma alvenaria formada por bloco cerâmico assentado na posição deitado, com 9 cm de espessura, resultando em uma resistência térmica relativamente alta ($R = 0,35 \text{ (m}^2 \cdot \text{K)/W}$) e capacidade térmica relativamente baixa ($Ct = 97,27 \text{ kJ/(m}^2 \cdot \text{K)}$). A ausência de reves-

timento contribui para um custo final mais reduzido (R\$ 568,76/m²), o que pode ter favorecido sua recorrência no Cenário 2, considerando o peso dominante atribuído a custo e demanda energética. Além disso, essa configuração tende a favorecer o desempenho energético quando há uso de sistemas AVAC, pois a combinação de maior resistência térmica com baixa inércia permite resposta mais rápida ao condicionamento artificial e reduz a troca térmica com o exterior, tornando a edificação menos dependente das variações climáticas externas.


No caso do piso, os sistemas pi4 (51 recorrências) e pi1 (47 recorrências), bem como a cobertura co28 (35 recorrências), voltaram a se destacar como soluções otimizadas para o clima de Curitiba no Cenário 2, pelos mesmos mecanismos já discutidos. Agora, entretanto, o piso pi4 apresenta maior predominância em um cenário ainda mais exigente em relação ao custo, o que pode estar relacionado ao seu baixo valor unitário (R\$ 106,70/m²). Embora pi1 também apresente um custo relativamente competitivo (R\$147,82/m²), o pi4 se sobressai como opção economicamente mais atrativa, sem comprometer o desempenho energético exigido pelo Cenário 2. A cobertura co28 mantém valores relativamente inferiores quando comparada às alternativas de cobertura (R\$ 205,66/m²).

Além disso, observa-se uma coincidência relevante entre os sistemas com menor custo unitário e os agrupamentos mais frequentes no gráfico R versus Ct. As soluções que se repetem tendem a ocupar uma faixa concentrada de valores térmicos intermediários e custo reduzido, sugerindo que, no Cenário 2, essa sobreposição entre desempenho adequado ao uso condicionado e competitividade econômica se tornou o principal direcionador das escolhas otimizadas. Essa relação reforça que o processo de otimização não apenas identificou alternativas energeticamente compatíveis com climatização artificial, mas também priorizou aquelas cuja viabilidade financeira favorece sua adoção prática no contexto construtivo analisado.


São Paulo

A Figura 4.7 reúne os sistemas construtivos com recorrência igual ou superior a duas aparições entre as melhores soluções do Cenário 2 em São Paulo. Os mesmos padrões foram observados em São Paulo, com destaque para a parede pa34 (71 ocorrências, custo de R\$


540,43/m²), os pisos pi1 (60, R\$ 133,32/m²) e pi4 (35, R\$168,14/m²), e a cobertura co28 (28, R\$ 219,14/m²), indicando uma tendência semelhante à encontrada em Curitiba nas soluções otimizadas do Cenário 2. Assim como no clima mais frio, as soluções recorrentes se concentram em uma faixa estreita do gráfico R versus Ct, indicando que o peso atribuído ao custo e ao desempenho energético sob climatização artificial direcionou a seleção para sistemas de menor custo e com propriedades térmicas semelhantes, resultando em um agrupamento consistente e menor diversidade de alternativas.



(a) Recorrência ≥ 2 dos sistemas construtivos nas soluções otimizadas para o Cenário 2 em São Paulo.



(b) Custo dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 2 em São Paulo.




(c) R vs Ct dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 2 em São Paulo.

Figura 4.7: Materiais recorrentes para São Paulo. Tons mais escuros representam maior frequência de seleção dos sistemas.


Fonte: Elaborado pelo autor.

Belém


Por fim, a Figura 4.8 mostra os sistemas construtivos recorrentes (≥ 2 ocorrências) entre as soluções selecionadas como ótimas para Belém no Cenário 2.



(a) Recorrência ≥ 2 dos sistemas construtivos nas soluções otimizadas para o Cenário 2 em Belém.



(b) Custo dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 2 em Belém.



(c) R vs Ct dos sistemas construtivos com recorrência ≥ 2 nas soluções otimizadas para o Cenário 2 em Belém.

Figura 4.8: Materiais recorrentes para Belém. Tons mais escuros representam maior frequência de seleção dos sistemas.

Fonte: Elaborado pelo autor.

Observa-se que nenhum sistema construtivo apresentou predominância expressiva em relação aos demais no Cenário 2 para Belém. A maior recorrência ocorreu para a parede pa1, com 13 aparições, mas ainda assim sem formar uma tendência dominante dentro da categoria. Esse comportamento reforça a interpretação já identificada no Cenário 1 para Belém: diferentes sistemas, mesmo com características físicas distintas, obtive-

ram desempenho semelhante, sugerindo que a envoltória, isoladamente, exerce influência limitada no resultado da otimização para esse clima quente e úmido.

Essa dispersão é ainda mais evidente no Cenário 2, comparado ao 1. Nem mesmo o critério de custo, que é responsável pelo maior peso na função objetivo, gerou convergência para uma solução única ou um agrupamento mais consistente. A comparação do custo entre sistemas ilustra esse comportamento: a parede pa1, apesar de ser a mais recorrente, apresenta um valor relativamente baixo (R\$ 538,92/m²), situando-se próximo ao primeiro quartil da distribuição de custos; enquanto a parede pa18, com 10 recorrências, possui custo superior (R\$ 632,42/m²), posicionando-se acima da mediana.

A análise dos gráficos confirma esse padrão: os sistemas recorrentes permaneceram distribuídos em diferentes faixas de custo e de propriedades térmicas, sem formação de um agrupamento claro. Mesmo com o custo como critério dominante no Cenário 2, não houve convergência para soluções mais baratas ou termicamente semelhantes, indicando que, em Belém, diferentes combinações continuam apresentando comportamento equivalente no processo de otimização.

