



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

RODOLFO KIRCH SAMPAIO VEIGA

**Metamodelo para estimar o desempenho térmico de edificações residenciais
multifamiliares naturalmente ventiladas**

Florianópolis, SC

Fevereiro, 2021

Rodolfo Kirch Sampaio Veiga

**Metamodelo para estimar o desempenho térmico de edificações residenciais
multifamiliares naturalmente ventiladas**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia Civil da Universidade Federal de Santa Catarina, para a obtenção do título de mestre em Engenharia Civil.

Orientador: Prof. Roberto Lamberts, PhD.
Coorientadora: Eng. Civil Ana Paula Melo,
Dra.

Florianópolis, SC

Fevereiro, 2021

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Veiga, Rodolfo Marue Kirch Sampaio
Metamodelo para estimar o desempenho térmico de
edificações residenciais multifamiliares naturalmente
ventiladas / Rodolfo Marue Kirch Sampaio Veiga ;
orientador, Roberto Lamberts, coorientador, Ana Paula
Melo, 2021.
129 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Civil, Florianópolis, 2021.

Inclui referências.

1. Engenharia Civil. 2. Metamodelo. 3. Desempenho
térmico. 4. NBR 15.575. I. Lamberts, Roberto. II. Melo,
Ana Paula. III. Universidade Federal de Santa Catarina.
Programa de Pós-Graduação em Engenharia Civil. IV. Título.

Rodolfo Kirch Sampaio Veiga

**Metamodelo para estimar o desempenho térmico de edificações residenciais
multifamiliares naturalmente ventiladas**

O presente trabalho em nível de Mestrado foi avaliado e aprovado por banca examinadora
composta pelos seguintes membros:

Prof. Saulo Güths, PhD

Universidade Federal de Santa Catarina

Prof. Aldomar Pedrini, PhD

Universidade Federal do Rio Grande do Norte

Prof. Rogério Versage, Dr.

Instituto Federal de Santa Catarina

Certificamos que esta é a **versão original e final** do trabalho de conclusão que foi julgado
adequado para a obtenção do título de Mestre em Engenharia Civil.

Prof^a. Poliana Dias de Moraes, Dr^a.

Prof. Roberto Lamberts, PhD

Fevereiro, 2021

Este trabalho é dedicado a todas as pessoas que de alguma forma contribuíram para o meu bem-estar.

AGRADECIMENTOS

Aos professores Roberto Lamberts e Ana Paula Melo, pela paciência e empatia ao longo dessa desafiadora jornada.

À minha família, em especial Elvira Amélia Sampaio Veiga, Marcus Vinícius Sampaio Veiga e Morgani Kirch Sampaio Veiga, pelo amor incondicional, fator imprescindível para tornar os meus anseios possíveis.

Aos meus amigos, pelos ouvidos atentos e pelas palavras confortantes nos momentos de ansiedade, e pela energia e disposição nos momentos de alegria.

Aos meus colegas de laboratório, pelo compartilhamento das suas experiências e pela motivação no dia-a-dia de estudos e trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico e à Universidade Federal de Santa Catarina pelo financiamento desta pesquisa. O presente trabalho foi realizado com o apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

“The combination of some data and an aching desire for an answer does not ensure that a reasonable answer can be extracted from a given body of data.” (John W. Tukey)

RESUMO

Programas de simulação computacional termoenergética permitem a avaliação do desempenho térmico de edificações, porém, exigem alto custo computacional e qualificação profissional. A nova proposta para a Norma de Desempenho de Edificações Habitacionais (NBR 15.575) apresenta um método de simulação que avalia unidades habitacionais (UH) a partir da média aritmética do percentual de horas ocupadas em que a temperatura operativa dos seus ambientes de permanência prolongada se encontra dentro de uma faixa de interesse (PHFT). A fim de viabilizar a otimização do desempenho térmico de edificações por profissionais de diferentes áreas e níveis de conhecimento, vêm sendo desenvolvidos os metamodelos, que são ferramentas rápidas e de fácil operação que podem substituir as simulações computacionais. Esse tipo de ferramenta foi utilizado nas Propostas de Instrução Normativa do Inmetro para a Classe de Eficiência Energética de Edificações Residenciais (INI-R) e Comerciais (INI-C), e possui potencial para ser aprimorado e implementado na NBR 15.575. Sendo assim, esse trabalho visa o desenvolvimento de um metamodelo para prever o desempenho térmico de UHs de edificações residenciais multifamiliares, avaliado através do PHFT, de acordo com as premissas da NBR 15.575. Para desenvolver o metamodelo foi necessário criar um modelo parametrizável, elaborado através do estudo de simplificações de modelos de simulação computacional. As simplificações foram aplicadas nos modelos iniciais e as diferenças entre o PHFT das simplificações e dos seus respectivos modelos iniciais (Δ PHFT) foram comparadas, sendo que a simplificação com menor Δ PHFT foi escolhida como modelo parametrizável. O modelo parametrizável foi utilizado para elaborar duas amostras de simulações computacionais através da sequência de Sobol, a partir das quais foi estimado o PHFT. Uma das amostras foi utilizada para treinar e a outra para testar os metamodelos. Com o intuito de compreender a correlação entre os parâmetros da base de dados e elaborar critérios para a seleção dos parâmetros que mais influenciam o PHFT, foi executada a análise de sensibilidade de Sobol. Os metamodelos foram treinados, validados e testados. Dentre os diversos metamodelos otimizados, que consideraram cinco técnicas de metamodelagem diferentes, o metamodelo final foi escolhido de acordo com a acurácia e o número de parâmetros de entrada. Os resultados das simplificações indicam que assumir superfícies horizontais como adiabáticas compromete o fluxo de calor dos pavimentos superiores para os pavimentos inferiores, enquanto que assumir paredes como adiabáticas impede o fluxo de calor entre as fachadas. Das quatro simplificações testadas, simplificação n° 4 foi a que apresentou menores erros, com *Mean Absolute Error* (MAE) igual a 1,9%. A análise de sensibilidade indicou que a variável climática foi o parâmetro mais importante para estimar o PHFT, enquanto os parâmetros geométricos ficaram entre os 10 parâmetros menos influentes. A partir dos critérios para a seleção de parâmetros foram geradas três bases de dados considerando os 20 (B20), os 13 (B13) e os 10 (B10) parâmetros de entrada mais influentes. O resultado dos metamodelos na etapa de treino indicou que os metamodelos treinados a partir das técnicas RF e XGBT foram os mais acurados. Considerando a B20, os metamodelos da técnica XGBT apresentaram valor mediano de MAE igual a 2,1%. Os resultados da etapa de teste coincidiram com os resultados de treino, sendo que os metamodelos em XGBT foram os mais acurados, seguido de RF, SVM, ANN e MLR. O metamodelo final escolhido utilizou a B10 e obteve MAE igual a 1,7% na etapa de teste.

Palavras chave: metamodelo, desempenho térmico, NBR 15.575.

ABSTRACT

Building Energy Simulation (BES) software allow users to evaluate the thermal performance of buildings, however, they demand high computational cost and professional qualification. The new proposal for the Brazilian performance standard for residential buildings (NBR 15.575) presents a simulation method to evaluate housing units (UH) according to the percentage of occupied hours in which the operative temperature of the extensively used rooms is within a range of interest (PHFT). In order to make the optimization of buildings thermal performance feasible for professionals from distinct fields and with disparate levels of knowledge, metamodels have been developed as a substitute for BES. These fast and user-friendly tools were used in the proposal for the Inmetro's Commercial (INI-C) and Residential Normatives (INI-R), and has the potential to be improved and implemented in the NBR 15.575. To develop the metamodel, it was necessary to generate a parametric model, elaborated through the study of BES models' simplifications. The simplifications were applied on initial BES models and the differences between the PHFT of simplified and initial models (Δ PHFT) were compared. The simplification presenting the smallest Δ PHFT was chosen as the parametric model. The parametric model was used to elaborate two samples of BES by the Sobol's sequence, whose PHFT was then estimated. One of the samples was used to train and the other to test the metamodels. Sensitivity analysis was performed to comprehend the correlation among the dataset parameters and to select the most influencing parameters for the PHFT. The metamodels were trained, validated, and tested. Among a variety of optimized metamodels, which have considered five machine learning techniques, the final model was sorted out according to the accuracy and the number of input parameters. The simplifications' results have shown that considering horizontal surfaces as adiabatic compromises the heat flow coming from top to bottom storeys, while considering vertical surfaces as adiabatic hinders the heat flow from north to south facades. Among the four proposed simplifications, simplification number 4 presented the smallest errors, with Mean Absolute Error (MAE) equals to 1.9%. Sensitivity analysis results point to the weather variable as the most influent parameter to estimate PHFT, while the geometry parameters are among the 10 less influent parameters. From feature selection criteria, three datasets were developed considering the 20 (B20), the 13 (B13), and the 10 (B10) most influencing parameters. The training results have shown RF and XGBT were the most accurate models. Considering B20, the XGBT models presented median value of MAE equal to 2.1%. The testing results match the training results, thus the XGBT models were the most accurate, followed by RF, SVM, ANN, and MLR. The final metamodel chosen adopted B10 and obtained MAE equal to 1.7% in the training stage.

Palavras chave: metamodel, thermal performance, NBR 15.575.

LISTA DE FIGURAS

Figura 1 - Fluxograma metodológico.....	51
Figura 2 - Processo de desenvolvimento do modelo parametrizável.....	55
Figura 3 - Modelagem da simplificação n° 2.....	57
Figura 4 - Exemplo de adaptação da modelagem para simular as trocas de ar no EnergyPlus.	58
Figura 5 - Modelagem da simplificação n° 4.....	59
Figura 6 - Catálogo de tipologias de UH.....	61
Figura 7 - Espelhamento da tipologia da UH.....	62
Figura 8: PHFT nos modelos iniciais e na simplificação n° 2.....	70
Figura 9: Carga térmica referente às cargas internas e à ventilação natural nos modelos iniciais.....	71
Figura 10 - Distribuição do Δ PHFT na base de dados de simplificações.....	73
Figura 11 - Diferença absoluta do PHFT em relação ao modelo inicial.....	75
Figura 12 - Adaptação do modelo inicial para a simplificação n° 1 (Caso A).....	78
Figura 13 - Balanços térmicos do Caso A e do modelo inicial correspondente.....	79
Figura 14 - Adaptação do modelo inicial para a simplificação n° 2 (Caso B).....	80
Figura 15 - Balanços térmicos do Caso B e do modelo inicial correspondente.....	81
Figura 16 - Adaptação do modelo inicial para a simplificação n° 4 (Caso C).....	82
Figura 17 - Balanços térmicos do Caso C e do modelo inicial correspondente.....	83
Figura 18 - Adaptação do modelo inicial para a simplificação n° 4 (Caso D).....	84
Figura 19 - Balanços térmicos do Caso D e do modelo inicial correspondente.....	85
Figura 20 - Distribuição dos parâmetros de entrada na amostra de treino.....	86
Figura 21 - Distribuição dos parâmetros de entrada na amostra de teste.....	87
Figura 22 - Distribuição do PHFT nas amostras de treino e teste.....	88
Figura 23 - Distribuição do PHFT por intervalo de interesse.....	89
Figura 24 - Análise de sensibilidade de Sobol.....	91
Figura 25 - Distribuição dos parâmetros de entrada pré-processados na amostra de treino.....	96
Figura 26 - Acurácia dos metamodelos na etapa de treino.....	97

Figura 27 - Acurácia dos metamodelos mais acurados na etapa de teste.....	100
Figura 28 - PHFT predito pelo metamodelo final contra PHFT simulado.....	101

LISTA DE TABELAS

Tabela 1 - Faixas de temperatura operativa para determinar o PHFT.....	47
Tabela 2 - Propriedades de fluxo de ar pelas aberturas para a simulação de ventilação natural.	48
Tabela 3 - Características das edificações utilizadas nas simplificações.....	52
Tabela 4 - Componentes construtivos das envoltórias.....	53
Tabela 5 - TBSm dos arquivos climáticos.....	55
Tabela 6 - Condições de exposição de superfícies horizontais.....	56
Tabela 7 - Limites de aplicação do metamodelo.....	60
Tabela 8 - Hiperparâmetros e suas faixas de variação.....	66
Tabela 9 - Estatística descritiva, MAE e RMSE referentes ao Δ PHFT.....	69
Tabela 10 - Casos críticos de simplificação.....	77
Tabela 11 - Casos de simplificações com as maiores diferenças no PHFT.....	77

LISTA DE ABREVIATURAS

ANN	<i>Artificial Neural Networks</i>
APP	Ambiente de Permanência Prolongada
APT	Ambiente de Permanência Transitória
B10	Base de dados contendo 10 parâmetros de entrada
B13	Base de dados contendo 13 parâmetros de entrada
B20	Base de dados contendo 20 parâmetros de entrada
GBDT	<i>Gradient Boosted Decision Trees</i>
MAE	<i>Mean Absolute Error</i>
MLR	<i>Multiple Linear Regression</i>
PHFT	Percentual de horas em que uma unidade habitacional se encontra dentro de uma faixa de temperatura operativa pré-definida
RF	<i>Random Forest</i>
RMSE	<i>Root Mean Square Error</i>
RT	<i>Regression Trees</i>
S1	Simplificação n° 1
S2	Simplificação n° 2
S3	Simplificação n° 3
S4	Simplificação n° 4
SVM	<i>Support Vector Machines</i>
TBSm	Média anual da Temperatura de Bulbo Seco
UH	Unidade habitacional
XGBT	<i>Extreme Gradient Boosted Trees</i>

SUMÁRIO

1 INTRODUÇÃO.....	12
1.1 JUSTIFICATIVA.....	12
1.2 OBJETIVO.....	14
2 REVISÃO BIBLIOGRÁFICA.....	16
2.1 A DEMANDA E O CONSUMO DE ENERGIA.....	16
2.2 A EFICIÊNCIA ENERGÉTICA EM EDIFICAÇÕES.....	18
2.3 AS SIMULAÇÕES DE DESEMPENHO ENERGÉTICO E SUAS SIMPLIFICAÇÕES.....	23
2.4 O ESTADO DA ARTE DE METAMODELOS.....	26
2.4.1 Definições.....	26
2.4.2 Algoritmos de otimização.....	27
2.4.3 Fase inicial de projeto.....	28
2.4.4 Retrofit.....	29
2.4.5 Técnicas de metamodelagem.....	30
2.4.6 Pré-processamento, treinamento, validação e teste.....	35
2.4.7 Aplicações.....	38
2.5 AMOSTRAGEM e ANÁLISE DE SENSIBILIDADE.....	43
2.6 O MÉTODO DE SIMULAÇÃO COMPUTACIONAL DA NOVA PROPOSTA PARA A NBR 15.575.....	45
2.7 CONSIDERAÇÕES FINAIS.....	49
3 MÉTODO.....	50
3.1 MODELO PARAMETRIZÁVEL.....	51
3.1.1 Modelos iniciais.....	52
3.1.2 Simplificações.....	54
3.1.2.1 Simplificação nº 1 (S1).....	56
3.1.2.2 Simplificação nº 2 (S2).....	56
3.1.2.3 Simplificação nº 3 (S3).....	57
3.1.2.4 Simplificação nº 4 (S4).....	58
3.2 AMOSTRAGEM.....	59

3.2.1 Amostra de parâmetros de entrada.....	60
3.2.2 Simulação da amostra.....	64
3.3 ANÁLISE DE SENSIBILIDADE.....	64
3.4 DESENVOLVIMENTO DO METAMODELO.....	65
4 RESULTADOS.....	69
4.1 MODELO PARAMETRIZÁVEL.....	69
4.2 AMOSTRAGEM.....	86
4.3 ANÁLISE DE SENSIBILIDADE.....	90
4.4 DESENVOLVIMENTO DO METAMODELO.....	95
5 CONCLUSÃO.....	102
5.1 LIMITAÇÕES.....	108
5.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	109
BIBLIOGRÁFICA.....	111
APÊNDICE A.....	123
APÊNDICE B.....	124
APÊNDICE C.....	125

1 INTRODUÇÃO

1.1 JUSTIFICATIVA

A demanda por energia vem sofrendo aumentos significativos a cada ano, sendo que, estima-se um aumento de 28% no consumo energético a nível internacional, de 2015 a 2040 (EIA, 2017). Devido ao aumento da população, das exigências de conforto e da permanência dos ocupantes dentro dos edifícios (CHUA et al., 2013), em 2017 a eletricidade correspondeu a 19% do consumo total de energia elétrica e a participação das edificações representou 32% do consumo total (IEA, 2018a).

Com relação às exigências de conforto dos usuários, o condicionamento artificial do ar visa promover o bem-estar e aumentar a produtividade dos ocupantes, porém, o seu uso intensivo tem colaborado consideravelmente para o aumento do consumo energético dos edifícios (MCQUISTON, PARKER, SPITLER, 2004; CHUA et al., 2013). As vendas de aparelhos de condicionamento artificial do ar quadruplicaram entre os anos de 1990 a 2016, chegando a um total mundial de vendas de 135 milhões de aparelhos, onde 69,6% foram vendidos ao setor residencial (IEA, 2018b). Apesar de garantir o controle das condições de temperatura do ar interno, independente das condições climáticas externas (MAHDAVI, KUMAR, 1996), o condicionamento artificial do ar não garante o conforto de todos os ocupantes devido a diferenças nas preferências individuais quanto às condições micro climáticas internas ideais (FOUNTAIN, BRAGER, DE DEAR, 1996). Ainda assim, esse tipo de condicionamento representa parte significativa do consumo energético dos edifícios (KAYNAKLI, 2012).

Em contrapartida, o uso da ventilação natural em edificações é uma estratégia que tende a reduzir o consumo energético e a aumentar a qualidade do ar e a satisfação dos usuários (ALLARD, GHIAUS, 2012; NEVES, RORIZ, 2012), especialmente em climas quentes (KALOKOTRONI, ARONIS, 1999). Em climas quentes e úmidos, o aumento da renovação do ar e da sua velocidade estimula a evaporação, reduzindo o desconforto causado pela umidade. Já em climas quentes e secos, essa estratégia resfria o ambiente durante a noite (GIVONI, 2011). Além dos benefícios térmicos, segundo Brager e de Dear (2000), a exposição à ventilação natural aumenta a faixa de aceitação às condições climáticas dos ocupantes de edifícios.

Como foco na relevância e na tendência de aumento da demanda de energia do setor de edificações, nota-se que a implementação da eficiência energética, através de estratégias como a ventilação natural, pode exercer um papel relevante na redução do consumo energético mundial (PEREIRA, 2009; SADINENI, MADALA, BOEHM, 2011; MATHEW, 2015).

Normas e regulamentações foram desenvolvidas e são constantemente revisadas e atualizadas, a fim de avaliar a eficiência de edificações brasileiras (BRASIL, 2000; BRASIL, 2001; ABNT, 2005). A Norma de Desempenho de Edificações Habitacionais (NBR 15.575) tem sido revisada desde 2019 e uma nova proposta para a norma vêm sendo elaborada. Destaca-se a revisão da parte do item 11 da norma, que trata da avaliação do desempenho térmico através do método de simulação. O método de simulação da norma vigente estima o desempenho de salas e dormitórios desconsiderando as cargas internas e considerando taxas de renovação do ar constantes, sendo que o critério de avaliação é a comparação do valor máximo diário da temperatura interna com a externa (ABNT, 2013). A nova proposta sugere diversas modificações, dentre elas citam-se a consideração de cargas internas e o uso da ventilação natural e do condicionamento artificial do ar intercalados. A avaliação do desempenho do ambiente é realizada através da comparação da edificação real com um modelo de referência, onde são analisados o percentual de horas ocupadas dentro uma faixa de temperatura operativa de interesse, as temperaturas operativas anuais máximas e mínimas e a carga térmica (LABEEE, 2020).

Nesse contexto, diversas ferramentas de simulação termoenergética foram desenvolvidas nas últimas décadas para auxiliar na avaliação do desempenho de estratégias de eficiência energética aplicadas em projetos de construção civil (CRAWLEY et al. 2008; RYAN, SANQUIST, 2012). Apesar de serem flexíveis e possibilitarem modelagens variadas, as simulações computacionais são sofisticadas e exigem alto nível de detalhamento, consomem muito tempo e requerem a intervenção de profissionais altamente qualificados (FOUCQUIER, 2013; CHALAL et al. 2016). Metamodelos são simplificações capazes de compreender os fenômenos termo-físicos das simulações e de reproduzir o seu comportamento de forma mais rápida, sem demandar do usuário um número massivo de parâmetros de entrada (ZHAO, MAGOULÈS, 2012; AMASYALI, EL-GOHARY, 2018).

Os metamodelos podem ser aplicados em diversos cenários de promoção da eficiência energética, como a elaboração de amostras para algoritmos de otimização e análise de

sensibilidade, a tomada de decisões em fase inicial de projeto e de *retrofit* (MAGNIER, HAGHIGHAT, 2010; EISENHOWER et al., 2012; KUMBAROĞLU, MADLENER, 2012; ASADI et al., 2014; AMIRI, MOTTAHEDI, ASADI, 2015; ØSTERGÅRD, JENSEN, MAAGAARD, 2017). Essas ferramentas consistem em uma alternativa de baixo custo-benefício para a implementação da eficiência energética (WEI et al., 2018).

O aumento da credibilidade dos metamodelos que estimam o desempenho térmico de edificações permitiu a sua implementação em normas de conformidade (EISENHOWER et al., 2012). No Brasil, as propostas de Instrução Normativa do Inmetro para a Classe de Eficiência Energética de Edificações Residenciais (INI-R) e Comerciais (INI-C) já contam com metamodelos para estimar as cargas térmicas de aquecimento e de resfriamento e o percentual de horas ocupadas em conforto térmico quando a UH é ventilada naturalmente (CB3E, 2017; CB3E, 2018). Apesar de contribuírem significativamente para a adesão dos modelos preditivos em regulamentações, os metamodelos desenvolvidos para a INI-R abrangem um número pequeno de tipologias residenciais, restringindo sua aplicação a esses padrões construtivos (MAZZAFERRO, 2018). Além disso, o metamodelo da INI-R que estima o conforto térmico apresenta acurácia pouco satisfatória e permite aprimorações.

De acordo com a revisão a respeito de metamodelos para a predição do consumo energético de edificações, elaborada por Amasyali e El-Gohary (2018), apenas 19% dos metamodelos encontrados se aplicam à residências. Entretanto, devido à grande parcela que esse setor representa no consumo energético e ao alto potencial de energia que pode ser economizada a partir de medidas de eficiência energética, os pesquisadores encorajam o desenvolvimento de modelos de predição do desempenho térmico de edificações residenciais. Dada a vasta gama de implementações de metamodelos no setor de edificações, a carência de metamodelos para prever o desempenho térmico de edificações residenciais e a ausência de um metamodelo que facilite a aplicação da NBR 15.575, esse trabalho visa preencher essa lacuna.

1.2 OBJETIVO

Desenvolver um metamodelo para estimar o desempenho térmico de edificações residenciais multifamiliares, considerando as premissas da nova proposta para a NBR 15.575 (LABEEE, 2020).

Diante do objetivo geral, os seguintes objetivos específicos foram abordados:

- Analisar as diferenças entre o desempenho térmico de modelos de simulação termoenergética completos e de modelos de simulação termoenergética simplificados;
- Desenvolver um modelo de simulação termoenergética parametrizável para edificações residenciais multifamiliares capaz de representar desempenho térmico de seus respectivos modelos completos;
- Compreender a relevância dos parâmetros do modelo parametrizável para o desempenho térmico, segundo a nova proposta para a NBR 15.575;
- Otimizar os hiperparâmetros de metamodelos para estimar o desempenho térmico de edificações multifamiliares, considerando diferentes técnicas de modelagem, e comparar as suas performances.

2 REVISÃO BIBLIOGRÁFICA

2.1 A DEMANDA E O CONSUMO DE ENERGIA

Acompanhado pelo crescimento populacional em conjunto com fatores como o aumento do poder aquisitivo e do acesso à eletricidade, o consumo energético global tem aumentado a cada ano, de modo a tornar-se uma preocupação ambiental internacional. A situação tende a se agravar, visto que, de 2015 a 2040, projeta-se um aumento populacional de 17% (DESA, 2017), seguido de uma expansão de 28% do consumo de energia primária e de 31% do consumo de eletricidade, em escala global (EIA, 2017).

Segundo o *World Energy Outlook* (IEA, 2018a) o consumo de eletricidade no mundo correspondeu a 19% do consumo total de energia primária em 2017, sendo que as edificações foram responsáveis por 32% dessa quantidade. Como consequência do consumo excessivo e pouco eficiente, o relatório *Global Status Report* (IEA, 2018b) registrou que, também no ano de 2017, o setor das edificações e da construção civil foi responsável por 36% das emissões de gases de efeito estufa ao redor do mundo.

Em 2018, a demanda de eletricidade no Brasil representou 18% da demanda de energia primária nacional e o consumo de energia elétrica das edificações chegou a 42,6% do consumo total de eletricidade do país, dos quais 21,4% foi consumido por edifícios residenciais (EPE, 2019). O documento *Demanda de Energia 2050* (EPE, 2016), estimou que até 2050 a demanda de energia elétrica brasileira representará 23,6% da demanda de energia primária interna do país e o setor residencial será responsável por pelo menos 22,0% do consumo total de energia elétrica das edificações nacionais.

O condicionamento artificial de ar tem aumentado significativamente sua parcela no consumo de energia tanto de edificações residenciais quanto comerciais, podendo exceder 50% do consumo total de energia em determinados edifícios (CHUA et al., 2013). Essa estratégia é amplamente utilizada para controlar as condições climáticas internas à edificação como a temperatura, a umidade e a qualidade do ar. Através do aquecimento e do resfriamento artificial do ar, visa-se promover um ambiente favorável à produtividade e ao bem-estar dos ocupantes, porém, à custos elevados (MCQUISTON, PARKER, SPITLER, 2004). Segundo Kaynakli (2012), os sistemas de condicionamento artificial de ar caracterizam parcela significativa da energia consumida por edificações. Logo, o gerenciamento

competente desses sistemas a fim de manter os ambientes em condições climáticas satisfatórias aos usuários é essencial para viabilizar a eficiência energética (CHANG, THOMAS, LU; 2017), pois, corresponde a uma parte significativa da demanda de eletricidade das edificações.

De acordo com o *Future of Cooling* (IEA, 2018c), há uma tendência de aumento do consumo com refrigeração principalmente nos países em desenvolvimento, onde predominam-se os climas quentes e úmidos. Essa tendência é proporcionada pelo crescimento da população urbana e do poder aquisitivo nessas regiões, somado ao aumento da temperatura, decorrente do aquecimento global. Ao aumentar o poder de compra, a população que vive em condições climáticas de calor excessivo, naturalmente, tende a investir em condicionamento artificial do ar. O Brasil se enquadra nesse perfil de aumento no consumo com climatização, sendo que, em 2016, o consumo de energia elétrica para climatização foi equivalente a 7,7% do consumo de eletricidade das edificações do país. O relatório registrou que, de 1990 a 2016, as vendas de aparelhos de condicionamento artificial do ar quadruplicaram, chegando a um total mundial de vendas de 135 milhões de aparelhos ao ano, sendo que 69,6% foram vendidos para uso no setor residencial. Assim, a demanda de energia elétrica para refrigeração de edifícios também tem crescido anualmente, atingindo o valor de 2.020 TWh em 2016, com projeções para chegar a 6.200 TWh em 2050. Devido ao fato de que grande parte do setor comercial já possui sistema de condicionamento artificial do ar, a previsão é de que o setor residencial seja responsável por aproximadamente 70% desse crescimento, de forma a aumentar sua representatividade na demanda de eletricidade para refrigeração de 45% para 65%.

Tendo em vista que o desenvolvimento econômico depende do suprimento de energia, as previsões de aumento no consumo energético preocupam, pois, a oferta não acompanha a demanda, logo, o preço da energia tende a aumentar (HADJIPASCHALIS, POULLIKKAS, EFTHIMIOU, 2009). Considerando a situação energética mundial, a relevância da eletricidade no consumo do setor residencial e a representatividade desse setor no contexto internacional, entende-se que investir na eficiência energética de habitações consiste em uma alternativa viável para reduzir a demanda de energia (PEREIRA, 2009).

2.2 A EFICIÊNCIA ENERGÉTICA EM EDIFICAÇÕES

A substituição das tecnologias de baixa eficiência energética utilizadas no setor das edificações apresenta um potencial significativo de economia de energia e de redução da emissão de gases de efeito estufa. Ações como o aumento da eficiência das envoltórias e dos equipamentos de refrigeração seriam capazes de reduzir consideravelmente a demanda de energia e a emissão de gases nocivos ao meio ambiente (IEA, 2017).

Estimativas para o ano de 2040, realizadas pela *International Energy Agency* (2018a), apontam que políticas que impõem limites mínimos de eficiência energética para eletrodomésticos e aparelhos de refrigeração possibilitariam uma redução no consumo energético do setor de edificações, a nível mundial, de até 4.000 TWh. Em um cenário sem avanços em eficiência energética o aumento da demanda de energia primária global poderia chegar a quase 40%.

Com o advento dos sistemas de condicionamento artificial do ar, o controle das condições do ar internas às edificações se tornou possível independente das condições externas, e tem sido utilizado com o objetivo de manter o clima interno dentro de padrões aceitáveis pelos usuários (MAHDAVI, KUMAR, 1996). Entretanto, além de exigir um alto investimento e custo energético operacional, essa estratégia não satisfaz grande parte dos ocupantes devido a diferenças nas preferências individuais quanto às condições de conforto (FOUNTAIN, BRAGER, DE DEAR, 1996).

A ventilação natural é uma medida de eficiência energética com potencial para reduzir drasticamente o consumo energético de edifícios, especialmente em climas quentes, sem comprometer a satisfação dos usuários quanto às condições climáticas internas (KOLOKOTRONI, ARONIS, 1999). Um estudo realizado por Schulze e Eicker (2013) comprovou que salas comerciais de uma mesma tipologia apresentam a capacidade de reduzir o consumo anual de energia com refrigeração através do uso da ventilação natural, até mesmo em climas moderados. Escritórios em Estugarda, na Alemanha, em Turim, na Itália, e em Istambul, na Turquia, apresentaram potenciais de redução no consumo de eletricidade de 13 a 22 kWh/m², de 32 a 36 kWh/m² e de 38 a 44 kWh/m², respectivamente.

As oportunidades de economia de energia através do uso da ventilação natural se devem ao fato de que, em climas quentes, frequentemente as temperaturas internas do edifício são maiores do que as externas, logo, as trocas de ar entre o edifício e o ambiente externo são

essenciais para o desempenho térmico das edificações. Como o uso da ventilação natural aumenta as trocas de ar entre os ambientes interno e externo, o uso dessa medida pode contribuir para o resfriamento do ambiente, provocando uma redução na sensação de calor dos usuários sem a necessidade de aumentar o consumo energético (ETHERIDGE, SANDBERG, 1996; NEVES, RORIZ, 2012). Além das trocas de ar, a ventilação natural aumenta a velocidade do ar, que em climas quentes e úmidos estimula a evaporação e diminui o desconforto gerado pela umidade e em climas quentes e secos resfria o ambiente durante a noite (GIVONI, 2011).

Segundo o estudo sobre ventilação na Europa desenvolvido por Allard e Ghiaus (2012), o uso da ventilação natural em edificações é uma técnica eficiente que não só reduz o consumo de energia, como também aumenta a qualidade do ar, proporcionando saúde aos usuários. Não obstante, de acordo com Brager e de Dear (2000), usuários expostos à ventilação natural apresentam maior faixa de aceitação às condições climáticas internas do que usuários em ambientes condicionados artificialmente. Logo, o uso da ventilação natural apresenta-se como uma medida que pode reduzir o consumo energético e controlar de forma eficiente o clima interno às edificações, sem comprometer a satisfação dos ocupantes.

Através de simulações termoenergéticas de um edifício em Singapura, Wang, Nyuk e Li (2007) constataram que o tamanho da abertura das fachadas e a direção da fachada e do vento têm forte relação com a velocidade do ar interno e, conseqüentemente, com a satisfação dos ocupantes e com o consumo energético. Para a maioria das fachadas da edificação analisada, aumentando-se o tamanho das janelas aumenta-se também a velocidade do ar interno, proporcionando uma condição de climatização que tende a diminuir o consumo energético. Todavia, os autores atentam o leitor ao fato de que o aumento da janela incrementa também o ganho de calor por radiação, que, eventualmente, pode diminuir a satisfação dos ocupantes e levar ao acionamento do sistema de condicionamento artificial do ar.

Em sua análise a respeito dos fatores mais importantes para o conforto térmico, Haase e Amato (2009) se atentaram à relevância da ventilação natural em diferentes climas asiáticos. Dada a tendência de incorporar fachadas envidraçadas nas edificações contemporâneas, os pesquisadores recorreram a simulações termoenergéticas para variar a orientação dos edifícios. Dos resultados das simulações, identificou-se que o potencial de benefícios resultantes do uso da ventilação natural varia tanto com as condições climáticas quanto com a

orientação. A ventilação natural apresentou alta aceitabilidade dos ocupantes em climas tropicais e temperados, entretanto, em climas subtropicais a estratégia não foi muito eficaz, especialmente no verão. Visto que o uso da ventilação natural diminui o controle dos usuários sobre o sistema de condicionamento do ar, a pesquisa cita o uso do condicionamento híbrido (ventilação natural e condicionamento artificial do ar) como possível estratégia bioclimática.

Nota-se uma tendência de consumo excessivo de energia na fase de operação de edificações, que pode ser justificado pela busca por conforto (JANDA, 2011). Nas últimas décadas, estratégias sustentáveis que consideram medidas de eficiência energética em toda a vida útil dos edifícios têm substituído a prática tradicional do setor da construção civil, onde foca-se na fase de construção, enquanto a fase de operação, que corresponde a uma parte considerável do consumo dos edifícios durante sua vida útil, é desprezada (BAKAR et al., 2015).

Segundo Mathew et al. (2015), baseados em diversos estudos que estimam grandes economias energéticas e financeiras a partir de investimentos modestos, a eficiência energética é uma alternativa economicamente viável para reduzir o consumo de energia e a emissão de gases poluentes em edifícios. Nesse setor, a eficiência energética pode ser alcançada através de soluções direcionadas ao sistema de envoltória, de condicionamento artificial do ar, de iluminação ou de aquecimento da água (INMETRO, 2012).

A partir da constatação de que a aplicação de eficiência energética nas edificações pode reduzir significativamente a demanda de energia, os países mais desenvolvidos começaram a elaborar normas que definem desempenhos mínimos, ou consumos máximos, de edifícios. O primeiro documento relevante, elaborado pela organização americana *American Society of Heating, Refrigerating and Air-Conditioning Engineers* (ASHRAE), em 1975, foi a norma ASHRAE Standard 90.1. A norma, atualizada em 2019, tem o propósito de estabelecer requisitos mínimos de eficiência energética de edificações nas etapas de projeto e construção e nos planos de operação e manutenção (ASHRAE, 2019).

Devido a pressão global para reduzir o consumo energético e a emissão de gases de efeito estufa, em julho de 2000, o Brasil promulgou a Lei nº 9.991/2000, que impõe que determinadas empresas do setor de energia elétrica invistam em pesquisa e desenvolvimento de eficiência energética (BRASIL, 2000). Com a crise energética de 2001, o país ampliou os investimentos em medidas de eficiência energética ao lançar o Decreto nº 4059/2001, que regulamenta a Lei nº 10.295/2001 (BRASIL, 2001), conhecida como “Lei da Eficiência

Energética”. Essa legislação estabelece níveis máximos de consumo energético para equipamentos consumidores de energia elétrica.

Com o incentivo das leis nacionais de eficiência energética, em 2005 a Associação Brasileira de Normas e Técnicas (ABNT) elaborou a Norma de Desempenho Térmico de Edificações (NBR 15.220), que define limites mínimos para o desempenho térmico de edifícios. A NBR 15.220 é dividida em cinco partes, sendo que a primeira delas trata da definição das grandezas físicas relacionadas à termodinâmica dos edifícios. A segunda parte da normativa oferece métodos de cálculo das propriedades térmicas dos materiais, enquanto as partes quatro e cinco descrevem os procedimentos para a medição das mesmas propriedades. A terceira parte do documento define o zoneamento bioclimático brasileiro, que divide o país em oito zonas bioclimáticas. Edificações localizadas na mesma zona bioclimática tendem a apresentar comportamento térmico similar, portanto, a norma recomenda estratégias construtivas para habitações de acordo com a zona bioclimática a mesma se localiza. As partes quatro e cinco da norma tratam dos métodos de medição da resistência e da condutividade térmica (ABNT, 2005).

