



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

Michel Klein Pinheiro da Silva

Desenvolvimento de benchmark energético em centros de saúde

Florianópolis

2022

Michel Klein Pinheiro da Silva

Desenvolvimento de benchmark energético em centros de saúde

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

Orientadora: Prof^a. Ana Paula Melo, Dr^a.

Florianópolis

2022

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

Silva, Michel Klein Pinheiro da
Desenvolvimento de benchmark energético em centros de
saúde / Michel Klein Pinheiro da Silva ; orientadora, Ana
Paula Melo, 2022.
101 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico, Programa de Pós-Graduação em
Engenharia Civil, Florianópolis, 2022.

Inclui referências.

1. Engenharia Civil. 2. Eficiência Energética em
Edificações. 3. Benchmark. 4. Unidades Básicas de Saúde. 5.
Aprendizado de Máquina. I. Melo, Ana Paula. II.
Universidade Federal de Santa Catarina. Programa de Pós
Graduação em Engenharia Civil. III. Título.

Michel Klein Pinheiro da Silva

Desenvolvimento de *benchmark* energético em centros de saúde

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

Prof^a. Thalita Gorban Ferreira Giglio, Dr^a.
Universidade Estadual de Londrina

Prof. Roberto Lamberts, PhD.
Universidade Federal de Santa Catarina

Maria Andrea Triana, Dr^a.
DUX Arquitetura e Engenharia Bioclimática

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

Prof. Philippe Jean Paul Gleize, Dr.
Coordenador do Programa de Pós-Graduação

Prof^a. Ana Paula Melo, Dr^a.
Orientadora

Florianópolis, 2022.

Agradecimentos

Agradeço à minha família, em especial à minha mãe, Lúcia, e à minha irmã, Milena, pelo apoio e companhia, principalmente durante o período de pandemia.

À minha namorada, Anaís, por estar sempre comigo e por me acompanhar nos momentos mais felizes.

À prof^a. Ana Paula Melo, por todas as sugestões que possibilitaram a melhoria deste trabalho.

À prof^a. Thalita Gorban Ferreira Giglio, ao prof. Roberto Lamberts e à Maria Andrea Triana, por aceitarem fazer parte da banca examinadora.

À Eng^a. Vanessa, que forneceu dados e projetos de centros de saúde da Prefeitura de Florianópolis.

Aos colegas do LabEEE, em especial o Tiago e o Antonio, parceiros na jornada de desenvolvimento de benchmark. Ao Matheus Geraldi, Verônica e demais integrantes da equipe do Cidades Eficientes, pelas discussões e trocas de informações sobre benchmark.

À Universidade Federal de Santa Catarina, pelo ensino de qualidade. Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, pelo auxílio financeiro que permitiu a realização do mestrado.

Enfim, agradeço à todos que participaram da minha jornada de vida até o momento.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

“Os problemas significativos com os quais nos deparamos não podem ser resolvidos no mesmo nível de pensamento em que estávamos quando eles foram criados.” (Albert Einstein)

Resumo

As edificações são responsáveis por grande parte do consumo energético mundial e, conseqüentemente, dos impactos ambientais causados pela geração de energia. Os edifícios em operação costumam não apresentar a eficiência energética prevista na fase de projeto, resultando no fenômeno de *performance gap*. No entanto, estudos relacionados ao consumo energético de edifícios na fase de operação estão sendo desenvolvidos, denominados *benchmarks*. O objetivo deste trabalho é desenvolver um *benchmark* da tipologia de centros de saúde. Foi adotado um arquétipo baseado em um projeto padrão dessa tipologia, e foram definidos parâmetros de entrada fixos e variados a serem aplicados nas simulações computacionais. Os parâmetros variados foram relacionados à orientação da edificação e aos seus materiais construtivos, assim como a densidade de potência de iluminação, a densidade e o período de ocupação, as características do sistema de condicionamento de ar e os dados climáticos representando oito diferentes cidades: Campos do Jordão/SP, São Paulo/SP, Florianópolis/SC, Campinas/SP, Rio de Janeiro/RJ, Vitória/ES, Recife/PE e Fortaleza/CE. Uma amostragem de Saltelli foi realizada sobre os parâmetros variados, composta por 64 amostras para cada parâmetro, com exceção da eficiência do sistema de condicionamento de ar e do arquivo climático, resultando em 1.408 amostras. A partir dessa amostragem, foram incorporados três valores de eficiência do sistema de condicionamento de ar e dados climáticos das diferentes localidades, resultando em 33.792 simulações. Para a verificação dos parâmetros de entrada mais influentes sobre o consumo total da tipologia, foram realizadas análises de sensibilidade de Sobol para as cidades de Florianópolis e Fortaleza, assim como uma análise de correlação de Pearson para todas as cidades simuladas. Foram desenvolvidos modelos preditivos utilizando os métodos de aprendizado de máquina denominados Máquinas de Vetor de Suporte e Redes Neurais Artificiais. A quantidade de parâmetros de entrada dos modelos preditivos foi determinada a partir de três diferentes pontos de corte para o coeficiente de correlação de Pearson. Dois centros de saúde foram utilizados para a validação do *benchmark* desenvolvido. Adicionalmente, cinco casos simulados foram utilizados para validação. Por fim, o metamodelo de avaliação do uso de ventilação natural da Instrução Normativa Inmetro para a Classificação de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas foi aplicado para os casos de consumo mínimo e máximo simulados. A densidade de potência de iluminação, o período de funcionamento e os cenários de ambientes condicionados foram identificados como os parâmetros mais impactantes sobre o consumo energético total em Florianópolis. Adicionalmente, foram identificados como impactantes os parâmetros de eficiência do sistema de condicionamento de ar e a absorvância da cobertura para a cidade de Fortaleza. Para a validação, foram adotados dois modelos preditivos de Redes Neurais Artificiais, com 12 parâmetros de entrada e com 7 parâmetros de entrada, para comparação dos resultados. Os modelos preditivos de Redes Neurais Artificiais apresentaram menores erros para o consumo energético total de ambas as edificações utilizada para a validação, em comparação com a equação de *benchmark* desenvolvida em um estudo do CBCS. A aplicação do metamodelo de avaliação do uso de ventilação natural da INI-C identificou a possibilidade de redução do consumo energético com a utilização de ventilação natural nas cidades de Campos do Jordão, São Paulo, Florianópolis e Campinas.

Palavras-chave: Eficiência Energética em Edificações, *Benchmark*, Simulação computacional, Unidades Básicas de Saúde, Aprendizado de Máquina

Abstract

Buildings are responsible for a big fraction of the global energy use and, therefore, of the environmental impacts caused by energy generation. Buildings in operation usually do not present the same energy efficiency predicted at the project phase, resulting in a difference between the projected and the real energy performance, named performance gap. There are studies related to the energy use in the buildings operational phase, denominated benchmarks. The objective of this work is to develop a benchmark for health centers. An archetype based on a standard government project was adopted. Fixed and variable parameters were defined for the simulations. The variable parameters were related to the building orientation and its construction materials, as well as the lighting power density, the occupation density and period, the air conditioning characteristics and climate data for different cities. It was considered 12 variable parameters. A Saltelli sampling was applied on the variable parameters, composed of 64 samples for each parameter, excepting the air conditioning system efficiency and the climate data, resulting in 1,408 samples. From those samples, parameters of three different air conditioning system efficiencies, and eight different cities climate data were included, resulting in 33,792 simulations. For the verification of the most influential variable parameters on the total energy consumption of the archetype, a Sobol sensitivity analysis was applied for the cities of Florianópolis and Fortaleza, as well as a correlation Pearson analysis for all the cities simulated. Predictive models were developed using Support Vector Machine (SVM) and Artificial Neural Network (ANN) machine learning techniques. The amount of input parameters was determined from three different Pearson coefficient thresholds. Two health centers were selected for the benchmark validation. Also, five simulated cases were used for validation. Finally, a natural ventilation metamodel was applied for the simulations that presented the minimum and maximum energy consumption. The lighting power density, the working period and the conditioned areas were identified as the most influential parameters on the total energy consumption for the city of Florianópolis. Additionally, the air conditioning system efficiency and the roof absorptance parameters were identified as influential for the city of Fortaleza. For validation, two ANN models were adopted, with 12 input parameters and with 7 input parameters, for a results comparison. The ANN predictive models developed presented lower errors for the predicted total energy consumption for both buildings, in comparison with the CBCS benchmark equation. The natural ventilation metamodel identified the possibility of reducing the air conditioning energy consumption using natural ventilation for the cities of Campos do Jordão, São Paulo, Florianópolis and Campinas.

Palavras-chave: Building Energy Efficiency, Benchmark, Energy Simulation, Health Centers, Machine Learning

Lista de Figuras

Figura 1 – Fluxograma da metodologia utilizada neste trabalho.....	45
Figura 2 – Planta baixa do projeto padrão de postos de saúde UBS II, com a separação em zonas térmicas.....	46
Figura 3 – Arquétipo em 3D.....	48
Figura 4 – Cenário 1 de áreas condicionadas.....	53
Figura 5 – Cenário 2 de áreas condicionadas.....	54
Figura 6 – Cenário 3 de áreas condicionadas.....	54
Figura 7 – Fluxograma das simulações computacionais.....	57
Figura 8 – Centro de Saúde de João Paulo.....	63
Figura 9 – Centro de Saúde Novo Continente.....	63
Figura 10 – Consumo energético de centros de saúde para todas as cidades simuladas. ..	65
Figura 11 – Consumo energético separado por uso final das amostras simuladas.....	66
Figura 12 – Distribuição dos consumos totais das simulações agrupados por período de funcionamento.....	66
Figura 13 – Consumo energético simulado de centros de saúde para Florianópolis.....	67
Figura 14 – Distribuição do consumo energético total simulado de centros de saúde para todos os Graus-Hora de Resfriamento considerados.....	67
Figura 15 – Índices de sensibilidade total e de primeira ordem para os parâmetros variados na cidade de Florianópolis.....	70
Figura 16 – Índices de sensibilidade total e de primeira ordem para os parâmetros variados na cidade de Fortaleza.....	71
Figura 17 – Coeficientes de correlação de Pearson.....	72
Figura 18 – Relação entre consumo predito e simulado e histograma de erros para a ANN com 12 parâmetros.....	75
Figura 19 – Relação entre consumo simulado e o consumo predito, e histograma de erros para a ANN com 7 parâmetros.....	75
Figura 20 – Distribuição do consumo energético real dos centros de saúde de Florianópolis em 2019.....	76
Figura 21 – Distribuição do consumo energético real dos centros de saúde de Florianópolis em 2020.....	77
Figura 22 – Consumo energético real e predito para o Centro de Saúde João Paulo.....	81
Figura 23 – Consumo energético real e predito para o Centro de Saúde Novo Continente.....	84
Figura 24 – Comparação dos resultados de consumo energético das simulações de validação.....	86