5 Conclusão

Este trabalho investigou a aplicação de técnicas de otimização multiobjetivo para apoiar a seleção de materiais de construção de forma integrada ao desempenho térmico, custo e emissões operacionais. A abordagem proposta combinou simulações termoenergéticas realizadas no EnergyPlus, metamodelos baseados em XGBoost para acelerar a avaliação de soluções e o algoritmo evolutivo R-NSGA-III para conduzir o processo de busca dos melhores conjuntos em cenários atuais e futuros. A análise contemplou três cidades com climas diferentes (Curitiba, São Paulo e Belém), reforçando a variedade de demandas térmicas presentes no território brasileiro.

Os resultados mostraram que o uso de metamodelos exigiu um custo computacional significativamente baixo da otimização, ao invés de vários dias caso todos os conjuntos fossem simulados separadamente (8 min para cada conjunto em um computador pessoal convencional). Essa redução possibilitou a análise eficiente de mais de 199123 combinações construtivas ao longo das execuções realizadas.

Na comparação entre as representações avaliadas, o *Gray Code* apresentou o melhor desempenho global, obtendo um valor médio de $HV = 0,964505$ e $Spacing = 0,095300$, superando as representações discreta e binária.

A análise das soluções otimizadas revelou comportamentos distintos entre os cenários. No Cenário 1, no qual o foco é o conforto térmico obtido por estratégias passivas, os resultados indicam uma melhora consistente no desempenho térmico das soluções otimizadas quando comparadas ao conjunto total de alternativas avaliadas. De modo geral, as soluções selecionadas apresentaram uma redução nos valores de Graus-Hora (GH) e um aumento na autonomia térmica (AT), com variações típicas entre 6% e 10%, a depender da cidade analisada. Isso significa que, após a otimização, as edificações tendem a apresentar menos horas de desconforto térmico e uma maior proporção do tempo em condições aceitáveis de conforto. No caso de São Paulo, esse efeito foi mais pronunciado, com uma redução de aproximadamente 7% em GH e um aumento de cerca de 17% em AT, evidenciando o potencial da abordagem para melhorar o conforto térmico sem o uso

de estratégias ativas. Ainda que CT e CTf tivessem pesos menores, as medianas ainda apresentaram diferença em torno de 180 kWh, o que pode representar variação de R\$ 112 a R\$ 167 anuais no presente dependendo da tarifa energética local.

No Cenário 2, com maior peso para custo, carga térmica (CT) e carga térmica no clima futuro (CTf), houve forte convergência para soluções específicas. As medianas otimizadas aproximaram-se dos pontos de referência definidos, atingindo 87% de aderência para CT e 87% para CTf. Esse comportamento foi mais evidente em Curitiba e São Paulo, onde algumas combinações apareceram entre 12 e 20 vezes dentro das 100 execuções. Já em Belém, a maior dispersão permaneceu: a combinação mais frequente ocorreu apenas 2 vezes, reforçando a menor sensibilidade da envoltória construtiva nesse clima quente-úmido. Observa-se ainda que, em todos os casos, as soluções recorrentes concentram-se predominantemente em faixas de custo mais baixo para paredes, pisos e coberturas, evidenciando que a otimização, ao priorizar custo e carga térmica, favorece materiais economicamente mais acessíveis.

No total, a otimização permitiu identificar soluções capazes de reduzir custos operacionais e melhorar o desempenho térmico de forma integrada. Comparando as melhores soluções de cada cenário com o espaço amostral, verificaram-se ganhos globais entre 8% e 22% nos indicadores priorizados, demonstrando o potencial da abordagem como ferramenta de apoio ao projeto.

Como possibilidades de aprimoramento e continuidade deste estudo, destaca-se que as análises foram conduzidas considerando uma única tipologia de edificação residencial, o que restringe a abrangência dos resultados a esse modelo específico. A ampliação da metodologia para diferentes tipologias arquitetônicas, com variações geométricas e funcionais, permitiria avaliar a robustez da abordagem frente a configurações construtivas distintas. Além disso, o espaço de soluções foi limitado a um conjunto finito e previamente definido de sistemas construtivos para paredes, pisos e coberturas. Investigações futuras podem expandir esse espaço de busca, incorporando novas alternativas construtivas ou variações mais amplas de propriedades termofísicas, de modo a explorar um conjunto mais diverso de soluções potenciais. Adicionalmente, uma extensão relevante consiste em incorporar o custo operacional ao modelo de avaliação, considerando o consumo energético

anual e sua conversão em custos ao longo do ciclo de vida. Nesse contexto, também se mostra promissora a inclusão de cenários de geração distribuída, como sistemas fotovoltaicos, permitindo estimar o impacto de energias renováveis na redução do custo operacional e das emissões de CO₂ associadas à operação da edificação.

Em conclusão, os achados indicam que não existe uma solução universal, mas sim alternativas sensíveis ao clima, e aos pesos atribuídos. Portanto, o desenvolvimento desta ferramenta evidenciou o potencial da integração entre simulação termoenergética, aprendizado de máquina e otimização multiobjetivo como um caminho robusto, escalável e aplicável para apoiar decisões construtivas mais racionais e alinhadas às demandas atuais e futuras do setor.