Em 2013 entrou em vigor a Norma de Desempenho de Edificações Habitacionais (NBR 15.575), também promovida pela ABNT, que avalia as edificações através dos benefícios que traz ao consumidor. Dentre os diversos tópicos envolvidos no escopo da NBR 15.575 estão o desempenho térmico, acústico e lumínico, a segurança estrutural, a qualidade do ar, a acessibilidade e a durabilidade. O desempenho térmico, abordado no item 11 da primeira parte da normativa, apresenta três métodos de avaliação: simplificado, medição e simulação. O método de medição verifica o atendimento de pré-requisitos de acordo com medições, entretanto, é meramente informativo. O método simplificado trata de uma análise de atendimento de pré-requisitos referentes à envoltória. Caso os pré-requisitos não sejam atendidos, deve-se realizar o método de simulação. O método de simulação compara as temperaturas internas e externas diárias de ambientes de permanência prolongada (APP) de acordo com as zonas bioclimática, separando os resultados em desempenho no verão e no inverno. Para o desempenho no verão, a temperatura interna máxima de um dia típico de verão deve ser menor do que a temperatura externa máxima nesse mesmo dia. Já para o desempenho de inverno, a temperatura interna mínima de um dia típico de inverno deve ser maior do que a temperatura externa mínima nesse mesmo dia nas zonas bioclimáticas de 6 a 8, e maior do que a temperatura externa mínima somada a 3°C nas zonas bioclimáticas de 1 a

5. Para apresentar desempenho mínimo, todos os APPs da edificação devem respeitar os critérios de desempenho de verão e de inverno (ABNT, 2013).

Com o propósito de classificar as edificações quanto ao nível de desempenho energético, foram publicados os Regulamentos Técnicos da Qualidade para o Nível de Eficiência Energética de Edificações Comerciais (RTQ-C) e Residenciais (RTQ-R), que tratam da classificação de edifícios quanto ao desempenho energético. O RTQ-R foi atualizado em 2012 e conta com os métodos prescritivo e de simulação. O método prescritivo realiza as estimativas de carga térmica utilizando previsões de metamodelos, elaborados a partir de regressões lineares múltiplas (INMETRO, 2010; INMETRO, 2012).

Fossati et al. (2016), em sua análise crítica sobre o RTQ-R, identificaram que o modelo de *Multiple Linear Regression* (MLR) não é o mais adequado para lidar com as variáveis não-lineares presentes nos cálculos que envolvem a classificação energética através do regulamento brasileiro. Modelos baseados em técnicas mais complexas, que utilizam inteligência artificial, são os mais indicados para solucionar equações não-lineares, pois apresentam melhores resultados (AHMAD et al., 2014; BAKAR et al., 2015).

Nos últimos anos o RTQ-R passou por uma extensa revisão e a Proposta de Instrução Normativa do Inmetro para a Classe de Eficiência Energética de Edificações Residenciais (INI-R) foi indicada para substituí-lo. Um dos tópicos centrais da nova proposta é o uso de um novo metamodelo para a predição da carga térmica, baseado em redes neurais artificiais. Além disso, a proposta sugere a comparação do desempenho térmico do modelo real, que considera as características do edifício em análise, com um modelo de referência, que serve como base para a classificação do nível de eficiência energética do edifício (CB3E, 2018).

A eficiência energética de edificações consiste em uma alternativa de baixo custo, que pode ser implementada e aprimorada através de modelos de predição (WEI et al., 2018). Segundo Wang e Srinivasan (2017), nas últimas décadas, diversas pesquisas a respeito de técnicas utilizando inteligência artificial para a predição do consumo energético foram realizadas e uma quantidade considerável de modelos preditivos foi desenvolvida. Esses modelos contribuem para a gestão e conservação dos recursos energéticos em edifícios.

2.3 AS SIMULAÇÕES DE DESEMPENHO ENERGÉTICO E SUAS SIMPLIFICAÇÕES

Programas computacionais de simulação energética são ferramentas que calculam o desempenho energético de edificações (RYAN, SANQUIST, 2012). O uso dessas ferramentas tem contribuído consideravelmente para a gestão (controle e operação) de recursos energéticos no setor. Todavia, modelar de forma fiel sistemas energéticos de edifícios não é uma tarefa simples, visto que a relação entre os fatores que influenciam esses sistemas é complexa e, dificilmente, edificações reais são monitoradas a fim de se obter informações seguras que sirvam de patamar comparativo entre a simulação e a edificação real (LI, WEN, 2014).

As ferramentas de simulação energética de edificações levam em consideração basicamente os componentes construtivos em conjunto com os sistemas de condicionamento artificial do ar e estratégias de eficiência energética, como a ventilação natural e os sombreamentos (RYAN, SANQUIST, 2012). Dentre tantas utilidades, os resultados das simulações energéticas podem auxiliar na tomada de decisões multiobjetivas em projetos arquitetônicos, em projetos de sistemas complexos de condicionamento artificial que exigem alto consumo energético, e na tomada de decisões de políticas públicas (DOE, 2019a).

Diversos programas computacionais têm sido desenvolvidos para descrever o desempenho térmico de edificações, fornecendo aos usuários indicadores de performance como a demanda de energia, temperatura e umidade (CRAWLEY et al. 2008). O Diretório de Ferramentas de Simulações Computacionais do Departamento de Energia dos Estados Unidos (DOE) apresenta alguns dos programas de simulação energética já desenvolvidos, dentre eles estão: EnergyPlus, BuildSimHub, DesignBuilder, Simergy (DOE, 2019b).

O EnergyPlus é um programa gratuito e internacionalmente reconhecido, que foi desenvolvido através da união dos programas DOE-2 e BLAST por diversos laboratórios (CRAWLEY et al. 2008), tendo como principal contribuinte o *Lawrence Berkeley National Laboratory*. Essa foi uma iniciativa do DOE para estimular o desenvolvimento de um código computacional que fosse capaz de simular as trocas de ar entre ambientes e as cargas térmicas de aquecimento e refrigeração, possibilitando estimar o consumo de energia de sistemas de climatização e descrever o desempenho energético de edifícios (ENERGYPLUS, 2019a; ENERGYPLUS, 2020).

Para realizar a simulação da ventilação natural e do condicionamento artificial do ar

no programa EnergyPlus é necessário, inicialmente, modelar a geometria e os componentes construtivos do ambiente, as cargas internas e os padrões de ocupação e uso dos usuários. Finalmente, pode-se definir os sistemas de ventilação natural, através do grupo de objetos *Airflow Network*, e de condicionamento artificial do ar, através do grupo de objetos *HVAC Template* (ENERGYPLUS, 2019a; ENERGYPLUS, 2019b).

Dada a importância das aplicações de simulações energéticas de edificações no contexto energético atual, compreende-se que há uma necessidade de se realizar simulações acuradas. Sendo assim, toda e qualquer simplificação de um modelo original, independente do motivo pela qual foi realizada, deve ser cautelosa.

Kim et al. (2014) realizaram simplificações no envelope de um modelo de simulação detalhado utilizando a linguagem de modelagem Modelica, uma ferramenta que permite modificar algoritmos numéricos de simulação de forma simples. O modelo detalhado descreve as superfícies (translúcidas e opacas) de forma completa e calcula as transferências de calor unidimensional, levando em conta os coeficientes de condução, convecção e radiação e a transmissão solar, sendo que a radiação transmitida pela janela é totalmente absorvida pelo piso. A ventilação foi considerada com uma taxa de renovação de ar constante. Como a edificação conta com um número grande de superfícies externas, optou-se por unir todas as janelas em um único dado de entrada, assim como as paredes, ignorando suas respectivas orientações. O envelope equivalente considerou que a média da irradiação solar incidente absorvida por todas as paredes detalhadas foi absorvida por uma parede equivalente, a média da irradiação solar incidente absorvida por todas as janelas detalhadas foi absorvida por uma janela equivalente e a média da irradiação solar transmitida por todas as janelas detalhadas foi absorvida por um piso equivalente. Assim, o modelo detalhado de alta complexidade transformou-se em um modelo de zona térmica única. Os erros encontrados através da diferença de consumo energético anual do modelo detalhado para o modelo simplificado, ou equivalente, foram inferiores a 1%.

Para desenvolver modelos de predição do desempenho térmico de salas comerciais localizadas em Florianópolis, Versage (2015), em sua tese de doutorado, optou por elaborar um modelo base parametrizável no programa EnergyPlus. A partir desse modelo os parâmetros foram variados e foram gerados milhares de casos que, por fim, foram utilizados para treinar os metamodelos. Como a simulação no EnergyPlus é bem detalhada e os parâmetros influenciam uns aos outros, diversas simplificações precisaram ser realizadas para

tornar o modelo base parametrizável. As paredes e a cobertura do modelo detalhado, com transmitância térmica variando de 0,544 à 4,396 W/m².K e capacidade térmica variando de 0,22 a 220 kJ/m².K, foram representadas por uma camada equivalente de concreto e outra de isolante térmico com espessuras variáveis. As superfícies internas das zonas térmicas foram consideradas adiabáticas, sendo que a massa térmica das paredes internas foi representada por um objeto do EnergyPlus que contabiliza a massa térmica sem a necessidade de representar as paredes de fato. A geometria das janelas foi descrita a partir da porcentagem envidraçada em cada fachada externa, variando de 0% a 80%, sendo que o centro geométrico das janelas coincide com o centro geométrico das respectivas fachadas. Considerou-se que todos os vidros da edificação teriam as mesmas propriedades, definidas através do fator solar, que variou de 0,21 a 0,87, e da transmitância térmica, que variou entre vidro simples (5,7 W/m².K), duplo (2,8 W/m².K) e triplo (1,9 W/m².K). Para descrever o sombreamento do edifício foram simulados dois brises verticais e um horizontal, todos perimetrais às janelas. O tamanho dos brises foi calculado a partir de três variáveis paramétricas: os ângulos de sombreamento vertical e horizontal e o percentual de abertura da fachada. Já para descrever o sombreamento do entorno foi simulada uma superfície vertical de sombreamento em frente à abertura. A geometria dessa superfície de sombreamento foi calculada a partir apenas do ângulo de sombreamento do entorno. A exposição do piso foi considerada em contato com o solo, adiabática ou exposta apenas ao vento, para simular um pavimento sobre pilotis, enquanto a exposição da cobertura foi considerada exposta ao ambiente externo ou adiabática. Para a infiltração do ar foi utilizada uma taxa de renovação de ar fixa, que variou de 0,2 à 1,0 trocas de ar por hora. Além das propriedades térmicas e físicas, também foram simplificados os padrões de ocupação e as densidades de carga de iluminação e de equipamentos. É importante lembrar que o modelo foi desenvolvido para prever o desempenho térmico do ambiente, portanto, as simplificações foram realizadas de modo a alterar o mínimo possível as trocas de calor entre ambientes, ou seja, o balanço térmico.

2.4 O ESTADO DA ARTE DE METAMODELOS

2.4.1 Definições

De acordo com Chalal et al. (2016), duas abordagens principais são utilizadas para estimar o desempenho energético de edificações: modelos físicos (simulações) e modelos preditivos (metamodelos). Os modelos de engenharia, ou físicos, utilizam princípios físicos termodinâmicos para estimar a performance energética de edifícios. Apesar de serem flexíveis, possibilitando modelagens variadas, e de viabilizarem a interoperação com plataformas gráficas e visuais, esses modelos requerem alto custo computacional e alto nível de detalhamento, ou seja, exigem uma grande quantidade de parâmetros de entrada, sendo que a falta ou imprecisão desses parâmetros pode gerar resultados duvidosos. Sendo assim, as simulações termoenergéticas consomem muito tempo e devem ser realizadas por profissionais com alta qualificação, capazes de fornecer parâmetros de entrada confiáveis e de realizar análises cautelosas dos resultados (FOUCQUIER, 2013).

Já os metamodelos, ou modelos preditivos, são simplificações de modelos mais complexos e são tipicamente baseados em “aprendizado de máquinas”, ou seja, utilizam bases de dados, compostas por conjuntos de parâmetros de entrada representativos e seus respectivos parâmetros de saída. A base de dados alimenta o modelo, que passa por um processo de treinamento onde aprende a deduzir funções matemáticas efetivamente capazes de descrever o comportamento dos parâmetros de entrada em relação à saída. O processo de desenvolvimento dos metamodelos conta com profissionais qualificados, capazes de compreender os fenômenos termo-físicos e de analisar as variáveis utilizadas no modelo detalhado, para por fim, simplificá-lo (ZHAO, MAGOULÈS, 2012; FOUCQUIER, 2013; CHALAL et al. 2016).

Metamodelos são ferramentas que, eventualmente, podem substituir programas de simulação sofisticados, que exigem alto nível de conhecimento e prática, parâmetros de entrada detalhados e alto custo computacional. Assegura-se que os metamodelos reproduzem os resultados de simulações de forma mais rápida, sendo que, a partir de um desenvolvimento acompanhado de validações e testes rigorosos, podem ser suficientemente acurados. Assim, o uso de metamodelos como ferramentas de análise térmica tem um impacto considerável para a compreensão e otimização do desempenho energético de edifícios, já que sua operação

dispensa a compreensão prévio de teorias termo-físicas avançadas (AMASYALI, EL-GOHARY, 2018).

2.4.2 Algoritmos de otimização

Para concretizar a otimização do desempenho térmico de edificações podem ser utilizadas técnicas como a análise de sensibilidade global ou ainda podem ser utilizados algoritmos de otimização. Visto que a quantidade de variáveis que influenciam o desempenho térmico é significativa, essas técnicas necessitam de ampla parametrização para cobrir de forma representativa o espaço amostral, tornando o procedimento complexo e exigindo muito tempo de simulação (CHLELA et al., 2009). O uso de algoritmos acoplados à metamodelos é uma alternativa que vem sendo utilizada nos últimos anos para automatizar a otimização do desempenho energético das edificações (MAGNIER, HAGHIGHAT, 2010; EISENHOWER et al., 2012; ASADI et al., 2014).

A metodologia apresentada por Eisenhower et al. (2012) utiliza metamodelos em combinação com algoritmos de otimização para otimizar o desempenho energético de edificações. A metodologia se inicia com a variação dos parâmetros de entrada do modelo de simulação dentro de uma faixa de interesse. As simulações são realizadas e um metamodelo é treinado, através da técnica *Support Vector Machine* (SVM), e posteriormente validado. Análises de incerteza e de sensibilidade global são aplicadas sobre uma grande amostra gerada pelo metamodelo. Caso as análises identifiquem que determinados parâmetros de entrada têm pouca influência sobre o parâmetro de saída de interesse, um novo metamodelo reduzido é treinado e validado sem esses parâmetros e uma nova amostra é gerada. Finalmente, o algoritmo de otimização é aplicado na amostra desenvolvida pelo metamodelo reduzido. Os pesquisadores testaram a metodologia para otimizar o conforto térmico, através do voto médio predito, o PMV de Fanger et al. (1970), e o consumo energético anual de um edifício comercial de dois andares em Illinois, EUA. Foram executadas 5.000 simulações no programa EnergyPlus, sendo que cada simulação durou 15 minutos, considerando um computador com processador de 2,8 GHz. O modelo foi treinado e, ao ser comparado com as simulações, apresentou erros de 2,15% e 0,02% para o PMV e para o consumo energético anual, respectivamente. O algoritmo de otimização foi aplicado utilizando resultados gerados pelo metamodelo e alcançou uma redução de 45% no consumo energético para um PMV de -

0,09. A otimização seria altamente custosa e inviável sem o uso do metamodelo, tendo em vista que cada simulação durou 15 minutos e o processo de otimização necessitou de aproximadamente 1.000.000 de iterações para convergir em um resultado satisfatório.

2.4.3 Fase inicial de projeto

De acordo com Yu et al. (2015), a tomada de decisões em fase inicial de projeto é uma tarefa conceitual, multiobjetiva e essencial para o desenvolvimento de edificações de alta performance, pois falhas nesse processo podem ser amplificadas em processos posteriores. A multiobjetividade se deve ao fato de que dois fatores conflitantes devem ser levados em conta na tomada de decisões: o conforto térmico e o consumo energético. Dentre as considerações que devem ser realizadas, estratégias variadas que influenciam o consumo energético e o conforto térmico, como a ventilação natural e o aproveitamento da inércia térmica, devem ser testadas levando-se em conta inúmeros fatores como a forma geométrica, a orientação, o percentual envidraçado da fachada e as propriedades térmicas dos materiais construtivos.

Por ter poucos parâmetros definidos, a fase inicial de projeto é uma etapa que permite inovações, entretanto, exige precaução para que as decisões não entrem em conflito em etapas futuras. Nessa fase de projeto é possível testar inúmeras alternativas e soluções construtivas, a fim de tentar satisfazer ambas as exigências de conforto térmico e de consumo energético (AMIRI, MOTTAHEDI, ASADI, 2015).

Portanto, o processo de tomada de decisões em fase inicial de projetos para a concepção de edificações eficientes pode contar com o auxílio de metamodelos, que possibilitam estimar índices de conforto térmico, consumo energético e retornos financeiros com respostas rápidas que exigem baixo custo computacional. Entretanto, devido à alta complexidade e à quantidade de fatores que influenciam no consumo energético, previsões acuradas são, ainda, um desafio (MATHEW, et al., 2015).

Østergård, Jensen e Maagaard (2017) apresentam uma metodologia para a otimização multiobjetiva de parâmetros de saída conflitantes em fase inicial de projeto. A metodologia inicia elaborando-se uma base de dados de simulações termoenergéticas através do método de amostragem de Sobol. Realiza-se a análise de sensibilidade global de Sobol e aplica-se o Filtro de Monte Carlo combinado com gráficos de coordenadas paralelas para realizar a priorização ou a fixação de variáveis. Essas análises são aplicadas sobre uma classificação que

deve representar a relevância de cada um dos parâmetros de saída de interesse para o projeto. Finalmente, desenvolve-se um metamodelo com o objetivo de explorar subespaços da amostra e responder às variações específicas nos parâmetros de entrada. Os autores aplicaram a metodologia apresentada para otimizar três dados de saída conflitantes em fase inicial de projeto: a demanda de energia anual, o número de horas acima de 26°C em ambientes críticos e a disponibilidade de luz natural. A base de dados foi preenchida com simulações no Be10, um programa de simulação baseado na ISO 13790, e o metamodelo foi desenvolvido a partir de MLR. A aplicação da metodologia proposta para um projeto em específico deve ser realizada por especialistas que entendem plenamente tanto os fenômenos termo-físicos que regem o comportamento do espaço amostral quanto as técnicas utilizadas para elaborar e analisar a amostra e desenvolver o metamodelo. Somente na etapa de tomada de decisões é que a metodologia é apresentada para os engenheiros, arquitetos e acionistas que, junto com a equipe desenvolvedora, exploram o espaço amostral. Quando aplicada, a metodologia incentivou os projetistas a explorarem de forma ampla as inúmeras soluções possíveis na fase de projeto e auxiliou os profissionais na compreensão do comportamento térmico da edificação e na tomada de decisões bem fundamentadas.

2.4.4 Retrofit

Visto que o setor das edificações é um alto consumidor de energia (IEA, 2018a) e a rotatividade do estoque da construção civil é baixa, reduzir o consumo de edificações já existentes é uma necessidade real. Graças ao avanço tecnológico, diversas alternativas de *retrofit* para aumentar a eficiência energética são possíveis, dentre elas, destacam-se as medidas que aumentam o desempenho térmico dos envelopes. Entretanto, como o processo de *retrofit* é de natureza irreversível, é importante que se faça uma vasta varredura nas alternativas viáveis de medidas de eficiência energética. Essa varredura pode ser realizada através de algoritmos de otimização (KUMBAROĞLU, MADLENER, 2012).

Magnier e Haghghat (2010) utilizaram algoritmos genéticos para realizar a otimização multiobjetiva do conforto térmico, através do PMV, e do consumo energético anual no *retrofit* de duas habitações estudantis no campus do *National Research Council*, no Canadá. Os autores utilizaram o método do Hipercubo Latino para desenvolver uma amostra de 475 simulações no programa TRNSYS, variando seis dos seus parâmetros de entrada. As

simulações duraram cerca de três semanas para serem realizadas em um computador com processador de 1,66 GHz. A otimização só foi possível porque uma *Artificial Neural Networks* (ANN) foi treinada com a base de dados e então utilizada para gerar novos casos que alimentaram o algoritmo genético. Como a otimização realizada possui caráter multiobjetivo, a escolha do caso ótimo dependeu de uma ponderação entre o conforto térmico e o consumo energético. Os casos otimizados encontrados pelo algoritmo foram comparados com duas seleções randômicas dos parâmetros de entrada e duas seleções baseadas no conhecimento dos autores, sendo que, em ambas as comparações, o algoritmo se mostrou significativamente melhor.

Asadi et al. (2014) replicaram a otimização multiobjetiva desenvolvida por Magnier e Haghighat (2010) no *retrofit* de 6 blocos de edificações de uma escola em Coimbra, Portugal. Os parâmetros a serem otimizados foram: o consumo energético, o custo do *retrofit* e as horas em desconforto térmico, baseado no PMV. Os autores desenvolveram uma amostra de 1045 simulações no programa TRNSYS por Hipercubo Latino, sendo que 950 simulações treinaram e 95 simulações validaram um metamodelo através da técnica de ANN. O metamodelo foi utilizado para gerar resultados que alimentaram um algoritmo genético. O procedimento de otimização necessitou 20.736 iterações e durou 3 dias. Caso a ANN não fosse utilizada, o processo teria duração de 75 dias, já que cada uma das simulações durou em média 5,19 minutos em um computador com processador de 2,66 GHz. A metodologia ofereceu uma série de soluções para o estudo de caso e se provou como uma ferramenta útil para auxiliar a tomada de decisões de projetos de *retrofit*.

2.4.5 Técnicas de metamodelagem

Com o aumento da credibilidade dos metamodelos de desempenho térmico de edificações, devido ao seu progresso em acurácia e facilidade de uso, estes passaram a ser aplicados em normas de conformidade (EISENHOWER et al., 2012). No Brasil, Mazzaferro et al. (2018) desenvolveram três metamodelos para a INI-R, que predizem as cargas térmicas de aquecimento e refrigeração e o percentual de horas ocupadas em conforto térmico quando o ambiente é ventilado naturalmente. Os autores escolheram 32 parâmetros de entrada e, devido a não-linearidade entre eles, utilizaram uma ANN para solucionar o problema. A amostragem para treinar as redes foi desenvolvida através do método Hiper Cubo Latino, que

forneceu os parâmetros de entrada para realizar as simulações no programa EnergyPlus. A acurácia final dos metamodelos para prever as cargas térmicas de aquecimento e refrigeração foi alta, com R^2 iguais a 0,99, entretanto, a acurácia do metamodelo que estima o conforto térmico obteve resultado menos satisfatório, com R^2 e RMSE iguais a 0,924 e 9,0%, respectivamente.

Segundo Zhao e Magoulès (2012), apesar da grande variedade de métodos para desenvolver modelos preditivos que descrevem o comportamento de edifícios, os métodos a partir de ANN e SVM estão entre os mais utilizados. A revisão de Amasyali e El-Gohary (2018) identificou que 47%, 25% e 4% dos metamodelos da literatura utilizaram as técnicas ANN, SVM, *Regression Trees* (RT), respectivamente. A capacidade de lidar com sistemas não-lineares torna essas técnicas adequadas para estimar o consumo energético de edificações, devido à complexidade de interação entre os parâmetros de entrada e de saída envolvidos (AHMAD et al., 2014; BAKAR et al., 2015).

A técnica ANN assemelha-se ao funcionamento de um cérebro humano, onde cada camada é formada por um conjunto de neurônios. Os neurônios da camada de entrada recebem blocos de informações e repassam as informações para os neurônios da próxima camada adjacente. Os blocos de informações correspondem aos parâmetros de entrada e seus respectivos parâmetros de saída amostrados. A interação entre as camadas de neurônios é realizada através de funções de ativação, que, analogamente, são representadas por conexões sinápticas. Sendo assim, as funções de ativação decidem se a informação deve ou não seguir para o próximo neurônio. As informações transferidas entre as camadas são armazenadas nos neurônios na forma de “pesos”, que são gerados e ajustados na etapa de treinamento do modelo. O treinamento da rede finaliza quando as diferenças entre os resultados amostrados e preditos atingem um valor mínimo pré-determinado pelo desenvolvedor (DEB et al., 2017).

Na etapa de treinamento de uma ANN são utilizados os conceitos de função custo e gradiente descendente. A função custo compara o resultado amostrado com o resultado da predição, estimado pelo metamodelo. A medida em que a função custo diminui, os valores amostrados e preditos se aproximam (VAPNIK, 1999; BOTTOU, 2010). Portanto, a ANN estará bem treinada, para o conjunto de dados fornecido, quando cada conexão sináptica encontrar seu “peso” correspondente otimizado, fornecendo o valor mínimo para a função custo. Para acelerar o treinamento e encontrar o valor mínimo da função custo, é possível utilizar a técnica chamada gradiente descendente. Essa técnica se inicia analisando um ponto

qualquer da função custo e identificando o gradiente naquele ponto, ou seja, em que direção a função decresce. Identificada a direção na qual a função decresce, avança-se para o próximo ponto nessa direção e, novamente, identifica-se o gradiente. O ciclo se repete até que o mínimo global da função custo é encontrado, isso acontece quando o gradiente descendente converge a um valor próximo de zero (ZEILER, 2012). O algoritmo conhecido como *backpropagation* pode ser utilizado em conjunto com o gradiente descendente para calibrar os pesos dos neurônios, tornando o processo mais rápido e eficiente. Esse código trata de encontrar as derivadas parciais da função custo e computar os erros derivados de todas as camadas, simultaneamente. Como a função custo se relaciona aos resultados (parâmetros de saída), o código propaga a correção dos erros na direção do parâmetro de saída para os parâmetros de entrada (AMARI, 1993; LECUN et al., 2012; REZENDE, MOHAMED, WIERSTRA, 2014).

A técnica conhecida como SVM, desenvolvida por Vapnik (1999), foi desenvolvida com o intuito de resolver problemas de classificação e posteriormente foi generalizada para problemas de regressão. O treinamento com a SVM consiste em mapear pontos, ou vetores de suporte, que definem limites entre grupos de classificação. A partir dos vetores de suporte é possível traçar hiperplanos que classificam a base dados de acordo com esses grupos. Um hiperplano deve ser traçado de tal forma que apresente a maior distância possível até qualquer vetor de suporte que separa os grupos, ou seja, o hiperplano localiza-se na distância euclidiana média entre os grupos. Entre os hiperplanos e os pontos mais próximos a ele localizam-se as margens, que são subespaços ortogonais aos hiperplanos, tangenciados pelos vetores de suporte. Visto que o objetivo principal da SVM é encontrar os vetores de suporte, a partir dos quais definem-se as margens e os hiperplanos, ao realizar as previsões, a base de dados pode ser resumida a esses vetores, aumentando significativamente a eficiência da técnica. Para resolver problemas não-lineares, a técnica utiliza funções nucleares, do inglês *kernel functions*. As funções nucleares elevam a dimensionalidade da base de dados, permitindo que se encontrem hiperplanos que melhor descrevem os grupos de classificação em dimensões de maior grau. Dependendo da disposição dos pontos na base de dados, diferentes funções nucleares podem ser mais adequadas para caracterizar os grupos e encontrar hiperplanos ótimos, reduzindo os erros do modelo (AWAD, KHANNA, 2015). Apesar de ser uma técnica competitiva e apresentar resultados acurados, a calibração dos seus hiperparâmetros é difícil e deve ser determinante para a acurácia das previsões, tornando o processo de otimização dos

hiperparâmetros um dos pontos chave no desenvolvimento de SVMs (BORDEAU, 2019).

A RT é uma técnica de aprendizado de máquinas simples e de fácil interpretação. A técnica consiste em dividir a base de dados recursivamente em duas porções mutuamente excludentes, através de critérios binários, até que cada porção forme um grupo com determinado grau de homogeneidade. Cada grupo é caracterizado pela média dos valores dos dados de saída dos elementos que formam o grupo. Fazendo uma analogia aos componentes de uma árvore, a raiz seria a base de dados fornecida no treinamento e cada ramificação da árvore seria um critério para dividir da base de dados, sendo que a última ramificação, ou critério, leva até as folhas, que apontam para o valor de saída. Na prática, em cada predição o conjunto de parâmetros de entrada inicia sua trajetória na raiz e passa por uma sequência de perguntas com respostas do tipo sim ou não, até chegar em uma folha e ser enquadrada em um grupo, que determina o valor da predição. Árvores excessivamente grandes tendem a gerar grupos com ruídos e causar *overfitting*, pois buscam descrever detalhadamente as características da amostra de treino. Uma técnica muito comum para evitar o *overfitting* é podar as folhas mais distantes da raiz da árvore, tornando o modelo mais generalista e aumentando a acurácia da amostra de teste (BUNTINE, 1992; DE'ATH, FABRICIUS, 2000).

Apesar de os modelos em RT serem fáceis de interpretar e apresentarem alto valor no processo de análise de dados, já que dividem a base de dados em grupos “homogêneos”, frequentemente esses modelos realizam predições pouco acuradas para novos dados (LOH, 2011). A técnica de metamodelagem conhecida como *Random Forest* (RF) combina a simplicidade de diversas RT, resultando em um modelo mais flexível e acurado. O treinamento de um modelo em RF se inicia com a aplicação da técnica *Bootstrapping*, que seleciona amostras aleatórias da base de dados, sendo que um mesmo elemento pode se repetir em uma ou mais amostras. Em seguida, para cada amostra é treinada uma RT, que considera um subconjunto aleatório de parâmetros de entrada da amostra correspondente. A desconsideração de alguns dos parâmetros de entrada em cada uma das amostras diminui a correlação entre as RTs, aumentando a diversidade e a flexibilidade do metamodelo. A predição final de um modelo em RF é realizada calculando-se a média das predições de todas as RTs desenvolvidas durante o seu treinamento (QUINLAN, 1986; BREIMAN, 2001; HASTIE, TIBSHIRANI, FRIEDMAN, 2009).

Além das técnicas de metamodelagem levantadas por Amasyali e El-Gohary (2018), nos últimos anos a técnica *Gradient Boosted Decision Trees* (GBDT) tem sido aplicada com

maior frequência na solução de problemas de desempenho energético de edificações (PAPADOPOULOS et al. 2017; FAN et al., 2018; PAPADOPOULOS, KONTOKOSTA, 2018; TOUZANI, GRANDERSON, FERNANDES, 2018; WANG, LU, LI, 2019; GONG et al., 2020; KAMEL, SHEIKH, HUANG, 2020; LU et al. 2020). A GBDT utiliza os conceitos fundamentais da RT para gerar um metamodelo formado por um conjunto sequencial de árvores de baixa complexidade, chamadas de *weak learners*. Diferente da técnica RF, a GBDT evita que as árvores que a compõe repitam os mesmos erros, pois cada árvore sequencial é treinada para corrigir os erros do conjunto das árvores que a precedem. Segundo evidências empíricas levantadas por Friedman (1999), a acurácia de um modelo que combina diversas RTs de baixa complexidade é maior do que a acurácia de uma única RT de alta complexidade. O treinamento de uma GBDT se inicia com a criação de uma árvore contendo apenas a raiz, ou folha, cujo valor da predição é equivalente à média dos valores dos dados de saída da amostra. Em seguida é gerada uma árvore residual, isto é, uma árvore que estima, para cada elemento da amostra, os erros provenientes da primeira árvore. A predição do modelo contendo as duas árvores é obtida através da subtração do erro predito pela segunda árvore com a predição da primeira árvore, de modo que o erro da predição inicial é reduzido. O procedimento se repete na medida em que novas árvores são adicionadas ao modelo, entretanto, os erros preditos pelas novas árvores são estimados considerando a predição realizada por todas as árvores anteriores. O treinamento se encerra quando os erros param de reduzir substancialmente ou quando o modelo atinge um número de RTs pré-definido (FRIEDMAN, 2001; ELITH, LEATHWICK, HASTIE, 2008).

Uma das implementações da técnica GBDT é a *Extreme Gradient Boosted Trees* (XGBT), que, além de utilizar estratégias para evitar o *overfitting*, otimiza o uso de recursos computacionais (FAN et al., 2018). A principal diferença entre as duas técnicas reside na maneira como as árvores residuais são elaboradas. Assim como a GBDT, a XGBT inicia seu treinamento com uma árvore contendo apenas a raiz, sendo que o valor da predição inicial é um palpite aleatório, normalmente assumido como 0,5. Em seguida, é gerada uma árvore residual, que prediz os erros do palpite inicial. As predições dessa árvore são subtraídas do palpite inicial, e assim sucessivamente. Durante o treinamento de uma XGBT é introduzido o conceito de similaridade dos nós e de ganho das ramificações, que são utilizados para avaliar os possíveis critérios de divisão dos dados no processo de construção das árvores residuais. O valor da similaridade de um nó da árvore (raiz ou folha) é calculado pelo quadrado da soma

dos resíduos dividido pelo número de elementos presentes naquele nó. O ganho da ramificação é calculado pela soma das similaridades das duas folhas ramificadas subtraída da similaridade da raiz da ramificação. Portanto, na construção de uma árvore residual definem-se diversos critérios para dividir a base de dados em cada ramificação, o ganho é calculado para cada um dos possíveis critérios e o critério com maior ganho determina a divisão dos dados na ramificação correspondente. Esse procedimento se repete para cada árvore residual e os resíduos de todas as árvores são subtraídos do palpite inicial (CHEN, GUESTRIN, 2016).

2.4.6 Pré-processamento, treinamento, validação e teste

A elaboração de metamodelos abrange quatro etapas principais: coleta de dados, pré-processamento dos dados, treinamento e teste do metamodelo. A primeira etapa consiste, basicamente, na elaboração do banco de dados. A segunda etapa trata os dados incorretos, que podem comprometer o treinamento do modelo e a acurácia das predições. Assim, os dados obtidos devem ser ajustados às necessidades do metamodelo, processo que pode incluir a extração, integração e transformação de informações inconsistentes. Por fim, o modelo preditivo é treinado com uma parte dos dados fornecidos, que consiste nos casos vistos, e testado pela parte não utilizada na etapa de treinamento, casos nunca vistos (AMASYALI, EL-GOHARY, 2018).

Para amostras consideravelmente grandes, Lever, Krzywinski e Altman (2016), sugerem uma divisão da amostra de treinamento em duas partes: uma para o treinamento propriamente dito (casos vistos) e outra para a validação (casos não vistos). Para esses autores, os dados podem ser divididos da seguinte maneira: 80% para treinar e validar e 20% para testar o modelo.

De acordo com a natureza dos dados, diversas técnicas de pré-processamento de dados podem ser utilizadas, entretanto, essa é uma tarefa desafiadora que demanda esforço manual extensivo e tempo para o desenvolvimento de códigos de programação (MALIK, GOYAL, SHARMA, 2010). O livro *Applied Predictive Modeling*, de Kuhn e John (2013), instrui modeladores de máquinas de aprendizado a utilizar as diversas funções da biblioteca Caret, da linguagem de programação R, para realizar o pré-processamento de dados. Dentre os pré-processamentos abordados no livro, citam-se: a normalização ou padronização, a transformação de variáveis qualitativas em variáveis lógicas e a remoção ou transformação de

parâmetros de acordo com suas correlações.

A normalização é uma das técnicas utilizada no pré-processamento de dados para aprendizado de máquinas, pois torna o seu acesso mais eficiente. Mohd Nawi, Atomia e Rehman (2013) testaram as técnicas conhecidas como normalização min-max, padronização e escala decimal para pré-processar três bases de dados extraídas do *UCI Machine Learning Repository*. A normalização min-max consiste em extrair o mínimo amostral de cada valor amostrado e dividi-lo pelo alcance da amostra. A padronização consiste em subtrair a média amostral de cada valor amostrado e dividi-lo pelo desvio padrão amostral. A escala decimal consiste em transformar todos os valores amostrados na escala decimal. As bases de dados foram treinadas utilizando ANN de classificação e os autores demonstraram que todas as técnicas de normalização aumentaram a acurácia e robustez dos modelos desenvolvidos.

Outra técnica amplamente utilizada é a criação de variáveis lógicas. O uso de variáveis lógicas é útil para substituir variáveis qualitativas (categóricas), que não podem ser medidas através de uma escala numérica e assumem mais de dois possíveis valores. Para cada valor da variável qualitativa é atribuída uma variável lógica, que assume valores binários de 0 e 1, ou -1 e 1, indicando a ausência ou a presença da qualidade representada por aquela variável. Como cada valor das variáveis qualitativas pode se comportar de maneira singular, seria necessário utilizar um modelo de regressão linear para representar cada um desses valores. A partir das variáveis lógicas, o uso de um único modelo de regressão linear que represente os múltiplos valores das variáveis qualitativas torna-se possível (SUITS, 1957; DRAPER, SMITH, 1998).