Lista de tabelas

Tabela 1 – Descrição das zonas térmicas.....	47
Tabela 2 – Materiais construtivos da cobertura para o limite inferior, o caso intermediário e o limite superior.....	50
Tabela 3 – Materiais construtivos das paredes externas para o limite inferior, o caso intermediário e o limite superior.....	51
Tabela 4 – Parâmetros de entrada variados.....	55
Tabela 5 – Faixas de GHR consideradas e cidades simuladas.....	56
Tabela 6 – Escala de classificação do benchmark desenvolvido neste trabalho.....	61
Tabela 7 – Limites de consumo energéticos das faixas de edificações de centros de saúde eficientes e típicos, para os períodos de funcionamento considerados nas simulações.....	68
Tabela 8 – Valores dos parâmetros equivalentes aos consumos mínimo e máximo para o estabelecimento da escala de classificação do benchmark desenvolvido neste trabalho.....	69
Tabela 9 – Modelos preditivos com todos os parâmetros variados.....	73
Tabela 10 – Modelos preditivos desenvolvidos de acordo com pontos de corte dos coeficientes de correlação de Pearson.....	74
Tabela 11 – Escala de classificação do benchmark top-down dos centros de saúde de Florianópolis para o ano de 2019.....	76
Tabela 12 – Características do Centro de Saúde de João Paulo e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 12 parâmetros para a realização da tabela de classificação de benchmark, e os respectivos consumos energéticos.....	78
Tabela 13 – Escala de classificação do benchmark desenvolvido a partir da ANN com 12 parâmetros.....	79
Tabela 14 – Características do Centro de Saúde de João Paulo e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 7 parâmetros para a realização da tabela de classificação de benchmark, e os respectivos consumos energéticos.....	79
Tabela 15 – Escala de classificação do benchmark desenvolvido a partir da ANN com 7 parâmetros.....	80
Tabela 16 – Limites mínimo, máximo e consumo do edifício em estudo obtidos pela equação do CBCS para a realização da tabela de classificação de benchmark.....	80
Tabela 17 – Escala de classificação do benchmark estabelecido pelo CBCS.....	80
Tabela 18 – Características do Centro de Saúde Novo Continente e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 12 parâmetros para a realização da tabela de classificação de benchmark, e os respectivos consumos energéticos.....	81
Tabela 19 – Escala de classificação do benchmark desenvolvido a partir da ANN com 12 parâmetros.....	82
Tabela 20 – Características do Centro de Saúde Novo Continente e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 7 parâmetros para a realização da tabela de classificação de benchmark, e os respectivos consumos energéticos.....	83
Tabela 21 – Escala de classificação do benchmark desenvolvido a partir da ANN com 7 parâmetros.....	83
Tabela 22 – Limites mínimo, máximo e consumo do edifício em estudo obtidos pela equação do CBCS para a realização da tabela de classificação de benchmark.....	84
Tabela 23 – Escala de classificação do benchmark estabelecido pelo CBCS.....	84
Tabela 24 – Características dos casos de validação simulados.....	85
Tabela 25 – Valores das métricas de erro para as predições de consumo das simulações de validação.....	86

Tabela 26 – Estimativas da fração de horas excedentes por calor ao ano (FHdesc) obtidas pela aplicação do metamodelo de avaliação do uso da ventilação natural da INI-C.....87

Lista de abreviaturas e siglas

ANN – Redes Neurais Artificiais (*Artificial Neural Network*)
ASHRAE – *American Society of Heating, Refrigerating and Air-conditioning Engineers*
BREEAM – *Building Research Establishment Environmental Assessment Method*
Building EQ – *Building Energy Quotient*
CBCS – Conselho Brasileiro de Construção Sustentável
CB ECS – *Commercial Buildings Energy Consumption Survey*
CIBEUS – *Commercial and Institutional Building Energy Use Survey*
CIBSE – *Chartered Institute of Building Services Engineers*
CNAE – Classificação Nacional de Atividades Econômicas
COP – Coeficiente de Performance
DEC – *Display Energy Certificate* (DEC)
DEO – Desempenho Energético Operacional
DOE – *U.S. Department of Energy*
DPE – Densidade de Potência de Equipamentos
DPI – Densidade de Potência de Iluminação
EARM – *Energy Assessment and Reporting Methodology*
ECON19 – *Energy Consumption Guide 19*
EIA – *Energy Information Administration*
EPA – *Environmental Protection Agency*
EPBD – *Energy Performance of Buildings Directive*
EUI – *Energy Use Intensity*
HQE – *Haute Qualité Environnementale des Bâtiments*
IDRS – Índice de Desempenho de Resfriamento Sazonal
INI-C – Instrução Normativa Inmetro para a Classificação de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas
INMET – Instituto Nacional de Meteorologia
LEED – *Leadership in Energy & Environmental Design*
MAE – Erro Absoluto Médio
NABERS – *National Australian Built Environment Rating System*
NRCAN – *Natural Resources Canada*
Procel – Programa Nacional de Conservação de Energia Elétrica
Projeto META – Projeto de Assistência Técnica dos Setores de Energia e Mineral
RMSE – Raiz do Erro Quadrático Médio
SCIEU – *Survey of Commercial and Institutional Energy Use*
SVM – Máquinas de Vetor de Suporte (*Support Vector Machine*)
UBS – Unidades Básicas de Saúde

Sumário

1. Introdução.....	15
1.1. Justificativa.....	15
1.2. Objetivos.....	18
1.2.1. Objetivo geral.....	18
1.2.2. Objetivos específicos.....	18
1.2.3. Estrutura do trabalho.....	19
2. Referencial teórico.....	20
2.1. <i>Benchmark</i> energético.....	20
2.2. Métodos de <i>benchmark</i>	27
2.2.1. Cálculos de engenharia.....	28
2.2.2. Simulação computacional.....	28
2.2.3. Métodos estatísticos.....	30
2.2.4. Aprendizado de máquina.....	33
2.2.5. Outros métodos.....	37
2.3. Classificações dos métodos de <i>benchmark</i>	38
2.4. Diagnóstico energético.....	39
2.5. Análise de sensibilidade.....	40
2.6. Síntese.....	43
3. Método.....	45
3.1. Caracterização do arquétipo.....	46
3.2. Definição dos parâmetros de entrada.....	48
3.2.1. Parâmetros de entrada fixos.....	48
3.2.2. Parâmetros de entrada variados.....	49
3.3. Amostragem de Saltelli.....	56
3.4. Simulações computacionais.....	57
3.5. Análise de sensibilidade e de correlação.....	57
3.6. Desenvolvimento do modelo preditivo do <i>benchmark</i>	58
3.7. Comparação de métricas de erro.....	59
3.8. Estabelecimento da escala de <i>benchmark</i>	60
3.9. Análise estatística e validação do <i>benchmark</i>	61
3.9.1. Estoque de edificações de centros de saúde de Florianópolis.....	62
3.9.2. Projeto 1: Centro de Saúde de João Paulo.....	62
3.9.3. Projeto 2: Centro de Saúde Novo Continente.....	63
3.9.4. Casos simulados de validação.....	64

3.9.5. Aplicação do metamodelo de avaliação da utilização de ventilação natural da INI-C.....	64
4. Resultados e discussão.....	65
4.1. Amostragem de Saltelli e simulações computacionais.....	65
4.2. Análise de sensibilidade e de correlação.....	70
4.3. Desenvolvimento do modelo preditivo do <i>benchmark</i> e comparação de métricas de erro.....	72
4.4. Análise estatística e validação do <i>benchmark</i>	75
4.4.1. Estoque de edificações de centros de saúde de Florianópolis.....	75
4.4.2. Projeto 1: Centro de Saúde de João Paulo.....	77
4.4.3. Projeto 2: Centro de Saúde Novo Continente.....	81
4.4.4. Casos simulados de validação.....	85
4.4.5. Aplicação do metamodelo de conforto por ventilação natural da INI-C.....	86
5. Conclusões.....	88
5.1. Sugestões de trabalhos futuros.....	90
6. Referências bibliográficas.....	91

1. Introdução

1.1. Justificativa

As preocupações quanto aos impactos ambientais decorrentes da exploração de fontes de energia e matéria-prima não renováveis vêm se destacando nos últimos anos. Frente a essas preocupações, evidencia-se o estudo da sustentabilidade, definida pela Organização das Nações Unidas como a utilização adequada dos recursos naturais finitos de forma a atender as necessidades atuais da humanidade, sem comprometer a capacidade de atender as necessidades das futuras gerações (CMMAD, 1991).

As edificações, ao longo de sua vida útil, são responsáveis por grande parte do consumo de matérias-primas e energia primária e, portanto, causadoras de grande parte do impacto ambiental. Mundialmente, as edificações tem participação de 36% no uso final de energia e 39% da emissão de dióxido de carbono, destacando-se como um dos maiores agentes do aquecimento global (IEA, 2019). Com isso, verifica-se a importância dos estudos relacionados à sustentabilidade das edificações para a redução dos seus impactos ambientais. A demanda energética mundial apresenta uma tendência de aumento em torno de 1% ao ano, como consequência do crescimento populacional e do aumento da busca por conforto, com o crescente uso de aparelhos eletrônicos e equipamentos de condicionamento de ar (IEA, 2014).

No Brasil, as edificações são responsáveis por 51,2% do consumo de energia elétrica, sendo 27,6% referente às edificações residenciais, 15,7% às edificações comerciais e 7,9% referente às edificações públicas (EPE, 2021). A demanda energética brasileira apresenta uma tendência de aumento de 2,2% ao ano, uma taxa de crescimento maior do que a tendência mundial (BP, 2019). O consumo de energia tem assumido participação cada vez mais significativa nos custos e nos impactos ambientais de edifícios ao longo de sua vida útil, tornando essencial a elaboração de medidas que aumentem a eficiência energética de edificações.

O conceito de eficiência energética em edificações consiste em utilizar menos energia para aquecimento, resfriamento e iluminação, entre outros sistemas, sem que a saúde, o conforto e a produtividade dos ocupantes sejam afetados (PÉREZ-LOMBARD et al., 2009). Há um grande potencial de redução de consumo energético em função do aumento da eficiência energética em edificações, sendo que apenas 20% desse potencial é aproveitado (IEA, 2014).

Países como Estados Unidos, Canadá e Austrália possuem seus respectivos regulamentos e normas para a verificação da eficiência energética dos edifícios. Para a classificação dos edifícios, incluindo seu respectivo desempenho energético, surgiram procedimentos de certificação ambiental, sendo os pioneiros o BREEAM (*Building Research Establishment Environmental Assessment Method*) no Reino Unido, o LEED (*Leadership in Energy & Environmental Design*) nos Estados Unidos,

e o HQE (*Haute Qualité Environnementale des Bâtiments*) na França (GONÇALVES; BODE, 2015).

A certificação de edifícios na fase de projeto não necessariamente indica um menor consumo de energia na fase de operação, quando comparados com edifícios não certificados. Scofield (2013) indica que edifícios de escritórios, localizados na cidade de Nova York, com certificação LEED, não apresentam redução de consumo de energia quando comparados a outros edifícios com a mesma tipologia sem a certificação. Scofield e Doane (2018), ao analisarem escolas, edifícios de escritórios e residências multifamiliares com a certificação LEED e localizados na cidade de Chicago, também verificaram que não há melhoria no desempenho energético em comparação com edifícios sem a certificação. Nesse estudo, as escolas certificadas apresentaram menor consumo de gás e maior consumo de energia elétrica, resultando em um aumento de 12% no consumo de energia primária.

Os edifícios em operação, geralmente, não apresentam o mesmo desempenho energético previsto na avaliação em fase de projeto. Essa diferença de desempenho é denominada na literatura de *performance gap*, sendo as principais causas as incertezas nas especificações do modelo, o comportamento dos ocupantes e más práticas operacionais (VAN DRONKELAAR et al., 2016). Pequenos desvios nos parâmetros de entrada da simulação dos sistemas existentes na edificação podem resultar em um desvio até dez vezes superior em relação ao desempenho energético (BURMAN et al., 2014). Diferenças construtivas entre o edifício projetado e a situação real, como materiais diferentes do especificado e infiltração de ar decorrente de falhas construtivas também influenciam, significativamente, no fenômeno de *performance gap* (MENEZES et al., 2012).