A Lista de materiais dos sistemas construtivos

A.1 Paredes

Tabela A.1: Materiais e propriedades térmicas equivalentes dos sistemas de paredes

Número do Sis- tema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
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	0.2000	1560.0000	1000.0000	2.2951	131.3647
	Bloco Cerâmico	0.0900	0.4846	860.0833	689.4000		
	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000		
5	Reboco	0.0150	1.1500	1950.0000	1000.0000	4.1984	114.0718
	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	133.5718
	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	153.0718
	Bloco Cerâmico	0.1150	0.5422	806.5978	599.1000		

Número do Sis- tema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [J/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	Reboco	0.0250	1.1500	1950.0000	1000.0000		
8	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000	2.1640	133.5718
	Bloco Cerâmico	0.1150	0.5422	806.5978	599.1000		
	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000		
9	Reboco	0.0150	1.1500	1950.0000	1000.0000	2.6549	155.7660
	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	2.5950	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	0.2000	1560.0000	1000.0000	1.6651	175.2660
	Bloco cerâmico 9cm deitado	0.1900	0.5420	968.4167	528.6220		
	Reboco isolante	0.0250	0.2000	1560.0000	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		
	Reboco	0.0250	1.1500	1950.0000	1000.0000		

Número do Sis- tema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [J/(m²·K)] equivalente	Ct [J/(m²·K)] equivalente
	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	0.2000	1560.0000	1000.0000	1.6909	175.8134
	Bloco cerâmico 11.5cm deitado	0.1900	0.5565	870.1685	591.6180		
	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000		
17	Reboco	0.0150	1.1500	1950.0000	1000.0000	7.6245	205.3581
	Tijolo maciço	0.1000	0.9517	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	0.9517	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	0.9517	1592.8570	921.9790		
	Reboco	0.0250	1.1500	1950.0000	1000.0000		
20	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000	2.8163	224.8581
	Tijolo maciço	0.1000	0.9517	1592.8570	921.9790		
	Reboco isolante	0.0250	0.2000	1560.0000	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		
	Reboco isolante	0.0250	1.1500	2023.4000	2000.0000		

Número do Sis- tema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [J/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	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	0.7131	1506.4027	928.7600		
	Reboco	0.0150	1.1500	1950.0000	1000.0000		
26	Reboco	0.0200	1.1500	1950.0000	1000.0000	6.2118	203.9178
	Bloco de Concreto	0.0900	0.7131	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	0.7131	1506.4027	928.7600		
	Reboco	0.0250	1.1500	1950.0000	1000.0000		
28	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000	2.6582	203.9178
	Bloco de Concreto	0.0900	0.7131	1506.4027	928.7600		
	Reboco isolante	0.0250	0.2000	1560.0000	1000.0000		
29	Tijolo maciço	0.1000	0.9517	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	0.7131	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

A.2 Pisos

Tabela A.2: Materiais e propriedades térmicas equivalentes dos sistemas de pisos

Número do Sis- tema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
1	Contrapiso	0.0300	1.1500	1950.0000	1000.0000	25.7944	86.0000
	Argamassa Colante	0.0050	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	82.6200
	Taco de madeira	0.0200	0.2900	900.0000	1340.0000		
3	Contrapiso	0.0300	1.1500	1950.0000	1000.0000	27.7108	63.4920
	Vinil	0.0040	0.4000	1300.0000	960.0000		
4	Contrapiso	0.0300	1.1500	1950.0000	1000.0000	23.0000	97.5000
	Cimento queimado	0.0200	1.1500	1950.0000	1000.0000		
5	Contrapiso	0.0300	1.1500	1950.0000	1000.0000	14.0673	77.6475
	Madeira laminada	0.0090	0.2000	925.0000	2300.0000		
6	Contrapiso	0.0300	1.1500	1950.0000	1000.0000	26.9531	112.6800
	Argamassa Colante	0.0050	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	10.4263	316.0000
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Argamassa Colante	0.0050	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	6.3880	323.1200
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Argamassa Colante	0.0050	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	10.7262	293.4920
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Vinil	0.0040	0.4000	1300.0000	960.0000		
	Laje	0.1000	1.7500	2300.0000	1000.0000	9.9383	327.5000

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	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		
13	Laje	0.1000	1.7500	2300.0000	1000.0000	10.6107	342.6800
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Argamassa Colante	0.0050	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	2.3297	316.5775
	Manta lã de vidro	0.0150	0.0450	55.0000	700.0000		
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Argamassa Colante	0.0050	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	2.3443	294.0695
	Manta termoacústica	0.0150	0.0450	55.0000	700.0000		
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Vinil	0.0040	0.4000	1300.0000	960.0000		
	Laje	0.1000	1.7500	2300.0000	1000.0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	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	2.3388	343.2575
	Manta termoacústica	0.0150	0.0450	55.0000	700.0000		
	Contrapiso	0.0300	1.1500	1950.0000	1000.0000		
	Argamassa Colante	0.0050	1.1500	2100.0000	1000.0000		
	Granito	0.0200	3.0000	2600.0000	840.0000		
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		

A.3 Cobertura

Tabela A.3: Materiais e propriedades térmicas equivalentes dos sistemas de cobertura