A remoção ou transformação dos parâmetros de entrada depende da análise de correlação entre eles. Segundo Yu e Liu (2004), um parâmetro de entrada é útil para o modelo se ele for relevante para o parâmetro de saída, correlação alta, e redundante para os outros parâmetros de entrada, correlação baixa. A baixa correlação entre um parâmetro de entrada e um parâmetro de saída indica que esse parâmetro influencia pouco o parâmetro de saída e não traz vantagens ao modelo. A alta correlação entre dois parâmetros de entrada indica que os dois predizem o mesmo comportamento do parâmetro de saída, logo, um deles pode ser removido sem comprometer a performance do modelo (KUHN, JOHNSON, 2013). A remoção de parâmetros de entrada é uma estratégia que diminui a dimensionalidade, o esforço computacional e a complexidade do modelo, tornando-o mais generalista e interpretável e, eventualmente, aumentando a sua acurácia (HALL, 2000).

Um modelo descrito por funções excessivamente complexas compreenderá bem os casos vistos, porém, dificilmente responderá bem aos casos não vistos. O fenômeno em que o modelo está muito adaptado aos padrões da amostra de treinamento, logo, é pouco generalista e não consegue prever com acurácia os casos não vistos, é chamado de *overfitting* (SILVER, 2012).

Controlar a distribuição dos dados nas etapas de treinamento, validação e teste consiste em uma maneira alternativa para evitar o *overfitting*. A validação cruzada é uma das maneiras de dividir e intercalar a amostra na etapa de treinamento e validação (POLINE et al, 2010). Nesse procedimento, a amostra de treinamento e validação é dividida em “K” blocos e, a cada ciclo de treinamento seguido por validação, “K - 1” blocos são utilizados para treinamento e 1 bloco é utilizado para validação. Os “K” blocos intercalam-se a cada ciclo, assim, variam-se continuamente as amostras para treinamento e para validação, evitando que o modelo se viciie no conjunto de dados de entrada fornecidos para treinamento e que haja a possibilidade de *overfitting* (RONCHETTI, FIELD, BLANCHARD, 1997). O valor de “K” é um hiperparâmetro a ser definido pelo desenvolvedor e, de acordo com Vehtari, Gelman e Gabry (2017), a divisão típica da amostra encontrada na literatura para validação cruzada é de 10 blocos.

Outra maneira de diminuir a complexidade dos modelos, a fim de torná-los mais generalistas, é utilizar a técnica chamada de regularização, que pode ser aplicada em diversas técnicas de aprendizado de máquinas, como ANN, SVM, RF e GBDT (GIROSI, JONES, POGGIO, 1995). Essa técnica trata de adicionar um termo na soma dos erros quadráticos que penaliza as previsões realizadas durante o treinamento do metamodelo, tornando o modelo menos complexo, já que o força a se ajustar menos à amostra de treinamento (HAGAN et al., 1996; SRIVASTAVA et al., 2014). O valor do termo adicionado na regularização é um hiperparâmetro que deve ser definido pelo desenvolvedor.

O algoritmo conhecido como Validação Cruzada Generalizada consiste em uma maneira automatizada de encontrar valores ótimos para o termo adicionado na regularização a cada ciclo da validação cruzada (GOLUB, HEATH, WAHBA, 1979; GOLUB, VON MATT, 1997). Dessa maneira, o valor ideal desse hiperparâmetro é utilizado, tornando o modelo mais generalista e diminuindo, consideravelmente, a chance de *overfitting*.

2.4.7 Aplicações

A relevância do uso de metamodelos para estimar o desempenho térmico de edificações foi esclarecida na extensa revisão de literatura realizada por Amasyali e El-Gohary (2018). Apesar da relevante quantidade (47%) de modelos desenvolvidos para prever o consumo global dos edifícios, que envolve o consumo com eletrodomésticos, iluminação e climatização, a maior parte dos trabalhos encontrados (51%) focaram no consumo exclusivo dos sistemas de climatização, aquecimento e refrigeração. Os autores detectaram ainda que 81% dos modelos preditivos pesquisados foram aplicados a edificações comerciais, sendo que apenas 19% dos metamodelos encontrados na literatura estimam o desempenho térmico de edifícios residenciais.

Ekici e Aksoy (2009) estimaram a demanda anual de energia para aquecimento de três edificações residenciais multifamiliares em Elazig, Turquia, através de três ANN que utilizaram o algoritmo de *backpropagation*. Os modelos foram treinados por uma base de dados simulada através do método de diferenças finitas. Foram utilizados a função de treinamento Levenberg-Marquardt, uma camada interna com 20 neurônios, taxa de aprendizado igual a 90% e a acurácia durante a etapa de treinamento e validação foi avaliada pelo *Root Mean Square Error* (RMSE). Os modelos levaram de 172 a 402 ciclos para alcançar a performance exigida e apresentaram erros médios de 1,48%, 3,64% e 5,16%, valores que foram consideradas satisfatórios pelos desenvolvedores.

Magnier e Haghghat (2010) desenvolveram uma ANN para a otimização multiobjetiva do consumo energético anual e do conforto térmico, através do PMV, de uma habitação estudantil no Canadá. Para a predição foram utilizados seis parâmetros de entrada, a função de treinamento Levenberg-Marquardt, uma camada interna com 20 neurônios, a técnica regularização bayesiana e a avaliação de performance na etapa de treinamento e validação foi definida através da soma dos erros quadráticos. A ANN levou 516 ciclos para atingir a acurácia pré-determinada e os erros para o consumo com aquecimento, refrigeração e ventilação foram 3,7%, 3,4% e 7,3%, respectivamente.

Naji et al. (2016) utilizaram o algoritmo *Extreme Learning Machine* (ELM) acoplado a uma ANN de apenas três parâmetros de entrada e uma camada interna para estimar a demanda anual de energia para aquecimento e refrigeração de uma residência unifamiliar de 2 pavimentos em Istambul, Turquia. A base de dados foi constituída de 180 simulações no

programa EnergyPlus, sendo 70% para treinamento e 30% para validação. O modelo foi treinado e validado, e na fase de teste apresentou RMSE de 74,02, coeficiente de Pearson (r) de 0,9985 e coeficiente de determinação (R^2) de 0,997. Quando comparado com uma ANN treinada por *backpropagation*, o modelo ELM apresentou menor tempo de treinamento, menor RMSE e maiores “ r ” e R^2 .

Chou e Bui (2014) desenvolveram nove metamodelos diferentes para prever a carga térmica de aquecimento e refrigeração de um conjunto de 12 edificações residenciais localizadas em Atenas, Grécia. Foram considerados oito parâmetros de entrada e a base de dados foi constituída de 768 simulações no programa Ecotect. Os modelos foram treinados utilizando validação cruzada com 10 blocos e técnicas de metamodelagem variadas, como ANN, MLR, RT e SVM. Apesar de manterem os hiperparâmetros de todos os metamodelos na configuração padrão, os pesquisadores inovaram ao desenvolver modelos combinados, gerados a partir da união dos melhores modelos avaliados isoladamente. Os modelos mais acurados foram SVM, com *Mean Absolute Error* (MAE) de 1,13 kW e RMSE de 1,99 kW, e a combinação de ANN com SVM, com MAE de 1,27 kW e RMSE de 1,99 kW. Dentre os nove metamodelos desenvolvidos, aqueles treinados através das técnicas MLR e RT foram os menos acurados.

Visto que a família de modelos baseados em árvores têm sido pouco aplicados para prever o desempenho de edificações, Papadopoulos et al. (2018) desenvolveram e compararam três metamodelos dessa família para prever o consumo energético com aquecimento e refrigeração de 12 tipologias de edificações residenciais. Todas as tipologias possuem mesma volumetria (771,75 m³) e os seguintes parâmetros foram variados nos modelos de simulação: compactidade relativa, área das superfícies, das paredes e da cobertura, pé-direito médio, orientação, área envidraçada e distribuição dos vidros nas fachadas. Os pesquisadores recorreram a simulações termoenergéticas no programa Ecotect para gerar os valores de consumo energético de 768 edificações que formaram a base de dados. A base de dados foi dividida em amostras para treino e teste, na proporção 80 por 20, respectivamente. A amostra de treino foi utilizada para otimizar os hiperparâmetros das técnicas RF, *Extremely Randomized Trees* e GBDT através da amostragem por grade. Para dar mais diversidade à amostra e evitar o fenômeno de *overfitting* foi utilizada a técnica de validação cruzada com 10 blocos. Entre os três modelos desenvolvidos, a GBDT apresentou os resultados mais acurados, com MAE igual a 0,20 kWh/m² e RMSE igual a 0,32 kWh/m² para o consumo com

aquecimento, e MAE igual a 0,40 kWh/m² e RMSE igual a 0,56 kWh/m² para o consumo com refrigeração. Já o modelo RF foi o menos acurado, apresentando MAE e RMSE aproximadamente iguais a 0,30 e 0,44 kWh/m², respectivamente, para o consumo com aquecimento, e MAE e RMSE aproximadamente iguais a 0,85 e 1,52 kWh/m², respectivamente, para o consumo com refrigeração. O mesmo experimento foi realizado anteriormente por Tsanas e Xifara (2012), porém, apenas a técnica RF foi implementada e os seus hiperparâmetros não foram otimizados. Mesmo sendo o modelo menos acurado, os autores comparam os resultados do seu modelo em RF com o trabalho anterior e identificaram que um aumento de até 70% na acurácia pode ser alcançado através da otimização adequada dos hiperparâmetros.

Wang, Lu e Li (2019) compararam o desempenho de cinco modelos para prever o consumo energético horário com aquecimento de edificações residenciais localizadas em zonas climáticas frias da China. As técnicas de metamodelagem abordadas foram: ANN, SVM, RF, GBDT e XGBT. Como parâmetros de entrada foram adotados a hora do dia, o histórico de consumo com aquecimento, a temperatura de bulbo seco, a temperatura de ponto de orvalho, a umidade relativa, a velocidade do vento e a radiação solar, todos medidos durante a estação de inverno. A etapa de otimização dos hiperparâmetros foi realizada através da amostragem em grade executada sobre 10 blocos, gerados a partir do método validação cruzada. Assim, foram definidos valores discretos para cada hiperparâmetro e cada possível combinação de hiperparâmetros foi treinada 10 vezes, utilizando nove blocos da amostra para treino, e um bloco para validação. Considerando uma amostra de apenas 900 elementos, os modelos em XGBT e RF empataram na primeira colocação, com RMSE igual a 0,19 kW, seguidos do modelo em GBDT, com RMSE de 0,20 kW. Os modelos em SVM e ANN apresentaram os resultados menos acurados, com RMSE de 0,22 kW e 0,23 kW, respectivamente.

Em um estudo aplicado sobre aproximadamente 7500 edificações residenciais de Nova Iorque, Papadopoulos e Kontokosta (2019) propuseram uma metodologia de desenvolvimento de um modelo de *benchmarking* de consumo energético que superasse o modelo vigente. A base de dados foi elaborada a partir de uma união dos dados provenientes do projeto *Primary Land Use Tax Lot Output* (PLUTO) e da Lei Local americana nº 84 (LL84), que exige que proprietários de edificações com mais de 50.000 pés quadrados de área total forneçam relatórios anuais de consumo de energia e água, além de características

construtivas do edifício. Após realizarem a limpeza e o pré-processamento dos dados, os pesquisadores aplicaram a técnica XGBT para realizar a predição do consumo energético dos edifícios, considerando como parâmetros de entrada as características volumétricas, a fonte energética primária, o entorno, entre outras. A base de dados foi dividida em duas amostras, 80% para treino e 20% para teste, sendo que a técnica de validação cruzada com 5 blocos foi aplicada para evitar o *overfitting*. O modelo em XGBT gerado através da nova metodologia obteve R^2 igual a 0,31, valor que superou significativamente o modelo vigente (MLR), que apresentou R^2 igual a -0,07. O valor negativo de R^2 indica que a média dos dados de saída da amostra fornecida gera predições mais acuradas do que o modelo desenvolvido. A fim de aumentar a interpretabilidade do modelo em XGBT, os autores aplicaram a técnica *Shapley Additive exPlanation*, que estima a importância dos parâmetros de entrada em relação ao consumo energético.

Kamel, Sheikh e Huang (2020) desenvolveram e compararam diversos metamodelos para estimar o consumo energético com aquecimento, refrigeração, ventilação e aquecimento de água de edificações residenciais baixas localizadas em Nova Iorque. As características dos edifícios basearam-se nos padrões residenciais levantados na Pesquisa de Consumo Energético Residencial (RECS) e os modelos foram elaborados e simulados no programa *Building Energy Optimization Tool* (Beopt). O Beopt atende às exigências da ASHRAE para edificações residenciais baixas e as suas simulações são executadas no programa EnergyPlus. O estudo considera 25 parâmetros de entrada que abrangem características do clima, dos sistemas de climatização e de aquecimento de água e das cargas internas. A base de dados gerada através das simulações foi dividida em duas partes, 70% para o treino e 30% para o teste dos metamodelos. Dentre as técnicas de metamodelagem abordadas, os autores utilizaram MLR, acoplada a diferentes métodos de seleção de parâmetros, e XGBT. Mesmo implementando estratégias para selecionar os parâmetros de entrada e otimizar as MLRs, em termos de acurácia o modelo em XGBT superou todos os outros. O R^2 da XGBT para os consumos com aquecimento, refrigeração, ventilação e aquecimento de água foram iguais a 0,999, 0,999, 0,881 e 0,909, respectivamente.

A seleção manual dos hiperparâmetros deve ser realizada por profissionais experientes, pois afeta consideravelmente a acurácia do modelo. Entretanto, algoritmos de automatização da seleção dos hiperparâmetros podem ser utilizados, de forma a maximizar a acurácia do modelo sem exigir a intervenção total de profissionais especialistas (SNOEK,

LAROCHELLE, ADAMS, 2012; FEURER et al., 2015). A otimização automatizada dos hiperparâmetros foi pouco aplicada nos metamodelos de desempenho energético de edificações, pois é um processo extremamente custoso, visto que cada simulação demanda um custo computacional considerável.

Para realizar a otimização dos hiperparâmetros de metamodelos de desempenho energético, Østergård, Jensen e Maagaard (2018) recorreram a uma metodologia que utiliza análises gráficas. O método foi aplicado no desenvolvimento de um metamodelo que utilizou 14 parâmetros de entrada para prever os seguintes parâmetros de saída: a demanda anual de energia, a disponibilidade de luz natural, o número de horas em que a temperatura da interna se encontrou acima de 16°C e o nível máximo de CO₂ anual. As amostras de 64, 256 e 1024 elementos, relativas a salas de escritórios genéricas e a uma edificação educacional, foram desenvolvidas através da sequência de Sobol e foram simuladas no BSim Energy, um programa de simulação avançado desenvolvido pelo Instituto Dinamarquês de Pesquisa em Edificações. Metade de cada uma das amostras foi reservada para etapa de treinamento e a outra metade para a etapa de validação. Através dessa base de dados os pesquisadores treinaram e avaliaram seis técnicas de metamodelagem diferentes com os hiperparâmetros otimizados, dentre elas estavam: ANN, MLR, RF e SVM. Para realizar a otimização, os pesquisadores elaboraram amostras de hiperparâmetros utilizando a técnica de amostragem em grade. Assim, cada combinação de hiperparâmetros gerou um modelo, que foi treinado com todos os tamanhos de amostra. Foram utilizadas a análise de sensibilidade global e o Filtro de Monte Carlo auxiliado por plots de coordenadas paralelas para identificar visualmente o conjunto de hiperparâmetros ótimo para cada uma das técnicas de metamodelagem avaliadas. O filtro foi aplicado sobre uma classificação que levou em conta 5 fatores: a acurácia, calculada pelo R², a eficiência computacional, a robustez, a simplicidade e a interpretabilidade. Em todos os modelos desenvolvidos foi identificado que os valores dos hiperparâmetros otimizados são muito similares em todos os tamanhos de amostra. Assim, a otimização pode ser realizada com amostras pequenas e os valores ótimos podem ser utilizados em amostras maiores, diminuindo consideravelmente o esforço computacional necessário. Dos resultados relativos à acurácia dos metamodelos para prever o número de horas em que a temperatura da interna do edifício encontrou-se acima de 16°C, nota-se que a técnica ANN obteve o maior valor de R², entre 0,99 e 1, seguido de SVM e RF, com R² entre 0,95 a 0,99 e entre 0,80 e 0,85, respectivamente. A técnica MLR apresentou R² igual a 0,48 e

foi o modelo menos acurado entre as nove técnicas otimizadas.

2.5 AMOSTRAGEM E ANÁLISE DE SENSIBILIDADE

A análise de sensibilidade é uma ferramenta valiosa que pode ser aplicada na análise do desempenho energético de edificações. Segundo Saltelli et al. (2000), a análise de sensibilidade pode ser definida como “o estudo da influência relativa de diferentes parâmetros de entrada sobre os parâmetros de saída de um modelo”. Essa ferramenta pode ser dividida em dois grupos de maior relevância: análise de sensibilidade local e global. A análise de sensibilidade local investiga individualmente a influência de um parâmetro de entrada específico do espaço amostral, sobre um parâmetro de saída. Já a análise de sensibilidade global investiga concomitantemente a influência direta e indireta de todos os parâmetros de entrada do espaço amostral, sobre um parâmetro de saída (TIAN, 2013).

Apesar de a análise de sensibilidade local ser a mais disseminada e aplicada, ela não é sugerida quando o objetivo é identificar a influência relativa de diferentes parâmetros de entrada sobre um parâmetro de saída. Para esses casos, a análise de sensibilidade global é mais indicada, pois todos os parâmetros variam simultaneamente, de forma a abranger todo o espaço amostral (SALTELLI, TARANTOLA, CAMPOLONGO, 2000). A análise de sensibilidade global permite identificar quais são os parâmetros de entrada mais importantes (“priorização de variáveis”) para a variância do parâmetro de saída em estudo e quais são os parâmetros de entrada menos importantes (“fixação de variáveis”). Assim, obtêm-se estimativas mais precisas a respeito da influência dos parâmetros de entrada sobre o parâmetro de saída (SILVA, 2016).

Sobol (1990) desenvolveu um dos métodos mais difundidos para a análise de sensibilidade global. Baseado na variância do parâmetro de saída, esse método é capaz de estimar a sensibilidade total dos parâmetros de entrada, representada pela soma dos efeitos de primeira ordem e de ordens superiores do parâmetro de entrada em análise associado aos outros parâmetros envolvidos. Sendo o efeito de primeira ordem de determinado parâmetro de entrada definido como a fração de redução da variância esperada quando apenas esse parâmetro é desconhecido, o efeito total é definido como a fração de redução da variância esperada quando apenas esse parâmetro é conhecido (SALTELLI et al., 2000).

A análise de sensibilidade de Sobol exige que a amostra seja desenvolvida através do

método de amostragem de baixa discrepância conhecido como a sequência de Sobol. Inicialmente, o objetivo das sequências de baixa discrepância, também chamadas de sequências pseudoaleatórias, foi substituir as sequências aleatórias no processo de amostragem de pontos para estimar equações integrais em computadores (MOROKOFF, CAFLISCH, 1994). Posteriormente, visto que representam o espaço amostral de forma uniforme, as sequências de baixa discrepância têm sido utilizadas no desenvolvimento de análises de sensibilidade e de amostragens para alimentar algoritmos de otimização e modelos de inteligência artificial (KIMURA, MATSUMURA, 2005; CHENG, DRUZDZEL, 2013).

Kimura e Matsumura (2005) identificaram que o uso das amostragens de baixa discrepância de Van Der Corput e de Halton aumenta a probabilidade de algoritmos genéticos encontrarem soluções ótimas. Cheng e Druzdzel (2013) afirmaram que o uso das amostragens de baixa discrepância aumenta significativamente a performance de redes neurais bayesianas, sendo que, nos casos testados pelos pesquisadores, a sequência de Sobol obteve melhores resultados do que as sequências de Halton e Faure.

Mara e Tarantola (2008) realizaram a calibração de um modelo para simulação térmica de edificações, onde 35 parâmetros de entrada geraram 10 parâmetros de saída. Os autores utilizaram uma metodologia de análise de sensibilidade global baseada na variância, assim, estimaram os efeitos de primeira ordem, de ordens superiores e a sensibilidade total. Dentre as metodologias aplicadas, os autores utilizaram a análise de sensibilidade global de Sobol.

Van Der Knaap (2011) aplicou a análise de sensibilidade global na última fase do seu estudo de comparação entre a carga térmica de superaquecimento, aquecimento e refrigeração, obtidas através dos métodos prescritivo e de simulação do RTQ-R. Os resultados encontrados indicaram que houve divergência entre a sensibilidade dos parâmetros de entrada quando avaliados pelos diferentes métodos.

Devido à falta de estudos sobre a análise de sensibilidade global aplicada à avaliação do desempenho energético de edificações, Silva e Ghisi (2013) se propuseram a elaborar um estudo nesse viés. Nesse trabalho, os autores identificaram quais parâmetros de entrada são mais influentes na eficiência energética de uma edificação residencial quando aplicado o método de simulação do RTQ-R.

A técnica de análise de sensibilidade global, quando aplicada em amostras robustas, cujos elementos preenchem de forma bem distribuída o espaço amostral, é capaz de identificar os parâmetros mais influentes em um modelo dependente de um número

considerável de parâmetros (CAMPOLONGO, CARIBONI, SALTELLI, 2007). Devido à sua alta flexibilidade, acurácia e capacidade de informação (HOMMA, SALTELLI, 1996), essa técnica pode ser utilizada na calibração de metamodelos de desempenho térmico de edificações (EISENHOWER et al., 2012; ØSTERGÅRD, JENSEN, MAAGAARD, 2017; 2018), trazendo informações relevantes sobre o comportamento dos parâmetros que regem os fenômenos termo-físicos envolvidos.

2.6 O MÉTODO DE SIMULAÇÃO COMPUTACIONAL DA NOVA PROPOSTA PARA A NBR 15.575

Nos últimos anos a NBR 15.575 tem sido revisada, sendo que desde 2019 uma nova proposta para o item 11 da norma, que trata do desempenho térmico, vem sendo elaborada pela Comissão de Estudos CE-002:136.001. A nova proposta oferece os métodos simplificado e de simulação computacional para classificar a edificação em um dos três níveis de desempenho térmico: mínimo, intermediário ou superior. O método simplificado compara as propriedades geométricas e térmicas dos sistemas construtivos de cada ambiente de permanência prolongada (APP), comparando-as com valores de referência. Esse método possui caráter obrigatório e é suficiente para alcançar apenas o nível mínimo de desempenho térmico. Caso algum dos critérios do método simplificado não seja atendido por pelo menos um dos APPs ou caso tenha-se interesse em alcançar o nível intermediário ou superior de desempenho, toda a edificação deve ser avaliada através do método de simulação computacional, que se trata de uma avaliação mais detalhada. O método de simulação possui caráter facultativo e é necessário apenas para edificações que buscam níveis de desempenho maiores do que o mínimo. Portanto, o método de simulação considera diversas variáveis que podem influenciar o desempenho térmico quando aplicadas diferentes estratégias bioclimáticas.

Para classificar o desempenho térmico de uma edificação através do método de simulação computacional da nova proposta para a NBR 15.575, é necessário elaborar dois modelos: o modelo real e o modelo de referência. O modelo real utiliza a orientação, as condições de exposição, as características volumétricas, os percentuais transparentes das fachadas, os fatores de ventilação, as propriedades térmicas dos sistemas construtivos e a presença de elementos de sombreamentos externos fixos nas fachadas da própria edificação

real. O modelo de referência utiliza a orientação, as condições de exposição e as propriedades volumétricas da edificação real, entretanto, as outras características variam de acordo com a zona bioclimática onde localiza-se a edificação real.

Todos os ambientes de uma UH que podem ser fechados por portas ou janelas são definidos como zonas térmicas, sendo que as áreas de circulação fazem parte da mesma zona térmica do ambiente na qual estão inseridas. Todavia, apenas as zonas térmicas ocupadas, ou seja, salas e dormitórios, são consideradas APPs. Para a avaliação de UHs unifamiliares, todos os APPs e ambientes de permanência transitória (APT) devem ser modelados, entretanto, apenas os APPs são avaliados. Para a avaliação de edificações multifamiliares, devem ser modelados todos os APPs e APTs do pavimento térreo, de um pavimento tipo e do pavimento de cobertura, sendo que apenas os APPs são avaliados.

Para avaliar o nível mínimo de desempenho térmico de uma UH através do método de simulação é preciso realizar duas simulações com ventilação natural: uma para o modelo real e uma para o modelo de referência. A partir dessas simulações são determinados o percentual de horas ocupadas em que a temperatura operativa do APP encontra-se dentro de uma faixa de interesse ($PHFT_{APP}$), Equação 1, e as temperaturas operativas anuais máxima ($T_{O,MAX,APP}$) e mínima ($T_{O,MIN,APP}$) de ambos os modelos. Estimados os valores do $PHFT_{APP}$ para cada APP, encontra-se o $PHFT_{UH}$ fazendo a média aritmética do $PHFT_{APP}$ de todos os APPs da UH, Equação 2. A $T_{O,MAX,UH}$ é igual ao valor máximo entre as $T_{O,MAX,APP}$ de todos os APPs da UH, enquanto a $T_{O,MIN,UH}$ é igual ao valor mínimo entre as $T_{O,MIN,APP}$.

$$PHFT_{APP} = \frac{Nh_{FT}}{Nh_{Ocup}} \cdot 100 \quad \text{Equação 1}$$

Onde:

- $PHFT_{APP}$ é o percentual de horas ocupadas em que o APP se encontra dentro da faixa de temperatura operativa pré-definida (%);
- Nh_{FT} é o número de horas em que o APP se encontra dentro da faixa de temperatura operativa pré-definida (horas);
- Nh_{Ocup} é o número de horas em que o APP é ocupado ao longo do ano (horas).

$$PHFT_{UH} = \frac{\sum_{i=1}^n PHFT_{APP,i}}{n} \quad \text{Equação 2}$$

Onde:

- $PHFT_{UH}$ é o percentual de horas ocupadas em que a UH encontra-se dentro da faixa de temperatura operativa pré-definida (%);
- $PHFT_{APP}$ é o percentual de horas ocupadas em que o APP i encontra-se dentro da faixa de temperatura operativa pré-definida (%);
- n é o número de APPs.

A faixa de interesse varia de acordo com a média da temperatura de bulbo seco do clima para o qual a edificação projetada, como descreve a Tabela 1. A temperatura de bulbo seco deve ser extraída do mesmo arquivo com o qual a edificação foi simulada. A adoção de faixas de temperatura operativa variadas permite a classificação da eficiência energética em climas extremos, onde a temperatura operativa excede os limites das faixas de temperatura mais restritivas durante todo o ano. Nesses casos os PHFTs real e de referência aproximam-se de 0%, ou 100%, o que impossibilita a identificação de aumento ou redução no desempenho térmico do modelo real, quando comparado com o modelo referência.

Tabela 1 - Faixas de temperatura operativa para determinar o PHFT.

Intervalo	Média anual da temperatura de bulbo seco do arquivo climático – TBSm (°C)	Faixa da temperatura operativa de interesse (°C)
1	TBSm < 25	18 < T _{O,APP} < 26
2	25 ≤ TBSm < 27	T _{O,APP} < 28
3	TBSm ≥ 27	T _{O,APP} < 30

Fonte: adaptado da nova proposta para a NBR 15.575 (CB3E, 2020).

Para obter-se o nível mínimo de desempenho, quando comparados, o valor do $PHFT_{UH,REAL}$ deve ser maior que $9,0 \cdot PHFT_{UH,REF}$ e a $T_{OMAX,UH,REAL}$ deve ser menor que a $T_{OMAX,UH,REF}$. Em edificações localizadas nas zonas bioclimáticas de 1 a 4, além da análise do $PHFT_{UH}$ e da $T_{OMAX,UH}$, é preciso também garantir que a $T_{OMIN,UH,REAL}$ é maior que a $T_{OMIN,UH,REF}$.

Nas simulações de ventilação natural permite-se a abertura das janelas quando o APP está ocupado e sua temperatura de bulbo seco é maior ou igual a 19°C e maior que a temperatura de bulbo seco externa. A porta de entrada da UH mantém-se fechada durante toda

a simulação. As portas entre os APPs e APTs são consideradas sempre abertas, com exceção das portas dos banheiros, que se mantêm sempre fechadas. As janelas e frestas dos APTs são consideradas sempre fechadas, com exceção das janelas dos banheiros, que se mantêm sempre abertas. As propriedades de infiltração das janelas e frestas devem assumir os valores indicados na Tabela 2.

Tabela 2 - Propriedades de fluxo de ar pelas aberturas para a simulação de ventilação natural.

Posição	Portas	Janelas	
	Fechada	Fechada	Aberta
Fator de ventilação	0	0	0,45
Coefficiente de fluxo de massa de ar (kg/s)	0,0024	0,00063	-
Expoente de fluxo de massa de ar (kg/s)	0,9	0,63	-
Coefficiente de descarga	0,60	0,60	0,65

Fonte: Adaptado da nova proposta para a NBR 15.575 (LABEEE, 2020).

A norma define que cada dormitório das habitações deve ser ocupado por duas pessoas, das 22h às 8h da manhã do dia seguinte. As salas são ocupadas com metade dos usuários da habitação das 14h às 18h, sendo que das 18h às 22h esses ambientes são ocupados por todos os usuários da habitação. Os dormitórios são iluminados apenas das 6h às 8h e das 22h às 00h, enquanto as salas são iluminadas das 16h às 22h. Equipamentos são utilizados somente nas salas, das 14h às 22h. Tanto os padrões de ocupação e uso quanto as cargas internas se repetem em todos os dias do ano e devem ser as mesmas para os modelos real e de referência.

A taxa metabólica dos ocupantes de salas e dormitórios é igual a 60 e 45 W por área de superfície corporal, respectivamente, e a fração radiante em ambos os ambientes é igual a 0,30. A densidade de potência instalada, a fração radiante e a fração visível do sistema de iluminação em todos os APPs é igual a 5 W/m², 0,32 e 0,23, respectivamente. As cargas internas e a fração radiante de equipamentos das salas é igual a 120 W e 0,30, respectivamente.

2.7 CONSIDERAÇÕES FINAIS

Em atenção à necessidade da população por condições térmicas satisfatórias e, conseqüentemente, à elevada demanda energética dos edifícios, diretamente relacionada ao consumo expressivo de sistemas de condicionamento artificial do ar, o desenvolvimento de modelos acurados para a predição do desempenho térmico de edifícios têm se intensificado.

Os metamodelos são ferramentas rápidas e de fácil uso, capazes de identificar soluções de baixo custo que levem à eficiência energética. Essas ferramentas podem auxiliar não apenas em fases iniciais de projetos de edificações novas e em projetos de *retrofit*, onde se procura a solução ótima entre um conjunto significativo de possibilidades de implementação de eficiência energética, como também facilitam a expansão de mecanismos de avaliação de desempenho térmico, como a NBR 15.575.

Devido à alta complexidade dos parâmetros de entrada que devem ser analisados, destaca-se a carência de modelos preditivos para o consumo energético de habitações (AMASYALI, EL-GOHARY, 2018). Sendo assim, o desenvolvimento de um metamodelo que descreva com acurácia o desempenho térmico de residências é um desafio pertinente, já que pode ser aplicado a um extenso grupo de edificações. Dessa maneira, viabiliza-se uma ferramenta que pode ser amplamente aplicada, gerando, indiretamente, um aumento na eficiência energética do setor de edificações residenciais.

3 MÉTODO

Esse trabalho visa o desenvolvimento de um metamodelo para estimar o percentual de horas em que uma unidade habitacional (UH) se encontra dentro de uma faixa de temperatura operativa pré-definida (PHFT), seguindo as premissas da nova proposta para a NBR 15.575 (LABEEE, 2020). O metamodelo desenvolvido é capaz de estimar o desempenho térmico de UHs de edificações residenciais multifamiliares, em climas típicos brasileiros, que variam de frio e seco à quente e úmido.

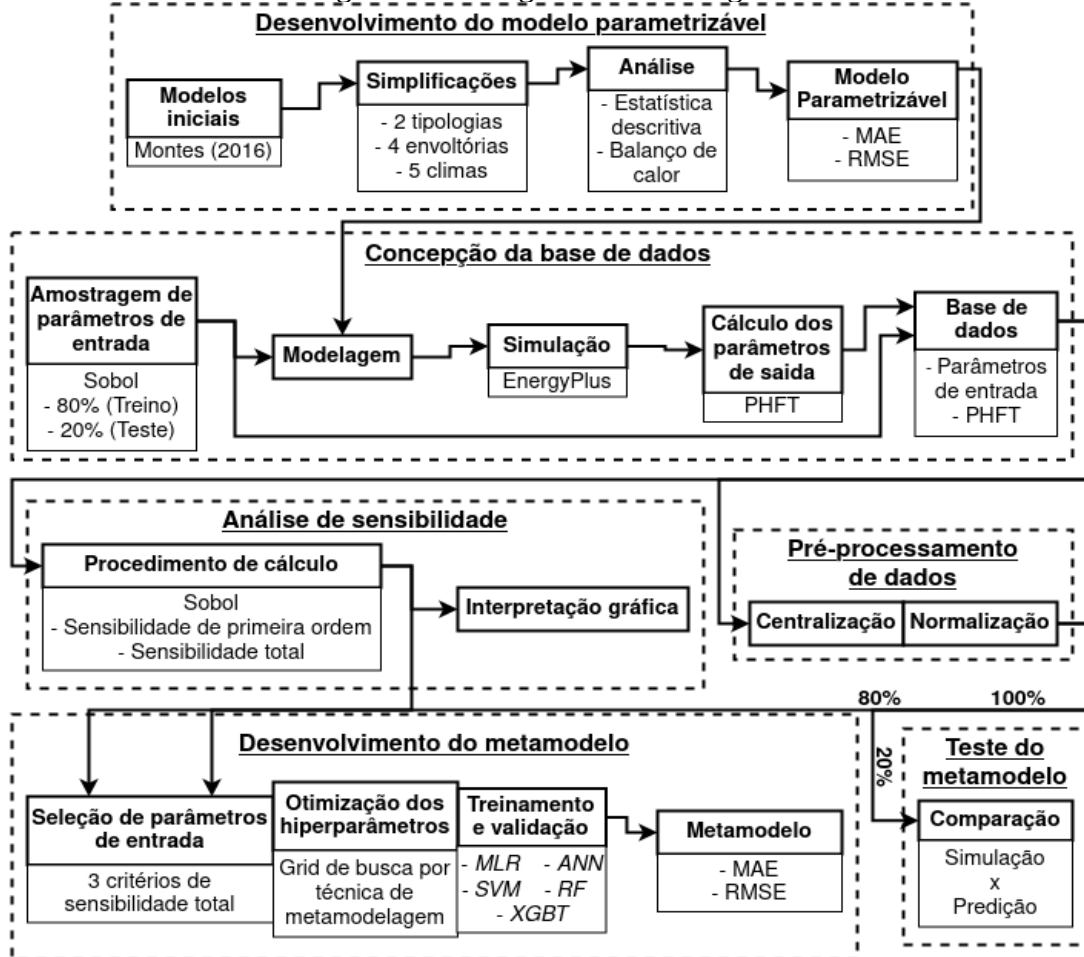
O método proposto, sintetizado no fluxograma da Figura 1, se inicia com o desenvolvimento de um modelo parametrizável, realizado a partir da simplificação da modelagem computacional de edificações completas, modelos iniciais. O objetivo das simplificações é reduzir a complexidade da descrição do modelo de simulação, tal que o $PHFT_{UH}$ pudesse ser estimado descrevendo-se apenas as características da UH de interesse, isto é, a UH a ser avaliada. As simplificações realizadas foram avaliadas através de índices estatísticos e da análise do balanço térmico das simplificações que apresentaram comportamentos adversos.

O modelo parametrizável foi utilizado para elaborar duas amostras de parâmetros de entrada, uma para treino e a outra para teste. As amostras de parâmetros de entrada foram desenvolvidas a partir da sequência de Sobol. Para cada elemento das duas amostras foi efetuada uma simulação no programa EnergyPlus e, com os dados de saída da simulação, foi calculado o $PHFT_{UH}$.

Com o objetivo de identificar a influência dos parâmetros de entrada sobre o $PHFT_{UH}$, foi executada a análise de sensibilidade global de Sobol sobre a amostra de treino. Para cada parâmetro de entrada foram estimadas a sensibilidade de primeira ordem e a sensibilidade total. Três valores de sensibilidade total foram utilizados como critério na etapa de seleção de parâmetros de entrada.

O desenvolvimento do metamodelo propriamente dito iniciou após o pré-processamento dos dados, que foi aplicado sobre a amostra de treino e replicado na amostra de teste. Diversos metamodelos foram treinados e validados utilizando a amostra de treino, buscando otimizar a definição de hiperparâmetros e a seleção de parâmetros de entrada. Por fim, o metamodelo com melhor desempenho na etapa de treino foi selecionado e a sua acurácia foi estimada através da amostra de teste.

Figura 1 - Fluxograma metodológico.