Wilde (2014) classifica o *performance gap* em três tipos: discrepâncias de simulações computacionais, incertezas dos modelos de aprendizado de máquina e divergências em certificações ambientais. Por meio da implementação de medidores automáticos de consumo de energia, o autor observou um consumo de energia até 2,5 vezes superior ao esperado na fase de projeto. As incertezas associadas ao desempenho energético de edificações são decorrentes principalmente do relacionamento entre o ser humano e o ambiente construído, que impactam nas características de uso e ocupação (D'OCA; HONG; LANGEVIN, 2018). Nikolaou et al. (2009a), ao avaliarem um edifício de escritórios na Grécia, identificaram algumas das principais influências dos ocupantes sobre o consumo energético, como a variação da temperatura de *setpoint* do sistema de condicionamento de ar, de acordo com as preferências pessoais nos dias mais quentes ou frios do ano. Além disso, os autores identificaram diferenças nos horários de funcionamento difíceis de serem previstas, como a necessidade de horas extras em determinados dias, assim como a ocupação mais intensa de ambientes de ocupação temporária, como salas de reuniões e auditórios.

Com o avanço e a consolidação dos processos de certificação ambiental, diversos países identificaram o *performance gap* e buscaram solucioná-lo, por meio

da avaliação de edifícios em sua fase de operação. O método desenvolvido para atingir esse objetivo foi a comparação entre edifícios similares, de forma a determinar um nível típico de consumo. Esse procedimento é denominado na literatura de *benchmark*. Segundo Chung (2011), o desenvolvimento de sistemas de *benchmark* permite a comparação do desempenho energético dos edifícios existentes de mesma tipologia, favorecendo a implementação de melhorias de eficiência energética nos edifícios com menor desempenho energético. Como as atividades desenvolvidas em edificações comerciais são bem diversas e envolvem diferentes ocupações, equipamentos e consumo de energia, torna-se necessário avaliar o desempenho energético de forma distinta para cada tipologia.

Os países que identificaram a necessidade do desenvolvimento de *benchmarks* para a melhoria do desempenho energético do seu conjunto de edifícios desenvolveram legislação e incentivos para o fornecimento de informações que compõem o banco de dados que fundamenta o procedimento de *benchmark*. São exemplos de *benchmarks* consolidados o *Portfolio Manager* do *Energy Star*, dos Estados Unidos, o *Display Energy Certificate* (DEC), do Reino Unido, e a classificação energética do *National Australian Built Environment Rating System* (NABERS), da Austrália.

No Brasil, observa-se que há uma grande lacuna para o desenvolvimento de avaliações de diversas tipologias de edificações já existentes, dependentes da disponibilidade de dados de uso de energia, dificultada por preocupações de confidencialidade e concorrência (BORGSTEIN; LAMBERTS, 2014).

Em 2013, o Conselho Brasileiro de Construção Sustentável (CBCS) identificou a necessidade de um parâmetro de comparação para edifícios em operação, com o objetivo de tornar visível o consumo energético do edifício em uso, na forma de uma etiqueta semelhante a etiquetagem Procel Edifica existente para edifícios em projeto e já construídos. Com isso, iniciou-se o programa de Desempenho Energético Operacional (DEO), com o objetivo de desenvolver a metodologia e as escalas de *benchmark* para diferentes tipologias não-residenciais (CBCS, 2013). Dentre os *benchmarks* já desenvolvidos para o Brasil, destacam-se: agências bancárias (BORGSTEIN; LAMBERTS, 2014), escritórios de serviços públicos e escritórios corporativos (BORGSTEIN; LAMBERTS; HENSEN, 2018). Em 2018, o CBCS, em convênio com a Eletrobras, deu continuidade ao processo de desenvolvimento de *benchmarks*, propondo escalas de classificação de edifícios em operação para 15 diferentes tipologias comerciais (VELOSO et al., 2021). Para preencher a falta de dados detalhados de edifícios comerciais para o desenvolvimento de *benchmarks*, foi estabelecido o Projeto de Assistência Técnica dos Setores de Energia e Mineral (Projeto META), desenvolvido pelo Ministério de Minas de Energia (EPE, 2015). Nessa pesquisa, a tipologia de hospitais e pronto-socorros apresentou o terceiro maior consumo médio anual de energia elétrica no setor não-residencial, com 63 mil kWh, considerando uma amostragem nacional de 25 tipologias estudadas. Isso demonstra a alta densidade energética e a importância do estudo da tipologia de saúde para reduzir o consumo nacional de energia elétrica.

Na cidade de Florianópolis, os centros de saúde demandam 4,95% do custo total de energia elétrica da prefeitura em 2020, porcentagem menor apenas do que a iluminação pública e que supera inclusive os custos energéticos de edifícios administrativos e escolares, o que evidencia a importância de uma análise de eficiência energética dessa tipologia (CBCS, 2020).

Com base nesse contexto de carência de ferramentas nacionais para comparação do desempenho energético de edifícios em operação, o objetivo deste trabalho consistiu no desenvolvimento de um *benchmark* energético para postos de saúde. A partir de um arquétipo desenvolvido com base no padrão de Unidades Básicas de Saúde do Ministério da Saúde, foi realizada uma análise de sensibilidade, de forma a caracterizar os parâmetros de entrada mais significativos sobre o consumo de energia elétrica. Em seguida, foram aplicados os algoritmos de Máquinas de Vetor de Suporte e de Redes Neurais Artificiais, técnicas de aprendizado de máquina, para o desenvolvimento do *benchmark*, permitindo comparar os desempenhos energéticos dos edifícios em uso da tipologia analisada. Por fim, o modelo desenvolvido foi validado por meio de dados de consumo de edifícios reais da tipologia de Centros de Saúde localizados em Florianópolis.

1.2. Objetivos

1.2.1. Objetivo geral

O objetivo geral deste trabalho é desenvolver um *benchmark* para a tipologia de postos de saúde, por meio de desenvolvimento de modelo preditivo, considerando as variações de consumo energético para oito diferentes cidades representativas dos diferentes climas brasileiros: Campos do Jordão/SP, São Paulo/SP, Florianópolis/SC, Campinas/SP, Rio de Janeiro/RJ, Vitória/ES, Recife/PE e Fortaleza/CE.

1.2.2. Objetivos específicos

Para alcançar o objetivo geral, são definidos os seguintes objetivos específicos:

- Definir os parâmetros de entrada mais influentes sobre os parâmetros de saída da simulação computacional, a partir de um arquétipo de simulação, por meio de análise de sensibilidade e análise de correlação;
- Desenvolver modelos preditivos de aprendizado de máquina a partir das simulações realizadas;
- Validar os resultados obtidos, por meio de dados de centros de saúde fornecidos pela Prefeitura de Florianópolis.

1.2.3. Estrutura do trabalho

Esta dissertação está organizada em seis capítulos. No Capítulo 1, define-se os principais pontos que justificam o desenvolvimento da pesquisa, e delimita-se os objetivos deste trabalho. O Capítulo 2 consiste em um referencial teórico, que aborda os principais tópicos necessários para a contextualização deste trabalho. São abordados os seguintes temas: *Benchmark* energético, métodos de *benchmark*, classificações dos métodos de *benchmark*, auditorias energéticas e análise de sensibilidade. O Capítulo 3 trata da metodologia utilizada neste trabalho, com a caracterização do arquétipo utilizado nas simulações computacionais, a definição dos parâmetros fixos e variados e o estabelecimento do método utilizado para as análises de sensibilidade e de correlação desenvolvidas, os modelos preditivos desenvolvidos e a validação do *benchmark*. O Capítulo 4 relata os resultados obtidos. O Capítulo 5 traz as conclusões obtidas a partir dos resultados da pesquisa, com recomendações de trabalhos futuros que visem aprimorar o *benchmark* desenvolvido. Por fim, o Capítulo 6 enumera as referências bibliográficas utilizadas para embasar este trabalho.

2. Referencial teórico

Neste capítulo, serão apresentadas as principais referências que embasaram esta pesquisa. Primeiramente, a definição de *benchmark* energético é introduzida, com as suas principais características e estudos internacionais e nacionais. Em seguida, são apresentados os diferentes métodos de desenvolvimento de *benchmarks* utilizados na literatura. Posteriormente, são apresentadas propostas de classificação dos métodos de *benchmark* de acordo com suas principais características. Em seguida, é apresentado o conceito de diagnóstico energético. Finalmente, são apresentados os conceitos e métodos de análise de sensibilidade local e global.

2.1. *Benchmark* energético

O termo *benchmark*, inicialmente utilizado para definir pontos de referência em topografia, foi incorporado em processos industriais para definir medidas de melhoria de performance produtiva e, posteriormente, na avaliação da performance energética em edifícios (PÉREZ-LOMBARD et al., 2009). O *benchmark* energético em edificações consiste em uma avaliação do desempenho energético de um edifício, por meio da comparação com o desempenho de edifícios semelhantes (*stock-level*), ou o desempenho ideal do mesmo edifício (*building-level*) (GERALDI; GHISI, 2020).

Os modelos de *benchmark* são elaborados a partir de um banco de dados de referência, e devem levar em consideração fatores climáticos, construtivos, administrativos e de operação (CHUNG, 2011). As referências utilizadas no desenvolvimento do *benchmark* podem ter como base o desempenho atual ou desejada de edifícios semelhantes, desenvolvendo um *benchmark* público e que pode ser utilizado para regulamentos governamentais, ou o desempenho anterior ou desejado do mesmo edifício, desenvolvendo um *benchmark* privado que pode ser utilizado internamente como uma linha de base para avaliação de possíveis melhorias (LI; HAN; XU, 2014).

O consumo energético das edificações é influenciado por fatores como o clima, a envoltória, os sistemas, a operação e a manutenção, o comportamento do usuário e o conforto ambiental (IEA, 2016). Durante o desenvolvimento de um *benchmark*, destaca-se a importância de investigar os fatores mencionados, que envolvem características construtivas e operacionais, para que os dados de consumo de energia sejam compreendidos e classificados. Os fatores relacionados ao comportamento humano podem influenciar no consumo energético tanto quanto os fatores construtivos e apresentam dificuldades para serem estimados durante a fase de projeto dos edifícios, sendo possível obter valores mais realísticos apenas na fase de operação (MENEZES et al., 2012).

A avaliação do desempenho energético de um edifício não considera somente o consumo de energia, mas também o conforto ambiental oferecido aos usuários. Portanto, o *benchmark* deve levar em conta o projeto do edifício, suas tecnologias

(que devem ser coerentes com outros edifícios de mesma tipologia) e sua operação (OLOFSSON; MEIER; LAMBERTS, 2004).

Segundo Borgstein e Lamberts (2014), um *benchmark* deve ser desenvolvido de forma simples e com poucas variáveis, de forma a utilizar a base de dados disponível e facilitar a obtenção, por parte do usuário do *benchmark*, dos dados necessários para a classificação dos edifícios. Também, destaca-se que deve ser robusto, mostrando as variações de consumo de acordo com as variáveis selecionadas, indicando a eficiência com que os edifícios providenciam o conforto ambiental. As diferenças nas classificações de eficiência energética do *benchmark* devem ser estatisticamente relevantes e confiáveis, de forma a identificar adequadamente quais os edifícios que apresentam melhor eficiência energética (PAPADOPOULOS; KONTOKOSTA, 2019).

Segundo Pérez-Lombard et al. (2009), um processo de desenvolvimento de *benchmark* é constituído de quatro fases. Primeiramente, é desenvolvido um banco de dados com informações suficientes sobre o desempenho energético de um número estatisticamente relevante de edifícios. Em seguida, obtém-se informações relevantes para a avaliação do desempenho do edifício em estudo. Posteriormente, são realizadas análises comparativas do desempenho energético do edifício em estudo com o banco de dados de outros edifícios de mesma tipologia. Finalmente, são desenvolvidas recomendações de medidas de eficiência energética viáveis a partir de perspectivas técnicas e econômicas.

Para *benchmarks* mais precisos, as pequenas cargas de equipamentos não podem ser desprezadas, pois são responsáveis por cerca de 20% do consumo total em escritórios (MENEZES et al., 2013). Além disso, as diferenças de consumo de um aparelho em *stand-by* e em uso normal têm aumentado significativamente, destacando a importância da consideração do período de utilização efetiva desses equipamentos na previsão de consumo energético.