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Reboco	0.0200	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 [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	Laje de concreto	0.1000	1.7500	2300.0000	1000.0000		
	Caixa de ar	0.1500	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
2	Reboco	0.0200	1.1500	1950.0000	1000.0000	2.9184	247.4645
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
3	Reboco	0.0200	1.1500	1950.0000	1000.0000	2.0168	204.2113
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
4	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.7956	315.0000
	Laje de concreto	0.1000	1.7500	2300.0000	1000.0000		
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
5	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.0134	265.8645
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
6	Reboco	0.0200	1.1500	1950.0000	1000.0000	2.0617	222.6113
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
7	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.8707	278.0720
	Laje de concreto	0.1000	1.7500	2300.0000	1000.0000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
8	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.0605	228.9365
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
9	Reboco	0.0200	1.1500	1950.0000	1000.0000	2.0837	185.6833
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
10	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.0840	296.6202
	Laje de concreto	0.1000	1.7500	2300.0000	1000.0000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	2.5468	247.4846
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	1.8321	204.2315
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Manta termoacústica	0.0020	0.0400	12.0000	840.0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
13	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.1902	315.0202
	Laje de concreto	0.1000	1.7500	2300.0000	1000.0000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Manta termoacústica	0.0020	0.0400	12.0000	840.0000		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
14	Reboco	0.0200	1.1500	1950.0000	1000.0000	2.6188	265.8846
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	1.8690	222.6315
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Manta termoacústica	0.0020	0.0400	12.0000	840.0000		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
	Reboco	0.0200	1.1500	1950.0000	1000.0000	3.2431	278.0922
	Laje de concreto	0.1000	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 [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	2.6543	228.9566
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	1.8871	185.7035
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	4.2474	36.7875
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
20	Painel de gesso	0.0125	0.3500	875.0000	840.0000	4.4515	55.1875
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
21	Painel de gesso	0.0125	0.3500	875.0000	840.0000	4.5552	18.2595
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
22	Painel de gesso	0.0125	0.3500	875.0000	840.0000	3.5034	36.8077
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	3.6411	55.2077
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	3.7102	18.2797
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	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	0.2000	1300.0000	960.0000	3.3592	247.0790
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	2.7316	197.9435
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	1.9258	154.6903
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	0.2000	1300.0000	960.0000	4.0044	40.0800
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
	Forro de PVC	0.0100	0.2000	1300.0000	960.0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m ³)	c (J/kg.K)	U [W/(m ² ·K)] equivalente	Ct [J/(m ² ·K)] equivalente
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
30	Forro de PVC	0.0100	0.2000	1300.0000	960.0000	4.2769	21.5520
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
31	Forro de PVC	0.0100	0.2000	1300.0000	960.0000	3.3364	40.1002
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	0.2000	1300.0000	960.0000	3.4611	58.5002
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	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	0.2000	1300.0000	960.0000	3.5234	21.5722
	Caixa de ar	0.2000	Rt = 0,1775 (m ² ·K)/W	-	-		
	Manta termoacústica	0.0020	0.0400	12.0000	840.0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
34	Forro de madeira	0.0050	0.1500	500.0000	1340.0000	3.5585	237.9490
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	1340.0000	2.8619	188.8135
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	1340.0000	1.9897	145.5603
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	1340.0000	4.2908	30.9500
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de cerâmica	0.0200	0.9000	1500.0000	920.0000		
	Forro de madeira	0.0050	0.1500	500.0000	1340.0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
39	Forro de madeira	0.0050	0.1500	500.0000	1340.0000	4.6051	12.4220
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
40	Forro de madeira	0.0050	0.1500	500.0000	1340.0000	3.5329	30.9702
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	1340.0000	3.6729	49.3702
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Manta termoacústica	0.0020	0.0400	12.0000	840.0000		
	Telha de concreto	0.0200	1.7500	2300.0000	1000.0000		
42	Forro de madeira	0.0050	0.1500	500.0000	1340.0000	3.7432	12.4422
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Manta termoacústica	0.0020	0.0400	12.0000	840.0000		

Número do Sistema	Materiais	e (m)	λ (W/m.K)	ρ (kg/m³)	c (J/kg.K)	U [W/(m².K)] equivalente	Ct [J/(m².K)] equivalente
	Telha de fibrocimento	0.0060	0.9500	1800.0000	840.0000		
43	Painel de gesso	0.0125	0.3500	875.0000	840.0000	3.5286	243.7865
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	2.8426	194.6510
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Impermeabilizante	0.0030	0.2300	1050.0000	1460.0000		
45	Painel de gesso	0.0125	0.3500	875.0000	840.0000	1.9803	151.3978
	Caixa de ar	0.2000	Rt = 0,1775 (m².K)/W	-	-		
	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	11.4184	273.5990
	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	6.4115	224.4635
	Laje treliçada de cerâmica	0.1200	0.9559	1629.7620	924.8000		
	Impermeabilizante	0.0030	0.2300	1050.0000	1460.0000		
	Reboco	0.0200	1.1500	1950.0000	1000.0000		

Número do Sis- tema	Materiais	e (m)	λ	ρ	c	U	Ct
			(W/m.K)	(kg/m³)	(J/kg.K)	[W/(m².K)] equivalente	[J/(m².K)] equivalente
	Laje treliçada de EPS	0.1200	0.4305	1289.8000	889.1000		
	Impermeabilizante	0.0030	0.2300	1050.0000	1460.0000		

B Tabelas de calibração de hiperparâmetros

B.1 *Random search* na representação discreta

Tabela B.1: Configurações gerais utilizadas no random search para a representação discreta.

Configuração	Descrição
Número de tentativas (trials)	20 execuções
Operador de amostragem	IntegerRandomSampling
Operador de cruzamento	SBX
Operador de mutação	PM (Polynomial Mutation)
Eliminação de duplicatas	Ativada (eliminate_duplicates=True)
Critério de avaliação	Hipervolume (HV)
Indicador de HV	ref_point = [1.1] * 10

Tabela B.2: Faixas de hiperparâmetros obtidas pelo *random search* (representação discreta).

Hiperparâmetro	Faixa (mín–máx)
pop_per_ref_point	1 – 2
pm_prob	0.01035821 – 0.0171512
pm_eta	14.34564 – 18.7204
sbx_eta	11.454559 – 22.00091
sbx_prob	0.905015 – 0.94675
n_gen	97 – 99

Tabela B.3: Melhor conjunto de hiperparâmetros obtido pelo *Optuna* (representação discreta).

Hiperparâmetro	Valor ótimo
pop_per_ref_point	1
pm_prob	0.0143118
pm_eta	17.6370
sbx_eta	21.8359
sbx_prob	0.923585
n_gen	99
<i>Hipervolume</i> (HV)	0.959858

B.2 *Random search* na representação binária

Tabela B.4: Configurações gerais utilizadas no *random search* para a representação binária.