3.1 MODELO PARAMETRIZÁVEL

O desenvolvimento de um metamodelo exige o uso de uma base de dados que define o alcance do mesmo, sendo que a elaboração dessa base de dados pode ser facilitada pelo uso de um modelo parametrizável. Portanto, a elaboração da base de dados utilizada nesse trabalho foi realizada através de um modelo parametrizável.

Visto que o objetivo desse trabalho é realizar previsões de desempenho térmico de UHs isoladas, a descrição de ambientes da edificação que não correspondem à UH de interesse foi evitada. Logo, a concepção do modelo parametrizável foi definida a partir de simplificações, que partiram da modelagem do edifício completo até a modelagem dos APPs isoladamente.

A fim de avaliar a consistência das simplificações propostas e garantir que elas possam ser replicadas em uma grande quantidade de edificações, foram escolhidas edificações

representativas do mercado brasileiro, chamadas de modelos iniciais. As simplificações foram executadas sobre os modelos iniciais e avaliadas.

3.1.1 Modelos iniciais

Foram selecionadas duas edificações multifamiliares com plantas em formatos “L” e “H”, extraídas da tese de Montes (2016). Um pavimento tipo de cada um dos modelos iniciais foi ilustrado no Apêndice A.

Montes (2016) fez um extenso levantamento das edificações brasileiras de interesse social, segmentando-o em diferentes níveis de renda familiar. A planta em formato “L”, com cinco pavimentos, foi a tipologia mais frequente no nível de renda 2, entre R\$ 1.600,00 e R\$ 5.000,00 mensais, correspondendo à 53% da amostra para esse nível de renda. Já a planta em formato “H”, de quatro e cinco pavimentos, representou 29% da amostra levantada para o nível de renda familiar 1, até R\$ 1.600,00 mensais, e 32% da amostra do nível de renda 2.

Algumas características dos modelos iniciais, como a distribuição de ambientes por pavimento e por UH, foram descritas na Tabela 3. Dado o caráter social das edificações adotadas, o pavimento térreo foi considerado como um pavimento tipo em contato com o solo. Os modelos iniciais não contam com qualquer tipo de sombreamento ou venezianas.

Tabela 3 - Características das edificações utilizadas nas simplificações.

	L	H
Nº de pavimentos	5	5
Ambiente de circulação comum por pavimento	1	1
Habitações por pavimento	8	4
Salas por UH	1	1
Dormitórios por UH	2	2
Média de banheiros por UH	1.5	1
Total de ambientes	185	85

As simulações dos modelos iniciais e as simplificações subsequentes foram realizadas no programa EnergyPlus, versão 9.0, de acordo com as premissas da nova proposta para a NBR 15.575 para o cálculo do PHFT, descritas na seção 2.3.

A modelagem do piso, paredes e cobertura baseou-se na biblioteca de componentes construtivos desenvolvida por Weber et al. (2018). Essa modelagem substitui estruturas

complexas de componentes construtivos reais por conjuntos de camadas equivalentes que juntas possuem as mesmas propriedades térmicas do componente real.

Apesar de as características geométricas e térmicas dos modelos iniciais seguirem o levantamento de Montes (2016), quatro envoltórias frequentemente aplicadas no cenário da construção civil brasileiro foram consideradas para dar robustez à análise estatística realizada sobre as simplificações. A Tabela 4 lista os materiais utilizados nos componentes construtivos das quatro envoltórias adotadas, sendo que suas propriedades térmicas foram descritas no Apêndice B. Ressalta-se que a envoltória composta por paredes de concreto de 10 cm foi modelada seguindo as orientações da nova proposta para a NBR 15.575 para as condições de referência.

Tabela 4 - Componentes construtivos das envoltórias.

	Camada	Paredes externas	Cobertura
Referência	Externa	Concreto (10 cm)	Telha de fibrocimento
	2	-	Câmara de ar (cobertura)
	3	-	Concreto (10 cm)
Tijolo Vazado	Externa	Argamassa	Telha de fibrocimento
	2	Tijolo (9x19x19)	Câmara de ar (cobertura)
	3	Câmara de ar (parede)	Lã de vidro (5 cm)
	4	Tijolo (9x19x19)	Concreto (10 cm)
	5	Argamassa	-
Tijolo Maciço	Externa	Tijolo maciço (20 cm)	Telha de fibrocimento
	2	-	Câmara de ar (cobertura)
	3	-	Concreto (10 cm)
Steel Frame	Externa	Placa cimentícia	Telha de fibrocimento
	2	Lã de vidro (5 cm)	Câmara de ar (cobertura)
	3	Gesso	Concreto (10 cm)
	4	-	Câmara de ar (cobertura)
	5	-	Gesso

Os modelos iniciais possuem janelas compostas por vidros simples, sendo que o material foi modelado através do objeto “*Simple Glazing*” do EnergyPlus, com transmitância térmica igual a 5,7 W/m².K e fator solar igual a 0,87. As janelas dos APPs possuem área igual a 17% da área do piso do respectivo APP. As portas de madeira foram modeladas utilizando uma única camada de um material com espessura de 3 cm, densidade de 650 kg/m³,

condutividade térmica de $0,15 \text{ W/m}^2\cdot\text{K}$ e calor específico de $2300 \text{ J/kg}\cdot\text{K}$.

As cargas internas e os padrões de ocupação, bem como de operação dos sistemas de iluminação e de abertura das janelas, seguiram as recomendações da nova proposta para a NBR 15575. O entorno foi desconsiderado, visto que o levantamento de Montes (2016) não o menciona e que a norma não exige a sua modelagem.

3.1.2 Simplificações

O metamodelo proposto visa estimar o PHFT_{UH} para apenas uma UH de interesse. Logo, é conveniente que se descreva apenas as características da UH de interesse, caso contrário, a predição se tornaria excessivamente trabalhosa, tendo em vista que seria necessário especificar todas as características da edificação.

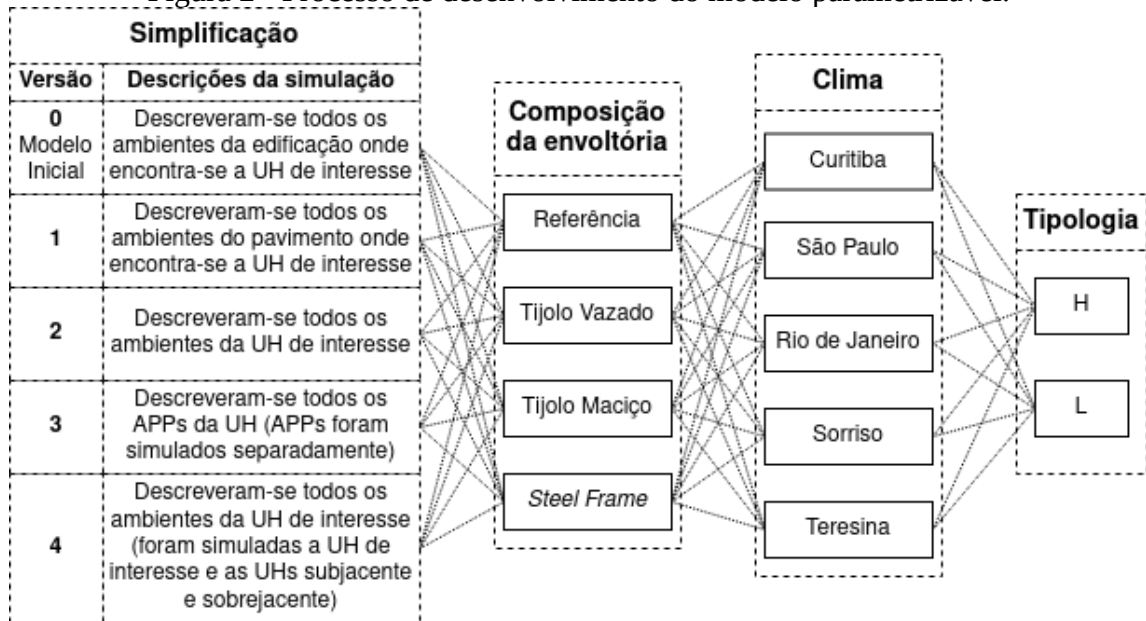
Além do trabalho do usuário para levantar todas as características do edifício, a descrição de uma quantidade excessiva de parâmetros de entrada é uma tarefa que torna o modelo pouco parametrizável. Isso pode inviabilizar o desenvolvimento das amostras e dificultar o processo de treinamento do metamodelo, devido à tendência de aumento nas correlações entre os parâmetros de entrada. O aumento do número de parâmetros de entrada torna o metamodelo mais complexo, dificultando a sua generalização.

Sendo assim, o objetivo das simplificações propostas é reduzir o número de parâmetros de entrada, de modo a tornar o modelo de simulação parametrizável, viabilizando a elaboração da amostra e reduzindo o grau de complexidade do metamodelo.

Para validar essas simplificações, os modelos iniciais foram simulados com quatro envoltórias diferentes, descritas na Tabela 4, nos climas de Curitiba, São Paulo, Rio de Janeiro, Sorriso e Teresina. A escolha dos climas visou abranger as três diferentes faixas de temperatura da Tabela 1 e representar a variedade climática brasileira, além de dar preferência a municípios mais populosos.

Fazendo as combinações entre composição das envoltórias, clima e tipologia, cada simplificação foi simulada 40 vezes, totalizando 7.200 UHs distintas por simplificação. A Figura 2 retrata de forma sucinta as combinações adotadas no desenvolvimento do modelo parametrizável.

Figura 2 - Processo de desenvolvimento do modelo parametrizável.



Nas simulações das simplificações foram adotados arquivos climáticos INMET. Esses arquivos podem ser acessados gratuitamente no repositório de arquivos climáticos para simulação de desempenho de edificações da organização *Climate One Building* (COB, 2019). A Tabela 5 descreve a média anual das temperaturas de bulbo seco (TBSm) de cada arquivo climático utilizado e a respectiva faixa de temperatura operativa que foi considerada no cálculo do PHFT, como exibe a Tabela 1.

Tabela 5 - TBSm dos arquivos climáticos.

	Curitiba	São Paulo	Rio de Janeiro	Sorriso	Teresina
Média anual da temperatura de bulbo seco	17,4	19,6	23,2	25,4	27,7
Limite mínimo para a temperatura operativa no cálculo do PHFT	18° C	18° C	18° C	-	-
Limite máximo para a temperatura operativa no cálculo do PHFT	26 °C	26 °C	26 °C	28 °C	30 °C

O desempenho térmico das simplificações foram comparados com o desempenho dos modelos iniciais correspondentes através dos índices *Mean Absolute Error* (MAE) e *Root Mean Square Error* (RMSE). O MAE e o RMSE de cada simplificação foram calculados baseando-se nas diferenças de PHFT entre modelo inicial e simplificação. O processo de

simplificação foi interrompido quando foi encontrado um modelo parametrizável cujo desempenho térmico assemelhou-se ao desempenho dos modelos base.

Além da estatística descritiva, foram elaborados gráficos de balanço térmico para casos que apresentaram as maiores diferenças absolutas no PHFT. Os gráficos de balanço de calor detalham os fluxos de calor proveniente das seguintes fontes: cargas internas, ventilação natural, piso, cobertura, paredes, janelas e portas.

3.1.2.1 Simplificação nº 1 (S1)

A S1 correspondeu à simulação isolada de cada um dos pavimentos dos modelos base. A partir da simulação dos pavimentos foi estimado o $PHFT_{UH}$ de cada UH do pavimento.

Foram considerados adiabáticos os pisos de todos os pavimentos, exceto do pavimento térreo, e as coberturas de todos os pavimentos, exceto do pavimento de cobertura. A Tabela 6 lista as condições de exposição dos pisos e coberturas adotadas nas simulações de cada tipo de pavimento.

Tabela 6 - Condições de exposição de superfícies horizontais.

Pavimento	Superfície	Condições de contorno
Cobertura	Cobertura	Exposição à radiação solar e ao vento
	Piso	Adiabático
Intermediário	Cobertura	Adiabático
	Piso	Adiabático
Térreo	Cobertura	Adiabático
	Piso (solo)	Contato com o solo
	Piso (pilotis)	Exposição à radiação ao vento

Para gerar o resultado de uma única UH através dessa simplificação, seria necessário descrever todas as UHs do pavimento, o que tornaria o processo custoso e o modelo pouco parametrizável.


3.1.2.2 Simplificação nº 2 (S2)

Buscando alcançar um modelo parametrizável, a S2 tratou de simular apenas a UH de interesse. As superfícies em contato com ambientes de outras UHs foram consideradas adiabáticas, sendo que as superfícies horizontais seguiram os padrões da Tabela 6.

A Figura 3 exemplifica essa simplificação através da UH do canto sudoeste do modelo inicial de planta em “H”. Nessa simplificação as paredes norte e leste da sala e cozinha conjugadas (sala/cozinha) foram consideradas adiabáticas, visto que estão em contato com ambientes não pertencentes à UH de interesse.

O EnergyPlus não permite que paredes adiabáticas possuam aberturas e façam trocas de ar, portanto, a porta que liga a UH de interesse com a área de circulação comum do edifício foi excluída da modelagem. A exclusão da porta deve gerar pouco impacto no PHFT, já que a nova proposta para a NBR 15.575 define que as portas que conectam a UH ao ambiente externo devem estar sempre fechadas e as trocas de ar são pouco expressivas.

Figura 3 - Modelagem da simplificação nº 2.



3.1.2.3 Simplificação nº 3 (S3)

O comportamento termodinâmico de um APP inserido em uma edificação depende do restante da edificação e das trocas de calor entre seus ambientes, logo, isolar um APP deve comprometer o balanço de calor da UH substancialmente. Apesar do comprometimento, modelar apenas um APP beneficia a parametrização do modelo de simulação, portanto, a modelagem dessa simplificação também foi avaliada.

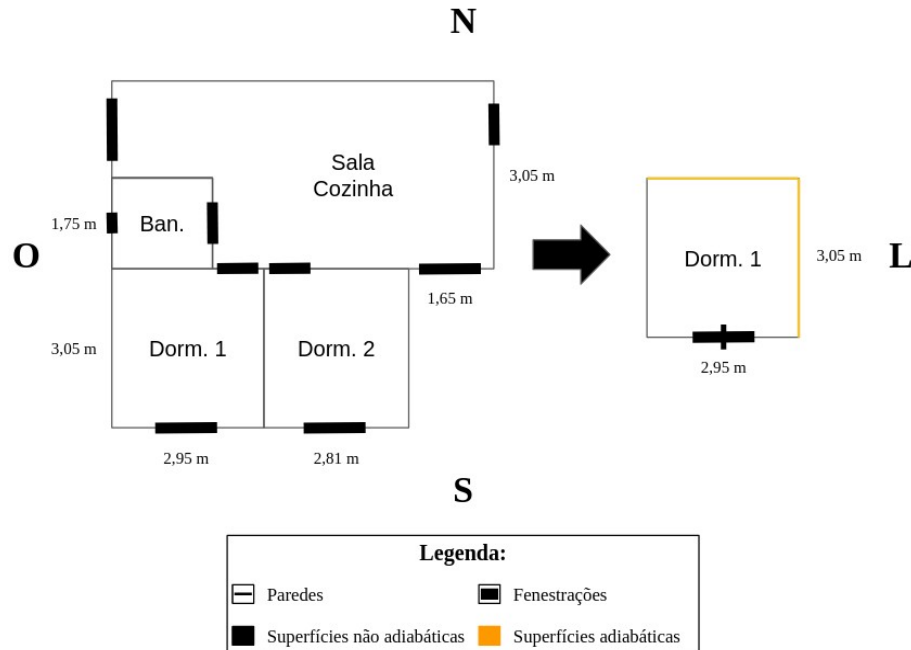
Sendo assim, a S3 correspondeu a uma simulação para cada um dos APPs da edificação. As superfícies do APP de interesse em contato com outros ambientes foram consideradas adiabáticas, e as condições de exposição do piso e da cobertura seguiram as descrições da Tabela 6. Devido à incapacidade de o EnergyPlus associar aberturas a superfícies adiabáticas, as portas que ligam o APP de interesse a outros ambientes foram excluídas.

Algumas simulações da S3 seriam inviabilizadas, pois o modelo de trocas de ar do EnergyPlus, o “*Airflow Network*”, só permite a ventilação natural caso o ambiente possua pelo menos duas superfícies com taxa de infiltração. Sendo assim, a janela dos APPs que

apresentaram essa limitação foi dividida em duas, posicionadas lado a lado. Somadas, a área das duas novas janelas deve ser igual à área da janela original.

No exemplo da Figura 4, extraído da tipologia de planta em “H”, o APP de interesse possui apenas uma superfície (parede sul) capaz de realizar trocas de ar, incapacitando o ambiente de fazer uso da ventilação natural através do “*Airflow Network*”. Portanto, a estratégia definida foi aplicada e a janela sul do APP foi dividida em duas, mantendo-se a posição e o tamanho da janela original.

Figura 4 - Exemplo de adaptação da modelagem para simular as trocas de ar no EnergyPlus.



3.1.2.4 Simplificação nº 4 (S4)


As condições de exposição do pavimento térreo e da cobertura dos modelos base faz com que as trocas de calor entre as superfícies horizontais dos edifícios sejam significativas. Isso ocorre, pois, as capacidades térmicas do solo e do ar diferem consideravelmente. Assim, as diferenças de temperatura entre o piso e a cobertura da edificação se acentuam ao decorrer do dia e forma-se um fluxo de calor vertical.

A fim de evitar diferenças no fluxo de calor vertical, decorrentes da consideração de pisos e coberturas adiabáticos, foi proposta a S4. Nessa simplificação foi descrita apenas a UH de interesse, entretanto, um código de programação modela UHs semelhantes nos

pavimentos inferior e superior. Isso faz sentido, pois há uma tendência de adoção de pavimentos tipo em projetos de edificações residenciais multifamiliares, garantindo que a UH de interesse e as UHs logo acima e logo abaixo possuam as mesmas características geométricas e térmicas.

A Figura 5 ilustra, em uma imagem, as três possíveis situações ao se adotar a S4. Quando a UH de interesse pertence ao pavimento térreo, são modeladas duas UHs acima, representantes dos pavimentos intermediário e de cobertura, sendo que a cobertura da UH superior está exposta ao ambiente externo. Nos casos onde a UH de interesse encontra-se no pavimento intermediário são modeladas uma UH abaixo, em contato com o solo, e uma UH acima, com a cobertura exposta ao ambiente externo. Em situações onde a UH de interesse faz parte do pavimento de cobertura são modeladas duas UHs abaixo para representar os pavimentos intermediário e térreo, sendo que o piso da UH inferior está em contato com o solo.

Figura 5 - Modelagem da simplificação n° 4.



3.2 AMOSTRAGEM

Duas amostras com conjuntos de parâmetros de entrada foram desenvolvidas, uma com 87.424 elementos, para as etapas de seleção de parâmetros de entrada, pré-processamento de dados, otimização dos hiperparâmetros, treinamento e validação e a outra amostra, com 21.852 elementos, utilizada na etapa de teste.

A partir dos conjuntos de parâmetros de entrada foram gerados e simulados os modelos e, finalmente, foi estimado o $PHFT_{UH}$ de cada elemento da amostra. Assim, a base de

dados foi complementada com os parâmetros de saída correspondentes aos parâmetros de entrada.

3.2.1 Amostra de parâmetros de entrada

As duas amostras de parâmetros de entrada seguem os limites de aplicação do metamodelo. Sendo assim, para desenvolver as amostras foi necessário definir os parâmetros de entrada fundamentais para descrever o desempenho térmico da UH de interesse. A definição dos parâmetros de entrada foi inspirada nos limites de aplicação do método simplificado da INI-R. Segundo a INI-R, através desses parâmetros e de suas respectivas faixas de alcance é possível descrever uma parte considerável das soluções arquitetônicas encontradas no contexto de edificações residenciais brasileiras (CB3E, 2018). A Tabela 7 lista os parâmetros de entrada, suas unidades de medida, suas siglas, e os seus limites, que foram utilizados para elaborar as amostras e para definir os alcances do metamodelo.

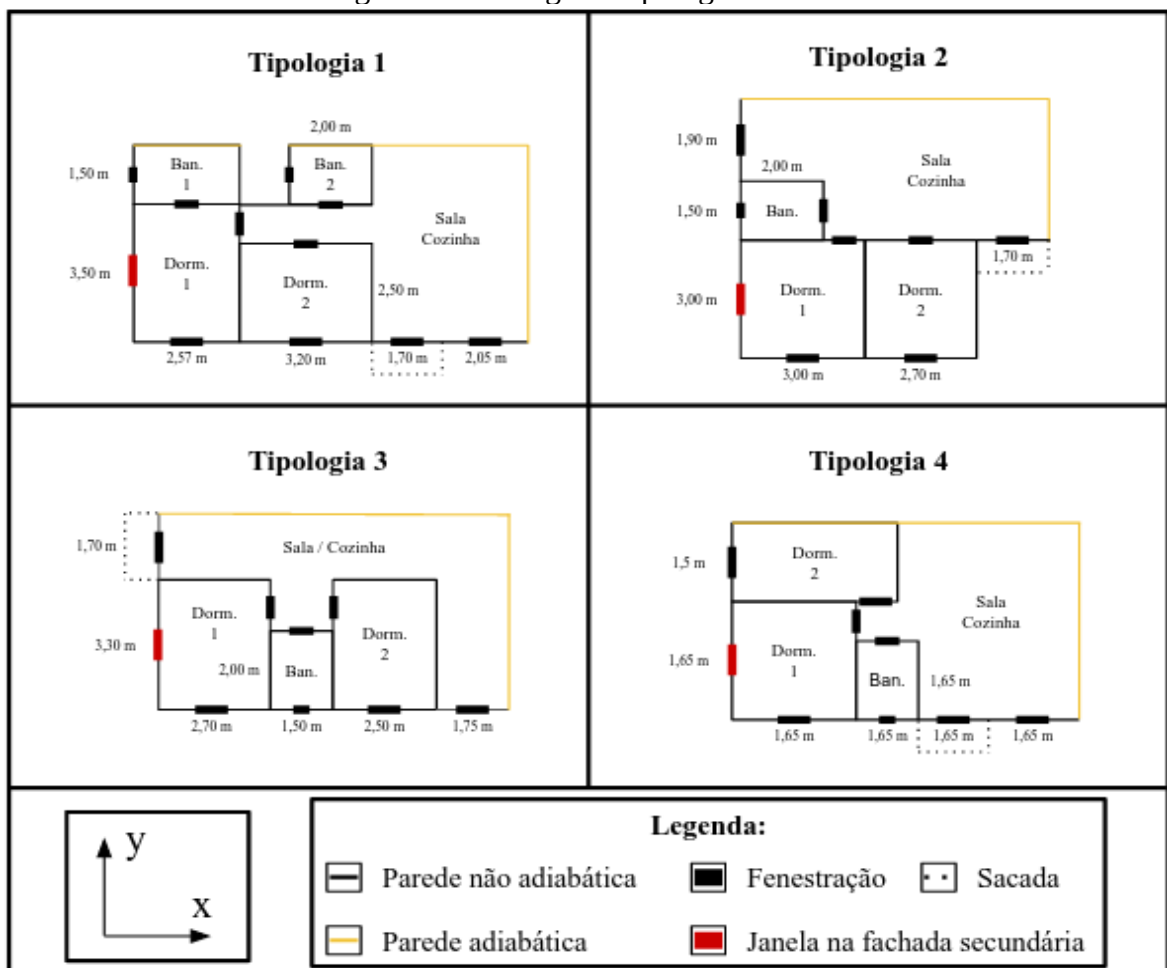
Tabela 7 - Limites de aplicação do metamodelo.

Parâmetro	Sigla	Limites da amostragem e do metamodelo	
		Mínimo	Máximo
Tipologia	seed	1, 2, 3 ou 4	
Pavimento	storey	“terreo” (1), “inter” (2) ou “cob” (3)	
Somatório da área de piso dos APPs (m ²)	area	50	150
Relação entre as dimensões – largura/comprimento	ratio	0,5	2
Pé-direito (m)	height	2,5	3,5
Ângulo azimutal (°)	azimuth	0,5	360
Espelhamento	mirror	0 ou 1	
Composição das paredes	shell_wall	1, 2, 3, 4, 5 ou 6	
Composição da cobertura	shell_roof	1, 2, 3 ou 4	
Absortância solar das paredes externas	abs_wall	0,2	0,8
Absortância solar da cobertura	abs_roof		
Percentual de abertura das fachadas da sala/cozinha (%)	wwr_liv	0,2	0,8
Percentual de abertura das fachadas dos dormitórios (%)	wwr_dorm		
Transmitância térmica dos vidros (W/m ² .K)	u_window	2,8	5,7
Fator solar dos vidros	shgc	0,22	0,87
Fator de ventilação	open_factor	0,4	1
Fachada de exposição da janela do dormitório 1	facade	1 ou 2	

Venezianas	blind	0 ou 1	
Profundidade da sacada (m)	balcony	0 ou 0,5	2,5
Média anual da temperatura de bulbo seco (°C)	dbt	10,83	28,24

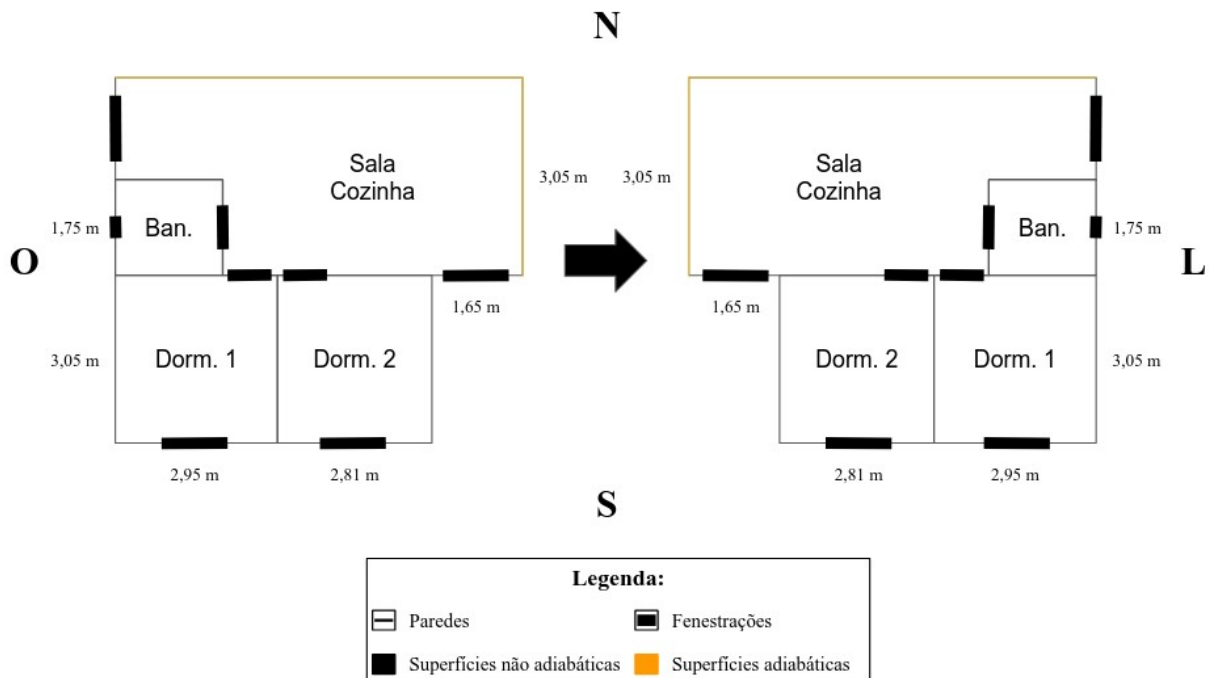
A fim de simplificar a descrição da disposição dos ambientes na UH e de suas condições de contorno, a tipologia da UH foi definida como um dos parâmetros de entrada. Através do catálogo da Figura 6, o usuário precisa definir a qual tipologia a UH de interesse pertence e inserir o código da tipologia como parâmetro de entrada do metamodelo. A base de dados utilizou a variável “tipologia” como um dos parâmetros de entrada, com valores discretos variando de 1 a 4, correspondendo às tipologias catalogadas. Apesar de o metamodelo ser limitado às tipologias abordadas no catálogo, o uso de amostras incrementais permite a adesão de novas tipologias ao catálogo, aumentando o seu alcance (MAZZAFERRO, 2020).

Figura 6 - Catálogo de tipologias de UH.



Os parâmetros de entrada relacionados às propriedades geométricas foram: pavimento, área do piso, relação entre as dimensões, pé-direito, ângulo azimutal e espelhamento da tipologia da UH. O pavimento onde localiza-se a UH variou entre “terreo”, “inter” e “cob”, e interfere nas condições de exposição das superfícies horizontais. O valor “terreo” indica que a UH possui o piso em contato com o solo, o valor “inter” indica que o piso e a cobertura da UH estão em contato com outros pavimentos e “cob” indica que a cobertura da UH é exposta ao ambiente externo. A área do piso da UH corresponde ao somatório das áreas de piso dos APPs e variou de 50 a 150 m². A relação entre o comprimento e a largura variou entre 0,5 e 2,0, o pé-direito variou de 2,5 a 3,5 m e o ângulo azimutal de 0° a 360°. O espelhamento da tipologia da UH trata-se de uma variável lógica que corresponde ao rebatimento da planta no “eixo y”, considerando o eixo cartesiano das plantas no catálogo. O espelhamento, ilustrado na Figura 7, variou entre os valores 0, sem espelhamento, e 1, espelhado.

Figura 7 - Espelhamento da tipologia da UH.



As propriedades térmicas foram descritas através dos seguintes parâmetros de entrada: composição das paredes, absorvância solar das paredes externas, composição do piso e absorvância solar do piso. Dentre os componentes construtivos que se destacam no mercado brasileiro, foram abordadas seis possibilidades de composição dos materiais das paredes e quatro opções de composição dos materiais de cobertura. O Apêndice C lista os componentes

construtivos considerados. Além dos componentes construtivos, a absorvância solar das paredes externas e a absorvância solar da cobertura variam de 0,2, superfície branca, a 0,8, superfície escura.

Visto que as janelas exercem papel fundamental sobre a ventilação natural, seis parâmetros de entrada que seguem definiram as propriedades geométricas e térmicas das janelas: percentual de abertura das fachadas da sala/cozinha, percentual de abertura das fachadas dos dormitórios, transmitância térmica dos vidros, fator solar dos vidros, fachada de exposição da janela do dormitório 1 e fator de ventilação. O percentual de abertura das fachadas é calculado pela relação entre a área da janela e a área da fachada onde está localizada a janela, sendo que esse valor variou de 0,2 a 0,8. O fator solar dos vidros variou entre 0,22, vidro de controle solar, a 0,87, vidro simples, e a transmitância térmica dos vidros variou entre 2,8 W/m².K, vidro duplo com câmara de ar, e 5,7 W/m².K, vidro simples. A janela do dormitório 1 pode estar posicionada na fachada principal ou na fachada secundária, representadas, respectivamente, pelas janelas de cor preta e vermelha na Figura 6. O fator de ventilação das janelas, *i.e.* a razão entre área de ventilação e área transparente, variou de 0,4, janela de folhas de duplas tradicional, a 1, janela que permite 100% de ventilação.

Venezianas e sacadas foram incorporadas aos modelos para prover sombreamento aos ambientes. Enquanto as venezianas assumem valores 0, sem veneziana, ou 1, com veneziana, a profundidade das sacadas pode assumir valor 0, sem sacada, ou qualquer valor entre 0,5 e 2,5 m de profundidade. As sacadas ficam posicionadas na sala e possuem comprimento atrelado ao parâmetro “ratio”, que define a relação entre as dimensões da UH, como sugere o catálogo.

O clima foi descrito pelo parâmetro de entrada TBSm, que variou de 10,83 °C (Urubici, SC), à 28,24 °C (São João do Piauí, PI). Os 411 arquivos climáticos da fonte INMET, disponibilizados pela organização *Climate One Building* (COB, 2019), representaram a vasta diversidade de climas brasileiros.

Definidos os limites dos parâmetros de entrada da base de dados, duas amostras foram elaboradas através da sequência de Sobol. A tarefa foi executada através de um código de programação na linguagem Python, que utiliza a biblioteca *Sensitivity Analysis Library in Python* (SALib). Assim, foi garantido que o espaço amostral de parâmetros de entrada fosse preenchido de forma uniforme.

Visto que a técnica de amostragem de Sobol define valores quase aleatórios dentro dos

intervalos contínuos pré-definidos, os valores amostrados que não corresponderam a valores de parâmetros de entrada factíveis foram aproximados para o valor mais próximo possível. Por exemplo, parâmetros de entrada qualitativos, como “seed”, permitem apenas valores inteiros, sendo assim, qualquer valor amostrado não inteiro foi aproximado para o valor inteiro mais próximo.

3.2.2 Simulação da amostra

Cada conjunto de parâmetros de entrada foi inserido em um código de programação, na linguagem R, de modo a gerar um modelo de simulação com ventilação natural para cada elemento da amostra, de acordo com as premissas da nova proposta da NBR 15.575. Para elaborar os modelos de simulação foram seguidas as condições do modelo parametrizável (simplificações de nº 2 a 4) que apresentou os melhores resultados em termos de acurácia.

Posteriormente, para cada conjunto de parâmetros de entrada foi executada a simulação correspondente e foi estimado o valor do PHFT. Cada parâmetro de saída foi acoplado ao seu respectivo conjunto de parâmetros de entrada, gerando as duas amostras que foram utilizadas nas etapas seguintes.

3.3 ANÁLISE DE SENSIBILIDADE

A análise de sensibilidade global de Sobol foi aplicada sobre a amostra de treino para identificar a influência dos parâmetros de entrada sobre o parâmetro de saída. Manter intacta a amostra de teste do metamodelo garante que a acurácia estimada de fato corresponde à acurácia do modelo para predições de dados nunca vistos. Qualquer análise prévia da amostra de teste gera enviesamento na base de dados e compromete a etapa de teste.

A análise de sensibilidade de Sobol foi implementada utilizando a biblioteca SALib, da linguagem de programação Python. Executada a análise de sensibilidade, para cada um dos parâmetros de entrada foram registradas a sensibilidade de primeira ordem e a sensibilidade total.

Por fim, foi analisada a influência de cada um dos parâmetros de entrada sobre os parâmetros de saída, levando-se em consideração a influência dos outros parâmetros de entrada que compõem o metamodelo. Em um gráfico de barras foram plotadas a sensibilidade de primeira ordem e a sensibilidade total de cada um dos parâmetros de entrada.

Com o intuito de excluir parâmetros de entrada que possuem baixa influência sobre o PHFT e acabam por gerar ruídos indesejáveis e reduzir a performance do metamodelo, foram definidos dois limites mínimos para a sensibilidade total. A partir dos limites de análise de sensibilidade, foram definidos dois novos conjuntos de parâmetros de entrada, além do conjunto que considera todos os parâmetros de entrada. Assim, foram extraídas da base de dados inicial duas novas bases de dados com diferentes quantidades de parâmetros de entrada. A base de dados inicial, contendo todos os parâmetros de entrada, foi rotulada como B20, pois possui 20 parâmetros de entrada. As duas novas bases de dados foram rotuladas com a letra “B” seguida do número de parâmetros de entrada que consideraram.

Não há uma regra pré-definida para a escolha desses critérios, pois, o somatório dos efeitos de primeira ordem é aproximadamente igual a um, logo, quanto maior o número de parâmetros de entrada, menor tende a ser a magnitude dos efeitos de primeira ordem e total. Assim, cada análise fundamenta seus critérios para a seleção de parâmetros de entrada a partir dos resultados da análise de sensibilidade global da base de dados como um todo, visto que os conceitos de “pouco” e “muito” importante referem-se à importância de um parâmetro em relação à importância dos outros parâmetros de entrada presentes na amostra. Sendo assim, os critérios de seleção foram definidos a partir de uma inspeção da magnitude dos efeitos totais estimados através da análise de sensibilidade.

3.4 DESENVOLVIMENTO DO METAMODELO

O desenvolvimento do metamodelo é completamente dependente da base de dados utilizada na etapa de treinamento e de validação. Apesar de todo o processo de elaboração da amostra ter sido validado, as amostras de treino, com 87.424 elementos, e de teste, com 21.852 elementos, precisaram passar por um pré-processamento. Assim, o metamodelo é capaz de interpretar os dados de forma clara e definir pesos apropriados para os parâmetros de entrada, independente da sua magnitude e amplitude.

O processo de desenvolvimento do metamodelo foi repetido para as três bases de dados, definidas seção 3.3. Visto que o pré-processamento de dados é realizado individualmente para cada um dos parâmetros de entrada, sem qualquer interferência do resto da base de dados, apenas o pré-processamento da B20 foi apresentado nos resultados. Os resultados do pré-processamento das outras duas bases de dados foram similares aos

resultados da B20, porém, os parâmetros que foram excluídos não foram pré-processados.