O *benchmark* é uma das ferramentas que podem ser utilizadas em políticas públicas holísticas para o reconhecimento de oportunidades de aplicação de medidas de eficiência energética, que envolvem o reconhecimento de oportunidades, a implantação de incentivos financeiros, a aplicação de normas técnicas e o incentivo a parcerias privadas, com a possibilidade de redução do consumo anual de energia em 23% nos Estados Unidos (MCKINSEY, 2009). Podem ser incluídos *benchmarks* como requisitos mínimos de códigos de obra ou normas técnicas, ou na forma de certificações voluntárias, como vantagem competitiva. Devem haver um balanço entre a precisão do modelo, que acarreta na necessidade de dados coletados e, conseqüentemente, em maiores custos, e a simplicidade do modelo, de forma a facilitar o seu uso.

Como as políticas de energia costumam ser de âmbito nacional, é interessante que haja iniciativas governamentais de implementação de um banco de dados que mantenha a privacidade e competitividade dos edifícios comerciais, mas também que possibilite um *benchmark* público balizador de reduções de consumo

dos edifícios que apresentem menor desempenho. A maior dificuldade é a coleta de dados de consumo, pois no Brasil esses dados são considerados confidenciais. Hsu (2014), ao desenvolver um *benchmark* por meio de regressão linear, verificou que a implementação de leis que obriguem a divulgação de dados pode ser mais relevante do que a utilização de auditorias.

Martin (2013) desenvolveu um *benchmark* de edifícios de comércio e escritórios na África do Sul para superar as dificuldades de falta de dados disponíveis e a impossibilidade de financiar um processo de coleta de dados. Utilizando dados de consumo de energia elétrica de edifícios das tipologias em estudo fornecidos pelas concessionárias municipais e conectando os respectivos edifícios com seus dados de área construída disponíveis nas prefeituras, foi possível estabelecer um *benchmark* simples que indica o consumo típico de energia elétrica por área construída para as tipologias, por meio de um modelo linear pelo método dos mínimos quadrados. A técnica de desenvolvimento de *benchmark* demonstrada pela autora tem o potencial de representar cerca de 60% de todos os consumidores de energia elétrica da África do Sul. O estabelecimento de um *benchmark* de consumo de energia elétrica torna-se um indicador representativo do consumo total de energia primária dos edifícios em climas mais quentes, onde o aquecimento a gás é pouco utilizado. A autora sugere a obtenção de período de ocupação, densidade de usuários e equipamentos como melhoria do banco de dados, para que seja possível melhorar a qualidade do *benchmark*.

Um dos trabalhos nacionais para suprir a falta de dados relacionados ao setor energético brasileiro foi realizado pelo Projeto de Assistência Técnica dos Setores de Energia e Mineral (META), desenvolvido pelo Ministério de Minas e Energia. O Projeto META foi composto por diversos subprojetos que abrangeram desde estudos de diagnóstico das principais fontes de energia da matriz energética brasileira até a aplicação de novas tecnologias para o monitoramento e a segurança do Sistema Interligado Nacional, incluindo ainda cursos de capacitação para aprimoramento profissional dos profissionais da área energética (MME, 2018).

Uma das atividades realizadas no âmbito do Projeto META foi a pesquisa do consumo de energia no setor de serviços, em que foram obtidos dados detalhados de 25 tipologias que incluíram boa parte das diferentes Classificações Nacionais de Atividades Econômicas (CNAEs) de edifícios comerciais. Foram selecionadas 400 amostras de edifícios para cada tipologia, localizadas em todos os estados brasileiros, totalizando 10.000 edifícios comerciais entrevistados (EPE, 2015). Foram levantadas características construtivas das edificações, como número de andares, tipo de fachada e de cobertura, área construída e ano de construção. Adicionalmente, foram obtidos dados relativos ao consumo energético dos edifícios, como período de funcionamento, fontes de energia utilizadas (eletricidade, gás, lenha e carvão), tipo de lâmpadas utilizadas na iluminação, equipamentos instalados e tipos de sistemas de condicionamento de ar presentes. Com isso, foi possível obter um panorama das características de uso de energia para cada tipologia. O consumo de energia das tipologias da área de saúde é, predominantemente,

composto por eletricidade, embora haja um consumo significativo de gás natural em hospitais para a confecção de refeições. Na amostra obtida evidencia-se uma porcentagem significativa de edifícios da área de saúde que apresentam aparatos elétricos antigos e ineficientes, como televisores de tubo de raios catódicos e lâmpadas incandescentes, o que indica o potencial de aumento da eficiência energética com a substituição por aparelhos e lâmpadas mais eficientes.

Um dos programas de certificação em eficiência energética de edifícios em operação mais conhecidos internacionalmente é o *Energy Star*. Este programa foi desenvolvido pela *Environmental Protection Agency* (EPA), dos Estados Unidos. O método utilizado pelo programa estabelece classificações com base em análise estatística dos dados recolhidos pela *Energy Information Administration* (EIA), por meio da pesquisa *Commercial Buildings Energy Consumption Survey* (CBECS) (EIA, 2003). O sistema de classificação foi estabelecido como uma faixa de 1 a 100 pontos (sendo 100 o melhor desempenho), e para serem elegíveis da obtenção da certificação, os edifícios devem obter nota superior a 75, o que indica que o edifício apresenta desempenho energético equivalente ao quartil mais eficiente dos edifícios similares dentro do banco de dados. Aproximadamente, 25% dos edifícios comerciais localizados nos Estados Unidos participam do *benchmark* do *Energy Star*, na plataforma *Portfolio Manager* (EPA, 2020).

O programa *Building Energy Quotient* (*Building EQ*), da *American Society of Heating, Refrigerating and Air-conditioning Engineers* (ASHRAE), é outro procedimento de avaliação do desempenho energético de edificações disponível nos Estados Unidos. O *Building EQ* apresenta uma categoria de avaliação de edifícios em operação, em que só podem ser classificados edifícios com pelo menos um ano de operação. O programa consiste no estabelecimento de uma nota dentro da categoria desejada uma divisão de sete níveis, entre A+ (Edificações de consumo zero) e F (insatisfatório) (ASHRAE, 2017).

No Canadá, o *Natural Resources Canada* (NRCAN) conduziu o *Commercial and Institutional Building Energy Use Survey* (CIBEUS), uma coleta de dados de 4101 edifícios comerciais e institucionais localizados nas principais regiões metropolitanas do país. As informações coletadas englobam características físicas e de ocupação, assim como tecnologias de eficiência energética implementadas e usos de energia. O CIBEUS é utilizado como banco de dados de referência para o desenvolvimento de *benchmarks* canadenses no âmbito do programa EnergyStar, em conjunto com o *Survey of Commercial and Institutional Energy Use* (SCIEU) (NRCAN, 2018). No Reino Unido, o desenvolvimento de um sistema nacional de *benchmark* iniciou-se com a divulgação do *Energy Consumption Guide 19* (ECON19), que consiste em parâmetros típicos e de boa prática para cada sistema de edifícios de escritórios, separadamente (CIBSE, 2003). Posteriormente, o *Display Energy Certificate* (DEC) foi introduzido em 2008 pelo *Energy Performance of Buildings Directive* (EPBD). Este programa apresenta uma escala de “A” a “G”, sendo “A” a faixa de edifícios mais eficientes, e o procedimento de *benchmark* é estabelecido pela norma CIBSE TM46 (CIBSE, 2008). Com relação ao *benchmark*

do DEC, estudos apontaram uma tendência de direcionar o consumo em direção ao aumento do consumo de energia elétrica para que o consumo de combustíveis fósseis seja reduzido, o que não necessariamente encaminha o edifício a uma maior sustentabilidade ou mesmo a uma maior eficiência energética (BRUHNS; JONES; COHEN, 2011).

Uma das ferramentas para avaliar o desempenho energético de edifícios no Reino Unido é o *Energy Assessment and Reporting Methodology* (EARM). Sistematizado pela norma CIBSE TM22 (CIBSE, 2006), o método consiste em avaliar o desempenho do edifício em uso baseada no consumo de energia, com o desmembramento em usos finais de energia, como iluminação e ventilação. Também são considerados fatores operacionais como horário de funcionamento e eficiência dos equipamentos. Podem ser incluídos na avaliação a autogeração de energia e o uso de energias renováveis, com o objetivo de melhorar a classificação do edifício (MENEZES et al., 2012).

O programa australiano de classificação energética dedicado a edificações comerciais em uso denomina-se *National Australian Built Environment Rating System* (NABERS). As ferramentas disponibilizadas pelo programa quantificam dados de energia, água, disposição de resíduos, emissão de gás carbônico e conforto ambiental interno. Primeiramente, o programa estava disponível apenas para edifícios de escritórios, mas, posteriormente, expandiu para a avaliação de hotéis, data centers e centros comerciais (COHEN; BORDASS, 2015). A classificação do NABERS concede uma pontuação baseada no desempenho da edificação por meio de um sistema de *benchmark* que varia em uma escala de 1 a 6 estrelas. Um edifício classificado como seis estrelas representa as melhores práticas de mercado enquanto uma estrela denota desempenho mínimo, o que sinaliza grande espaço para melhorias (BANNISTER, 2012). Atualmente, aproximadamente, 78% dos escritórios australianos são certificados pelo NABERS, cuja avaliação é obrigatória para edifícios de escritórios com mais de mil metros quadrados (NABERS, 2020).

Para suprir a falta de métodos de avaliação de edifícios na fase de operação, o Conselho Brasileiro de Construção Sustentável (CBCS) publicou um plano para o desenvolvimento de *benchmark* (CBCS, 2014), cujo primeiro resultado foi o desenvolvimento de um *benchmark* nacional de agências bancárias (BORGSTEIN; LAMBERTS, 2014). A partir de dados de consumo anual e área construída de aproximadamente 8 mil edifícios utilizados como agências bancárias no Brasil, os autores realizaram uma análise de regressão linear, com o número de graus-hora de resfriamento de cada zona bioclimática brasileira como fator de correção. Posteriormente, Borgstein, Lamberts e Hensen (2018) iniciaram a avaliação do desempenho energético de edifícios públicos. A amostra consistiu em 32 edifícios distribuídos em 14 cidades brasileiras. Foram realizadas correções para o número de dias úteis mensais, e o *benchmark* foi realizado com regressão linear, também em função do número de graus-hora de resfriamento.

Veiga et al. (2021) propuseram uma melhoria no *benchmark* nacional de agências bancárias já desenvolvido, com a consideração de mais parâmetros de entrada variados e a aplicação de aprendizado de máquina ao modelo preditivo. A análise de sensibilidade realizada identificou que a densidade de potência de iluminação e o valor de graus-hora de resfriamento foram os parâmetros que apresentaram maior impacto sobre o consumo energético total dessa tipologia, seguidos do tipo de sistema de condicionamento de ar (splits ou VRF), Coeficiente de Performance (COP) do sistema de condicionamento de ar e área do edifício. Adicionalmente, foi identificada a correlação entre o tipo de sistema de condicionamento de ar e o consumo de seus *fans*, assim como entre os graus-hora de resfriamento e o consumo de energia para resfriamento. Além disso, verificou-se a correlação entre a eficiência do sistema de condicionamento de ar e o consumo de energia para resfriamento, mas correlação nula entre esse mesmo parâmetro e o consumo de energia para aquecimento, devido a consideração do uso de resistências elétricas para o aquecimento do sistema de condicionamento de ar nas simulações. O modelo preditivo de Máquinas de Vetor de Suporte com a utilização de 9 parâmetros de entrada apresentou a maior acurácia, apresentando valores de MAE e RMSE de 3,16 e 4,45 kWh/(m².ano), respectivamente. A validação do modelo desenvolvido com três edifícios reais da tipologia de agências bancárias indicou uma melhor predição do consumo real dessa tipologia, quando comparado com o *benchmark* anterior.