Configuração	Descrição
Número de tentativas (trials)	20 execuções
Operador de amostragem	BinaryRandomSampling
Operadores de cruzamento avaliados	HUX, single point, two point, uniform
Operador de mutação	BitflipMutation
Eliminação de duplicatas	Ativada (eliminate_duplicates=True)
Critério de avaliação	<i>Hipervolume</i> (HV)
Indicador de HV	ref_point = [1.1] * 10

Tabela B.5: Faixas de hiperparâmetros obtidas pelo *random search* (representação binária).

Hiperparâmetro	Faixa (mín–máx)
pop_per_ref_point	1 – 4
mut_prob	0.0111832 – 0.01633134
sbx_prob	0.912424256 – 0.954234
n_gen	80 – 85
crossover	two_point

Tabela B.6: Melhor conjunto de hiperparâmetros obtido pelo *Optuna* (representação binária).

Hiperparâmetro	Valor ótimo
pop_per_ref_point	1
mut_prob	0.0143118
sbx_prob	0.9334565321
crossover	two_point
n_gen	81
<i>Hipervolume</i> (HV)	0.944688

B.3 *Random search* na representação *Gray Code*

Tabela B.7: Configurações gerais utilizadas no *random search* para a representação *Gray Code*.

Configuração	Descrição
Número de tentativas (trials)	20 execuções
Operador de amostragem	BinaryRandomSampling
Operadores de cruzamento avaliados	HUX, single point, two point, uniform
Operador de mutação	BitflipMutation
Eliminação de duplicatas	Ativada (eliminate_duplicates=True)
Critério de avaliação	<i>Hipervolume</i> (HV)
Indicador de HV	ref_point = [1.1] * 10

Tabela B.8: Faixas de hiperparâmetros obtidas pelo *random search* (representação *Gray Code*).

Hiperparâmetro	Faixa (mín–máx)
pop_per_ref_point	1 – 4
mut_prob	0.01167 – 0.01519844
sbx_prob	0.9225617 – 0.95328967
n_gen	81 – 83
crossover	two_point

Tabela B.9: Melhor conjunto de hiperparâmetros obtido pelo *Optuna* (representação *Gray Code*).

Hiperparâmetro	Valor ótimo
pop_per_ref_point	1
mut_prob	0.0143
sbx_prob	0.9376651123
crossover	two_point
n_gen	81
<i>Hipervolume</i> (HV)	0.9560

Bibliografia

ABDULQADER, H. A.; ABDULAZEEZ, A. M. A review on decision tree algorithm in healthcare applications. *Indonesian Journal of Computer Science*, v. 13, n. 3, p. 3863–..., 2024. Acesso em: 10 nov. 2025. Disponível em: https://www.researchgate.net/publication/382748363_Review_on_Decision_Tree_Algorithm_in_Healthcare_Applications.

ABNT. *NBR 15220-3: Desempenho térmico de edificações – Parte 3: Zoneamento bioclimático e estratégias de condicionamento térmico passivo*. Rio de Janeiro, 2005. Norma Brasileira.

ABNT. *NBR 15220-3: Desempenho térmico de edificações - Parte 3: Zoneamento bioclimático brasileiro e diretrizes construtivas para habitações unifamiliares de interesse social*. 2024. Rio de Janeiro, RJ, Brasil: ABNT. Norma Técnica Brasileira. Disponível em: <https://abnt.org.br/>.

ABNT. *NBR 15575: Edificações habitacionais - Desempenho*. Rio de Janeiro: [s.n.], 2024. Associação Brasileira de Normas Técnicas. Várias partes. Data da última atualização pode variar conforme a parte consultada.

AHMED, M.; SERAJ, R.; ISLAM, S. M. S. The k-means algorithm: A comprehensive survey and performance evaluation. *Electronics*, v. 9, n. 8, 2020. ISSN 2079-9292. Disponível em: <https://www.mdpi.com/2079-9292/9/8/1295>.

AKIBA, T. et al. *Optuna: A Next-generation Hyperparameter Optimization Framework*. 2019. Disponível em: <https://arxiv.org/abs/1907.10902>.

ALMEIDA, T. P. d.; BRASILEIRO, A.; SILVOSO, M. Influência dos materiais das vedações verticais no desempenho termo-energético de uma habitação de interesse social. *ENCONTRO NACIONAL DE TECNOLOGIA DO AMBIENTE CONSTRUÍDO*, v. 17, n. 1, p. 921–929, nov. 2018. Disponível em: <https://eventos.antac.org.br/index.php/entac/article/view/1426>.

ALPAYDIN, E. *Introduction to Machine Learning*. 4th. ed. Cambridge, MA: MIT Press, 2020. ISBN 9780262043793.

APOLONIO, R.; CALLEJAS, I.; ROSETA, F. Evaluation of the thermal resilience of buildings in overheating in present and climate change scenarios. *Ambiente Construído*, v. 24, 12 2024.

ASHRAE. *ANSI ASHRAE Standard 55 Thermal Environmental Conditions for Human Occupancy*. Atlanta, 2020.

BACHRUN, A.; ZHEN, T.; GANI, A. C. Building envelope component to control thermal indoor environment in sustainable building: A review. *SINERGI*, v. 23, p. 79–98, 06 2019.

BALARAS, C. *ENERGY EFFICIENCY and BUILDING PERFORMANCE*. 2021.

BALARAS, C. A. et al. Energy technologies and building performance: A review. *Energy and Buildings*, v. 298, p. 113488, 2024. Disponível em: <https://doi.org/10.1016/j.enbuild.2024.113488>.