As seguintes funções de pré-processamento de dados, listadas por Kuhn e Johnson (2013), foram definidas utilizando a amostra de treino: a) normalização; b) centralização, e; c) transformação de variáveis qualitativas em variáveis lógicas. Como a base de dados foi gerada através de uma técnica de amostragem de baixa discrepância, não há necessidade de se investigar a correlação entre parâmetros de entrada ou de checar se alguma dos parâmetros possui variância próxima de zero. Após definidas, as funções de pré-processamento foram aplicadas na amostra de treino e de teste.

Com a base de dados pré-processada, o processo de treinamento e validação foi realizado através da biblioteca Caret, utilizando as seguintes técnicas de metamodelagem: *Multiple Linear Regression (MLR)*, *Artificial Neural Networks (ANN)*, *Support Vector Machine (SVM)*, *Random Forest (RF)* e *Extreme Gradient Boosted Trees (XGBT)*. A Tabela 8 descreve os hiperparâmetros considerados e a suas faixas de variação. Dentre as técnicas de metamodelagem, MLR é a única que não possui hiperparâmetros a serem otimizados.

Tabela 8 - Hiperparâmetros e suas faixas de variação.

Técnica	Modelo no Caret	Hiperparâmetro	Sigla	Faixa de variação
MLR	lm	-	-	-
ANN	brnn	Quantidade de neurônios na camada escondida	neurons	25 ~ 45
SVM	svmRadial	Peso da função custo	cost	2 ~ 256
RF	rf	Número de parâmetros aleatórios em cada RT	mtry	2 ~ 35
XGBT	xgbTree	Taxa de aprendizado	eta	0,3 ~ 0,4
		Profundidade máxima das RTs	depth	6 ~ 10
		Porcentagem de parâmetros aleatórios em cada RT	ncols	0,6 ~ 0,8
		Quantidade de RTs	ntrees	200 ~ 600

O modelo “brnn” (*Bayesian Regularized Neural Network*) trata-se de uma ANN de apenas uma camada escondida, que utiliza a técnica conhecida como regularização bayesiana para penalizar as previsões durante o treinamento, reduzindo a complexidade do modelo. O número de neurônios na camada escondida variou de 25 a 45, sendo que, a medida que se aumenta o número de neurônios, aumenta também a quantidade de interações entre os neurônios (pesos) e, conseqüentemente, a complexidade do modelo.

A técnica SVM foi treinada através do modelo “svmRadial” (*Support Vector Machine with Radial Basis Function Kernel*), que se refere a uma SVM que utiliza a função radial em seu núcleo. O peso da função custo descreve o quanto as margens do modelo devem se adaptar aos dados utilizados na etapa de treino, sendo que pesos menores resultam em margens mais maiores e pesos maiores resultam em margens menores. Margens maiores geram hiperplanos suaves, que podem resultar em previsões pouco acuradas durante o treino, porém, evitam que os ruídos da amostra de treino sejam contabilizados e tornam o modelo mais generalista.

O modelo “rf” (*Random Forest*) permite que se otimize o número de parâmetros de entrada aleatórios adotado nas RTs que compõem o modelo final. Modelos que adotam uma quantidade excessivo de parâmetros nas RTs apresentam alta complexidade e exigem grande esforço computacional na etapa de treinamento, já que precisam formar uma floresta de árvores mais robustas. Florestas mais robustas podem descrever a amostra de treino muito bem, mas tendem a considerar os seus ruídos e, eventualmente, apresentam dificuldades para descrever a amostra de teste. O hiperparâmetro “mtry” permite que o mesmo parâmetro de entrada se repita em uma mesma árvore, assim, o valor de “mtry” pode exceder o número de parâmetros da base de dados.

Para treinar a XGBT foi utilizado o modelo “xgbTree” (*Extreme Gradient Boosted Trees*) e foram variados os parâmetros “eta”, “depth”, “ncols” e “ntrees”. A taxa de aprendizado (“eta”) trata-se de um valor que é multiplicado pelos resultados das previsões das árvores residuais, a fim de que essas previsões não se ajustem perfeitamente à amostra de treino e tornem o modelo pouco generalista. A profundidade máxima das RTs (“depth”) é um parâmetro que poda as árvores que apresentam uma quantidade de ramificações maior do que o valor estabelecido. Assim como o hiperparâmetro “mtry”, no modelo “rf”, “ncols” controla a porcentagem de parâmetros de entrada escolhida aleatoriamente em cada RT. Diferente de “mtry”, “ncols” não permite que o mesmo parâmetro seja utilizado mais de uma vez em uma mesma RT. Portanto, o valor 0,8 indica que cada RT utiliza aleatoriamente 80% dos parâmetros de entrada da amostra de treino, enquanto o valor 0,6 indica que 60% dos parâmetros de entrada são utilizados. O modelo “xgbTree” também permite controlar o número de RTs no modelo final e foi variado de 200 a 600 RTs. Quanto maior os valores de “depth”, “ncols” e “ntrees”, maior a complexidade do modelo, logo, o modelo é torna-se menos generalista e pode, eventualmente, apresentar baixa acurácia na amostra de teste.

Durante a etapa de treinamento, diversas iterações foram necessárias para encontrar a configuração de hiperparâmetros e a combinação de parâmetros de entrada ideal para o problema abordado. Sendo assim, cada iteração de treinamento e validação foi avaliada através da acurácia e do número de parâmetros de entrada. Os resultados de cada iteração do processo de treinamento foram armazenados, para que posteriormente fosse escolhido o metamodelo mais adequado (metamodelo final). A acurácia dos metamodelos foi avaliada através dos índices MAE e RMSE.

Sugere-se o uso do MAE e do RMSE, pois os índices se complementam, tornando a análise mais criteriosa. Enquanto o MAE demonstra a magnitude média dos erros, importante para identificar os erros de generalização do metamodelo, o RMSE penaliza erros individuais, já que os erros são elevados ao quadrado antes de a média aritmética ser realizada.

Após o seu desenvolvimento, o metamodelo final, extraído da etapa de treinamento foi testado através da amostra teste, que contém 21.852 elementos nunca vistos, representando 20% da base de dados. O teste consistiu em extrair os conjuntos de parâmetros de entrada da amostra de teste e utilizá-los para realizar uma série de predições. Os resultados dessas predições foram comparados com os resultados originais da amostra de teste, gerados através das simulações.

Novamente, a comparação matemática entre os resultados do metamodelo e das simulações foi efetuada através dos índices MAE e RMSE. Além da análise matemática foram elaborados gráficos de dispersão contrapondo os resultados do metamodelo com os resultados das simulações.

4 RESULTADOS

4.1 MODELO PARAMETRIZÁVEL

O processo de simplificação dos modelos iniciais foi resumido na Tabela 9 e nos gráficos das Figuras 10 e 11, que representam toda a base de dados utilizada no desenvolvimento do modelo parametrizável. A proposta das análises é compreender a magnitude dos erros gerados entre as UHs dos modelos iniciais e as UHs dos modelos simplificados. Portanto, na Tabela 9 foram estimados, para cada uma das simplificações propostas, a estatística descritiva, o MAE e o RMSE da diferença entre o PHFT das simplificações e o PHFT dos modelos iniciais (Δ PHFT). Valores de Δ PHFT iguais a zero sugerem que a simplificação é “ideal”, *i.e.* não há erros ou perdas de informação entre o modelo inicial e a simplificação. Todos os valores da tabela encontram-se na mesma unidade do PHFT (%), exceto pela primeira coluna, que é qualitativa.

Tabela 9 - Estatística descritiva, MAE e RMSE referentes ao Δ PHFT.

Simp.	Mín.	5° Percentil	1° Quartil	Média	Mediana	3° Quartil	95° Percentil	Máx.	MAE	RMSE
S1	-6,5	-3,1	-0,9	0	0,1	1,0	3,0	5,1	1,4	1,8
S2	-13,0	-7,0	-3,5	-1,9	-1,8	-0,3	2,5	8,5	2,7	3,6
S3	-12,0	-7,1	-3,6	-1,3	-1,5	0,7	5,8	11,6	3,2	4,0
S4	-12,1	-5,9	-2,2	-1,4	-0,9	0	1,7	5,9	1,9	2,8

Da Tabela 9 percebe-se que as Δ PHFT se intensificam desde a S1, onde cada pavimento foi modelado separadamente, com as superfícies horizontais adiabáticas. As diferenças encontradas na S1 resultaram em valores de MAE e RMSE muito próximos, iguais a 1,4% e 1,8%, respectivamente, o que indica que os erros se comportam de forma consistente, com poucos pontos fora da curva (*outliers*), já que a diferença entre o MAE e o RMSE consiste na penalização de erros individuais.


Nota-se um aumento significativo nas Δ PHFT ao avançar da S1 para a S2, pois a segunda apresentou MAE e RMSE iguais a 2,7% e 3,6%, respectivamente. Visto que a S2 foi derivada da S1, os erros provenientes da adoção de pisos e coberturas adiabáticos também foram incorporados nas Δ PHFT da S2. Logo, entende-se que o aumento dos erros foi causado pela introdução de paredes adiabáticas entre a UH de interesse e as UHs adjacentes, que

trocavam calor na S1. A princípio não há indícios de que houve compensações entre os erros gerados pela adoção de pisos e coberturas adiabáticos e os erros relacionados à adoção de paredes adiabáticas, caso contrário o aumento do MAE e do RMSE seria mais brando ou haveria redução dos erros.

Simular as UHs isoladamente e considerar as paredes que estariam em contato com outras UHs como adiabáticas gera perdas de informações referentes ao calor trocado entre as fachadas da edificação, sendo que essa foi uma das fontes de erro da S2. As fachadas de edificações multifamiliares se expõem a diferentes níveis de irradiação solar, o que as leva a apresentarem temperaturas discordantes ao longo do dia.

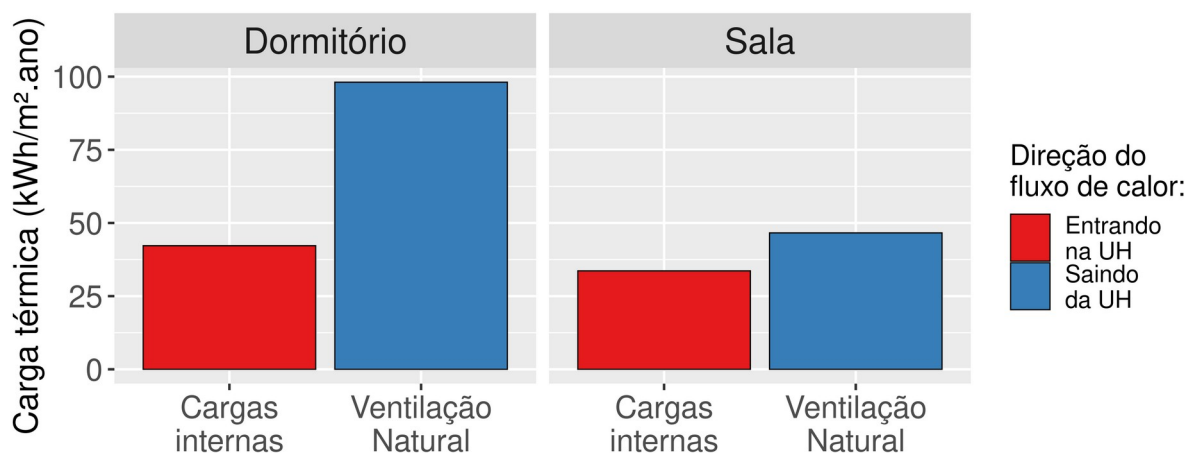
A Figura 8 descreve o PHFT médio, no eixo y , das UHs localizadas nas fachadas norte e sul, eixo x , do modelo inicial e da S2, considerando os cinco climas abordados na análise das simplificações. Nota-se que o PHFT médio das UHs dos modelos iniciais localizadas na fachada norte de pavimentos intermediários do clima Sorriso, foi igual a 58,2%, enquanto o PHFT médio das UHs da fachada sul foi igual a 67,4%. Ao analisar a média do PHFT na S2, a fachada norte do clima Sorriso apresentou PHFT médio igual a 51,0% e a fachada sul apresentou PHFT médio igual a 64,1%. A diferença entre o PHFT médio das fachadas foi acentuada na S2, sugerindo que o fluxo de calor entre as fachadas diminuiu.

Figura 8: PHFT nos modelos iniciais e na simplificação n° 2.



Além das trocas de calor entre fachadas, o fluxo de calor entre UHs vizinhas também fica comprometido na S2. A troca de calor entre UHs deve representar uma parcela importante do balanço de calor, especialmente quando os APPs das UHs adjacentes possuem padrões de ocupação opostos, *e.g.* a sala de uma UH em contato com o dormitório de uma UH adjacente. A Figura 9 descreve a carga térmica média dos modelos iniciais, no eixo y, através das cargas internas e da ventilação natural, no eixo x, para salas e dormitórios. Da figura é possível notar que a média do calor absorvido pelas salas através de cargas internas foi igual a 33,6 kWh/m².ano, enquanto a média do calor absorvido pelos dormitórios foi igual a 42,2 kWh/m².ano. Ao comparar esses valores com a média do calor cedido por salas e dormitórios através da ventilação natural, iguais a 46,6 e 98,1 kWh/m².ano, respectivamente, percebe-se que o fluxo de calor gerado pelas cargas internas representa uma parcela significativa do calor que entra na UH. Visto que as salas e dormitórios apresentam padrões de ocupação opostos, um fluxo de calor significativo é estabelecido do ambiente ocupado, mais quente, para o ambiente desocupado, menos quente. Esse fluxo foi considerado no modelo inicial e na S1, entretanto, precisou ser omitido nas simplificações seguintes para viabilizar o desenvolvimento do modelo parametrizável, o que aumentou as $\Delta PHFT$ das S2, S3 e S4.

Figura 9: Carga térmica referente às cargas internas e à ventilação natural nos modelos iniciais.



Parte dos erros da S3 foram justificadas através da descrição dos erros das simplificações anteriores, todavia, uma nova fonte de erros foi introduzida ao considerar ao permite fluxo de calor apenas nas superfícies em contato com o ambiente externo. Logo, as $\Delta PHFT$ aumentaram da S2 para a S3, sendo que os valores de MAE e RMSE da S3 foram

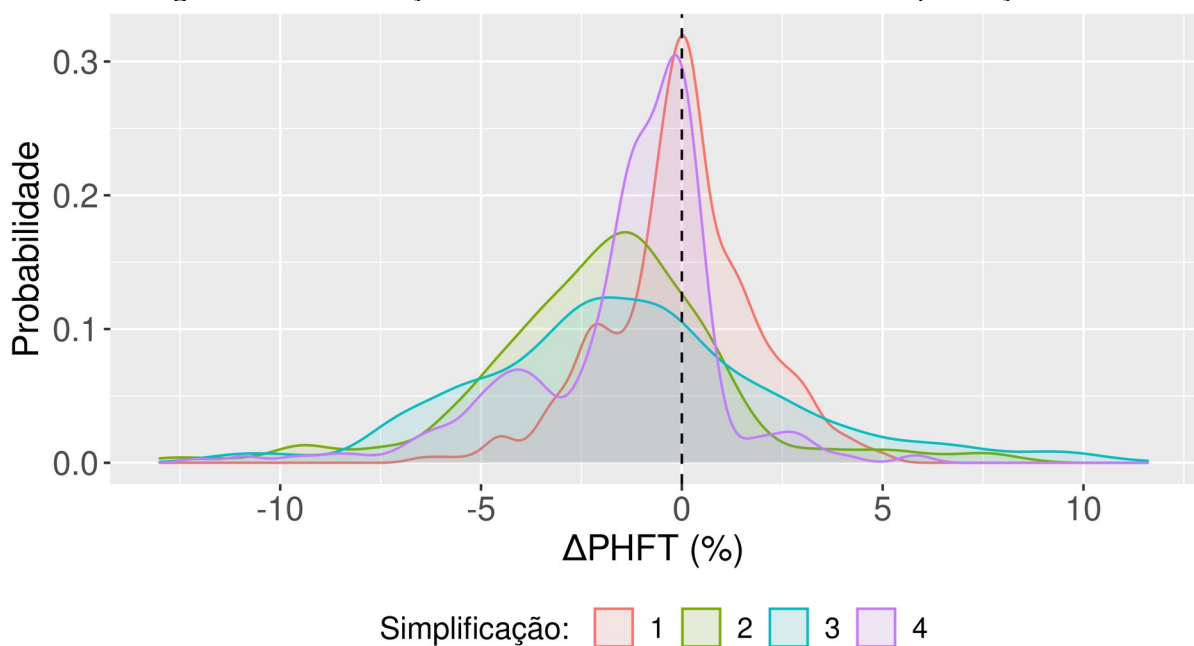
iguais a 3,2% e 4,0%, respectivamente.

Intencionalmente, as trocas de calor entre os pavimentos foram mantidas na S4, sendo que essa foi a única simplificação que considerou as trocas de calor entre as superfícies horizontais. Visto que a S4 segue as hipóteses da S2, exceto pela condição de contorno das superfícies horizontais, garante-se que a redução das $\Delta PHFT$ entre a S2 e a S4 está relacionada com o restabelecimento das trocas de calor entre essas superfícies. O MAE e o RMSE da S4 foram iguais a 1,9% e 2,8%, respectivamente. Visto que os erros da S1 resultaram exclusivamente da remoção das trocas de calor entre os pavimentos, os erros da S4 poderiam ser estimados através do cálculo da diferença entre os erros das S1 e S2. Assumindo essa estimativa como correta, o MAE e o RMSE da S4 seriam equivalentes a 1,3% (2,7 - 1,4) e 1,8% (3,6 - 1,8), respectivamente. Os resultados encontrados para o MAE e o RMSE da S4 são diferentes dos valores estimados, pois o fluxo de calor que seria trocado através das paredes, consideradas adiabáticas nessa simplificação, foi redistribuído entre os pavimentos através das superfícies horizontais, assim, um novo balanço de calor é estabelecido. As condições de exposição consideradas na S4 alteram o comportamento térmico das UHs como um todo e, naturalmente, esse comportamento se difere do modelo inicial, logo, uma nova parcela de erro foi introduzida ao PHFT. Apesar de a comparação dos erros estimados com os erros da simplificação consistir em uma ideia inicial da origem dos erros das simplificações, foi necessário estudar o balanço de calor de alguns dos casos amostrados para melhor compreender e fundamentar esses erros.

A Figura 10 ilustra o comportamento da base de dados, descrito estatisticamente na Tabela 9, através de gráficos de densidade, que exibem a distribuição das $\Delta PHFT$ nas simplificações. Sendo assim, o eixo x do gráfico representa as $\Delta PHFT$ e o eixo y a probabilidade relativa de se encontrar um caso na amostra com $\Delta PHFT$ igual ao valor correspondente no eixo x . As linhas com diversas cores identificam as quatro simplificações estudadas. Do gráfico de densidade da S1 (cor vermelha), observa-se uma densidade elevada de pontos ao redor de $\Delta PHFT$ igual a zero (linha tracejada preta). Quando a $\Delta PHFT$ afasta-se de zero, tanto no sentido negativo quanto positivo do eixo x , o valor de y reduz abruptamente, indicando que as UHs da S1 apresentam poucos casos com $\Delta PHFT$ relativamente alto. Na medida em que se adotam simplificações mais restritivas, onde menos ambientes são modelados e mais superfícies são consideradas adiabáticas, os gráficos de densidade achatam-se, aumentando a probabilidade de encontrar casos com valores negativos de $\Delta PHFT$ com

maior magnitude, o que significa que o PHFT da simplificação é menor que o PHFT do modelo inicial. Assim, a S2 (cor verde) apresenta maior grau de achatamento que a S1, que considera apenas as superfícies horizontais adiabáticas, assim como a S3 (cor azul), que considera um número maior de paredes adiabáticas, apresenta grau de achatamento maior do que as simplificações anteriores. A S4 (cor roxa) apresenta comportamento intermediário em relação às S1 e S2, pois, apesar de adotar paredes adiabáticas, essa simplificação realiza troca de calor entre as superfícies horizontais, como explicado anteriormente. Através da inspeção visual desses gráficos é possível afirmar que as ΔPHFT concentram-se em torno de zero e deslocadas no sentido negativo de x .

Figura 10 - Distribuição do ΔPHFT na base de dados de simplificações.



A Figura 11 representa a distribuição das ΔPHFT através de gráficos de caixas, separados por simplificação, pavimento e clima. As envoltórias foram identificadas através de pontos com diferentes cores. A reta preta horizontal dentro de cada caixa equivale à mediana dos pontos da caixa considerada, enquanto as extremidades de baixo e de cima equivalem ao primeiro e terceiro quartil, respectivamente. O eixo y representa as ΔPHFT , ou erros, e o eixo x representa as simplificações. As linhas pretas tracejadas foram traçadas em y igual a zero, logo, quanto mais próximo um ponto estiver dessas linhas, menor é o seu erro. Através dos gráficos de caixas é possível identificar padrões de ΔPHFT de acordo com as características


da simplificação e compreender quando os resultados do modelo parametrizável devem ser tratados com maior cautela.

Analisando a Figura 11, percebe-se que a maioria dos casos dos pavimentos intermediário e de cobertura encontram-se abaixo da linha tracejada, indicando que as simplificações obtiveram PHFT menor que os modelos iniciais. O pavimento de cobertura pode ser considerado o pavimento crítico, pois foi o pavimento com o pior desempenho térmico, com PHFT médio igual a 64,8%. Esse pavimento obteve distribuições com menor magnitude e amplitude do que os outros pavimentos, *i.e.* caixas mais curtas com Δ PHFT próximas de zero. Entre os três pavimentos, a cobertura foi o que apresentou os menores valores absolutos de Δ PHFT. A S3 pode ser considerada uma exceção em relação ao pavimento de cobertura, pois foi a única que obteve média de Δ PHFT maior que zero (0,895%), além de possuir caixas mais alongadas.

As caixas do pavimento térreo também tendem a assumir valores de Δ PHFT negativos, porém, seus corpos mais alongados por vezes trespassam a linha tracejada preta no sentido positivo de y . Esse padrão se acentua em climas mais quentes, como Sorriso e Teresina, e é mais brando em climas mais frios, como Curitiba. O pavimento térreo possui caixas mais alongadas e média dos valores absolutos de Δ PHFT igual a 2,4% e, contra 2,3% no pavimento intermediário e 2,1% na cobertura. Esse também foi o pavimento que apresentou o melhor desempenho térmico, pois obteve o maior PHFT médio, igual a 77,6%. As análises garantem que a magnitude dos erros médios obtidos foi relativamente pequena, quando comparada aos valores do PHFT por pavimento, já que os maiores erros se encontram nos pavimentos com maior PHFT médio, e vice-versa.

A partir da distribuição dos pontos sobre as caixas nota-se que, nos climas quentes do Rio de Janeiro, de Sorriso e de Teresina, os pontos azuis (tijolo maciço de 20 cm) e vermelhos (concreto de 10 cm), que apresentam maior inércia térmica, se concentram na parte inferior das caixas, com mediana das Δ PHFT igual a -1,4%. Já os pontos roxos (tijolo vazado) e verdes (*steel frame*), que possuem menor inércia térmica, se concentram na parte superior das caixas, com mediana das Δ PHFT igual a -0,5%. O oposto foi constatado nos climas frios de Curitiba e São Paulo, que apresentaram mediana das Δ PHFT das UHs com maior inércia térmica igual a -0,2% e -0,6, respectivamente.

Figura 11 - Diferença absoluta do PHFT em relação ao modelo inicial.



As análises das simplificações indicam que as $\Delta PHFT$ apresentam, majoritariamente, valores negativos, ou seja, as simplificações possuem desempenho térmico pior que o desempenho dos modelos iniciais. Em climas quentes, os modelos simplificados com envoltória de alta e de baixa inércia térmica exibem desempenho térmico pior que os modelos iniciais correspondentes, entretanto, essa piora de desempenho se acentua em UHs com envoltória de alta inércia térmica. Isso faz com que, nesses climas, a comparação entre o desempenho térmico de modelos simplificados de baixa e de alta inércia térmica, favoreça os modelos de baixa inércia térmica. Essa é uma característica dos modelos simplificados que merece atenção especial, pois a nova proposta para a NBR 15.575 compara o modelo real com um modelo de referência, sendo que o modelo de referência possui envoltória em concreto, que possui alta inércia térmica. Em climas quentes, um modelo real de baixa inércia térmica simulado de forma simplificada tende a apresentar redução do desempenho térmico, quando comparado ao seu respectivo modelo completo. O modelo de referência simulado de forma simplificada também apresenta tendência de redução do desempenho térmico, porém, essa redução deve ser maior do que a redução do modelo real, já que o modelo de referência possui maior inércia térmica. Dadas as circunstâncias, a adoção da simulação simplificada torna a comparação dos modelos real e de referência favorável ao modelo real.

Dentre as simplificações consideradas parametrizáveis, que são as S2, S3 e S4, a S4 apresentou os resultados mais satisfatórios, principalmente por possuir os menores MAE e RMSE. Além disso, essa foi a simplificação que apresentou o melhor comportamento no pavimento de cobertura (crítico), com $\Delta PHFT$ próximas de zero e distribuições com baixa amplitude. Portanto, a S4 foi adotada como modelo parametrizável para desenvolver a base de dados que alimentou o metamodelo.

O processo de validação do modelo parametrizável resultou em valores de MAE e RMSE satisfatórios, porém, esses valores representam médias globais das $\Delta PHFT$ e podem esconder informações relevantes sobre casos específicos da base de dados. A fim de se aprofundar nas limitações das simplificações, foram investigadas as UHs da base de dados das simplificações que apresentaram $\Delta PHFT$ entre o valor mínimo e o 5º percentil, ou entre 95º percentil e o valor máximo. Foram analisadas as diferenças entre os balanços de calor dos modelos iniciais e dos modelos simplificados de quatro dessas UHs, consideradas casos críticos. A Tabela 10 lista os quatro casos críticos escolhidos para analisar o balanço de calor.

Tabela 10 - Casos críticos de simplificação.

Caso	Simp.	Tipo.	Envoltória	Pavimento	Posição da UH	Orientação	Clima
A	1	H	Tijolo maciço	Térreo	Canto	N	Sorriso
B	2	L	Tijolo maciço	Térreo	Meio	S	Curitiba
C	4	L	Tijolo maciço	Intermediário	Meio	N	Teresina
D	4	L	Steel frame	Térreo	Meio	S	Rio de Janeiro

Os climas de Sorriso e de Teresina, os mais quentes da base de dados, dominaram os casos críticos com uma representatividade de 66,2%, enquanto o clima de São Paulo, mais ameno, não possui nenhum caso entre os críticos. Dentre os casos críticos da S4, 87,3% das UHs pertencem à tipologia com formato em “L”, sendo que 85,5% delas estão posicionadas na parte central da edificação, com apenas uma fachada exposta. Essa simplificação também apresentou erros maiores nas UHs de pavimento térreo, que representaram 71,8% dos casos críticos, e nas UHs com envoltória em tijolo maciço de 20 cm, que representou 40,8% dos casos críticos.

Detalhes dos resultados dos casos críticos listados na Tabela 10 foram expostos na Tabela 11. O PH_{INF} e o PH_{SUP} são, respectivamente, o percentual de horas em que a temperatura operativa de um APP está abaixo do limite inferior e acima do limite superior definidos pela nova proposta para a NBR 15.575. A $T_{OP,MÍN}$ e a $T_{OP,MÁX}$ são as temperaturas operativas mínima e máxima da UH de interesse, respectivamente. A Tabela 11 exibe os valores do PHFT do modelo inicial correspondente à cada caso crítico, além dos valores de $\Delta PHFT$, do ΔPH_{INF} , ΔPH_{SUP} , $\Delta T_{OP,MÍN}$ e $\Delta T_{OP,MÁX}$. Os valores delta dos índices foram calculados subtraindo do valor do modelo simplificado, o valor do modelo inicial.

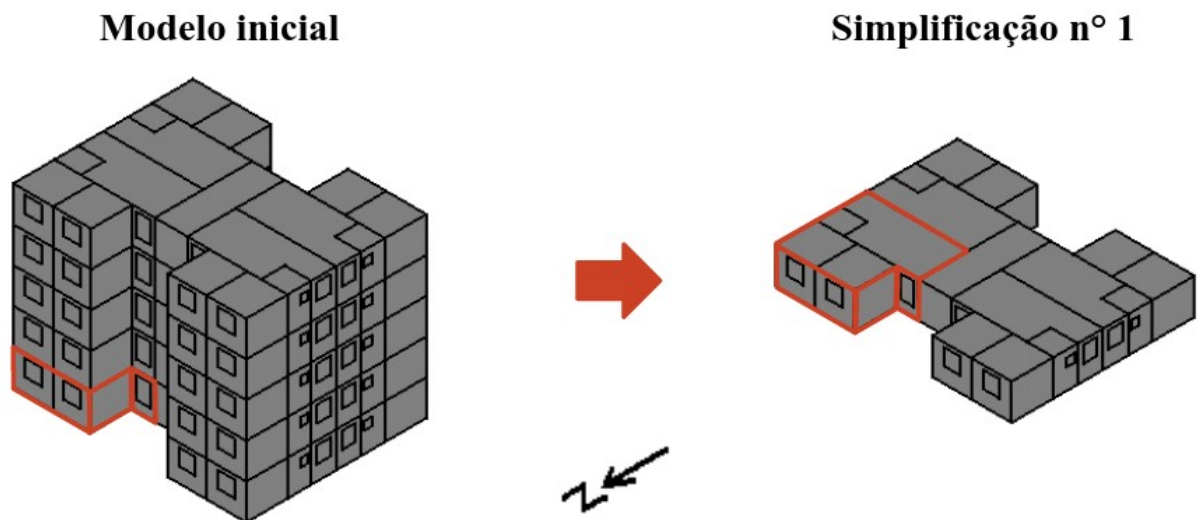
Tabela 11 - Casos de simplificações com as maiores diferenças no PHFT.

Caso	PHFT do modelo inicial (%)	$\Delta PHFT$ (%)	ΔPH_{INF} (%)	ΔPH_{SUP} (%)	$\Delta T_{OP,MÍN}$ (°C)	$\Delta T_{OP,MÁX}$ (°C)
A	67,8	5,1	0	-5,1	0	-0,6
B	97,6	-13,0	13,0	0	-0,7	-0,5
C	58,2	-10,9	0	10,9	0,6	0,5
D	61,0	5,8	0	-5,8	-0,3	-0,4

O Caso A corresponde à S1, cuja premissa é simular todos os ambientes do pavimento onde encontra-se a UH de interesse. Nesse caso, como a UH de interesse pertence ao pavimento térreo, o piso foi considerado em contato com o solo e a cobertura foi considerada

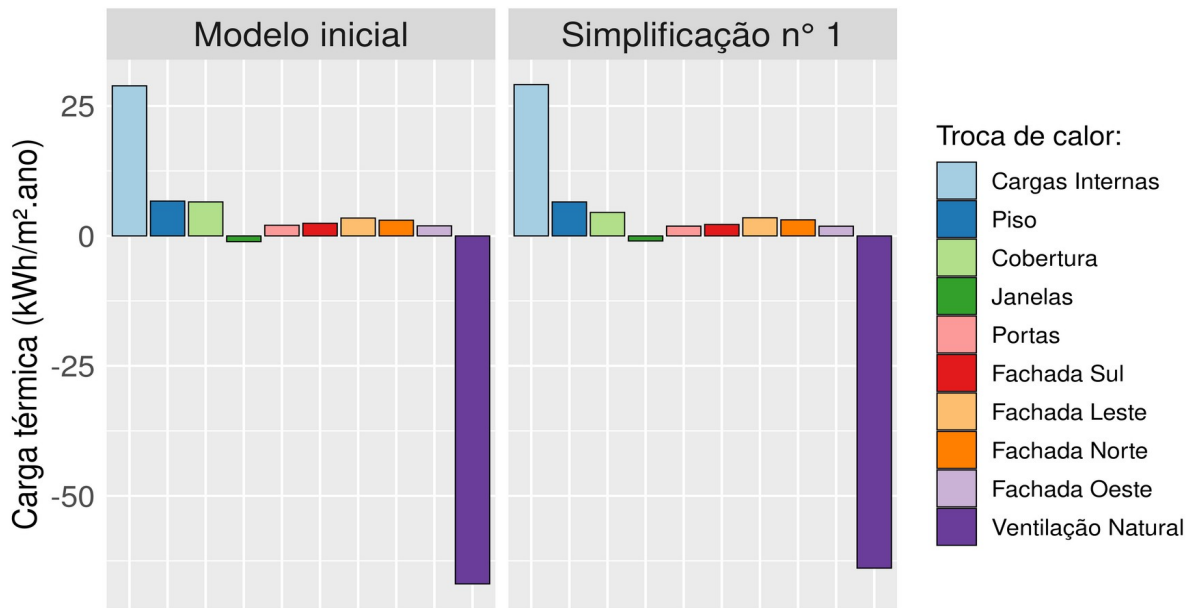
adiabática. A Figura 12 ilustra o processo de simplificação do Caso A, que parte do modelo inicial até a S1. A UH de interesse foi marcada com a cor vermelha. Apesar de os modelos inicial e simplificado exigirem a simulação de diversas UHs, apenas os resultados da UH de interesse foram extraídos e analisados.

Figura 12 - Adaptação do modelo inicial para a simplificação n° 1 (Caso A).



A Figura 13 expõe, lado a lado, gráficos de barras referentes aos balanços de calor anuais do Caso A e da UH correspondente simulada no modelo inicial. No gráfico, valores positivos indicam que a UH ganhou calor e valores negativos indicam que a UH perdeu calor. Do gráfico, identifica-se uma redução do ganho de calor através da cobertura de 2,0 kWh/m².ano (30,9%). Em contrapartida, houve uma redução de 3,0 kWh/m².ano (4,5%) na perda de calor por ventilação natural desse caso.

Figura 13 - Balanços térmicos do Caso A e do modelo inicial correspondente.




Dada a sua exposição ao sol ao longo do dia inteiro, pavimentos de cobertura aquecem mais que os pavimentos inferiores, especialmente em climas quentes, como o de Sorriso, onde a incidência solar é alta. Nessas condições, forma-se um fluxo de calor do topo dos edifícios, que possui temperaturas mais altas, para o solo, que tende a apresentar temperaturas mais baixas. Como a cobertura do pavimento térreo do modelo simplificado do Caso A foi considerada adiabática, uma parcela do fluxo de calor que entraria por essa superfícies foi bloqueada, o que reduziu o ganho de calor pela cobertura, resultando em uma $\Delta T_{OP,MÁX}$ de $-0,6^{\circ}\text{C}$. Naturalmente, como a temperatura operativa da UH reduziu e o clima é quente, houve uma ΔPH_{SUP} de $-5,1\%$, acarretando em uma $\Delta PHFT$ de $5,1\%$. A redução das temperaturas operativas reduziu também a necessidade de se ativar o sistema de ventilação natural no modelo simplificado e, conseqüentemente, reduziu as trocas de calor através desse sistema.

É importante notar que a perda de calor pelas janelas observada na Figura 13 é consequência da abordagem do programa EnergyPlus para lidar com a radiação solar que incide sobre elementos translúcidos. A radiação solar transmitida para o interior das zonas térmicas através das janelas é absorvida pelo piso e refletida pelo piso para as demais superfícies em proporções equivalentes. Portanto, o calor absorvido pela UH através da radiação solar é contabilizado pelo piso, cobertura e paredes. Assim, o valor do balanço de calor das janelas representa apenas o calor que sai da UH, o que explica o resultado negativo encontrado.


A Figura 14 ilustra a progressão do modelo inicial para simular através da S2, no Caso B. Seguindo as premissas dessa simplificação e dado o posicionamento da UH na porção central da fachada sul do pavimento térreo do edifício, as paredes leste, norte e oeste da UH, bem como a sua cobertura, foram consideradas adiabáticas, pois estão em contato com outros ambientes da edificação que não foram modelados. Devido à vista em perspectiva, algumas das superfícies adiabáticas não podem ser visualizadas na imagem, portanto, apenas as paredes adiabáticas visíveis foram coloridas em amarelo, no lado direito da figura.

Figura 14 - Adaptação do modelo inicial para a simplificação nº 2 (Caso B).



Dos balanços de calor anuais ilustrados na Figura 15, nota-se a inversão do comportamento do piso, da cobertura e das paredes norte no Caso B, que deixam de inserir calor na UH e passam a removê-lo. As diferenças nas trocas de calor do piso, da cobertura e das paredes norte do modelo simplificado foram, respectivamente, 6,2 (150,8%), 2,6 (255,8%) e 1,2 kWh/m².ano (116,9%). Para compensar as reduções descritas e outras oscilações de menor intensidade, a fim de atingir o equilíbrio térmico, o modelo simplificado apresentou uma redução nas perdas de calor a partir do sistema de ventilação natural de 13,2 kWh/m².ano (29,2%).