Em 2018, o CBCS firmou convênio com a Eletrobras e, no âmbito do projeto denominado “Estruturação do setor de edificações por meio de estudos e desenvolvimentos de base de dados com indicadores”, realizou estudos para o desenvolvimento de *benchmarks* energéticos. Por meio dos dados obtidos no projeto META, além da realização de auditorias energéticas, o projeto culminou no desenvolvimento de um relatório interno que propõe *benchmarks* para 15 diferentes tipologias comerciais, entre elas os postos de saúde (VELOSO et al., 2021). Os autores identificaram que os parâmetros de graus-hora de resfriamento e aquecimento, tipo de sistema de condicionamento de ar (ventilador, split ou inverter), densidade de potência de iluminação e absorvância solar da fachada apresentaram impacto significativo sobre o consumo total da tipologia de centros de saúde. Esses parâmetros foram utilizados para o estabelecimento de uma equação linear multivariada para cidades que apresentam graus-hora de resfriamento menor do que 54 mil, que inclui o parâmetro de graus-hora de aquecimento, e outra equação linear multivariada para cidades que apresentam graus-hora de resfriamento maior do que 54 mil, que desconsidera o parâmetro de graus-hora de aquecimento.

Como parte de um estudo para melhoria de eficiência energética em edificações públicas, em 2018 o CBCS propôs o programa Cidades Eficientes (CBCS, 2018). No âmbito desse programa, foram obtidos dados de consumo energético dos edifícios públicos da cidade de Florianópolis, que resultaram na elaboração da plataforma de gerenciamento de edifícios públicos (CBCS, 2020), fornecendo subsídios para o desenvolvimento de *benchmarks* internos, que

proporcionam uma comparação da eficiência energética das edificações em operação na cidade. Gnecco (2021) utilizou os dados obtidos no âmbito desse programa e, após desenvolver um *benchmark* local de escolas públicas de ensino infantil para a cidade de Florianópolis por meio de regressão linear, realizou uma comparação com o *benchmark* de escolas desenvolvido pelo CBCS. O arquétipo de simulação proposto pela autora para o *benchmark* local é constituído de uma edificação térrea, diferentemente do proposto pelo CBCS, que apresenta dois pavimentos. Em uma análise de sensibilidade local, a autora identificou os parâmetros de densidade de potência de iluminação, a carga do sistema de condicionamento de ar e os cenários de uso do ar condicionado como mais influentes sobre o consumo energético da tipologia. Para 12 edifícios de validação do *benchmark* desenvolvido pela autora, a classificação obtida foi a mesma encontrada pelo *benchmark* nacional desenvolvido pelo CBCS, sendo 5 edificações com consumo típico, 6 edificações classificadas como ineficientes e 1 edificação classificada como eficiente.

Outros estudos realizados no Brasil também foram desenvolvidos, embora com menor banco de dados e escopo reduzido a escala regional. Ao analisar as áreas comuns de edificações comerciais de alto padrão na região metropolitana de São Paulo, Silva (2013) desenvolveu um modelo de *benchmark* utilizando o método de regressão de múltiplas variáveis. A partir de dados relacionados a idade, ocupação e tipo de condicionamento dos edifícios, foram estabelecidos consumos típicos e faixas de níveis de eficiência energética. O autor dividiu os edifícios em dois grupos: edifícios com condicionadores de ar central e edifícios com ar condicionado unitário. Foram sugeridas cinco faixas de eficiência energética, de acordo com a separação dos edifícios em faixas iguais de percentis. Os valores médios de intensidade no uso de energia encontrados pelo autor foram 145,70 kWh/(m².ano) para edificações com condicionamento de ar central, e 53,42 kWh/(m².ano) para edificações com ar condicionado unitário. Esses resultados indicam que os sistemas de condicionamento de ar central apresentam maior consumo em comparação com os sistemas unitários, o que pode ser explicado pelas maiores dificuldades de otimização do consumo energético. Os sistemas unitários podem ser operados individualmente, facilitando o aproveitamento da ventilação natural e o ajuste das temperaturas de operação e do período de funcionamento do sistema. Além disso, os edifícios de escritórios costumam ser compartilhados por diversas empresas, o que dificulta o controle de consumo individual de energia elétrica dos equipamentos centrais e, conseqüentemente, a avaliação e implantação de medidas de eficiência energética.

Ainda no contexto brasileiro de estudos relativos ao desenvolvimento de *benchmarks*, Veloso (2017) desenvolveu um *benchmark* de edificações de escritórios localizados em Belo Horizonte. A partir de 101 amostras, a autora realizou uma análise de sensibilidade de variáveis relacionadas a geometria das edificações e aos seus parâmetros construtivos, assim como relacionadas ao condicionamento de ar da edificação. Utilizando regressão linear multivariada, o

estudo teve como resultado uma previsão de intensidade de uso de energia em função do modo de condicionamento de ar, absorvância solar das paredes, fator solar dos vidros e fator de abertura de fachada. Essas variáveis foram determinadas pela autora como as mais importantes para a determinação do consumo energético dessa tipologia. A autora sugere ainda classificações das edificações em faixas entre “A” e “E”, sendo “A” a mais eficiente. As faixas assumem valores diferentes de acordo com o tipo e o modo de operação do condicionamento de ar utilizado na edificação.

Sobre estudos relacionados ao desempenho energético de edificações da área de saúde, Torres et al. (2018) desenvolvem um *benchmark* para hospitais filantrópicos, a partir de dados de 15 hospitais. Os autores avaliam que a maior medida de eficiência energética é a substituição de lâmpadas fluorescentes por lâmpadas LED. Esta medida indica a importância dos sistemas de iluminação sobre o consumo total dessa tipologia, aliada à facilidade de implementação e ao rápido retorno financeiro. Os autores sugerem a utilização de métricas de desempenho energético mais específicas para edificações de saúde, utilizando consumo energético por número de atendimentos, por número de funcionários, por número de especialidades e por quantidade de leitos, em conjunto com o indicador tradicional de consumo por área. A métrica de consumo energético por número de atendimentos é apontada pelos autores como uma das mais importantes, pois indica a eficiência energética com relação a atividade fim das edificações de saúde. No entanto, destaca-se a dificuldade na medição da quantidade de atendimentos realizados.

Geraldi et al. (2021), em uma avaliação dos impactos das restrições de uso de edifícios públicos em Florianópolis devido à pandemia da COVID-19, identificou uma redução média de 11,1% no consumo de energia elétrica nos centros de saúde. Essa redução ocorreu devido ao incentivo à telemedicina, reduzindo as consultas presenciais. Algumas atividades presenciais, como distribuição de remédios e atividades administrativas, se mantiveram presenciais, o que impossibilitou uma maior redução do consumo energético que foi observada em outros edifícios públicos, de 49,6 % a 61,4 %. Os autores ressaltam que essa redução no consumo no curto prazo não implica mudanças no longo prazo, pois medidas de supressão do vírus com o retorno das atividades presenciais podem até mesmo aumentar o consumo energético, como a implementação de ventilação forçada.

2.2. Métodos de *benchmark*

Os diferentes objetivos de cada *benchmark* e os diferentes tamanhos e graus de detalhamento dos bancos de dados disponíveis demandam diferentes métodos de desenvolvimento de *benchmark*. De acordo com Borgstein, Lamberts e Hensen (2016), os métodos de desenvolvimento de *benchmark* podem ser divididos em cinco categorias: cálculos de engenharia, simulação, métodos estatísticos, aprendizado de máquina e outros métodos.

2.2.1. Cálculos de engenharia

Os cálculos de engenharia consistem em utilizar equações que descrevam o comportamento térmico da edificação a partir de parâmetros físicos dos sistemas componentes. Têm como características a facilidade de uso, a utilização de parâmetros físicos e a alta velocidade de cálculo, e são utilizados em fases preliminares de projeto, em estimativas de desempenho energético e em verificações de eficácia de medidas de eficiência energética (BORGSTEIN; LAMBERTS; HENSEN, 2016).

Um dos tipos de cálculos de engenharia utilizados no desenvolvimento de *benchmarks* é o cálculo de uso final agregado. Esse método consiste em calcular o uso total de energia a partir da soma das estimativas de consumo de todos os sistemas presentes no edifício (BURMAN et al., 2014). O uso final agregado permite o desenvolvimento de *benchmarks* a partir dos sistemas, separadamente, sendo possível verificar as causas de ineficiência de determinado edifício, mas apresenta a desvantagem de não conseguir mensurar os consumos de energia devidos às interações entre os sistemas. A dificuldade de cálculo de consumo agregado se caracteriza principalmente nos sistemas de condicionamento de ar pois dependem de fatores climáticos dinâmicos, como temperatura externa e radiação solar, assim como as cargas térmicas relativas aos demais sistemas das edificações (BORGSTEIN; LAMBERTS; HENSEN, 2016). O método de uso final agregado foi utilizado para o desenvolvimento do *benchmark* ECON19 para edifícios de escritórios no Reino Unido (CIBSE, 2003), assim como para os *benchmarks* disponíveis na norma CIBSE TM46 (CIBSE, 2008), que se aplica para as principais tipologias do Reino Unido.

Federspiel, Zhang e Arens (2002) utilizaram o método do consumo agregado para determinar o consumo médio de edifícios de laboratórios, de forma a superar a falta de banco de dados de edifícios dessa tipologia. A partir da definição de um edifício ideal de referência, onde os sistemas funcionariam com o máximo de eficiência possível, os autores desenvolveram um *benchmark* que penaliza determinados tipos de sistemas considerados ineficientes, como elevadores hidráulicos, equipamentos de condicionamento de ar de volume constante e sistemas de iluminação de baixa eficiência energética. Com isso, podem ser identificadas oportunidades de melhorias nos sistemas identificados como ineficientes.

2.2.2. Simulação computacional

A simulação computacional consiste em modelar uma edificação virtual, que tem o consumo energético estimado por meio da entrada de diversos valores que caracterizam o edifício real, como as propriedades térmicas da envoltória, o tipo e a eficiência do sistema de condicionamento de ar, a potência de iluminação e de equipamentos, assim como o padrão de uso. As simulações demandam diversas

iterações para obter um resultado confiável, e dependem muito do conhecimento do projetista na ferramenta escolhida (BURMAN et al., 2014). A simulação computacional diferencia-se dos métodos de cálculos de engenharia apresentados, anteriormente, pois leva em consideração não apenas os sistemas presentes na edificação, isoladamente, mas também as interações entre esses sistemas.

O método de simulação computacional pode ser utilizado para verificar a influência de medidas de eficiência energética em edificações na fase de projeto. Após a calibração com dados medidos de uso e operação, o método de simulação também pode ser utilizado para a avaliação e monitoramento na fase operacional (BORGSTEIN; LAMBERTS; HENSEN, 2016). A falta de dados de consumo e de gerenciamento na fase de uso da edificação limita a comparação do consumo energético real com o projetado, caracterizando o *performance gap*. As principais causas de inexatidão são as condições operacionais, que incluem densidade de ocupantes, período de utilização, configuração da temperatura de funcionamento do condicionamento de ar, assim como o modo de operação das janelas (MENEZES et al., 2012).

O principal uso da simulação computacional como método de *benchmark* é no desenvolvimento de um modelo comparativo do desempenho energético atual da edificação com o seu desempenho esperado ou ideal, estabelecendo-se uma linha de base para o desempenho energético do edifício (CHUNG, 2011). A simulação computacional também pode ser utilizada para estimar o consumo de outras edificações de mesma tipologia, o que depende de arquétipos calibrados e validados (FUMO; MAGO; LUCK, 2010). *Benchmarks* que são desenvolvidos com a combinação de medidas de consumo de energia em edifícios reais e uma base de dados gerada a partir de simulações computacionais devem ser calibrados a partir de dados reais ou a partir de auditorias energéticas, para assegurar a consistência da análise comparativa (PÉREZ-LOMBARD et al., 2009). Destaca-se a possibilidade da análise do consumo por uso final como benefício do uso de simulação no desenvolvimento de *benchmark*, para permitir a verificação de oportunidades de melhoria na eficiência energética.