- BAQER, N.; RASHIDI-KHAZAEI, P. Residential building energy usage prediction using bayesian-based optimized xgboost algorithm. *IEEE Access*, PP, p. 1–1, 01 2025.
- BARBARESI, A. et al. Application of machine learning models for fast and accurate predictions of building energy need. *Energies*, v. 15, p. 1266, 02 2022.
- BERGSTRA, J.; BENGIO, Y.; RACHMAD, Y. Random search for hyper-parameter optimization. *The Journal of Machine Learning Research*, v. 13, p. 281–305, 03 2012.
- BLANK, J.; DEB, K. Pymoo: Multi-objective optimization in python. *IEEE Access*, PPa, p. 1–1, 04 2020.
- BLOCKEEL, H. et al. Decision trees: From efficient prediction to responsible ai. *Frontiers in Artificial Intelligence*, v. 6, p. 1124553, 2023. Disponível em: <https://www.frontiersin.org/articles/10.3389/frai.2023.1124553/full>.
- CHAPRA, S. C.; CANALE, R. P. *Numerical Methods for Engineers*. 7th. ed. New York: McGraw-Hill, 2015. ISBN 978-0-07-339792-4.
- CHEN, T.; GUESTRIN, C. Xgboost: A scalable tree boosting system. In: *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. [S.l.: s.n.], 2016. p. 785–794.
- COELLO, C. A. C. et al. Evolutionary multiobjective optimization: open research areas and some challenges lying ahead. *Complex Intelligent Systems*, v. 6, n. 2, p. 221–236, 2020. ISSN 2198-6053. Disponível em: <https://doi.org/10.1007/s40747-019-0113-4>.
- COELLO, C. A. C.; LAMONT, G. B.; VELDHUIZEN, D. A. V. *Evolutionary Algorithms for Solving Multi-Objective Problems*. 2nd. ed. New York: Springer, 2007.
- CRAWLEY, D. B. et al. Energyplus: Creating a new-generation building energy simulation program. *Energy and Buildings*, v. 33, n. 4, p. 319–331, 2001.
- CRUZ, A. S. et al. What lies ahead? the future performance of global south residential buildings amid climate change: A systematic literature review. *Journal of Building Engineering*, v. 98, p. 111486, 2024. ISSN 2352-7102. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2352710224030547>.
- CURY, A. A.; ALVES, V. A. M.; ALVES, V. H. M. Revisão sistemática sobre o uso de inteligência artificial na detecção de deterioração estrutural por meio de sinais de vibração. *Revista da Universidade Federal de Minas Gerais*, v. 30, 2024. Disponível em: <https://periodicos.ufmg.br/index.php/revistadaufmg/article/view/47533>.
- DEB, K. Multiobjective optimization using evolutionary algorithms. wiley, new york. In: _____. [S.l.: s.n.], 2001.
- DEB, K. et al. A fast and elitist multiobjective genetic algorithm: Nsga-ii. *IEEE Transactions on Evolutionary Computation*, v. 6, n. 2, p. 182–197, 2002.
- DEB, K.; SUNDAR, J. Reference point based multi-objective optimization using evolutionary algorithms. In: *Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation*. New York, NY, USA: Association for Computing Machinery, 2006. (GECCO '06), p. 635–642. ISBN 1595931864. Disponível em: <https://doi.org/10.1145/1143997.1144112>.

- EIBEN, A. E.; SMITH, J. E. *Introduction to Evolutionary Computing*. [S.l.]: Springer, 2003.
- EIBEN, A. E.; SMITH, J. E. *Introduction to Evolutionary Computing*. 2. ed. Berlin: Springer, 2015.
- Elastic. *O que é machine learning supervisionado?* 2025. Acesso em: 10 nov. 2025. Disponível em: <https://www.elastic.co/pt/what-is/supervised-machine-learning>.
- ENERGIA, C. *Mapa de tarifas de energia no Brasil*. 2025. <https://clarke.com.br/mapa-de-tarifas-de-energia-no-brasil/>. Acesso em: 07 dez. 2025.
- EnergyPlus. *EnergyPlus™: Building Energy Simulation Software*. 2025. <https://energyplus.net>. Acesso em: 21/10/2025.
- FACELI, K. et al. *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. Rio de Janeiro: LTC, 2011. ISBN 978-85-216-2036-8.
- FONSECA, C.; FLEMING, P. Genetic algorithms for multiobjective optimization: Formulation discussion and generalization. *the fifth Intl conference on Genetic Algorithms*, v. 93, 02 1999.
- GAGGE, A.; NISHI, Y.; GONZALEZ, R. Standard effective temperature - a single temperature index of temperature sensation and thermal discomfort. *Proceeding of the CIB commission W45 symposium London 1972*, p. 229–250, 01 1972.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 2. ed. Sebastopol: O'Reilly Media, 2019.
- GÉRON, A. *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. 3rd. ed. [S.l.]: O'Reilly Media, 2022. ISBN 9781098125974.
- GONTIJO, L. *Algoritmo Genético: uma abordagem Fullstack*. 2020. <https://medium.com/@luigi.gontijo/algoritmo-gen%C3%A9tico-uma-abordagem-fullstack-31a6093a57b6>. Acessado em 14 de dezembro de 2025. Disponível em: <https://medium.com/@luigi.gontijo/algoritmo-gen%C3%A9tico-uma-abordagem-fullstack-31a6093a57b6>.
- GOSAIN, A. *Comparative Techno-Economic Analysis of Passive and Active Energy Efficiency Strategies in Buildings Across Diverse Climatic Zones*. 2025.
- HILLIER, F. S.; LIEBERMAN, G. J. *Introduction to Operations Research*. 10th. ed. [S.l.]: McGraw-Hill Education, 2015. ISBN 9780073523453.
- HONG, T. et al. Ten questions concerning thermal resilience of buildings and occupants for climate adaptation. *Building and Environment*, v. 244, p. 110806, 2023. ISSN 0360-1323. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0360132323008338>.
- HOYT, T.; ARENS, E.; ZHANG, H. Extending air temperature setpoints: Simulated energy savings and design considerations for new and retrofit buildings. *Building and Environment*, v. 88, p. 89–96, 06 2015.