Figura 15 - Balanços térmicos do Caso B e do modelo inicial correspondente.




Durante o dia a sala do modelo inicial do Caso B está ocupada e regula suas temperaturas através da ventilação natural, já que as cargas internas esquentam o ambiente. Como esses modelos foram simulados no clima de Curitiba, que possui TBSm igual a 17,4°C, o ar externo apresenta alta capacidade de resfriar as salas durante o dia. Os dormitórios, que durante o dia acumularam o calor proveniente da fachada norte e dos pavimentos superiores em suas paredes em tijolo maciço de 20 cm e piso em concreto de 10 cm, de alta inércia térmica, passam a ser ocupados a noite e ativam a ventilação natural, que libera o excesso de calor nesses ambientes. Devido às baixas temperaturas de Curitiba, acentuadas durante a noite, as trocas de ar nos dormitórios reduzem bruscamente as temperaturas internas, fazendo com que o piso lentamente ceda o calor estocado ao longo do dia ao ar interno, que está menos quente que o solo. Já no modelo simplificado, como a cobertura e as paredes leste, norte e oeste da UH são adiabáticas, houve $\Delta T_{OP,MÍN}$ e $\Delta T_{OP,MÁX}$ de -0,7°C e -0,5°C. Essas novas condições de exposição das superfícies, fazem com que os ambientes não aqueçam tanto durante o dia e a noite, quando os dormitórios passam a ser ocupados, as suas temperaturas estão mais baixas e não há necessidade de ativar a ventilação natural. Sendo assim, o piso, que estocou menos calor durante o dia no modelo simplificado, retira calor dos dormitórios, já que estes, por possuírem cargas internas e não apresentarem trocas de ar significativas, alcançam temperaturas mais altas. As reduções das temperaturas operativas no

modelo simplificado justificam as reduções do uso da ventilação natural, bem como um ΔPH_{FT} de -13,0%, causado exclusivamente por uma ΔPH_{INF} de 13,0%.

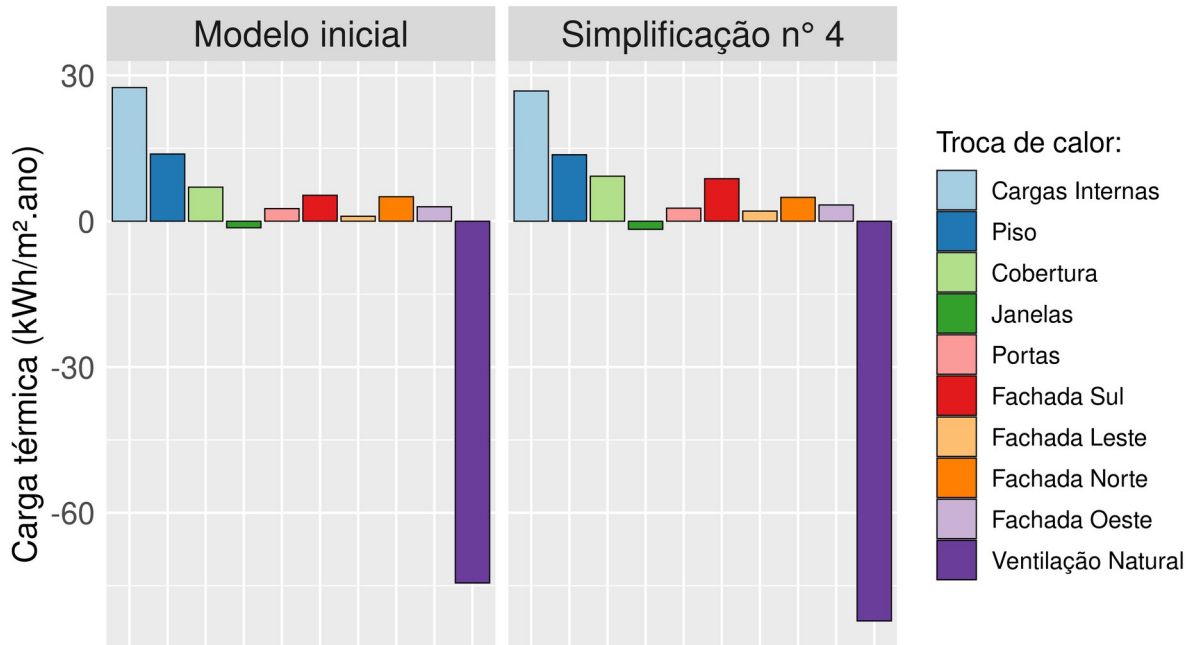
O processo de simplificação do caso C, que considera as premissas da S4, foi ilustrado na Figura 16. Nesse caso, as paredes sul, leste e oeste da UH de interesse foram consideradas adiabáticas, enquanto seu piso e sua cobertura fazem contato com UHs semelhantes. As paredes das UHs inferior e superior possuem a mesma condição de exposição das paredes da UH de interesse, já o piso do pavimento inferior está em contato com o solo e a cobertura do pavimento superior está exposta ao ambiente externo.

Figura 16 - Adaptação do modelo inicial para a simplificação n° 4 (Caso C).



Os balanços de calor anuais dos modelos inicial e simplificado do Caso C foram expostos na Figura 17. Percebe-se que, do modelo inicial para o modelo simplificado, houve um aumento de 2,3 (32,2%) e de 3,4 kWh/m².ano (64,2%) do calor absorvido através da cobertura e das paredes sul da UH de interesse, respectivamente. O aumento de 7,8 kWh/m².ano (10,5%) no calor removido através da ventilação natural minimizou o efeito do aumento do calor através da cobertura e das paredes sul no modelo simplificado.

Figura 17 - Balanços térmicos do Caso C e do modelo inicial correspondente.




Em todos os pavimentos do modelo simplificado do Caso C a condição adiabática das paredes sul, leste e oeste impediram o fluxo de calor da fachada norte, mais quente, para a fachada sul, menos quente. Dentre os três pavimentos simulados, o pavimento de cobertura recebe maior incidência de radiação solar, logo, esquenta mais que os pavimentos inferiores, formando um fluxo de calor em direção ao solo. Enquanto o modelo inicial possui um pavimento entre os pavimentos intermediário e de cobertura, o modelo simplificado possui o pavimento intermediário em contato direto com o pavimento de cobertura. Até alcançar a UH de interesse, o calor proveniente da cobertura no modelo inicial é parcialmente dissipado no próprio pavimento de cobertura e no pavimento logo acima do pavimento da UH de interesse. Já no modelo simplificado, o calor estocado na cobertura, além de não ser capaz de fluir para a fachada sul, é transferido diretamente para a UH de interesse, gerando um aumento no ganho de calor pela cobertura e, conseqüentemente, $\Delta T_{OP,MÍN}$ e $\Delta T_{OP,MÁX}$ de 0,6°C e 0,5°C. Já que está mais quente, o modelo simplificado atende aos critérios de ativação da ventilação natural por um período da simulação, porém, o calor retirado não é suficiente para manter o PHFT obtido no modelo inicial. Assim, houve uma $\Delta PHFT$ de -10,9%, gerada exclusivamente por um aumento de horas de simulação em que o limite superior de temperatura operativa foi desrespeitado.

O processo de simplificação do Caso D foi representado na Figura 18. Nesse caso, que

segue as premissas da S4, além da UH de interesse, posicionada no pavimento térreo, duas UHs semelhantes foram modeladas nos pavimentos superior e de cobertura. De acordo com as orientações da simplificação correspondente, as condições de exposição das paredes leste, norte e oeste de todos os pavimentos foram consideradas adiabáticas.

Figura 18 - Adaptação do modelo inicial para a simplificação n° 4 (Caso D).

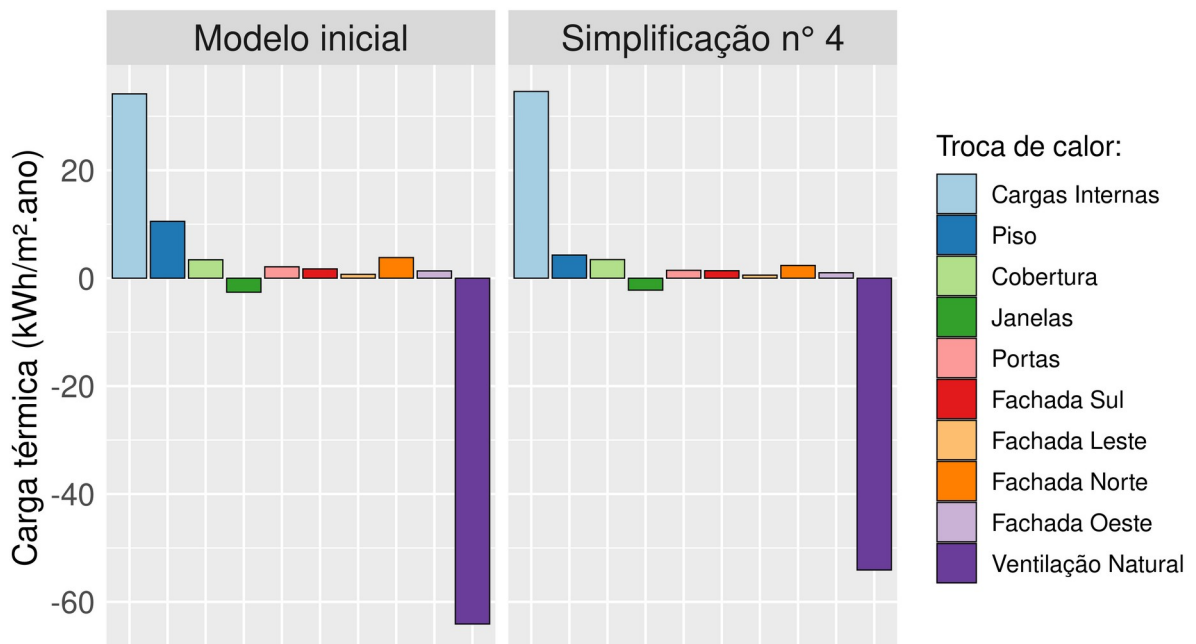


Os gráficos de barras da Figura 19 descrevem os balanços de calor anuais dos modelos inicial e simplificado do Caso D. Dos gráficos, nota-se que o modelo simplificado apresentou uma redução de 6,2 kWh/m².ano (59,3%) do ganho de calor através do piso e 10,0 kWh/m².ano (15,6%) da perda de calor através da ventilação natural, além de variações insignificantes no fluxo de calor das outras superfícies.

As condições adiabáticas das paredes da UH do Caso D impediram as trocas de calor com a fachada norte da edificação. A desconsideração da fachada norte, mais quente, resultou em $\Delta T_{OP,MÍN}$ e $\Delta T_{OP,MÁX}$ iguais a -0,3°C e -0,4°C. Durante o dia, a temperatura dos ambientes do modelo inicial se estabiliza em valores altos, pois o clima do Rio de Janeiro apresenta TBSm igual a 23,2°C. Ao iniciar a noite, os dormitórios, que estão excessivamente quentes, passam a ser ocupados e a ventilação natural é ativada, retirando o calor através das trocas de ar e fazendo com que a temperatura reduza repentinamente. No início da noite as paredes,

compostas por *steel frame* (baixa inércia térmica), reduzem bruscamente sua temperatura, enquanto o piso, composto por concreto de 10 cm, contrapiso e piso cerâmico (alta inércia térmica), reduz a temperatura de forma mais lenta. As diferenças entre os atrasos térmicos do piso e das paredes resultam em um fluxo de calor predominantemente do piso para o ar no interior da UH de interesse. O mesmo aconteceu com o modelo simplificado, porém, nesse caso o piso, que aqueceu menos durante o dia, forneceu menos calor para o ar no interior da UH de interesse. As reduções da temperatura das superfícies e da temperatura operativa dos ambientes gerou uma $\Delta PHFT$ de 5,8% e exigiu que a ventilação natural fosse ativada por um número menor de horas de simulação, reduzindo as perdas de calor através desse sistema.

Figura 19 - Balanços térmicos do Caso D e do modelo inicial correspondente.



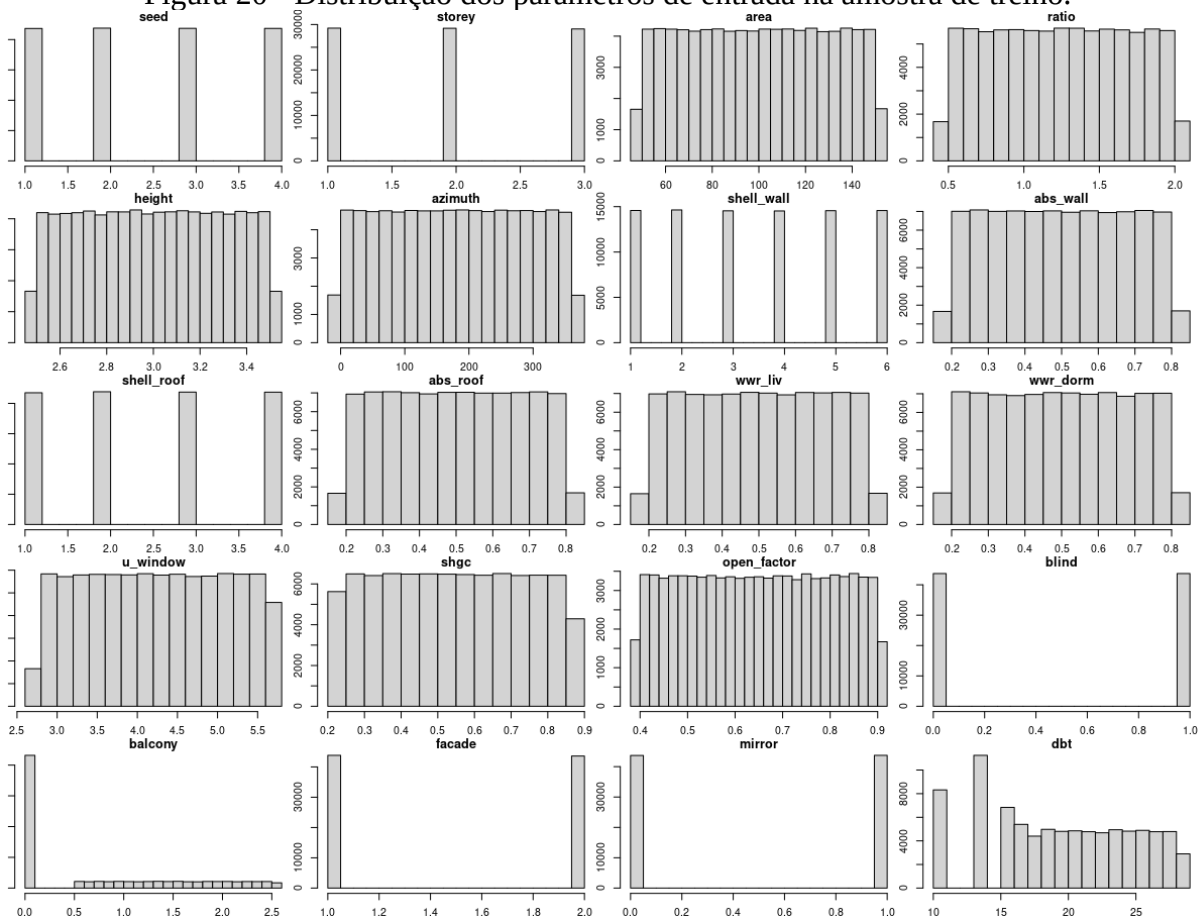
As análises dos Casos de A a D evidenciam que as cargas internas e a ventilação natural são os maiores contribuintes para o balanço de calor dos modelos estudados. A contribuição das cargas internas apresentou variações de acordo com as características climáticas e construtivas da UH, pois elas alteram consideravelmente a temperatura das superfícies, influenciando as trocas de calor sensível com equipamentos, pessoas e iluminação. Todavia, os valores das cargas internas não variaram significativamente entre os modelos iniciais e as simplificações correspondentes, pois as diferenças de temperatura não foram altas o suficiente para perturbar as trocas de calor sensível de maneira relevante. Em

todos os casos analisados, a ventilação natural foi identificada como um mecanismo eficaz no controle do desempenho térmico. As discrepâncias entre os fluxos de calor das superfícies das simplificações e dos modelos iniciais foram contrabalanceadas pela ventilação natural, que reduziu a magnitude das $\Delta PHFT$.

4.2 AMOSTRAGEM

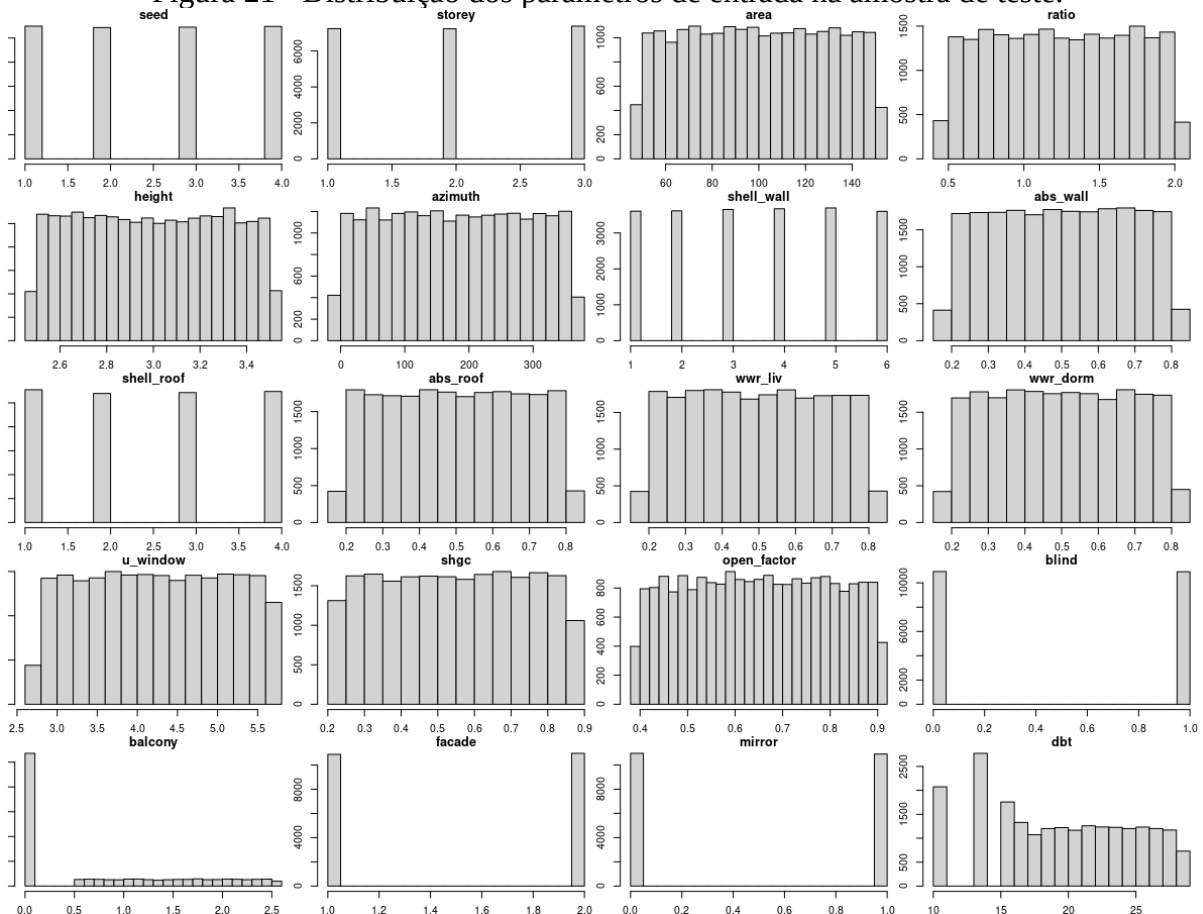
As amostras de treino e de teste foram geradas através da técnica de amostragem de Sobol. Portanto, a distribuição dos parâmetros de entrada tendeu a ser uniforme, com exceção de alguns parâmetros, que possuem limitação relacionadas à técnica de Sobol. Os histogramas da Figuras 20 e 21 exibem a distribuição dos parâmetros de entrada, sendo que no eixo x estão os valores dos parâmetros e no eixo y está a frequência. As siglas correspondentes aos parâmetros de entrada foram enumeradas na Tabela 7.

Figura 20 - Distribuição dos parâmetros de entrada na amostra de treino.



Os parâmetros de entrada que possuem restrições são: a profundidade da sacada (“balcony”) e a média anual da temperatura de bulbo seco (“dbt”). Visto que a profundidade da sacada aceita o valor 0 ou qualquer valor entre 0,5 e 2,5 m, a amostragem foi variada de -1,5 a 2,5 m. Qualquer valor abaixo de 0,5 foi considerado igual a 0, assim, metade da amostra não possui sacada e a outra metade possui sacadas com profundidade variando de 0,5 a 2,5 m.

Figura 21 - Distribuição dos parâmetros de entrada na amostra de teste.

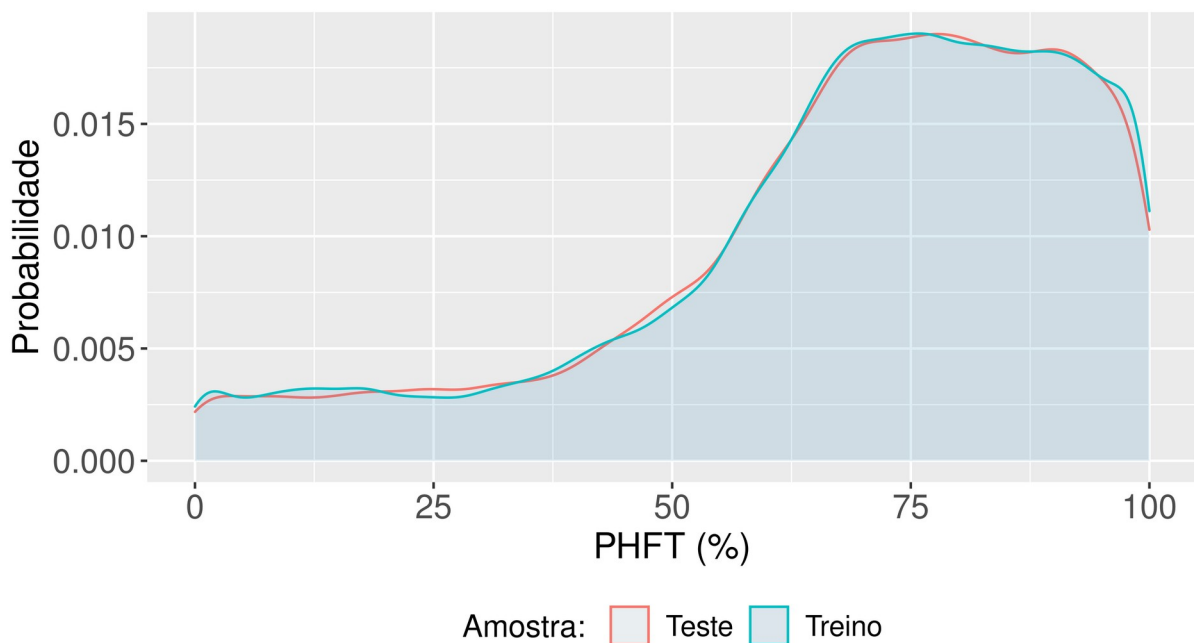


Devido à baixa diversidade de arquivos climáticos brasileiros com TBSm menor que 15°C, o parâmetro “dbt” apresentou bandas com maior frequência nos valores 10,8°C e 13,7°C. Dentre os 411 arquivos climáticos utilizados, apenas 4 possuem TBSm abaixo de 15°C, são eles: Uribici – SC (10,83°C), Petrópolis – RJ (13,60°C), São Joaquim – SC (13,64°C) e São José dos Ausentes – RS (13,80°C). Dado o caráter quase aleatório da amostragem de Sobol, as TBSm amostradas que não corresponderam a um arquivo climático em específico foram associadas ao arquivo climático com TBSm mais próxima. Assim, os espaços da amostra com menor variedade de arquivos climáticos apresentaram picos de maior

frequência.

Após simuladas as amostras, os resultados foram processados, de modo a gerar um conjunto de parâmetros de saída para cada uma das amostras. Os gráficos de densidade da Figura 22 evidenciam a distribuição do PHFT nas amostras. No eixo x encontram-se os valores de PHFT e no eixo y a probabilidade relativa com que os valores de PHFT podem ser encontrados nas amostras.

Figura 22 - Distribuição do PHFT nas amostras de treino e teste.



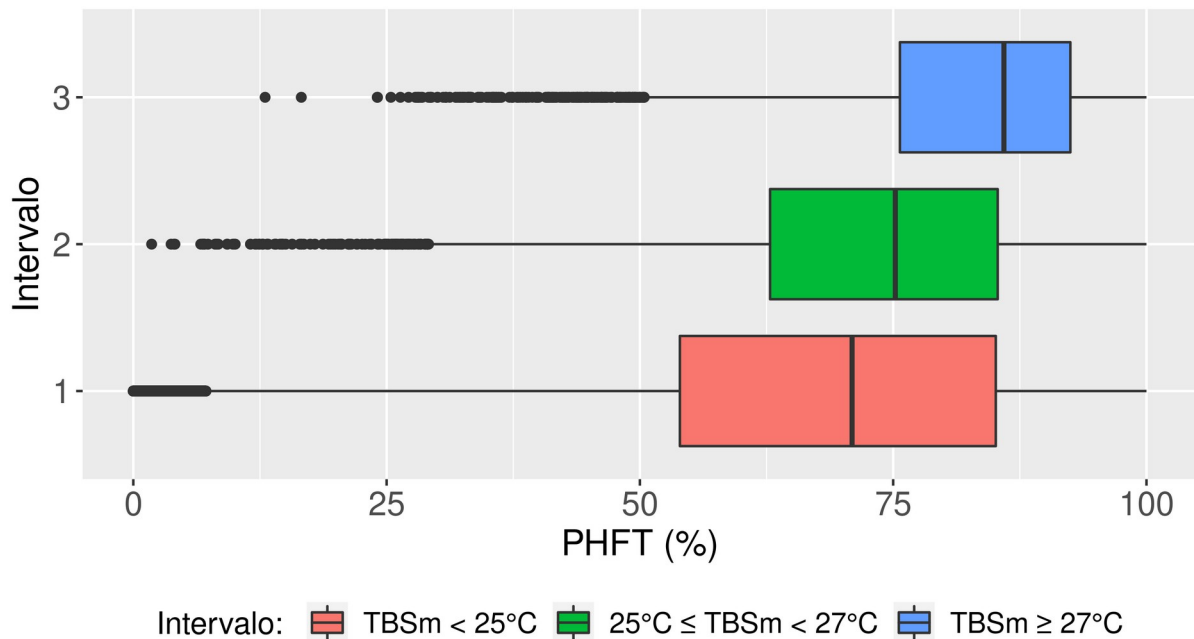
Devido à similaridade no desenvolvimento das amostras de treino e de teste, ambas desenvolvidas através da técnica de Sobol, utilizando os mesmos parâmetros de entrada e os mesmos intervalos de variação, as distribuições das amostras apresentaram comportamento similar.

Os gráficos de densidade exibem distribuições deslocada à esquerda, sendo que aproximadamente 81% dos elementos das amostras de treino e de teste apresentou PHFT maior que 50%, e 37% apresentou PHFT entre 70% e 90%. Os dados levantados indicam que parte significativa das soluções construtivas consideradas na base de dados possuem alto desempenho térmico nos climas brasileiros abordados.

De acordo com as definições da nova proposta para NBR 15.575, o PHFT está intrinsecamente ligado às temperaturas operativas dos APPs, que devem estar dentro de uma

faixa de valores pré-determinada. Visto que os três intervalos de temperatura operativa de interesse, enumerados na Tabela 1, variam de acordo com a TBSm, o desempenho térmico das UHs dentro desses intervalos foi investigado separadamente. O gráfico de caixas da Figura 23 representa a distribuição do PHFT na base de dados. O PHFT foi representado no eixo x, e os três intervalos de temperatura operativa foram representados no eixo y, cada um com uma cor. As linhas verticais pretas dentro de cada caixa correspondem às medianas do PHFT dos respectivos intervalos.

Figura 23 - Distribuição do PHFT por intervalo de interesse.



Na medida em que o intervalo de TBSm aumentam, aumenta também o desempenho térmico das UHs, *i.e.* o PHFT é diretamente proporcional ao intervalo de TBSm. Enquanto o Intervalo 1 apresentou média de PHFT igual a 66,1%, a média do PHFT dos Intervalos 2 e 3 foram iguais a 73,3% e 82,9%, respectivamente. Apesar de contra intuitivo, esse comportamento pode ser explicado pela alta capacidade de extração de calor das UHs proporcionado pelo uso da ventilação natural, comprovada nas Figuras 13, 15, 17 e 19.

O uso da ventilação natural beneficia climas quentes de maneira mais expressiva, pois nesses climas os critérios definidos pela nova proposta para a NBR 15.575 para a ativação do sistema de ventilação natural são atendidos por um número maior de horas de simulação. Assim, a ventilação natural troca o ar interno, resfriando o ambiente e levando sua


temperatura operativa para dentro do intervalo de interesse. Como a simulação da nova proposta para a NBR 15.575 não oferece mecanismos de aquecimento passivo com potencial de troca de calor tão alto quanto o potencial de retirada de calor da ventilação natural, em climas frios os ambientes são incapazes de elevar sua temperatura operativa, a qual permanece abaixo do limite mínimo de interesse. Por esse motivo as UHs localizadas em climas frios apresentaram PHFT relativamente baixo, formando uma disparidade entre o desempenho térmico de UHs localizadas climas quentes e frios.

4.3 ANÁLISE DE SENSIBILIDADE

A análise de sensibilidade de Sobol, que descreve a importância dos parâmetros de entrada para o parâmetro de saída (PHFT), foi exposta no gráfico de barras da Figura 24. Os eixos x e y representam, respectivamente, os valores dos índices de sensibilidade e o parâmetro de entrada correspondente. As barras na cor azul clara correspondem aos efeitos de primeira ordem e as barras azul escuras correspondem aos efeitos totais, estimados através da soma dos efeitos de primeira ordem com efeitos de ordens superiores.

Os resultados indicam que a TBSm (“dbt”) é o parâmetro que mais contribui para a variância do PHFT, representando mais de 60% da soma dos efeitos totais de todos os parâmetros da base de dados e superando o segundo parâmetro mais influente em 49%. O valor relativamente alto do efeito de primeira ordem (0,617) sugere que a “dbt”, por si só, é responsável por maior parte da variância do PHFT. Entretanto, há uma interação considerável entre a “dbt” e os outros parâmetros, pois o seu efeito total é 0,132 (21,4% do efeito total) maior que o efeito de primeira ordem.

Figura 24 - Análise de sensibilidade de Sobol.



Seguido da TBSm estão o uso ou não de veneziana (“blind”) e o fator solar dos vidros (“shgc”), com efeitos totais iguais a 0,075 e 0,066, respectivamente, representando, juntos, 11,5% da soma dos efeitos totais dos parâmetros de entrada. O parâmetro “blind” exibiu influência direta sobre o PHFT relativamente alta, com efeito de primeira ordem igual a 0,047 (62,7% do efeito total). Já o “shgc” influencia o PHFT essencialmente de maneira indireta, pois seu efeito de primeira ordem representou apenas 3,0% dos seus efeitos totais. O “shgc”

interage, por exemplo, com o parâmetro “blind”, pois ao acionar as venezianas a incidência de radiação solar sobre o vidro das janelas diminui, bem como a capacidade do fator solar dos vidros de controlar o fluxo de calor para dentro da UH. Apesar das distinções entre efeitos diretos e indiretos, os resultados encontrados atentam à importância do uso de sistemas que bloqueiam a entrada de radiação solar no controle do desempenho térmico em climas brasileiros. Esses mecanismos são completamente ignorados na NBR 15.575 vigente, porém, apresentam alto potencial de influência sobre o desempenho térmico, podendo levar ao aumento do conforto dos usuários e à redução do consumo energético de edificações que operam em condicionamento híbrido.

Após o clima e os mecanismos de sombreamento, o pavimento onde encontra-se a UH de interesse (“storey”) é o próximo parâmetro de maior importância para o PHFT, com efeito total igual a 0,060, que representa 4,9% dos efeitos totais. Quase 50% do efeito total desse parâmetro está relacionado aos efeitos diretos sobre o PHFT. Os efeitos diretos do parâmetro “storey” estão relacionados às condições de contorno dos pavimentos, que interagem com o solo, com o ar externo e com radiação solar dos pavimento de forma diferente. Independentemente dos outros parâmetros de entrada, sempre haverá diferenças entre o desempenho dos pavimentos, pois o solo e o ar externo possuem propriedades térmicas consideravelmente distintas e o piso e a cobertura respondem a essas propriedades de acordo com as suas condições de contorno. Já os efeitos indiretos desse parâmetro relacionam-se à influência que o clima, os componentes construtivos e outros parâmetros de entrada, exercem sobre as interações entre a UH e o ambiente externo. As discussões da seção 4.1 interpretam as trocas de calor entre a UH e o ambiente externo, levando em consideração o posicionamento da UH de interesse na edificação.

As absorptâncias da cobertura (“abs_roof”) e das paredes externas (“abs_wall”) apresentaram efeitos totais iguais a 0,058 e 0,041, respectivamente, o que corresponde à 8,1% da soma dos efeitos totais. Comparada às paredes, a cobertura normalmente recebe maior incidência de radiação solar, devido à sua maior área e ao menor ângulo de incidência solar. Assim, medidas que reduzem a absorção de calor através da cobertura tendem a influenciar mais o PHFT. A “abs_roof” e a “abs_wall” interagem com clima, bem como com os componentes construtivos das paredes (“shell_wall”) e da cobertura (“shell_roof”). Enquanto os climas quentes se beneficiam do uso de cores claras, que refletem a radiação solar e evitam o superaquecimento da UH, os climas frios são beneficiados com cores escuras, que são

absorvidas pelas superfícies e esquentam a UH. Os impactos da absortância na temperatura operativa da UH, que define o PHFT, também dependem dos componentes construtivos, que controlam a inércia e o atraso térmico. Os efeitos de ordens de primeira ordem dos parâmetros “shell_wall” e “shell_roof” representaram apenas 3,7% e 15,4% do seu efeito total, indicando que sua influência sobre o PHFT se dá majoritariamente através de outros parâmetros, como “dbt”, “storey”, “abs_wall” e “abs_roof”.

O percentual envidraçado das fachadas dos dormitórios (“wwr_dorm”) exibiu importância mediana em relação ao PHFT, sendo que seu efeito total foi igual a 0,038, dos quais aproximadamente 50% correspondeu ao efeito de primeira ordem. Curiosamente, o percentual envidraçado das fachadas da sala (“wwr_liv”) foi pouco importante para a estimativa do PHFT, com efeito total igual a 0,003. Uma justificativa para essa disparidade entre a importância de parâmetros aparentemente tão similares baseia-se no comportamento dos mecanismos de sombreamento. As instruções da nova proposta para a NBR 15.575 definem que as venezianas sejam ativadas sempre que a temperatura de bulbo seco externa seja maior do que 26°C. Como os dormitórios são ocupados somente durante a noite e de manhã cedo, as venezianas não exercem influência sobre as janelas, pois durante a noite não há radiação solar e de manhã cedo a temperatura externa costuma ser baixa, de modo que dificilmente atingirá. Sem o uso de venezianas, a radiação solar atinge diretamente o vidro, tornando o “wwr_dorm” um parâmetro relevante para o controle do calor transmitido para dentro da UH. Já as salas, que são ocupadas durante o dia, utilizam as venezianas por um período maior da simulação, visto que durante o dia as temperaturas externas são mais elevadas e os climas brasileiros são tipicamente quentes. Além disso, salas podem se prevalecer do sombreamento proveniente de sacadas, que variam de 50 cm a 2,5 m de profundidade. O sombreamento fornecido por esses dois mecanismos faz com que a importância do “wwr_liv” seja consideravelmente menor do que o “wwr_dorm”.

O fator de ventilação (“open_factor”) obteve efeito total igual a 0,021, equivalente a 1,7% da soma dos efeitos totais, sendo que 76,2% do seu efeito total corresponde ao efeito de primeiro ordem. Sendo assim, uma parcela considerável das variações desse parâmetro reflete diretamente na capacidade que a ventilação natural possui para contrabalancear as trocas de calor dos ambientes, o que resulta em variações do PHFT. Os efeitos de ordens superiores do “open_factor” estão relacionados a parâmetros como a TBSm e o percentual de abertura das fachadas. Visto que o fator de ventilação está intrinsicamente ligado à ventilação natural, o

seu potencial de alterar o desempenho térmico tende a ser maior em UHs localizadas em climas quentes, pois nesses climas há uma necessidade maior de ativação da ventilação natural, sendo que o oposto se aplica à climas frios. Em conjunto com o fator de ventilação, o percentual de abertura das fachadas altera a capacidade de trocas de ar da ventilação natural, permitindo o controle da temperatura operativa do ambiente e, conseqüente, do PHFT.