Atualmente, os principais programas de simulação computacional utilizados são o TRNSYS, desenvolvido pela Universidade de Wisconsin, e o EnergyPlus, desenvolvido pelo U.S. *Department of Energy* (DOE) (DOE, 2019). O EnergyPlus pode ser utilizado de maneira independente ou como motor de plataformas gráficas, como o DesignBuilder, o OpenStudio em conjunto com o SketchUp ou o Honeybee em associação ao Grasshopper, de forma a facilitar a confecção da geometria da edificação e a inserção das características construtivas e operativas desejadas (HARISH; KUMAR, 2016).

Em alguns casos, a simulação computacional é utilizada para desenvolver modelos de arquétipos, que são utilizados para representar um grupo de edifícios de uma determinada tipologia. O Departamento de Energia (DOE) dos Estados Unidos publicou uma série de modelos de referência para 16 tipologias de edifícios

comerciais, que englobam edifícios de escritórios, escolas, mercados, restaurantes, hospitais e hotéis de diferentes portes em 16 diferentes zonas climáticas dos Estados Unidos. O objetivo desse banco de dados de arquétipos é representar cerca de 70% dos edifícios comerciais americanos (DOE, 2012).

Katafygiotou and Serghides (2014) desenvolveram arquétipos de escolas no Chipre, localizado no Mediterrâneo, a partir de dados obtidos com questionários aplicados aos diretores das escolas, assim como visitas em campo. Com base nos modelos de simulação desenvolvidos no programa iSBEMcy, desenvolvido pelo governo do Chipre para modelagem computacional específica para as características construtivas e climáticas do país, foi possível desenvolver um *benchmark* da amostra. Como esta amostra representou grande parte da população total, foi possível identificar as principais características construtivas da tipologia de escolas desse país. A partir desses dados, foram analisadas possibilidades de *retrofit*, que consistiram em aumento do isolamento térmico da cobertura e das janelas.

Em uma análise de arquétipos de edifícios educacionais, Geraldi e Ghisi (2022) realizaram análise de agrupamento de dados e análise de entropia para definir formatos de geometrias representativas de edifícios dessa tipologia. Os autores propuseram sete diferentes formatos de arquétipos de simulação, que podem ser utilizados de acordo com a geometria da edificação real. Ainda foi proposto um *benchmark* para a tipologia, utilizando Redes Neurais Artificiais, que apresentou valor para a métrica de erro RMSE (Root Mean Squared Error) de 6,15 kWh/(m².ano). Os resultados de validação indicaram que 62,2% do estoque de edificações dessa tipologia apresentaram consumo energético maior do que o valor de *benchmark*, e uma análise de usos finais de energia indicou que ineficiências no sistema de iluminação e nos equipamentos, especialmente os refrigeradores, foram a causa desse maior consumo.

Considerando que a disponibilização de um banco de dados representativo para a implementação de um método de *benchmark* de determinada tipologia pode apresentar dificuldades técnicas e econômicas, Nikolaou et al. (2009b) desenvolveram um banco de dados virtual a partir de 30 mil simulações computacionais para desenvolver um *benchmark* nacional na Grécia, utilizando o programa TRNSYS. Os parâmetros de entrada foram estabelecidos a partir da legislação do país e de características construtivas típicas da região. O banco de dados virtual desenvolvido foi comparado com dois grupos de auditorias em diferentes zonas climáticas, apresentando resultados confiáveis.

2.2.3. Métodos estatísticos

Segundo Chung (2011), os principais métodos estatísticos de *benchmark* utilizados na literatura são: normalização simples, método dos mínimos quadrados (ou regressão simples), análise por envoltória de dados e análise de fronteira

estocástica. O método a ser escolhido depende da quantidade e grau de detalhamento do banco de dados disponível. A amostragem realizada deve refletir adequadamente a população total de edifícios, para que a análise estatística não apresente resultados enviesados (BORGSTEIN; LAMBERTS, 2014).

A normalização simples, também denominada estatística descritiva, consiste em utilizar apenas um parâmetro de entrada, como a área ou as horas diárias de operação, para obter o consumo energético típico da amostra de edifícios de mesma tipologia, por meio de análise estatística. A média ou a mediana é considerada como o valor típico de consumo e, para melhor visualização do comportamento do consumo da amostra, é possível realizar a divisão em faixas de percentis e utilizar histogramas, *boxplot* e outros tipos de gráficos. Esse método, apesar de ser simples e rápido, não leva em consideração especificidades dos edifícios, como o consumo do sistema de condicionamento de ar, elevadores e outros equipamentos. Destaca-se que os consumos energéticos devem ser ajustados de acordo com as variações climáticas. Uma das formas de realizar a correção climática é utilizando dados de graus-hora de resfriamento e aquecimento, que podem ser obtidos a partir de arquivos climáticos de cada local, selecionando-se uma faixa de temperatura dentro da qual considera-se uma situação de conforto ao usuário. O número de horas de desconforto acima ou abaixo dessa faixa de temperatura durante o ano é considerado o valor de graus-hora de resfriamento ou aquecimento, respectivamente.

Taylor et al. (2018) realizaram normalização simples em edifícios escolares do Reino Unido e em edifícios de escritórios da China, de forma a aproveitar os dados disponíveis de edifícios de cada país. Os dois países foram selecionados por representarem características climáticas contrastantes, assim como diferentes estágios de desenvolvimento urbano. Os resultados obtidos pelo estudo constataram que edificações etiquetadas como sendo eficientes pelos respectivos programas de etiquetagem nacionais não necessariamente apresentavam consumo de energia inferior quando comparados aos demais edifícios.

Boemi et al. (2011) obtiveram um valor de consumo típico de energia para hotéis da Grécia a partir de análise estatística descritiva, e concluíram que essa abordagem pode favorecer a eficiência energética desta tipologia. Li (2008) realizou uma análise estatística descritiva de 19 edifícios governamentais de Hong Kong, sugerindo medidas de eficiência energética a partir dos resultados. Métodos similares de estatística descritiva foram utilizados para comparar o desempenho energético de escolas na Argentina (FILIPPIN, 2000), o que caracteriza a simplicidade e a popularidade da aplicação desse método no desenvolvimento de *benchmarks* em verificações simples e estudos iniciais para o desenvolvimento de *benchmarks* mais complexos.

O método dos mínimos quadrados é utilizado em modelos de regressão simples e multivariada. Uma reta é ajustada de acordo com a distribuição dos pontos da amostra, de forma a minimizar o erro de predição. O programa *EnergyStar*, dos Estados Unidos, utiliza-se de *benchmarks* desenvolvidos por meio de regressões

lineares múltiplas, baseadas em diferentes características (COHEN; BORDASS, 2015), tomando como base o estudo de Sharp (1995). Este autor, após identificar que a média e a mediana não são indicadores confiáveis para *benchmarks* mais localizados, realizou diversas análises de regressão linear multivariadas com o objetivo de identificar as variáveis mais estatisticamente significantes para a determinação do consumo energético por área construída. Como resultado do estudo, o autor modelou um *benchmark* com os dados de edifícios da *Commercial Buildings Energy Consumption Survey* (CBECS), com base no logaritmo da densidade de ocupação, no número de computadores e em fatores relacionados ao condicionamento de ar, como a presença de economizadores.

Sabapathy et al. (2010) ao realizarem regressão linear de múltiplas variáveis utilizando dados de edifícios relacionados à tecnologia da informação na cidade de Bangalore, na Índia, definiram fatores relacionados à área, ocupação, idade do edifício e sistema de ventilação utilizado. Os resultados obtidos indicaram que um terço dos edifícios com certificação LEED apresentaram desempenho energético abaixo do esperado. O mesmo método foi utilizado para desenvolver o *benchmark* de edifícios de supermercados em Hong Kong (CHUNG; HUI; LAM, 2006). A partir de variáveis relacionadas a idade da edificação, as suas características de ocupação e o tipo de sistemas de iluminação e condicionamento de ar, os autores desenvolveram uma equação de regressão linear multivariada para estimar o consumo por metro quadrado de edifícios da tipologia avaliada.

Segundo Chung (2011), a análise por envoltória de dados é uma análise de múltiplas variáveis que compara as diferentes eficiências relativas de um conjunto homogêneo de edificações. Com isso, identifica-se fronteiras que podem ser utilizadas para caracterizar edifícios ineficientes. No entanto, a análise por envoltória de dados não pode ser utilizados para avaliar edifícios fora do banco de dados, pois as fronteiras estabelecidas não podem ser extrapoladas. Portanto, a análise por envoltória de dados pode ser aplicado em *benchmarks* internos, onde todos os dados relacionados aos edifícios a serem classificados já são conhecidos e utilizados para o estabelecimento das fronteiras, mas não tem aplicação recomendada para *benchmarks* públicos, em que serão classificados edifícios fora do banco de dados conhecido. Além disso, um banco de dados pequeno ou onde os edifícios sejam todos ineficientes pode prejudicar os resultados. Qualquer valor atípico dentro da amostra pode alterar o resultado significativamente.

Em um estudo de aplicação de *benchmark* energético em Taiwan, Lee (2008) utilizou-se a análise por envoltória de dados para classificar edifícios governamentais, caracterizando a eficiência energética de 47 edifícios e sugerindo um estudo mais aprofundado de medidas de redução de consumo energético, principalmente relacionado ao uso e operação, para os edifícios considerados ineficientes. Lee (2010), no desenvolvimento de *benchmark* de edifícios de escritórios em Taiwan, realizou, primeiramente, uma regressão linear do consumo de energia de cada edifício em função dos graus-hora de resfriamento, considerando 20 diferentes estações climáticas e estabelecendo a temperatura de base em 24°C. Em

seguida, aplicou a análise por envoltória de dados para classificar os edifícios analisados.

O método da análise de fronteira estocástica consiste em uma regressão pelo método dos mínimos quadrados, que separa variáveis de erro e fatores de ineficiência para prover resultados de eficiência relativa, de forma a melhorar a precisão das previsões de consumo para edifícios que não se encontram no banco de dados original (BORGSTEIN; LAMBERTS, 2014). A linha de regressão encontrada se torna uma fronteira de eficiência, que delimita edifícios de alto desempenho em *benchmarks* energéticos, sendo a ineficiência medida como a distância para a fronteira, uma vez que a variação aleatória seja removida (BORGSTEIN; LAMBERTS; HENSEN, 2016).

Yang, Roth e Jain (2018) desenvolveram um *benchmark* utilizando particionamento recursivo e análise de fronteira estocástica utilizando um banco de dados composto por 10 mil edifícios de 25 classificações de tipologias, localizados na cidade de Nova York. Os resultados do estudo indicaram um sistema de *benchmark* mais robusto quando comparado ao *EnergyStar*. Buck e Young (2007) utilizaram o método da fronteira estocástica para classificar edifícios comerciais do Canadá, utilizando o banco de dados do *Commercial and Institutional Building Energy Use Survey* (CIBEUS). Os autores avaliaram que edifícios públicos e de organizações sem fins lucrativos tendem a ser menos eficientes quando comparados com edifícios comerciais privados. Observou-se ainda que os edifícios comerciais que apresentam maiores consumos energéticos para aquecimento são aqueles preocupados com o conforto dos clientes, como restaurantes e locais recreativos.