IFSC Verifica. *Quais os desafios da Construção Civil diante das mudanças climáticas?* 2024. Acesso em: 10 nov. 2025. Disponível em: <https://www.ifsc.edu.br/web/ifsc-verifica/w/quais-os-desafios-da-construcao-civil-diante-das-mudancas-climaticas->.

INCROPERA, F. P. et al. *Fundamentos da Transferência de Calor e Massa*. 6. ed. Rio de Janeiro: LTC, 2008.

KRELLING, A. F. et al. Defining weather scenarios for simulation-based assessment of thermal resilience of buildings under current and future climates: A case study in brazil. *Sustainable Cities and Society*, v. 107, p. 105460, 2024. ISSN 2210-6707. Disponível em: <https://www.sciencedirect.com/science/article/pii/S2210670724002877>.

KUBWIMANA, B.; NAJAFI, H. A novel approach for optimizing building energy models using machine learning algorithms. *Energies*, v. 16, 01 2023.

LAMBERTS, R.; DUTRA, L.; PEREIRA, F. O. R. *Eficiência Energética na Arquitetura*. 3. ed. Rio de Janeiro: Eletrobras/PROCEL, 2014. Disponível em: <https://labeee.ufsc.br/pt-br/publicacoes/livros>. Acesso em: 2025-10-20.

LAMBERTS, R. et al. *CASA EFICIENTE: Simulação Computacional do Desempenho Termo-Energético (vol 4)*. [S.l.: s.n.], 2010. ISBN 978-85-7426-099-0.

LAMBERTS, R. et al. *Apostila da disciplina ECV5161 – Eficiência Energética em Edificações*. Florianópolis, SC, 2016. Disponível em: https://labeee.ufsc.br/sites/default/files/disciplinas/ApostilaECV5161_v2016.pdf. Acesso em: 2025-04-10.

LESSMANN, S. et al. Benchmarking state-of-the-art classification algorithms for credit scoring: An update of research. *European Journal of Operational Research*, v. 247, n. 1, p. 124–136, 2015.

LI, Y. et al. Machine learning based thermal comfort prediction in office spaces: Integrating smote and shap methods. *Energy and Buildings*, v. 329, p. 115267, 2025. ISSN 0378-7788. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378778824013835>.

LITJENS, G. et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, v. 42, p. 60–88, 2017.

LOUBACK. *Aprendizado de máquina aplicado à análise de desempenho térmico de edificações*. Monografia (Trabalho de Conclusão de Curso (Graduação em Engenharia Computacional)) — Universidade Federal de Juiz de Fora, Juiz de Fora, 2025. Disponível em: <https://repositorio.ufjf.br/jspui/handle/ufjf/19387>. Acesso em: 2025-02-10.

MANUEL; BRANKE, J.; PAQUETE, L. Reproducibility in evolutionary computation. *ACM Trans. Evol. Learn. Optim.*, Association for Computing Machinery, New York, NY, USA, v. 1, n. 4, out. 2021. ISSN 2688-299X. Disponível em: <https://doi.org/10.1145/3466624>.

MENDES, J. C. et al. *IA Aplicada à Engenharia: Primeiros passos e aplicações*. Juiz de Fora, MG, 2025. Acesso em: 08 dez. 2025. Disponível em: <https://www2.ufjf.br/editora/wp-content/uploads/sites/113/2025/11/IA-Aplicada-%C3%A0-engenharia-compressed.pdf>.

MENDES, V. F. *Novo método de avaliação do isolamento térmico de fachadas de edificações: análise da sensibilidade das propriedades termofísicas dos materiais*. Monografia (Graduação em Engenharia Civil) — Universidade Federal de Ouro Preto, Escola de Minas, Ouro Preto, 2021. Disponível em: <http://www.monografias.ufop.br/handle/35400000/3679>. Acesso em: 2025-10-20.

MENDES, V. F. *Métodos para avaliação de desempenho térmico de edificações envolvendo simulações energéticas*. Dissertação (Dissertação (Mestrado em Engenharia Civil)) — Universidade Federal de Ouro Preto, Escola de Minas, Ouro Preto, 2023. Disponível em: <http://www.repositorio.ufop.br/jspui/handle/123456789/16318>. Acesso em: 2025-10-20.

MENDES, V. F. et al. A systematic review of methods for evaluating the thermal performance of buildings through energy simulations. *Renewable and Sustainable Energy Reviews*, v. 189, p. 113875, 2024. ISSN 1364-0321. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1364032123007335>.

MENDES, V. F. et al. De horas para milissegundos: análise do desempenho térmico com aprendizado de máquina. *ENCONTRO NACIONAL DE APROVEITAMENTO DE RESÍDUOS NA CONSTRUÇÃO*, v. 9, n. 1, p. 1–6, ago. 2025. Disponível em: <https://eventos.antac.org.br/index.php/enarc/article/view/6895>.

MUSLIM, S. Energyplus-towards the selection of right simulation tool for building energy and power systems research. *Journal of Energy and Power Technology*, v. 3, p. 1–1, 07 2021.

NTC Brasil. *O impacto das mudanças climáticas na construção civil*. 2025. <https://www.ntcbrasil.com.br/blog/impacto-mudancas-climaticas-construcao/>. Acesso em: 10 nov. 2025.

OLIVEIRA, G. *Desenvolvimento de modelos de aprendizado de máquina para prever o desempenho térmico de edificações e converter carga térmica em graus-hora*. Dissertação (Dissertação (Mestrado)) — Universidade Federal de Ouro Preto, Ouro Preto-MG, 2025.