Os parâmetros menos importantes para o PHFT foram, nessa ordem, parâmetros referentes às propriedades geométricas, à profundidade da sacada (“balcony”), que está relacionada ao sombreamento da janela da sala, e à transmitância térmica das janelas (“u_window”). Juntos, os efeitos totais desses parâmetros somaram 0,069, que corresponde a apenas 5,6% da soma dos efeitos totais. Os parâmetros geométricos citados foram: o ângulo azimutal (“azimuth”), a tipologia (“seed”), a fachada de exposição da janela do dormitório (“facade”), o espelhamento da tipologia (“mirror”), o pé-direito (“height”), a relação entre as dimensões (“ratio”), a área (“area”) e o percentual envidraçado da fachada (“wwr_liv”).

As retas verticais tracejadas da Figura 24, que representam os critérios para a seleção de parâmetros de entrada, foram traçadas nos valores de índice de sensibilidade iguais a 0,01 e 0,02, que correspondem, respectivamente, à apenas 0,8% e 1,6% da soma dos efeitos totais. O critério 0,01 excluiu os sete parâmetros menos importantes para o PHFT, de acordo com o efeito total de Sobol. Foram eles: “mirror”, “height”, “ratio”, “area”, “wwr_liv”, “balcony” e “u_window”. Além dos sete parâmetros enumerados, o critério 0,02, mais restritivo, excluiu também “azimuth”, “seed” e “facade”. Assim, o treinamento dos metamodelos subsequente contará com as seguintes bases de dados: a) B20, que considera todos os 20 parâmetros de entrada; b) B13, que considera os 13 parâmetros mais influentes, e; c) B10, que considera os 10 parâmetros mais influentes.

Percebe-se que dos 10 parâmetros excluídos através do critério de sensibilidade total igual a 0,02, oito tratam de características geométricas da edificação. A remoção das características geométricas facilita o uso do metamodelo, pois o número de restrições em relação a geometria é reduzido. Por exemplo, caso a UH de interesse não pertença a uma das UHs catalogadas, o uso do metamodelo não é permitido, entretanto, caso o parâmetro “seed” seja excluído da amostra de treino, não haveriam restrições quanto ao “seed” e a predição poderia ser realizada. Vale lembrar que o metamodelo responde melhor aos casos vistos durante a etapa de treino, sendo que o uso do metamodelo para a predição de casos que não estão presentes na base de dados deve ser evitado, pois essa predição pode conter erros não

esperados, pois não foram discutidos previamente.


4.4 DESENVOLVIMENTO DO METAMODELO

No pré-processamento da B20, os sete parâmetros de entrada qualitativos foram transformados em variáveis lógicas. Visto que os parâmetros “seed”, “storey”, “shell_wall”, “shell_roof”, “blind”, “facade” e “mirror” possuem, respectivamente, 4, 3, 6, 4, 2, 2 e 2 possíveis valores, esses parâmetros de entrada foram substituídos por 23 ($4 + 3 + 6 + 4 + 2 + 2 + 2$) variáveis lógicas, que podem assumir os valores 0 ou 1. Cada uma dessas variáveis representa a ausência ou a presença de um dos valores dos parâmetros de entrada enumerados acima.

A Figura 25 exibe a distribuição dos 13 parâmetros de entrada quantitativos da B20 após passarem pelo processo de normalização e centralização. Cada histograma da figura apresenta no seu eixo x os valores amostrados do parâmetro correspondente após o pré-processamento, e no eixo y a frequência com que esses valores foram encontrados na amostra de treino.

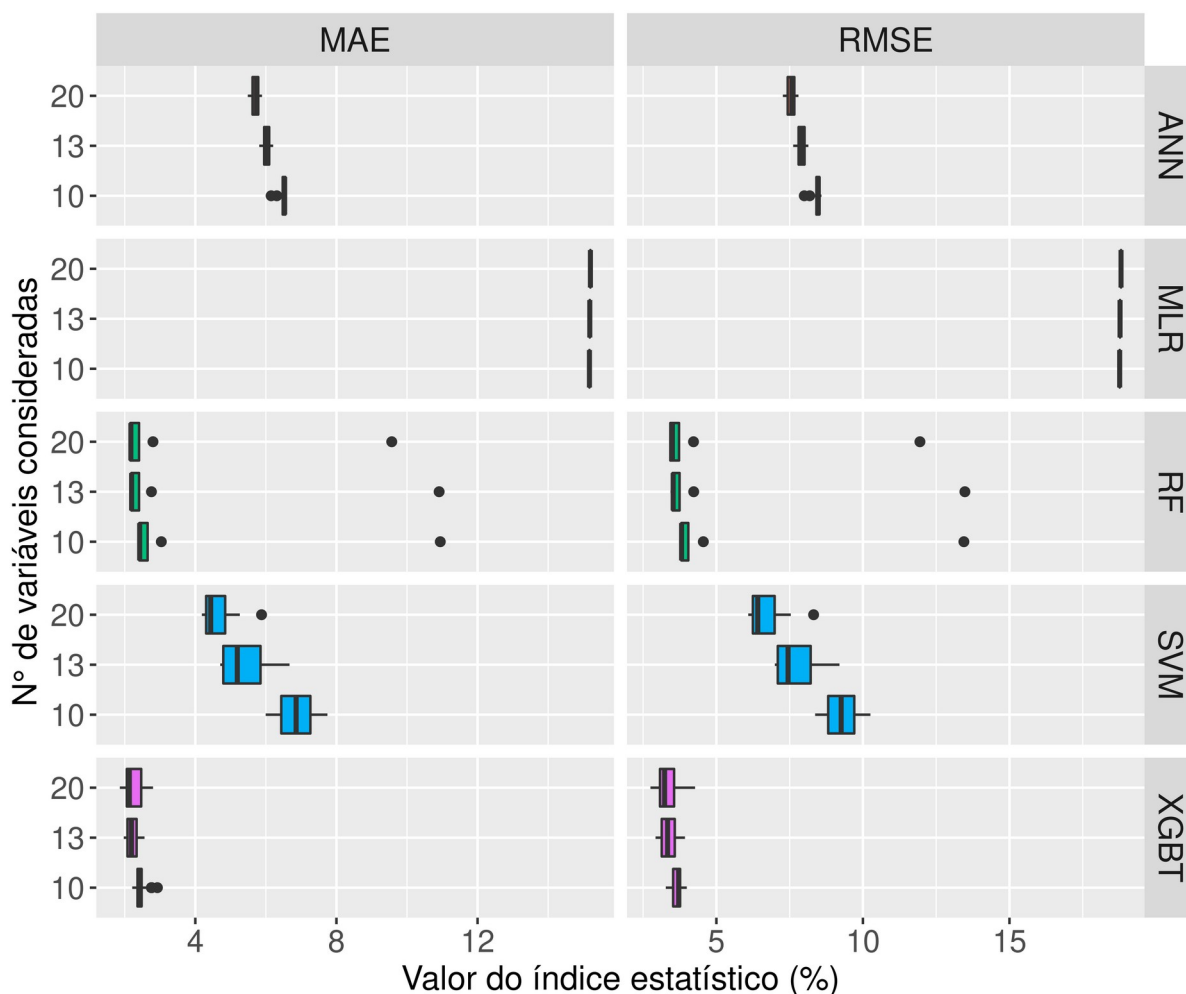
A partir dos histogramas, nota-se que a distribuição dos parâmetros de entrada se manteve uniforme, porém, os parâmetros de entrada foram centralizados em torno do valor 0 e normalizados, de forma que variam de - 2 a + 2. Devido a sua distribuição extremamente concentrada no valor 0, o parâmetro “balcony” não apresentou o mesmo padrão que os outros parâmetros após o pré-processamento. Todavia, os valores de “balcony” apresentaram a mesma magnitude do resto dos parâmetros, o que facilita o processo de otimização dos pesos dos metamodelos durante o seu treinamento.

Figura 25 - Distribuição dos parâmetros de entrada pré-processados na amostra de treino.



A acurácia de treino dos metamodelos otimizados a partir das cinco técnicas de metamodelagem foi exposta na Figura 26. O eixo x corresponde aos valores dos índices estatísticos MAE, na esquerda, e RMSE, na direita, e o eixo y corresponde à base de dados correspondente. As caixas representam a distribuição dos erros, MAE e RMSE, de todos os metamodelos que foram treinados. Os gráficos foram separados por índice estatístico e por técnica de metamodelagem aplicada.

Figura 26 - Acurácia dos metamodelos na etapa de treino.



É possível observar, a partir da Figura 26, que a MLR apresentou os maiores erros na etapa de treino, com MAE e RMSE respectivamente iguais a 15,2% e 18,8%. Como esse modelo não possui hiperparâmetros a serem configurados, apenas um metamodelo foi treinado para cada uma das três bases de dados, logo as suas caixas são linhas verticais que indicam o valor do erro para a base de dados correspondente. Nota-se também que o valor dos erros foi similar para B20, B13 e B10. Isso indica que a MLR foi incapaz de captar a influência dos parâmetros menos importantes para o PHFT, logo, a exclusão desses parâmetros não influenciou a acurácia das predições.

Seguida da MLR, a técnica ANN foi a que apresentou os resultados menos acurados na etapa de treino, com MAE e RMSE medianos para a B20 iguais a 5,7% e 7,6%, respectivamente. Em resposta à redução do número de parâmetros de entrada, a ANN aumentou os erros de forma pouco significativa, indicando que, para as configurações de

hiperparâmetros abordadas, os metamodelos não se ateuve ao comportamento dos parâmetros de entrada menos importantes. A variação do número de neurônios na camada escondida apresentou baixa influência sobre a acurácia de treino dos modelos, pois a amplitude máxima do MAE e do RMSE de B20, B13 e B10 foi igual a 0,6%. Devido a esse trabalho se limitar ao uso do modelo “brnn” através do pacote Caret, não foi possível variar outros parâmetros de entrada. Entretanto, a revisão bibliográfica aponta para uma quantidade extensa de hiperparâmetros que podem ser configurados nas ANNs, como o número de camadas escondidas, as funções de ativação, entre outros. Uma otimização mais aprofundada dos hiperparâmetros, utilizando bibliotecas de programação mais avançadas, pode resultar em ANNs mais acuradas.

A técnica SVM apresentou erros menores que a ANN, porém, consideravelmente maiores que os erros das técnicas baseadas nos conceitos de árvores (RF e XGBT). Os valores medianos do MAE e do RMSE obtidos na etapa de treino para a B20 foram iguais a 4,4% e 6,4%, respectivamente. O peso da função custo foi o único hiperparâmetro otimizado na SVM, sendo que a sua variação resultou em oscilações no MAE de até 2,0%, considerando três bases de dados. Portanto, a otimização do peso da função custo foi extremamente importante para atingir resultados acurados a partir dessa técnica. Visto que as diferenças dos valores medianos do MAE e do RMSE entre B20 e B10 foram respectivamente iguais a 2,4% e 2,8%, conclui-se que a técnica foi capaz de captar o comportamento dos parâmetros menos relevantes para o PHFT, já que a exclusão desses parâmetros de entrada resultou em aumentos significativos dos erros.

Os modelos baseados em árvores exibiram acurácia próximas, sendo que os modelos desenvolvidos a partir da técnica RF atingiram valores medianos de MAE e de RMSE respectivamente iguais a 2,2% e 3,5%, para a B20. A RF apresentou variações significativas nos erros durante o seu processo de otimização, sendo que o valor sugerido pelo pacote Caret para o número de variáveis aleatórias em cada RT resultou em MAE igual a 9,6%, 10,9% e 10,9%, para B20, B13 e B10, respectivamente. Sendo assim, foi essencial otimizar o hiperparâmetro “mtry”, caso contrário a RF não apresentaria resultados competitivos.

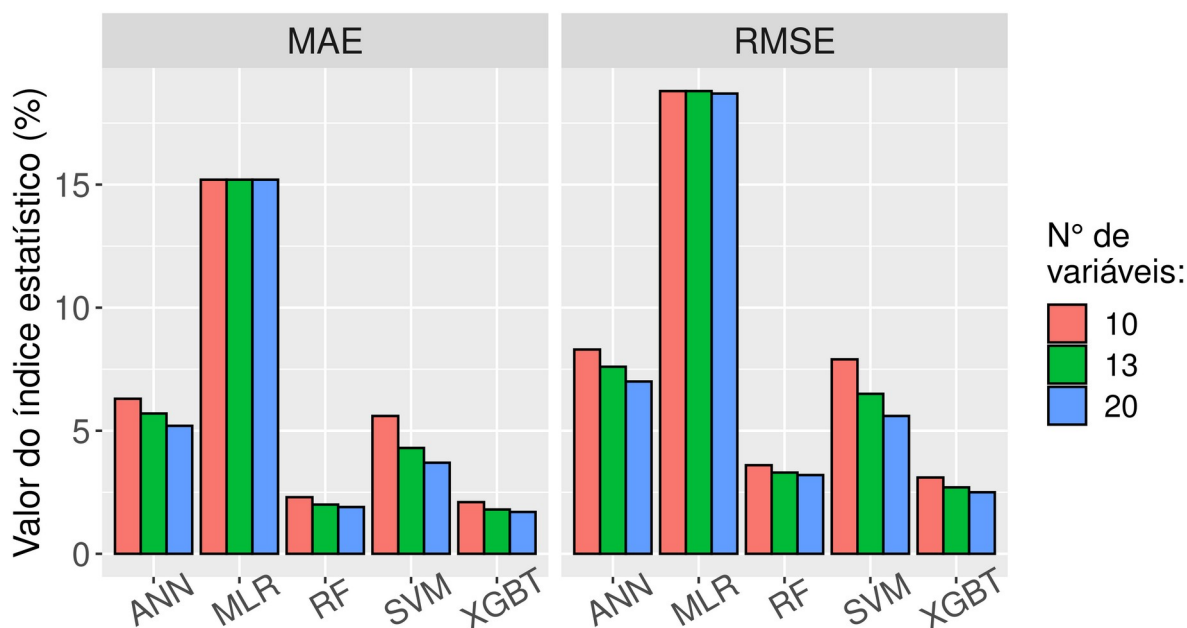
A técnica XGBT alcançou os menores erros durante a etapa de treino, com mediana do MAE e do RMSE para a B20 iguais a 2,1% e 3,2%, respectivamente. A prevalência de erros relativamente baixos durante o processo de otimização da XGBT sugere que configurar os hiperparâmetros não é estritamente necessário para essa técnica, já que os valores sugeridos

pelo pacote Caret resultaram em erros considerados baixos. Entretanto, o processo de otimização dos quatro hiperparâmetros foi capaz de reduzir os erros, fazendo com que a acurácia dessa técnica superasse todas as outras abordadas nesse estudo. Além da acurácia, o processo de otimização da XGBT demandou menos esforço computacional que a otimização das outras técnicas. O metamodelo mais acurado da XGBT para a B20 foi treinado em 229,5 s, enquanto os metamodelos que utilizaram as técnicas RF, ANN e SVM demandaram 15.482, 20.253 e 42.238 s, respectivamente. De acordo com os resultados da etapa de treino, essa foi considerada a técnica de metamodelagem mais adequada para esse estudo, pois apresentou erros pequenos e curto tempo para treinamento e otimização, viabilizando uma busca extensiva dos hiperparâmetros ideais.

Após a otimização dos hiperparâmetros foram extraídos os metamodelos que exibiram a maior acurácia para cada técnica de metamodelagem e para cada uma das bases de dados (B20, B13 e B10). A Figura 27 exibe a acurácia desses metamodelos durante a etapa de teste, sendo que no eixo x estão as técnicas de metamodelagem e no eixo y foram representados os valores dos índices estatísticos MAE e RMSE. As cores identificam as bases de dados.

Da Figura 27, nota-se que o comportamento dos metamodelos durante a etapa de treino e teste se mantiveram, sendo que a XGBT gerou os modelos mais acurados, seguida por RF, SVM, ANN e MLR. Nota-se que para a maioria das técnicas de metamodelagem, os resultados das bases de B20 foram os mais acurados na etapa de teste. Ao comparar os resultados da XGBT, a qual exibe os menores erros, percebe-se que as diferenças entre erros dos metamodelos das B20, B13 e B10 são relativamente baixas. Enquanto o metamodelo em XGBT para a B20 alcançou MAE e RMSE respectivamente iguais a 1,7% e 2,5%, para a B10 esses índices foram iguais a 2,1% e 3,1%, respectivamente. Em relação à magnitude do PHFT, de 0 a 100%, os aumentos do MAE em 0,4% e do RMSE em 0,6% foram considerados insignificantes.

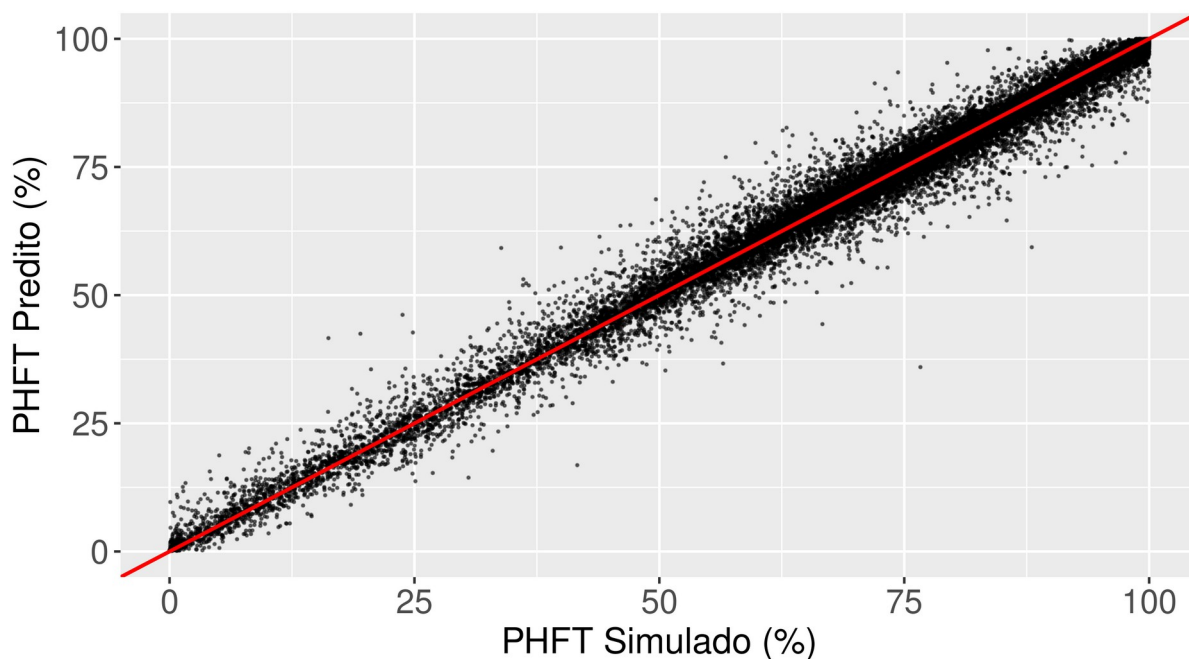
Figura 27 - Acurácia dos metamodelos mais acurados na etapa de teste.



A fim de evitar os parâmetros relacionados a geometria da UH e, conseqüentemente, facilitar o uso do metamodelo, o metamodelo final escolhido foi a XGBT, treinada com a B10, que considera apenas os 10 parâmetros de entrada mais relevantes para o PHFT. Assim, o metamodelo final correspondeu a uma XGBT com “eta”, “depth”, “ncols” e “ntrees” iguais a 0,3, 6, 0,8 e 600, respectivamente. Os parâmetros de entrada adotados foram: “dbt”, “blind”, “shgc”, “storey”, “abs_roof”, “abs_wall”, “wwr_dorm”, “shell_wall”, “shell_roof” e “open_factor”.

No gráfico da Figura 28 foram ilustrados os resultados obtidos a partir das predições da amostra de teste através do metamodelo final contra os resultados obtidos a partir das simulações. A reta diagonal vermelha representa a função $y = x$, *i.e.* quanto mais próximo um ponto está dessa reta, menor é o erro entre o valor predito e o valor simulado. O gráfico apresenta valores variando de 0 a 100% em ambos os eixos, pois o PHFT não permite valores fora desse intervalo.

Figura 28 - PHFT predito pelo metamodelo final contra PHFT simulado.



Corroborando com os resultados de MAE e RMSE, é possível perceber que houve uma concentração de pontos próximos da reta vermelha. Percebe-se ainda que há uma concentração maior de pontos na parte superior direita do gráfico, confirmando o alto desempenho da base de dados desenvolvida. A inspeção visual sugere ainda que os pontos apresentando maior PHFT tendem a apresentar erros maiores. Todavia, essa constatação não é preocupante, pois, como o PHFT dessas simulações é maior, o erro relativo acaba sendo menor.

5 CONCLUSÃO

A concepção do modelo parametrizável foi essencial para a elaboração de uma base de dados robusta, posteriormente utilizada para desenvolver o metamodelo propriamente dito. O modelo parametrizável foi concebido a partir de uma das quatro simplificações que reduziram o nível de descrição necessário para estimar, através do PHFT, o desempenho térmico de modelos iniciais. Duas edificações multifamiliares representativas do mercado nacional foram definidas como modelos iniciais, uma em “L” e outra em “H”. Essas tipologias foram simuladas com quatro envoltórias, que variaram de baixa à alta inércia térmica, nos climas de Curitiba, São Paulo, Rio de Janeiro, Sorriso e Teresina, totalizando 7.200 UHs distintas. As simplificações foram avaliadas através das Δ PHFT, que são as diferenças entre o PHFT das simplificações e o PHFT dos modelos iniciais. O MAE e o RMSE das Δ PHFT de cada simplificação foram estimados e utilizados como critério de decisão para escolher o modelo parametrizável mais acurado.

A análise estatística das Δ PHFT indicou que a S1 foi a mais acurada, com MAE e RMSE iguais a 1,4% e 1,8%. Porém, essa simplificação não foi adotada como modelo parametrizável, pois exige a modelagem de todos os ambientes do pavimento onde encontra-se a UH de interesse, demandando uma quantidade excessiva de parâmetros de entrada. Entre as simplificações que podem ser consideradas parametrizáveis, pois demandam um número menor de parâmetros para descrever a UH de interesse, a S4 foi a que apresentou as menores Δ PHFT, com MAE e RMSE iguais a 1,9% e 2,8%. A S3 foi a simplificação que exigiu menor nível de detalhamento e também foi a menos acurada, com MAE e RMSE iguais a 3,2% e 4,0%. Os resultados indicam que há uma troca justa entre o nível de detalhamento do modelo e as Δ PHFT, *i.e.* quanto menor o nível de detalhamento, maior as Δ PHFT.

Através das distribuições das Δ PHFT, notou-se que considerar as superfícies horizontais adiabáticas resultou em Δ PHFT próximas de zero, oscilando entre valores positivos e negativos. Já a consideração de paredes adiabáticas tendeu a gerar Δ PHFT negativas. O aumento do número de paredes consideradas adiabáticas aumentou a magnitude das Δ PHFT negativas. Assim, a S1 apresentou Δ PHFT concentradas em torno de zero, enquanto as S2 e S3 obtiveram distribuições consideravelmente deslocadas no sentido negativo de Δ PHFT. Como a S4 realiza trocas de calor entre pisos e coberturas, porém, possui paredes adiabáticas, a sua distribuição de Δ PHFT foi levemente deslocada no sentido negativo

de Δ PHFT, com pico próximo de zero.

Dentre os três tipos de pavimento estudados nos modelos iniciais e nas simplificações subsequentes, o pavimento de cobertura foi considerado o pavimento crítico, pois exibiu o pior desempenho térmico, com PHFT médio igual a 64,8%. Em contrapartida, esse também foi o pavimento que obteve a menor média dos valores absolutos de Δ PHFT, igual a 2,1%, contra 2,3% no pavimento intermediário e 2,4% no pavimento térreo. Apesar de o pavimento térreo exibir os maiores valores absolutos de Δ PHFT, esse foi o pavimento que obteve o melhor desempenho térmico, com PHFT médio igual a 77,6%. As análises garantem que a magnitude das Δ PHFT foi relativamente pequena, já que o pavimento com maior Δ PHFT também apresentou o maior PHFT médio, e vice-versa.

Além do pavimento e do clima onde encontra-se a UH, os componentes construtivos da envoltória também influenciaram a tendência das Δ PHFT. Notou-se que, em climas quentes, as envoltórias de alta inércia térmica apresentam Δ PHFT negativas de magnitude maior que as Δ PHFT das envoltórias de baixa inércia térmica, enquanto em climas frios observou-se o contrário. Nos climas do Rio de Janeiro, Sorriso e Teresina, as UHs cuja envoltória possui alta inércia térmica (tijolo maciço de 20 cm e concreto de 10 cm) obtiveram mediana das Δ PHFT igual a -1,4%, enquanto as UHs com envoltória de baixa inércia térmica (tijolo vazado e *steel frame*) apresentaram mediana das Δ PHFT igual a -0,5%. Nos climas de Curitiba e São Paulo, as Δ PHFT de UHs de baixa e de alta inércia térmica foram iguais a -0,2% e -0,6%, respectivamente. Assim, a comparação de modelos simplificados de alta e de baixa inércia térmica em climas quentes, favorece os modelos de baixa inércia térmica. Essa constatação é relevante, pois a nova proposta para a NBR 15.575 compara o modelo real com um modelo de referência, sendo que o modelo de referência possui envoltória em concreto. Ao comparar os resultados da simplificação com seus respectivos modelos iniciais, em climas quentes, o modelo de referência simplificado tende a apresentar uma redução no desempenho térmico mais acentuada que o modelo real simplificado. Logo, a adoção da simulação simplificada torna a comparação dos modelos real e de referência favorável ao modelo real.

Dentre as simplificações consideradas parametrizáveis (S2, S3 e S4), a S4 foi considerada a simplificação que apresentou os melhores resultados, pois apresentou os menores valores de MAE e RMSE e as menores Δ PHFT no pavimento de cobertura (crítico). Sendo assim, a S4 foi adotada como modelo parametrizável no desenvolvimento do metamodelo subsequente.

A fim de se aprofundar nas limitações das simplificações foram analisados casos considerados críticos, cuja ΔPHFT esteve entre limite mínimo e o 5º percentil ou entre o 95º percentil e o limite máximo encontrado na base de dados das simplificações. Os climas mais quentes da base de dados, Sorriso e Teresina, representaram 66,2% dos casos críticos, enquanto São Paulo não possui casos críticos. Dos casos críticos da S4, 87,3% pertencem à tipologia com formato em “L”, dos quais 85,5% possuem apenas uma fachada exposta, 71,8% estão localizados no pavimento térreo e 40,8% possuem envoltória em tijolo maciço de 20 cm.

A partir da análise do balanço de calor de quatro dos casos críticos foi comprovado que considerar as superfícies horizontais adiabáticas impede o fluxo de calor das regiões mais quentes, pavimentos superiores, para as regiões mais frias, pavimentos inferiores. Assim, as UHs dos pavimentos inferiores dos modelos simplificados aquecem menos que as UHs correspondentes simuladas através dos modelos iniciais. Já a consideração de paredes adiabáticas entre UHs impede o fluxo de calor da fachada norte dos edifícios, mais quente, para a fachada sul, menos quente. Os PHFTs médios das fachadas sul e norte dos modelos iniciais foram iguais a 55,2% e 62,1%, respectivamente, enquanto os PHFTs médios das fachadas sul e norte na S2 foram iguais a 49,5% e 59,5%, respectivamente. Os resultados indicam que, na média, a abstenção das trocas de calor entre as UHs acentua a diferença de temperatura entre as fachadas e, conseqüentemente, aumenta a diferença de PHFT entre elas. Em todos os casos as cargas internas foram responsáveis pelas maiores parcelas de ganho de calor da UH de interesse, enquanto a ventilação natural provou ser uma estratégia extremamente eficaz para retirar o excesso de calor dos ambientes. Essa estratégia contrabalanceou as diferenças entre as cargas térmicas dos modelos iniciais e seus respectivos modelos simplificados. Nos casos onde houve aumento de calor que entra na UH ou redução do calor que sai da UH, a ventilação natural aumentou a extração de calor dos ambientes. Já nos casos onde houve uma redução do calor que entra na UH ou aumento do calor que sai da UH, a ventilação reduziu a extração de calor dos ambientes.

A partir do modelo parametrizável foram geradas duas amostras através da sequência de baixa discrepância de Sobol, uma para treino e outra para teste. Todos os parâmetros amostrados apresentaram distribuição aproximadamente uniforme, com exceção da profundidade da sacada e da TBSm, que possuem concentrações de elementos da amostra em alguns valores devido, respectivamente, a restrições geométricas e climáticas impostas.

Aproximadamente 81% dos elementos das amostras de treino e de teste apresentou PHFT maior que 50%, sendo que 37% dos elementos apresentou PHFT de 70% a 90%, o que sugere que as soluções construtivas abordadas na base de dados possuem alto desempenho térmico, considerando a realidade climática brasileira. Uma investigação dos intervalos de temperatura operativa definidos na nova proposta para a NBR 15.575 concluiu que o PHFT é diretamente proporcional ao intervalo de TBSm. Os intervalos 1, 2 e 3, alcançaram PHFT médio iguais a 66,1%, 73,3% e 82,9%. Essa relação, apesar de contra intuitiva, pode ser explicada pelo benefício da ventilação natural em climas com TBSm elevada, sendo que essa provou ser uma estratégia eficaz na remoção de calor dos ambientes. Enquanto os climas mais quentes se prevalecem do uso da ventilação natural, os climas mais frios não possuem soluções passivas com alta capacidade de aquecer os ambientes.

Aplicada a análise de sensibilidade global de Sobol sobre a base de dados, foi possível identificar a influência que os parâmetros de entrada exercem sobre o parâmetro de saída, bem como a influência sobre os outros parâmetros de entrada. Um apanhado geral dos resultados aponta para a variável climática como fator mais importante para o desempenho térmico, seguido dos mecanismos de sombreamento, do pavimento onde localiza-se a UH de interesse, das propriedades térmica dos componentes construtivos, dos parâmetros relacionados à ventilação natural e, por fim, as propriedades geométricas da UH.

A TBSm foi o parâmetro de entrada que apresentou maior relevância para o PHFT, representando mais de 60% da soma dos efeitos totais de todos os parâmetros de entrada e superando o segundo parâmetro mais influente em 49,5%. A presença de venezianas nas janelas e o fator solar dos vidros foram, respectivamente, o segundo e o terceiro fator de maior importância para a estimar o PHFT, representando, juntos, 11,5% da soma dos efeitos totais. O resultado da sensibilidade dos mecanismos de sombreamento atenta à relevância desses mecanismos no controle do desempenho térmico em climas brasileiros. O quarto parâmetro de entrada mais influente foi o pavimento onde encontra-se a UH, que representou 4,9% da soma dos efeitos totais. Metade da influência que o pavimento exerce sobre o PHFT é direta, enquanto a outra metade é indireta. O efeito direto relaciona-se às condições de contorno dos pavimentos, que interagem de maneira diferente com o solo, com o ar externo e com a radiação solar. Já o efeito indireto diz respeito à influência dos outros parâmetros, como o clima e os componentes construtivos, sobre as interações da UH com o ambiente externo. Seguidos do pavimento, estão as absorvâncias solares da cobertura e das paredes

externas (“abs_roof” e “abs_wall”), o percentual de abertura das fachadas dos dormitórios (“wvr_dorm”), os componentes construtivos das paredes externas e da cobertura (“shell_wall” e “shell_roof”) e o fator de ventilação (“open_factor”). Juntas, “shell_wall” e “shell_roof” corresponderam à 12,4% da soma dos efeitos totais, entretanto, suas contribuições são majoritariamente indiretas, sendo que interagem com parâmetros como “dbt”, “storey”, entre outros. Já a “abs_roof” e “abs_wall” representaram 8,1% da soma dos efeitos totais, sendo que a “abs_roof” foi a mais importante das duas, devido à maior exposição da cobertura à radiação solar, quando comparada à exposição das paredes. A importância do “wvr_dorm” para o PHFT foi equivalente a 3,1% da soma dos efeitos totais, valor que difere significativamente da importância do “wvr_liv”, que representou apenas 0,2% da soma dos efeitos totais. Uma justificativa para essa disparidade é a exposição das janelas da sala ao sol, permitindo que os mecanismos de sombreamento inibam a sua influência sobre o PHFT. O “open_factor” obteve efeito total equivalente a 1,7% da soma dos efeitos totais, sendo que 76,2% do seu efeito total correspondeu ao efeito de primeira ordem. Visto que esse parâmetro está intrinsicamente ligado à ventilação natural, nota-se que há uma interação de ordens superiores entre o “open_factor” e parâmetros como a TBSm e o percentual de abertura das fachadas. A influência do fator de ventilação sobre o PHFT tende a ser maior em climas mais quentes, que exigem o uso da ventilação natural, e em ambientes com alto percentual de abertura das fachadas, que permitem trocas de ar mais intensas. Os parâmetros referentes às propriedades geométricas, à profundidade da sacada e à transmitância térmica dos vidros, nessa ordem, foram os parâmetros menos influentes para o PHFT, correspondendo, juntos, a apenas 5,6% da soma dos efeitos totais.

Dos resultados da análise de sensibilidade foram definidos dois critérios para a seleção de parâmetros de entrada. O primeiro critério excluiu da base de dados os parâmetros com efeito total menor ou igual a 0,02, que corresponde à apenas 1,6% das somas dos efeitos totais, logo, esse critério excluiu os 10 parâmetros menos influentes. O segundo critério removeu da base de dados os parâmetros com efeito total menor ou igual a 0,01, logo, os 7 parâmetros menos influentes foram excluídos. O critério de sensibilidade total igual a 0,02 removeu da base de dados todos os parâmetros geométricos, o que facilita o uso do metamodelo. É importante ressaltar que o metamodelo responde melhor para os casos presentes na amostra de treino, assim, deve-se evitar o seu uso para prever o desempenho térmico de casos nunca vistos. A partir desses critérios foram definidas três amostras que foram utilizadas no

treinamento dos metamodelos subsequente. As amostras diferem entre si na quantidade de parâmetros de entrada considerados, como segue: a) B20 considera todos os 20 parâmetros de entrada; b) B13 considera os 13 parâmetros mais influentes, e; c) B10 considera os 10 parâmetros mais influentes.

No pré-processamento de dados, os sete parâmetros qualitativos foram transformados em 23 variáveis lógicas, que representaram todos os possíveis valores desses parâmetros. Já os 13 parâmetros de entrada restantes foram centralizados e normalizados. Como as amostras foram geradas através da técnica de amostragem de Sobol, suas distribuições se mantiveram uniforme, entretanto, após processados, os valores dos parâmetros de entrada qualitativos variaram entre 0 ou 1, enquanto os parâmetros de entrada quantitativos variaram de - 2 a + 2.

Dentre as cinco técnicas de metamodelagem avaliadas, a MLR foi a que exibiu os maiores erros na etapa de treino, com MAE e RMSE iguais a 15,2% e 18,8%, respectivamente. Como essa técnica apresentou os mesmos erros para B20, B13 e B10, conclui-se que a MLR foi incapaz de captar a influência dos parâmetros de entrada menos importantes. A técnica ANN foi a segunda menos acurada durante a etapa de treino, pois apresentou MAE e RMSE medianos respectivamente iguais a 6,0% e 7,9% para a B20. Assim como a MLR, a ANN foi pouco sensível aos parâmetros de entrada menos relevantes para o PHFT, já que apresentou erros para a B20, B13 e B10 relativamente próximos. O processo de otimização da ANN não gerou variações consideráveis nos erros, o que aponta para uma limitação do modelo “brnn” do pacote Caret, que permite configurar apenas um hiperparâmetro, o número de neurônios na camada escondida. O processo de otimização da SVM resultou em valores medianos de MAE e RMSE respectivamente iguais a 4,4% e 6,4% para a B20, sendo esse o terceiro modelo menos acurado. As altas variações do MAE e do RMSE entre os metamodelos gerados a partir de B20, B13 e B10 indicam que a SVM se ateu ao comportamento dos parâmetros de entrada menos importantes. Além disso, foi constatado que o peso da função custo alterou a performance do modelo significativamente, sendo assim, a sua otimização é extremamente importante para atingir resultados acurados através dessa técnica.

Os modelos baseados em árvores foram os mais acurados na etapa de treino, sendo que a RF alcançou valores medianos de MAE e RMSE iguais a 2,2% e 3,5%, respectivamente, enquanto a XGBT atingiu valores medianos de MAE e RMSE iguais a 2,1% e 3,2%. Constatou-se a necessidade de se otimizar o hiperparâmetro “mtry” da RF para torná-

la competitiva, já que o valor sugerido pelo pacote Caret apresentou erros significativamente altos em todas as bases de dados. O oposto foi concluído para a XGBT, que, ao adotar os valores sugeridos pelo Caret apresentou performance satisfatória. A otimização da XGBT demandou baixo custo computacional em comparação com as outras técnicas, sendo assim, a otimização da XGBT é aconselhada, já que há uma redução dos erros em troca de uma baixa demanda computacional.