Hsu (2014) ao realizar uma análise de regressão bayesiana com múltiplas variáveis em um banco de dados de edifícios comerciais da cidade de Nova York, identificou que o tamanho da edificação e os equipamentos específicos de cada edifício são as variáveis mais significativas. Esse resultado, obtido a partir de um grande banco de dados, confirma a ideia de manter os *benchmarks* simples, com poucos fatores de correção. O autor indica que a melhoria na operação poderia trazer mais resultados quando comparado com a substituição dos sistemas por aparelhos mais eficientes.

2.2.4. Aprendizado de máquina

Os métodos de aprendizado de máquina são caracterizados por modelos de predição a partir de um treinamento de algoritmo de programação. Os algoritmos de aprendizado de máquina são capazes de identificar, automaticamente, padrões não lineares a partir de um grande número de dados. Com isso, os modelos treinados se comportam melhor quando comparados à regressão linear para a aplicação de sistemas complexos, como o comportamento térmico e energético de edificações. Os três tipos de aprendizado de máquina são: 1. Classificação, em que o banco de dados é dividido em grupos com características semelhantes; 2. Regressão, em que

é realizada uma interpolação entre os valores do banco de dados para a identificação de resultados que não estejam no banco de dados, por meio de relações não-lineares; e 3. Previsão, em que é estabelecida uma estimativa de resultados futuros a partir de dados históricos. Os métodos de aprendizado de máquina também podem ser separados em dois tipos de treinamento: 1. Supervisionado, em que os dados apresentam algum tipo de rótulo ou parâmetro de saída e são aplicados métodos de regressão ou predição; e 2. Não supervisionado, em que não há rotulagem dos dados e é desejado realizar a classificação dos dados a partir de padrões reconhecidos pelos diferentes algoritmos de aprendizado de máquina (CHALAL et al., 2016).

O ramo de eficiência energética em edificações apresenta diversos estudos e aplicações de aprendizado de máquina, o que inclui o desenvolvimento de *benchmarks*. Segundo Ahmad et al. (2018), as aplicações de redes neurais artificiais assumem uma participação de 41% dos novos estudos de predição de uso de energia em edificações, seguidos da utilização de regressão linear (26%) e máquinas de vetor de suporte (12%). O principal problema na aplicação de aprendizado de máquina no desenvolvimento de *benchmarks* públicos é que o funcionamento interno não é visualizado, dificultando interpretações físicas dos resultados modelados (BORGSTEIN; LAMBERTS; HENSEN, 2016). Um exemplo de implementação do aprendizado de máquina é por meio de redes neurais artificiais (*Artificial Neural Network* - ANN), que relacionam as variáveis de entrada e de saída de forma análoga ao funcionamento dos neurônios. As redes neurais são utilizadas para resolver problemas complexos e com muitas variáveis. Não requerem informações detalhadas dos sistemas, mas aprendem as relações entre as variáveis de entrada e de saída utilizando dados históricos (KALOGIROU, 2005). Os diferentes algoritmos de ANN são constituídos de uma camada de entrada e uma camada de saída, assim como uma ou mais camadas internas, a depender da quantidade de dados de treinamento disponível. Quanto maior o número de neurônios e conexões entre eles, maior a quantidade necessária de dados de treinamento e maior a dificuldade computacional envolvida (YALCINTAS, 2006).

Hong et al. (2014) aplicou o método de redes neurais artificiais em um *benchmark* para escolas no Reino Unido, atingindo um erro percentual absoluto médio de 22% para o consumo de aquecimento e 20,6% para o consumo de eletricidade. Os resultados do autor indicaram diferenças significativas de comportamento energético entre escolas de ensino primário e secundário, o que direciona ao desenvolvimento de *benchmarks* diferentes para cada um dos níveis escolares. As escolas secundárias, em geral, consomem mais energia por aluno, devido a presença de salas de computadores, laboratórios e bibliotecas.

Yalcintas e Ozturk (2007) exploraram a possibilidade de utilizar redes neurais artificiais para *benchmark* de edifícios de escritórios nos Estados Unidos, utilizando a base de dados do CBECS. Após diversas tentativas, os autores definiram as variáveis mais importantes para o resultado final: horas de operação, idade do edifício, área por usuário, área por computador, porcentagem de resfriamento e

iluminação, graus-hora de resfriamento e número de pavimentos. Como resultado final, encontrou-se um coeficiente de correlação que variou entre 0,45 e 0,73 com a aplicação do método de redes neurais, permitindo estimar a intensidade do uso de energia de forma mais precisa quando comparado ao uso da regressão multivariada.

Outro possível método de utilização de aprendizado de máquina é a análise de agrupamento de dados (*clustering analysis*), que consiste em categorizar um banco de dados não identificados, de acordo com uma estrutura obtida a partir de padrões internos. Posteriormente, o *benchmark* é realizado dentro de cada agrupamento. Esse método é interessante para identificar agrupamentos e padrões dentro de um banco de dados (GAO, MALKAWI, 2014). O algoritmo mais utilizado de agrupamento de dados em análise de desempenho energético de edifícios é o *K-means*, que consiste na classificação do banco de dados por meio de centroides, o ponto médio de um cluster. Deve ser seguido por um método de validação, assegurando que o número ótimo de clusters foi encontrado. A avaliação dos resultados envolve a verificação do edifício mais próximo de cada centroide, ou uma média entre os edifícios dentro de cada cluster (COTTAFAVA et al., 2018).

Papadopoulos, Bonczak e Kontokosta (2018) desenvolveram um *benchmark* para edifícios comerciais localizados na cidade de Nova York, utilizando análise de agrupamento de dados. Os autores utilizaram o método de agrupamento de dados *K-means*, em que é necessário definir a quantidade desejada de grupos previamente ao treinamento do modelo, e apresentaram resultados para diferentes quantidades de clusters. Utilizando as métricas de avaliação *Silhouette Score* e *Dunn Index*, que indicam a similaridade entre as amostras dentro de cada cluster e as diferenças entre clusters, os autores determinaram que a utilização de dois *clusters* foi o mais representativo para as amostras avaliadas.

Schaefer e Ghisi (2016) desenvolveram modelos de referência (arquétipos) para edifícios de baixa renda em Florianópolis utilizando análise de agrupamento de dados, a partir de uma amostra de 103 unidades habitacionais. Os resultados apontaram para dois agrupamentos homogêneos, onde os centroides determinaram dois edifícios representativos da tipologia analisada, sendo um deles composto por três quartos e com área de 76 m², e o outro com dois quartos e com área de 37 m².

A árvore de decisão é um dos métodos de aprendizado de máquina utilizados para a classificação de *benchmarks* energéticos em edificações. Esse método apresenta a vantagem da visualização do comportamento do modelo, em uma estrutura semelhante a um fluxograma. Utilizando um banco de dados de 80 edifícios residenciais no Japão, Yu et al. (2010) desenvolveram uma classificação por meio do método de árvore de decisão. Os autores determinaram os consumos dos edifícios, utilizando diversas características construtivas e de ocupação, e os separaram em alto ou baixo consumo energético, considerando como critério a média dos valores de consumo por metro quadrado encontrados no banco de dados. O modelo desenvolvido apresentou elevada acurácia, podendo ser utilizado para uma identificação rápida da situação de consumo energético de determinado edifício.

Entretanto, destaca-se que o desenvolvimento de um modelo com mais grupos é desejado para uma classificação de *benchmark*. No entanto, para uma melhor divisão em diversos grupos, torna-se necessário um banco de dados maior, tanto em número de amostras quanto em quantidade de variáveis medidas.

A partir de dados de 1072 edifícios de escritórios na Coreia do Sul, Park et al. (2016) propuseram novos grupos de classificação de *benchmark* e os compararam com a classificação existente no país. Primeiramente, os autores realizaram uma análise de correlação entre as variáveis de entrada e o consumo energético por metro quadrado do banco de dados, de forma a identificar as variáveis mais relevantes para a aplicação no modelo a ser desenvolvido. Em seguida, treinaram um modelo de árvore de decisão, de forma a classificar os edifícios em seis grupos distintos, a depender de características construtivas e de operação. Por fim, realizaram uma análise de variância para confirmar estatisticamente os diferentes grupos. Os resultados dos autores indicaram que a classificação proposta pelo artigo apresentou maior acurácia quando comparado com a classificação em vigor na Coreia do Sul. Por se tratar de um banco de dados de edifícios concentrado em um determinado distrito do país, um resultado de *benchmark* com características mais representativas em relação ao *benchmark* nacional já era esperado pelos autores.

Há diversos algoritmos de composição de árvores de decisão, para melhorar a acurácia dos modelos desenvolvidos. Um desses algoritmos é o *Random Forest*, que realiza uma média de um grande número de árvores de decisão compostas de uma amostragem tanto dos parâmetros de entrada quanto das observações do banco de dados. Com o objetivo de comparar os resultados de regressão linear e de *Random Forests*, Tsanas e Xifara (2012) utilizaram um banco de dados virtual de edifícios residenciais, desenvolvido a partir de uma geometria fictícia. Os modelos foram desenvolvidos utilizando variáveis de geometria como parâmetros de entrada e as cargas térmicas de aquecimento e resfriamento como parâmetros de saída. Os resultados obtidos pelos autores indicam que o método de *Random Forests* apresenta um modelo de previsão de carga térmica com menores métricas de erro quando comparados com a regressão linear.

Outro método de composição de árvores de decisão é o *Gradient Tree Boosting*. O algoritmo desse método é composto de uma sequência de árvores de decisão que utiliza residuais da árvore de decisão anterior. Papadopoulos e Kontokosta (2019) propuseram uma nova classificação de *benchmark* para um banco de dados de 7500 edifícios residenciais da cidade de Nova York, comparando-a com a classificação *EnergyStar*, que apresenta resultados gerais para os Estados Unidos e utiliza o método de regressão linear multivariada. O método de *Gradient Tree Boosting* foi utilizado para realizar a análise de regressão e, em seguida, foi utilizado o método de clusterização *K-means* para identificar os grupos da classificação de *benchmark* em que os edifícios foram distribuídos. Os resultados do artigo indicam que o modelo desenvolvido pelos autores apresentou melhor performance preditiva do consumo energético das edificações, devido ao uso de um método de aprendizado de máquina que apresenta elevada acurácia, em

geral, superior a regressão linear. Além disso, o treinamento com um banco de dados de edifícios concentrado em uma cidade melhora o poder preditivo do modelo treinado, levando as especificidades de clima, uso e características construtivas de cada local.

Outro método de aprendizado de máquina que pode ser aplicado no desenvolvimento de *benchmarks* é o algoritmo de máquinas de vetor de suporte. Esse método realiza a divisão dos dados por meio de hiperplanos definidos a partir dos parâmetros utilizados (CHOU; BUI, 2014). O algoritmo de máquinas de vetor de suporte apresenta menor erro de predição para um baixo tamanho amostral quando comparado com o método de redes neurais artificiais, devido a característica de minimização de erro estrutural (*Structural Risk Minimization*) intrínseca desse algoritmo, e também por causa da menor quantidade de parâmetros a serem otimizados no treinamento do modelo (DONG; CAO; LEE, 2005). Massana et al. (2015) concluíram que o método de máquinas de vetor de suporte apresentou o menor erro percentual médio de predição quando comparado com os modelos de regressão linear múltipla e redes neurais artificiais, porém ao custo de um maior tempo computacional.

2.2.5. Outros métodos

Um dos métodos de *benchmark* que os autores não encaixam nas categorias citadas anteriormente é o método dinâmico, que realiza uma análise das medições em tempo real utilizando simulação computacional, cálculos de engenharia, estatística ou redes neurais artificiais (BORGSTEIN; LAMBERTS; HENSEN, 2016).

Menezes et al. (2012) propuseram um método para reduzir o *performance gap*, utilizando dados de ocupação no processo de simulação. Por meio de monitoramento do consumo de energia para o sistema de iluminação, equipamentos de escritório e aparelhos de cozinha, a cada trinta minutos, foi possível aumentar a exatidão do modelo de simulação de um edifício de escritórios de Londres, reduzindo o erro da predição de consumo de energia do modelo para menos de 3%.