PHUA, C. et al. A comprehensive survey of data mining-based fraud detection research. *arXiv preprint arXiv:1009.6119*, 2010. Disponível em: <https://arxiv.org/abs/1009.6119>.

RIBAS, R. A. J. Avaliação construtiva e de desempenho térmico do prédio *Revista Engenharia Civil (REM)*, v. 22, n. 1, p. 29–38, 2007. Acesso em: 10 nov. 2025. Disponível em: <https://www.scielo.br/j/rem/a/Jb8ff5qLZJ4ZXVxbVjgN5Xs/?format=html&lang=pt>.

ROKA, A. et al. Multi-objective optimization based on surrogate models for sustainable building design: A systematic literature review. *Building and Environment*, v. 266, p. 112147, 10 2024.

ROKA, R. et al. A systematic review of sensitivity analysis in building energy modeling: Key factors influencing building thermal energy performance. *Energies*, v. 18, n. 9, 2025. ISSN 1996-1073. Disponível em: <https://www.mdpi.com/1996-1073/18/9/2375>.

ROTHLAUF, F. Representations for genetic and evolutionary algorithms. In: _____. [S.l.: s.n.], 2006. v. 104, p. 73 – 96. ISBN 978-3-642-88096-4.

RUSSELL, S.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3rd. ed. Upper Saddle River, NJ: Pearson, 2016. ISBN 978-0-13-461099-3.

RUSSELL, S. J.; NORVIG, P. *Artificial Intelligence: A Modern Approach*. 4th. ed. Pearson, 2020. ISBN 9780134610993. Disponível em: <http://aima.cs.berkeley.edu/>.

SADINENI, S.; MADALA, S.; BOEHM, R. Passive building energy savings: A review of building envelope components. *Renewable and Sustainable Energy Reviews - RENEW SUSTAIN ENERGY REV*, v. 15, p. 3617–3631, 10 2011.

SHASTRI, H.; FRACHTENBERG, E. *Revisiting Locality in Binary-Integer Representations*. 2020.

STANKEVIX, G. *Árvore de decisão em R*. 2020. <https://medium.com/@gabriel.stankevix/arvore-de-decis%C3%A3o-em-r-85a449b296b2>. Acessado em 14 de dezembro de 2025. Disponível em: <https://medium.com/@gabriel.stankevix/arvore-de-decis%C3%A3o-em-r-85a449b296b2>.

TIAN, Z. et al. A review of data-driven building performance analysis and design on big on-site building performance data. *Journal of Building Engineering*, v. 41, p. 102706, 05 2021.

TRIANA, M. et al. Energy efficiency strategies for brazilian social housing considering a life cycle perspective: Optimisation between thermal autonomy, energy consumption and costs. *Energy and Buildings*, v. 295, p. 113254, 06 2023.

UN Environment Programme; Global Alliance for Buildings and Construction (GlobalABC). *2023 Global Status Report for Buildings and Construction*. Nairobi, Kenya, 2023. Acessado em [8 de Novembro de 2025]. Disponível em: https://globalabc.org/sites/default/files/2024-11/global_status_report_buildings_construction_2023.pdf.

U.S. Department of Energy. *EnergyPlus*. 2025. Disponível em: <https://energyplus.net>.

USTA, D. F. B.; TEYMOURI, M.; CHATTERJEE, U. Assessment of temperature changes over iran during the twenty-first century using CMIP6 models under SSP1-26, SSP2-4.5, and SSP5-8.5 scenarios. *Arabian Journal of Geosciences*, v. 15, p. 416, 2022.

VAZ, I. C. M. et al. Dashboard for interpreting future climate files used in the simulation of buildings – an outdoor thermal comfort approach. *Energy and Buildings*, v. 326, p. 115059, 2024. ISSN 0378-7788. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0378778824011757>.

VESIKAR, Y.; DEB, K.; BLANK, J. Reference point based nsga-iii for preferred solutions. In: *Reference Point Based NSGA-III for Preferred Solutions*. [S.l.: s.n.], 2018. p. 1587–1594.

WIERZBICKI, A. P. The use of reference objectives in multiobjective optimization. In: FANDEL, G.; GAL, T. (Ed.). *Multiple Criteria Decision Making Theory and Application*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1980. p. 468–486. ISBN 978-3-642-48782-8.

WU, J. et al. Influencing factors on air conditioning energy consumption of naturally ventilated research buildings based on actual hvac behaviours. *Buildings*, v. 13, p. 2710, 10 2023.

XGBoost Developers. *XGBoost Documentation: Model Training and Evaluation*. [S.l.], 2025. Acesso em: 13 nov. 2025. Disponível em: <https://xgboost.readthedocs.io/en/stable/tutorials/model.html>.

YIQUN; XIANRUI, Y. X. Y. Evaluating multiobjective evolutionary algorithms using mcdm methods. *Mathematical Problems in Engineering*, v. 2018, p. 1–13, 03 2018.

ZHANG, H. a. Classification performance analysis of decision tree-based algorithms: A comparative study. *Scientific Reports*, v. 14, p. 6671395, 2024.

ZITZLER, E.; BROCKHOFF, D.; THIELE, L. The hypervolume indicator revisited: On the design of pareto-compliant indicators via weighted integration. In: OBAYASHI, S. et al. (Ed.). *Evolutionary Multi-Criterion Optimization*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007. p. 862–876. ISBN 978-3-540-70928-2.

ZITZLER, E.; DEB, K.; THIELE, L. Comparison of multiobjective evolutionary algorithms: Empirical results. *Evolutionary Computation*, v. 8, n. 2, p. 173–195, 2000.

ZITZLER, E. et al. Performance assessment of multiobjective optimizers: An analysis and review. *Evolutionary Computation, IEEE Transactions on*, v. 7, p. 117 – 132, 05 2003.