Os resultados da etapa de teste mantiveram o comportamento da etapa de treino, sendo que a XGBT gerou os metamodelos mais acurados, seguida por RF, SVM, ANN e MLR. A técnica XGBT treinada com a B20 apresentou MAE e RMSE na etapa de teste respectivamente iguais a 1,7% e 2,5%. Em geral, a acurácia dos metamodelos na etapa de teste reduziu na medida em que foram retirados os parâmetros de entrada menos influentes para o PHFT. Todavia, a diferença entre o MAE e o RMSE dos modelos em XGBT para a B20 e a B10 foram iguais a 0,4% e 0,6%, respectivamente, o que foi considerado relativamente baixo.

A fim de evitar os parâmetros de entrada relacionados a geometria da UH e, conseqüentemente, facilitar o uso do metamodelo, o metamodelo final correspondeu a uma XGBT com os 10 parâmetros de entrada mais relevantes para o PHFT. Os valores de MAE e RMSE do metamodelo final na etapa de teste foram iguais a 2,1% e 3,1%, respectivamente. Os valores otimizados dos hiperparâmetros “eta”, “depth”, “ncols” e “ntrees” foram iguais a 0,3, 6, 0,8 e 600, respectivamente.

5.1 LIMITAÇÕES

Durante o desenvolvimento desse estudo foram encontradas as seguintes limitações:

- Os balanços térmicos da base de dados das simplificações foram realizados a partir de valores agregados anuais que, eventualmente, omitem oscilações de comportamento sazonais, mensais e diárias;
- O modelo parametrizável, definido a partir da S4, tende a favorecer o desempenho térmico de UHs de baixa inércia térmica. Visto que o modelo de referência da nova proposta para a NBR 15.575 possui alta inércia térmica, seu desempenho pode ser subavaliado, fazendo com que as edificações de baixa inércia térmica sejam favorecidas no processo de avaliação da proposta de norma;

- Os efeitos de primeira ordem e total, estimados através da análise de sensibilidade de Sobol, descrevem a interação global dos parâmetros de entrada entre si e com o parâmetro de saída, porém, esses índices não detalham ou quantificam as interações dos parâmetros de entrada com cada um dos outros parâmetros;
- As amostras foram desenvolvidas utilizando apenas quatro tipologias de UH, que contém dois dormitórios e uma sala e cozinha conjugadas, portanto, a alta acurácia do metamodelo se limita a essas tipologias;
- O parâmetro TBSm das amostras apresenta baixa diversidade no intervalo de 10,83°C a 15°C, sendo que apenas quatro arquivos climáticos, com TBSm iguais a 10,83°C, 13,60°C, 13,64°C e 13,80°C, foram utilizados para representar esse intervalo. Para esses valores de TBSm o metamodelo deve responder de forma acurada, entretanto, para outros valores de TBSm dentro desse intervalo as previsões podem ficar comprometidas;
- Apesar de o metamodelo utilizar as premissas da nova proposta para a NBR 15.575 para realizar as previsões do PHFT, ele não é capaz de classificar o nível de desempenho da UH, pois a proposta de norma exige que, além do PHFT, sejam calculadas as temperaturas operativas mínima e máxima e as cargas térmicas de aquecimento e refrigeração da UH durante o ano de simulação.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

De acordo com os resultados e conclusões desse estudo, os seguintes tópicos são sugeridos para trabalhos futuros:

- Analisar do comportamento das simplificações ao longo do dia, considerando o fluxo de calor, a variação da temperatura das superfícies e as trocas de ar nos ambientes, que são extremamente importantes para os modelos, já que a climatização das edificações se dá, exclusivamente, através da ventilação natural;
- Levantar tipologias e componentes construtivos de edificações multifamiliares brasileiras, a fim de encontrar padrões representativos de outros níveis de renda e regiões do país, assim, o metamodelo torna-se mais abrangente e mantém-se acurado;
- Caracterizar a geometria das UHs através de parâmetros de entrada mais generalista, a fim de evitar o uso de um catálogo de tipologias que limita o alcance do metamodelo;

- Adicionar aos parâmetros de entrada do metamodelo a velocidade e a direção do vento, já que essas variáveis influenciam diretamente a ventilação natural e esse mecanismo se provou eficaz no controle do desempenho térmico de edificações residenciais multifamiliares;
- Desenvolver arquivos climáticos de cidades brasileiras que apresentam TBSm entre 10,83°C e 15°C, para, posteriormente, adicioná-los na etapa de treinamento dos metamodelos e garantir que essa faixa de TBSm também apresentará resultados acurados;
- Investigar os efeitos de segunda ordem dos parâmetros da base de dados, *i.e.* quantificar a interação que os parâmetros de entrada exercem sobre cada um dos outros parâmetros e o efeito que essas interações geram no PHFT;
- Estender o desenvolvimento dos metamodelos para predizer as temperaturas operativas mínima e máxima, bem como as cargas térmicas de aquecimento e resfriamento. Assim, será possível classificar o nível de desempenho térmico da UH de acordo com a nova proposta para a NBR.

REFERÊNCIA BIBLIOGRÁFICA

- AHMAD, A. S. et al. A review on applications of ANN and SVM for building electrical energy consumption forecasting. **Renewable and Sustainable Energy Reviews**, v. 33, p. 102-109, 2014.
- ALLARD, Francis; GHIAUS, Cristian (Ed.). **Natural ventilation in the urban environment: assessment and design**. Routledge, 2012.
- AMARI, Shun-ichi. Backpropagation and stochastic gradient descent method. **Neurocomputing**, v. 5, n. 4-5, p. 185-196, 1993.
- AMASYALI, Kadir; EL-GOHARY, Nora M. A review of data-driven building energy consumption prediction studies. **Renewable and Sustainable Energy Reviews**, v. 81, p. 1192-1205, 2018.
- AMERICAN SOCIETY OF HEATING, REFRIGERATING AND AIR-CONDITIONING ENGINEERS – ASHRAE. **ANSI/ASHRAE 90.1-2019: Energy Standard for Buildings Except Low-Rise Residential Buildings**. 2019.
- AMIRI, Shideh Shams; MOTTAHEDI, Mohammad; ASADI, Somayeh. Using multiple regression analysis to develop energy consumption indicators for commercial buildings in the US. **Energy and Buildings**, v. 109, p. 209-216, 2015.
- ASADI, Ehsan et al. Multi-objective optimization for building retrofit: A model using genetic algorithm and artificial neural network and an application. **Energy and Buildings**, v. 81, p. 444-456, 2014.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 15220: Desempenho Térmico de Edificações**. 2005.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS – ABNT. **NBR 15575: Edificações Habitacionais - Desempenho**. 2013.
- AWAD, Mariette; KHANNA, Rahul. Support vector regression. In: **Efficient learning machines**. Apress, Berkeley, CA, 2015. p. 67-80.

BAKAR, Nur Najihah Abu et al. Energy efficiency index as an indicator for measuring building energy performance: A review. **Renewable and Sustainable Energy Reviews**, v. 44, p. 1-11, 2015.

BOTTOU, Léon. Large-scale machine learning with stochastic gradient descent. **Proceedings of COMPSTAT'2010**. Physica-Verlag HD, 2010. p. 177-186.

BOURDEAU, Mathieu et al. Modeling and forecasting building energy consumption: A review of data-driven techniques. **Sustainable Cities and Society**, v. 48, p. 101533, 2019.

BRAGER, Gail; DE DEAR, Richard. A standard for natural ventilation. **ASHRAE Journal**, 2000.

BREIMAN, Leo. Random forests. **Machine learning**, v. 45, n. 1, p. 5-32, 2001.

BUNTINE, Wray. Learning classification trees. **Statistics and computing**, v. 2, n. 2, p. 63-73, 1992.

CAMPOLONGO, Francesca; CARIBONI, Jessica; SALTELLI, Andrea. An effective screening design for sensitivity analysis of large models. **Environmental modelling & software**, v. 22, n. 10, p. 1509-1518, 2007.

CENTRO BRASILEIRO DE EFICIÊNCIA ENERGÉTICA EM EDIFICAÇÕES – CB3E. **Proposta de Instrução Normativa do Inmetro para a Classe de Eficiência Energética de Edificações Comerciais**. 2017.

CENTRO BRASILEIRO DE EFICIÊNCIA ENERGÉTICA EM EDIFICAÇÕES – CB3E. **Proposta de Instrução Normativa do Inmetro para a Classe de Eficiência Energética de Edificações Residenciais**. 2018.

CHALAL, Moulay Larbi et al. Energy planning and forecasting approaches for supporting physical improvement strategies in the building sector: A review. **Renewable and Sustainable Energy Reviews**, v. 64, p. 761-776, 2016.

CHANG, Anna; THOMAS, Stephen; LU, Yang. **Energy Efficient HVAC Design in Residential Buildings**. 2017.

CHEN, Tianqi; GUESTRIN, Carlos. Xgboost: A scalable tree boosting system. In: **Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining**. 2016. p. 785-794.

CHENG, Jian; DRUZDZEL, Marek J. Computational investigation of low-discrepancy sequences in simulation algorithms for Bayesian networks. **arXiv preprint arXiv:1301.3841**, 2013.

CHLELA, Fadi et al. A new methodology for the design of low energy buildings. **Energy and Buildings**, v. 41, n. 9, p. 982-990, 2009.

CHOU, Jui-Sheng; BUI, Dac-Khuong. Modeling heating and cooling loads by artificial intelligence for energy-efficient building design. **Energy and Buildings**, v. 82, p. 437-446, 2014.

CHUA, K. J. et al. Achieving better energy-efficient air conditioning—a review of technologies and strategies. **Applied Energy**, v. 104, p. 87-104, 2013.

CLIMATE ONE BUILDING ORG. – COB. Disponível em: <http://climate.onebuilding.org/WMO_Region_3_South_America/BRA_Brazil/index.html>. Acessado em: julho de 2019. 2019.

CRAWLEY, Drury B. et al. Contrasting the capabilities of building energy performance simulation programs. **Building and environment**, v. 43, n. 4, p. 661-673, 2008.

DE'ATH, Glenn; FABRICIUS, Katharina E. Classification and regression trees: a powerful yet simple technique for ecological data analysis. **Ecology**, v. 81, n. 11, p. 3178-3192, 2000.

DEB, Chirag et al. A review on time series forecasting techniques for building energy consumption. **Renewable and Sustainable Energy Reviews**, v. 74, p. 902-924, 2017.

DEPARTMENT OF ECONOMIC AND SOCIAL AFFAIRS – DESA. **The impact of population momentum on future population growth**. 2017.

DRAPER, Norman R.; SMITH, Harry. **Applied regression analysis**. John Wiley & Sons, 1998.

EISENHOWER, Bryan et al. A methodology for meta-model based optimization in building energy models. **Energy and Buildings**, v. 47, p. 292-301, 2012.

EKICI, Betul Bektas; AKSOY, U. Teoman. Prediction of building energy consumption by using artificial neural networks. **Advances in Engineering Software**, v. 40, n. 5, p. 356-362, 2009.

ELITH, Jane; LEATHWICK, John R.; HASTIE, Trevor. A working guide to boosted regression trees. **Journal of Animal Ecology**, v. 77, n. 4, p. 802-813, 2008.

EMPRESA DE PESQUISA ENERGÉTICA – EPE. **Balço Energético Nacional 2019: ano base 2018**. 2019.

EMPRESA DE PESQUISA ENERGÉTICA – EPE. **Demanda de Energia 2050: Nota Técnica DEA 13/15**. 2016.

ENERGY INFORMATION ADMINISTRATION – EIA. **International Energy Outlook**. 2017.

ENERGYPLUS. Disponível em: <<https://energyplus.net/>>. Acessado em: janeiro de 2020. 2020.

ENERGYPLUS. **Engineering Reference**. 2019b.

ENERGYPLUS. **Input Output Reference**. 2019a.

ETHERIDGE, David W.; SANDBERG, Mats. **Building ventilation: theory and measurement**. John Wiley & Sons, 1996.

FAN, Junliang et al. Comparison of Support Vector Machine and Extreme Gradient Boosting for predicting daily global solar radiation using temperature and precipitation in humid subtropical climates: A case study in China. **Energy Conversion and Management**, v. 164, p. 102-111, 2018.

FANGER, Poul O. et al. Thermal comfort. Analysis and applications in environmental engineering. **Thermal comfort. Analysis and applications in environmental engineering**. 1970.

FEURER, Matthias et al. Efficient and robust automated machine learning. In: **Advances in neural information processing systems**. 2015. p. 2962-2970.

FOSSATI, Michele et al. Building energy efficiency: An overview of the Brazilian residential labeling scheme. **Renewable and Sustainable Energy Reviews**, v. 65, p. 1216-1231, 2016.

FOUCQUIER, Aurélie et al. State of the art in building modelling and energy performances prediction: A review. **Renewable and Sustainable Energy Reviews**, v. 23, p. 272-288, 2013.

- FOUNTAIN, Marc; BRAGER, Gail; DE DEAR, Richard. Expectations of indoor climate control. **Energy and Buildings**, v. 24, n. 3, p. 179-182, 1996.
- FRIEDMAN, Jerome H. Greedy function approximation: a gradient boosting machine. **Annals of statistics**, p. 1189-1232, 2001.
- FRIEDMAN, Jerome H. Stochastic gradient boosting. **Computational statistics & data analysis**, v. 38, n. 4, p. 367-378, 2002.
- FRIEDMAN, Jerome; HASTIE, Trevor; TIBSHIRANI, Robert. **The elements of statistical learning**. New York: Springer series in statistics, 2001.
- GIROSI, Federico; JONES, Michael; POGGIO, Tomaso. Regularization theory and neural networks architectures. **Neural computation**, v. 7, n. 2, p. 219-269, 1995.
- GIVONI, Baruch. Indoor temperature reduction by passive cooling systems. **Solar Energy**, v. 85, n. 8, p. 1692-1726, 2011.
- GOLUB, Gene H.; HEATH, Michael; WAHBA, Grace. Generalized cross-validation as a method for choosing a good ridge parameter. **Technometrics**, v. 21, n. 2, p. 215-223, 1979.
- GOLUB, Gene H.; VON MATT, Urs. Generalized cross-validation for large-scale problems. **Journal of Computational and Graphical Statistics**, v. 6, n. 1, p. 1-34, 1997.
- GONG, Mingju et al. Gradient boosting machine for predicting return temperature of district heating system: A case study for residential buildings in Tianjin. **Journal of Building Engineering**, v. 27, p. 100950, 2020.
- HAASE, M.; AMATO, A. An investigation of the potential for natural ventilation and building orientation to achieve thermal comfort in warm and humid climates. **Solar energy**, v. 83, n. 3, p. 389-399, 2009.
- HADJIPASCHALIS, Ioannis; POULLIKKAS, Andreas; EFTHIMIOU, Venizelos. Overview of current and future energy storage technologies for electric power applications. **Renewable and sustainable energy reviews**, v. 13, n. 6-7, p. 1513-1522, 2009.
- HAGAN, Martin T. et al. **Neural network design**. Boston: Pws Pub., 1996.
- HALL, Mark A. Correlation-based feature selection of discrete and numeric class machine learning. 2000.

HOMMA, Toshimitsu; SALTELLI, Andrea. Importance measures in global sensitivity analysis of nonlinear models. **Reliability Engineering & System Safety**, v. 52, n. 1, p. 1-17, 1996.

INSTITUTO NACIONAL DE METROLOGIA, NORMALIZAÇÃO E QUALIDADE INDUSTRIAL – INMETRO. Portaria nº 18, de 16 de janeiro de 2012. **Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas**. 2012.

INSTITUTO NACIONAL DE METROLOGIA, NORMALIZAÇÃO E QUALIDADE INDUSTRIAL – INMETRO. Portaria nº 18, de 16 de janeiro de 2012. **Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Residenciais**. 2012.

INSTITUTO NACIONAL DE METROLOGIA, NORMALIZAÇÃO E QUALIDADE INDUSTRIAL – INMETRO. Portaria nº 372, de 17 de setembro de 2010. **Regulamento Técnico da Qualidade para o Nível de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas**. 2010.

INTERNATIONAL ENERGY AGENCY – IEA. **Future of Cooling**. 2018c.

INTERNATIONAL ENERGY AGENCY – IEA. **Global Status Report**. 2017.

INTERNATIONAL ENERGY AGENCY – IEA. **Global Status Report**. 2018b.

INTERNATIONAL ENERGY AGENCY – IEA. **World Energy Outlook**. 2018a.

JANDA, Kathryn B. Buildings don't use energy: people do. **Architectural science review**, v. 54, n. 1, p. 15-22, 2011.

KAMEL, Ehsan; SHEIKH, Shaya; HUANG, Xueqing. Data-driven predictive models for residential building energy use based on the segregation of heating and cooling days. **Energy**, v. 206, p. 118045, 2020.

KAYNAKLI, Omer. A review of the economical and optimum thermal insulation thickness for building applications. **Renewable and Sustainable Energy Reviews**, v. 16, n. 1, p. 415-425, 2012.

KIM, Eui-Jong et al. Urban energy simulation: Simplification and reduction of building envelope models. **Energy and Buildings**, v. 84, p. 193-202, 2014.

KIMURA, Shuhei; MATSUMURA, Koki. Genetic algorithms using low-discrepancy sequences. In: **Proceedings of the 7th annual conference on Genetic and evolutionary computation**. 2005. p. 1341-1346.

KOLOKOTRONI, M.; ARONIS, Aj. Cooling-energy reduction in air-conditioned offices by using night ventilation. **Applied energy**, v. 63, n. 4, p. 241-253, 1999.

KUHN, Max; JOHNSON, Kjell. **Applied predictive modeling**. New York: Springer, 2013.

KUMBAROĞLU, Gürkan; MADLENER, Reinhard. Evaluation of economically optimal retrofit investment options for energy savings in buildings. **Energy and Buildings**, v. 49, p. 327-334, 2012.

LABORATÓRIO DE EDIFICÊNCIA ENERGÉTICA EM EDIFICAÇÕES DA UNIVERSIDADE FEDERAL DE SANTA CATARINA – LABEEE. **Proposta para a Norma de Desempenho de Edificações Habitacionais (NBR 15.575)**. Disponível em: <<https://labeee.ufsc.br/NBR15575-2020>>. Acessado em: dezembro de 2020. 2020.

LECUN, Yann A. et al. Efficient backprop. **Neural networks: Tricks of the trade**. Springer, Berlin, Heidelberg, 2012. p. 9-48.

Lei nº 10.295, de 17 de outubro de 2001. **Dispõe sobre a Política Nacional de Conservação e Uso Racional de Energia e dá outras providências**. Brasília, DF.

Lei nº 9.991, de 24 de julho de 2000. **Dispõe sobre realização de investimentos em pesquisa e desenvolvimento e em eficiência energética por parte das empresas concessionárias, permissionárias e autorizadas do setor de energia elétrica, e dá outras providências**. Brasília, DF.

LEVER, Jake; KRZYWINSKI, Martin; ALTMAN, Naomi. Points of significance: model selection and overfitting. 2016.

LI, Xiwang; WEN, Jin. Review of building energy modeling for control and operation. **Renewable and Sustainable Energy Reviews**, v. 37, p. 517-537, 2014.

LOH, Wei-Yin. Classification and regression trees. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 1, n. 1, p. 14-23, 2011.

LU, Hongfang et al. Short-term prediction of building energy consumption employing an improved extreme gradient boosting model: A case study of an intake tower. **Energy**, p. 117756, 2020.

MAGNIER, Laurent; HAGHIGHAT, Fariborz. Multiobjective optimization of building design using TRNSYS simulations, genetic algorithm, and Artificial Neural Network. **Building and Environment**, v. 45, n. 3, p. 739-746, 2010.

MAHDAVI, Ardeshir; KUMAR, Satish. Implications of indoor climate control for comfort, energy and environment. **Energy and Buildings**, v. 24, n. 3, p. 167-177, 1996.

MALIK, Jasdeep Singh; GOYAL, Prachi; SHARMA, Akhilesh K. A comprehensive approach towards data preprocessing techniques & association rules. In: **Proceedings of The4th National Conference**. 2010.

MARA, Thierry A.; TARANTOLA, Stefano. Application of global sensitivity analysis of model output to building thermal simulations. **Building Simulation**. Tsinghua Press, p. 290-302, 2008.

MATHEW, Paul A. et al. Big-data for building energy performance: Lessons from assembling a very large national database of building energy use. **Applied Energy**, v. 140, p. 85-93, 2015.

MAZZAFERRO, Leonardo et al. Desenvolvimento do metamodelo para a etiquetagem de edificações residenciais. **XVII Encontro Nacional de Tecnologia do Ambiente Construído, ENTAC**, 2018.

MAZZAFERRO, Leonardo. Metodologia para predição da carga térmica de refrigeração de edificações de escritórios em múltiplos climas brasileiros a partir de uma abordagem combinada de amostragens incrementais e redes neurais artificiais. 2021.

MCQUISTON, Faye C.; PARKER, Jerald D.; SPITLER, Jeffrey D. **Heating, ventilating, and air conditioning: analysis and design**. John Wiley & Sons, 2004.

MOHD NAWI, Nazri; ATOMIA, Walid Hasen; REHMAN, Mohammad Zubair. The effect of data pre-processing on optimized training of artificial neural networks. 2013.

MONTES, María Andrea Triana et al. Abordagem integrada no ciclo de vida de habitação de interesse social considerando mudanças climáticas. 2016.

MOROKOFF, William J.; CAFLISCH, Russel E. Quasi-random sequences and their discrepancies. **SIAM Journal on Scientific Computing**, v. 15, n. 6, p. 1251-1279, 1994.

NAJI, Sareh et al. Estimating building energy consumption using extreme learning machine method. **Energy**, v. 97, p. 506-516, 2016.

NEVES, Leticia de Oliveira; RORIZ, Maurício. Procedimentos estimativos do potencial de uso de chaminés solares para promover a ventilação natural em edificações de baixa altura. **Ambiente Construído**, v. 12, n. 1, p. 177-192, 2012.

ØSTERGÅRD, Torben; JENSEN, Rasmus L.; MAAGAARD, Steffen E. Early Building Design: Informed decision-making by exploring multidimensional design space using sensitivity analysis. **Energy and Buildings**, v. 142, p. 8-22, 2017.

ØSTERGÅRD, Torben; JENSEN, Rasmus Lund; MAAGAARD, Steffen Enersen. A comparison of six metamodeling techniques applied to building performance simulations. **Applied Energy**, v. 211, p. 89-103, 2018.

PAPADOPOULOS, Sokratis et al. Evaluation of tree-based ensemble learning algorithms for building energy performance estimation. **Journal of Building Performance Simulation**, v. 11, n. 3, p. 322-332, 2018.

PAPADOPOULOS, Sokratis; KONTOKOSTA, Constantine E. Grading buildings on energy performance using city benchmarking data. **Applied Energy**, v. 233, p. 244-253, 2019.

PEREIRA, Cláudia Donald. A influência do envelope no desempenho térmico de edificações residenciais unifamiliares ocupadas e ventiladas naturalmente. 2009.

POLINE, Jean-Baptiste et al. Imaging genetics: bio-informatics and bio-statistics challenges. **Proceedings of COMPSTAT'2010**. Physica-Verlag HD, 2010. p. 101-110.

QUINLAN, J.. Ross . Induction of decision trees. **Machine learning**, v. 1, n. 1, p. 81-106, 1986.

REZENDE, Danilo Jimenez; MOHAMED, Shakir; WIERSTRA, Daan. Stochastic backpropagation and approximate inference in deep generative models. **arXiv preprint arXiv:1401.4082**, 2014.

RONCHETTI, Elvezio; FIELD, Christopher; BLANCHARD, Wade. Robust linear model selection by cross-validation. **Journal of the American Statistical Association**, v. 92, n. 439, p. 1017-1023, 1997.

RYAN, Emily M.; SANQUIST, Thomas F. Validation of building energy modeling tools under idealized and realistic conditions. **Energy and Buildings**, v. 47, p. 375-382, 2012.

SADINENI, Suresh B.; MADALA, Srikanth; BOEHM, Robert F. Passive building energy savings: A review of building envelope components. **Renewable and sustainable energy reviews**, v. 15, n. 8, p. 3617-3631, 2011.

SALTELLI, Andrea et al. (Ed.). **Sensitivity analysis**. New York: Wiley, 2000.

SALTELLI, Andrea; TARANTOLA, Stefano; CAMPOLONGO, Francesca. Sensitivity analysis as an ingredient of modeling. **Statistical Science**, v. 15, n. 4, p. 377-395, 2000.

SCHULZE, Tobias; EICKER, Ursula. Controlled natural ventilation for energy efficient buildings. **Energy and Buildings**, v. 56, p. 221-232, 2013.

SILVA, Arthur Santos et al. Desenvolvimento de um método para avaliação do desempenho térmico e energético de edificações aplicando análise de incertezas e sensibilidade. 2016.

SILVA, Arthur Santos; GHISI, Enedir. Análise comparativa dos resultados do desempenho térmico da envoltória de uma edificação residencial pelos métodos de simulação do RTQ-R e da NBR 15575-1. **Ambiente Construído**, v. 14, n. 1, p. 215-230, 2013.

SILVER, Nate. **The signal and the noise: why so many predictions fail - but some don't**. Penguin, 2012.

SNOEK, Jasper; LAROCHELLE, Hugo; ADAMS, Ryan P. Practical bayesian optimization of machine learning algorithms. In: **Advances in neural information processing systems**. 2012. p. 2951-2959.

SOBOL', Il'ya Meerovich. On sensitivity estimation for nonlinear mathematical models. **Matematicheskoe modelirovanie**, v. 2, n. 1, p. 112-118, 1990.

SRIVASTAVA, Nitish et al. Dropout: a simple way to prevent neural networks from overfitting. **The Journal of Machine Learning Research**, v. 15, n. 1, p. 1929-1958, 2014.

SUITS, Daniel B. Use of dummy variables in regression equations. **Journal of the American Statistical Association**, v. 52, n. 280, p. 548-551, 1957.

TIAN, Wei. A review of sensitivity analysis methods in building energy analysis. **Renewable and Sustainable Energy Reviews**, v. 20, p. 411-419, 2013.

TOUZANI, Samir; GRANDERSON, Jessica; FERNANDES, Samuel. Gradient boosting machine for modeling the energy consumption of commercial buildings. **Energy and Buildings**, v. 158, p. 1533-1543, 2018.

U. S. DEPARTMENT OF ENERGY – DOE. Disponível em: <<https://www.energy.gov/eere/buildings/about-building-energy-modeling/>>. Acessado em: novembro de 2019. 2019a.

U. S. DEPARTMENT OF ENERGY – DOE. Disponível em: <<https://www.energy.gov/eere/buildings/downloads/energyplus-0>>. Acessado em: novembro de 2019. 2019b.

VAN DER KNAAP, A. N. Building performance simulation to support building energy regulation. **Eindhoven University of Technology**, 2011.

VAPNIK, Vladimir Naumovich. An overview of statistical learning theory. **IEEE transactions on neural networks**, v. 10, n. 5, p. 988-999, 1999.

VEHTARI, Aki; GELMAN, Andrew; GABRY, Jonah. Practical Bayesian model evaluation using leave-one-out cross-validation and WAIC. **Statistics and Computing**, v. 27, n. 5, p. 1413-1432, 2017.

VERSAGE, Rogério de Souza. Metamodelo para estimar a carga térmica de edificações condicionadas artificialmente. 2015.

WANG, Liping; NYUK, Hien Wong; LI, Shuo. Facade design optimization for naturally ventilated residential buildings in Singapore. **Energy and Buildings**, v. 39, n. 8, p. 954-961, 2007.

WANG, Ran; LU, Shilei; LI, Qiaoping. Multi-criteria comprehensive study on predictive algorithm of hourly heating energy consumption for residential buildings. **Sustainable Cities and Society**, v. 49, p. 101623, 2019.

WANG, Zeyu; SRINIVASAN, Ravi S. A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models. **Renewable and Sustainable Energy Reviews**, v. 75, p. 796-808, 2017.

WEBER, Fernando da Silva et al. Desenvolvimento de um modelo equivalente de avaliação de propriedades térmicas para a elaboração de uma biblioteca de componentes construtivos brasileiros para uso no programa EnergyPlus. 2018.

WEI, Yixuan et al. A review of data-driven approaches for prediction and classification of building energy consumption. **Renewable and Sustainable Energy Reviews**, v. 82, p. 1027-1047, 2018.

YU, Lei; LIU, Huan. Efficient feature selection via analysis of relevance and redundancy. **Journal of machine learning research**, v. 5, n. Oct, p. 1205-1224, 2004.

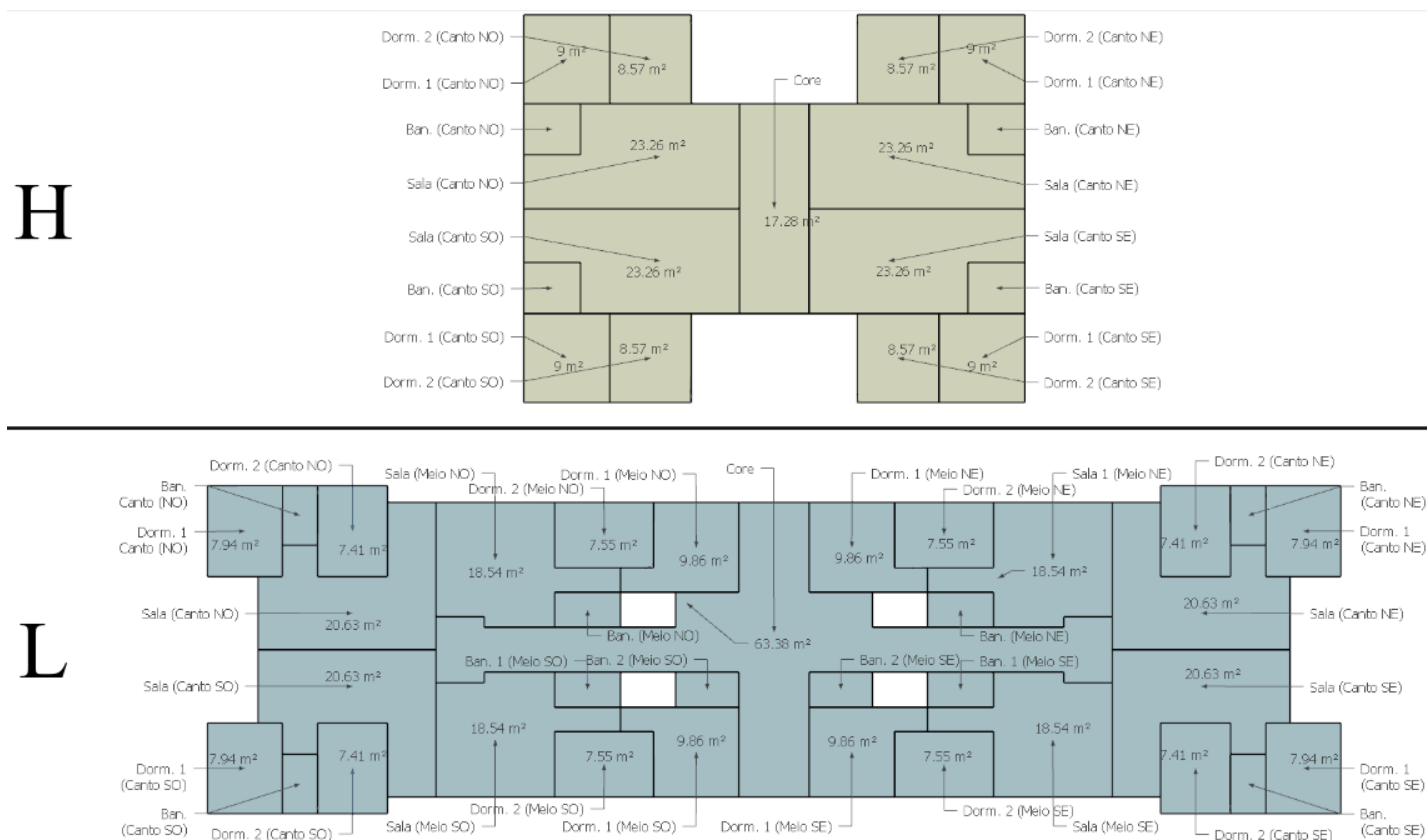
YU, Wei et al. Application of multi-objective genetic algorithm to optimize energy efficiency and thermal comfort in building design. **Energy and Buildings**, v. 88, p. 135-143, 2015.

ZEILER, Matthew D. ADADELTA: an adaptive learning rate method. **arXiv preprint arXiv:1212.5701**, 2012.

ZHAO, Hai-xiang; MAGOULÈS, Frédéric. A review on the prediction of building energy consumption. **Renewable and Sustainable Energy Reviews**, v. 16, n. 6, p. 3586-3592, 2012.

APÊNDICE A

Este apêndice visa retratar os pavimentos tipos dos modelos iniciais adotados no desenvolvimento do modelo parametrizável. As plantas em “H” e em “L” da figura apresentada neste apêndice identificam as disposições dos cômodos no pavimento, bem como sua ocupação e área. Nas plantas, as abreviaturas dorm. e ban. indicam, respectivamente, dormitórios e banheiros, enquanto a sala corresponde a sala e cozinha conjugadas.



APÊNDICE B

Este apêndice tem como objetivo descrever os materiais utilizados nos componentes construtivos dos modelos base, seção 3.1, e dos modelos desenvolvidos para as amostras de treino e de teste, seção 3.2.

Material	Espessura (cm)	Densidade (kg/m³)	Condutividade térmica (W/m².K)	Calor específico (J/kg.K)
Argamassa	2.5	2000	1.15	1000
Câmara de ar (cobertura)	-	-	4.76	-
Câmara de ar (paredes)	-	-	5.88	-
Concreto	10	2200	1.75	1000
Contrapiso	2	2000	1.15	1000
EPS	4	-	1	-
Gesso	1.25	900	0.35	870
Lã de vidro	2.5	-	1.49	-
Lã de vidro	5	-	0.8	-
Placa cimentícia	1	2000	1.15	1000
Piso cerâmico	0.75	2000	1.05	920
Telha de fibrocimento	8	1700	0.65	840
Tijolo (9x19x19)	1.3	1600	0.9	920
Tijolo maciço	10	1800	1.05	920
Tijolo maciço	20	1800	1.05	920

APÊNDICE C

Este apêndice descreve a composição dos componentes construtivos que podem ser selecionados para paredes e coberturas ao utilizar os metamodelos. As propriedades térmicas dos materiais utilizados nesses componentes foram descritas no Apêndice B.

Componentes construtivos das paredes	Código	Camada	Paredes internas	Paredes externas
	1	Externa	Concreto (10 cm)	Concreto (10 cm)
	2	Externa	Tijolo maciço (10 cm)	Tijolo maciço (10 cm)
	3	Externa	Tijolo maciço (10 cm)	Tijolo maciço (20 cm)
	4	Externa	Argamassa	Argamassa
		2	Tijolo (9x19x19)	Tijolo (9x19x19)
		3	Câmara de ar (parede)	Câmara de ar (parede)
4		Tijolo (9x19x19)	Tijolo (9x19x19)	
5	5	Argamassa	Argamassa	
	Externa	Placa cimentícia	Placa cimentícia	
	2	Lã de vidro (5 cm)	Lã de vidro (5 cm)	
6	3	Gesso	Gesso	
	Externa	Concreto (10 cm)	Argamassa	
	2	-	EPS	
	3	-	Concreto (10 cm)	
Componentes construtivos da cobertura	Código	Camada	Forro	Cobertura
	1	Externa	Piso cerâmico	Telha fibrocimento
		2	Contrapiso	Câmara de ar (cobertura)
		3	Concreto (10 cm)	Concreto (10 cm)
	2	Externa	Piso cerâmico	Telha fibrocimento
		2	Contrapiso	Câmara de ar (cobertura)
		3	Concreto (10 cm)	Lã de vidro (2.5 cm)
		4	-	Concreto (10 cm)
	3	Externa	Piso cerâmico	Telha fibrocimento
		2	Contrapiso	Câmara de ar (cobertura)
3		Concreto (10 cm)	Lã de vidro (5 cm)	
4		-	Concreto (10 cm)	

	Código	Camada	Forro	Cobertura
Componentes construtivos da cobertura	5	Externa	Piso cerâmico	Telha fibrocimento
		2	Contrapiso	Câmara de ar (cobertura)
		3	Concreto (10 cm)	Concreto (10 cm)
		4	Câmara de ar (cobertura)	Câmara de ar (cobertura)
		5	Gesso	Gesso