O'Neill et al. (2014) também propuseram um método para integrar monitoramento e simulação em tempo real para desenvolver um modelo energético contínuo. Por meio de medições nos diversos sistemas de um edifício de escritórios nos Estados Unidos e com o auxílio de uma estação meteorológica instalada no local, os autores desenvolveram um modelo de simulação que identifica possíveis falhas nos sistemas do edifício, assim como potenciais medidas de eficiência energética. O estudo apontou que uma discrepância maior que 5% entre os consumos energéticos simulado e real podem indicar um mal funcionamento de determinado sistema do edifício. O estudo indicou ainda que uma reestruturação da programação dos períodos de funcionamento do sistema de iluminação do edifício poderia reduzir o consumo de energia elétrica desse sistema em torno de 23%.

Outro método de avaliação do desempenho energético das edificações é a auditoria energética, também denominado diagnóstico energético, que consiste em

medições de consumo final de energia padronizadas pela ISO 50002 (ABNT, 2014). As auditorias energéticas são fundamentais para o desenvolvimento de outros métodos de *benchmark*, pois trazem dados mais precisos de consumo dos equipamentos para os cálculos de engenharia e a simulação computacional. Também podem ser utilizadas para caracterizar mais detalhadamente as possíveis medidas de eficiência energética, com seus respectivos custos de instalação e períodos de retorno (BORGSTEIN; LAMBERTS; HENSEN, 2016).

2.3. Classificações dos métodos de *benchmark*

Uma das classificações dos métodos de *benchmark* encontradas na literatura divide-os em *top-down* e *bottom-up*. Os métodos *top-down* utilizam-se de dados mais amplos dos edifícios, como dados de consumo anual de energia. Classificam-se nesse grupo os métodos estatísticos e o aprendizado de máquina. Os métodos *top-down* são mais utilizados para comparação entre edifícios de mesma tipologia, fornecendo um *feedback* relativo a seus pares, porém não fornecem estimativas precisas de eficiência energética de cada sistema separadamente, e são altamente dependentes da disponibilização de dados atualizados, em quantidade suficiente e representativos da população de edifícios (HONG et al., 2013).

Hong et al. (2013) ao analisarem os benefícios e limitações dos métodos *top-down* no desenvolvimento de um *benchmark* para escolas do Reino Unido, concluíram que a exatidão do método estatístico é altamente dependente do tamanho da amostra obtida, apesar de exigir pouco detalhamento para cada edifício. Além disso, a rede neural artificial do tipo *feed-forward*, utilizada no estudo, apresentou resultado mais robusto em comparação com o método de estatística descritiva, ao custo de uma maior complexidade de treinamento e otimização. Nesse estudo, a principal variável influenciadora do consumo de energia elétrica foi o número de alunos, o que indica que esse fator é preponderante sobre a área construída.

Já os métodos *bottom-up* necessitam de dados detalhados dos sistemas presentes nas edificações. Esse grupo constitui-se dos métodos de cálculo de engenharia e da simulação computacional. Tais métodos têm o potencial de fornecer resultados mais precisos e específicos de consumo e de eficiência energética, porém são mais custosos, pois necessitam de dados de uso mais detalhados. Os consumos de cada sistema são agregados para que seja verificado um único parâmetro de eficiência energética do edifício como um todo, mas, como os métodos *bottom-up* podem capturar características específicas de cada sistema do edifício, as oportunidades de melhoria na eficiência energética podem ser identificadas mais facilmente.

Burman et al. (2014), em continuação aos estudos de Hong et al. (2013), utilizaram os métodos de uso final agregado e simulação computacional para a comparação com os demais métodos. Foi demonstrado que pequenos desvios no

sistema de ventilação podem levar a um aumento de até dez vezes no consumo desse sistema. Os autores citam que uma forma de integrar os métodos *top-down* e *bottom-up* consiste em utilizar um método estatístico para comparar determinado edifício com outros edifícios de mesma tipologia, e em seguida realizar a simulação computacional ou uso final agregado, com uma comparação entre o estado de utilização atual e indicadores de referência, para fornecer possíveis medidas de eficiência energéticas para os edifícios com desempenho energético inferior dentro do grupo analisado.

Outra classificação dos métodos de *benchmark* é proposta por Li, Han e Xu (2014), que os divide em *white box*, *black box* e *grey box*, de acordo com a necessidade de dados mais detalhados de cada edificação. Os métodos *white box* são baseados em modelos dos sistemas físicos da edificação e demandam bastante esforço para ser calculado. Dentro dessa categoria, incluem-se os cálculos de engenharia. Os métodos *black box* consistem em análises estatísticas, com poucas informações sobre os sistemas construtivos, e são mais úteis para modelagens rápidas e para *benchmarks* públicos. Os métodos *grey box* são mistos e combinam dados dos sistemas com métodos estatísticos, e têm como exemplo o método de rede bayesiana e o método de grau-hora de resfriamento e aquecimento. Também se incluem na classificação *grey box* os metamodelos, combinando características de simulação e modelos estatísticos, de forma que uma amostra simulada corresponda à um universo de edificações de uma faixa desejada de parâmetros (VERSAGE, 2015).

2.4. Diagnóstico energético

O diagnóstico energético, também conhecido como auditoria energética, consiste em identificar e mensurar os consumos de energia de uma edificação, assim como determinar possíveis melhorias de eficiência energética (ABNT, 2014). As auditorias energéticas são utilizadas para identificar problemas no uso, operação e manutenção dos edifícios que possam acarretar em redução do desempenho energético ou falhas no atendimento a normas técnicas e parâmetros de conforto ambiental. Os dados coletados durante os diagnósticos energéticos são importantes para estabelecer a base de dados necessária ao desenvolvimento de *benchmarks*, para que os modelos estabelecidos sejam representativos dos edifícios reais em operação.

Durante o processo de diagnóstico energético de uma edificação, são realizadas medidas diretas do uso final de energia, o que possibilita a identificação de ajustes operacionais ou manutenções de baixo custo para melhorias imediatas da eficiência energética do edifício, assim como favorece o desenvolvimento de um plano de implementação de medidas de eficiência energética a longo prazo, com estimativas de custo e período de retorno dos investimentos (PNNL, 2011).

O procedimento de diagnóstico energético consiste em, primeiramente, identificar os principais aspectos do edifício. Em seguida, realiza-se um planejamento da visita técnica a partir do levantamento preliminar de dados do edifício. O passo seguinte é a visita técnica, que consiste em obter os dados necessários ao nível de detalhamento desejado. O diagnóstico energético é encerrado com a apresentação de um relatório, no qual são listados os dados obtidos, as análises realizadas e as medidas de eficiência energética sugeridas, com suas respectivas análises financeiras (CBCS, 2016).

As auditorias energéticas são divididas pela ASHRAE (2011) em três níveis de detalhamento. O nível I é caracterizado pela análise de contas de energia e uma inspeção breve no interior do edifício (*walkthrough*). O nível II já inclui uma pesquisa mais refinada dos usos finais de energia e da eficiência energética dos equipamentos utilizados, e o nível III exige monitoramento e coleta de dados detalhados dos usos finais de energia.

O consumo de cada equipamento pode ser estimado pela potência e tempo de uso, ou medido com os equipamentos adequados para os dados desejados. Devem ser medidos os equipamentos em pleno funcionamento, ou seja, o sistema de condicionamento de ar deve ser medido nos dias mais quentes/frios do ano para a identificação do maior consumo de resfriamento/aquecimento, e o consumo dos computadores deve ser medido em dias de ocupação máxima, por exemplo. Por outro lado, períodos de ocupação mínima permitem medições de consumo dos equipamentos em *stand-by* (CIBSE, 2004).

A implementação de medidas de eficiência energética desenvolvidas a partir dos resultados do diagnóstico energético pode, além de reduzir o consumo de energia, melhorar o conforto do ambiente, considerando as preferências individuais. Um dos exemplos é o aumento do *setpoint* de resfriamento dos sistemas de condicionamento de ar acompanhado do uso de ventiladores individuais (ANDRÉ, 2019). Também é possível ampliar o uso de iluminação natural e proporcionar o uso de luminárias individuais para complementar a luminância quando necessário.

2.5. Análise de sensibilidade

Em simulações computacionais energéticas, considerando que pequenas variações de determinados parâmetros de entrada podem causar grandes variações nos parâmetros de saída, torna-se importante a verificação das variáveis mais influentes no desempenho energético da edificação analisada. A análise de sensibilidade é uma ferramenta que permite avaliar como diferentes parâmetros de entrada de um modelo influenciam nos parâmetros de saída, fornecendo critérios para classificar as variáveis principais que devem ser consideradas na calibração e validação do modelo (SALTELLI, TARANTOLA, CAMPOLONGO, 2000).

A análise de sensibilidade pode ser realizada por meio de métodos locais ou globais. Os métodos de análise de sensibilidade locais são baseados na variação de

uma variável de entrada de cada vez, enquanto todos os outros parâmetros de projeto são mantidos constantes. Com isso, verifica-se a influência de cada variável em torno de um caso de referência. Este método caracteriza-se pela baixa complexidade e baixo custo computacional, porém não permite verificar a interação entre as variáveis. Já o método de análise de sensibilidade global se refere à variação de todos os parâmetros, simultaneamente, portanto verifica todo o espaço possível de variáveis de entrada (TIAN, 2013). Os métodos de análise de sensibilidade global permitem verificar os efeitos de primeira ordem e de ordens superiores. Os efeitos de primeira ordem indicam o quanto a variação de cada parâmetro de entrada impacta nos dados de saída, enquanto que os efeitos de segunda ordem são causados pela interação de dois parâmetros de entrada sobre a variável de saída.

Quanto à faixa de variação dos parâmetros de entrada a serem analisados, Tian (2013) sugere distribuições uniformes para parâmetros de projeto, pois assume-se que os diferentes valores para os dados de entrada são igualmente prováveis. No entanto, se forem considerados parâmetros sujeitos a incertezas e que apresentem tendência central, como as propriedades térmicas da envoltória com características definidas em projeto, mas dependentes de pequenas variações construtivas, deve ser utilizada a distribuição normal. Como as variações dos parâmetros na fase de projeto costumam ser maiores do que as variações relativas às incertezas construtivas, costuma-se desprezar estas últimas.

Podem ser encontrados na literatura diversos métodos de análise de sensibilidade global, baseados em regressão, variância ou metamodelo (TIAN, 2013). Os métodos de análise de sensibilidade global de Morris (1991) e de Sobol (2001) são os mais utilizados em simulação energética computacional de edificações. O método de Morris, denominado Método de Efeitos Elementares, propõe o uso de planos de amostragem fatorial para que o efeito na variável de saída seja devido apenas à variação de uma variável de entrada em particular. Com isso, variáveis que exerçam menor influência no resultado final podem ser excluídas sem gerar um erro muito significativo no modelo.

Sobol (2001) desenvolveu um dos métodos baseados em variância para a análise de sensibilidade global. A partir do cálculo de variância do parâmetro de saída, esse método é capaz de estimar a sensibilidade total, representada pela soma dos efeitos de primeira ordem e de ordens superiores, dos parâmetros envolvidos. O método de análise de sensibilidade de Sobol consiste em, primeiramente, utilizar o método de amostragem de Sobol de acordo com parâmetros de entrada a serem analisados e seus respectivos limites mínimo e máximo para o desenvolvimento da amostra, para posterior simulação da amostra desenvolvida. A amostragem de Sobol é realizada a partir de sequências de Sobol, que efetua uma amostragem pseudoaleatória de forma que as amostras estejam distribuídas, uniformemente, dentro do hipercubo constituído por todas as possibilidades de variáveis de entrada (BURHENNE; JACOB; HENZE, 2011). Posteriormente, Saltelli (2002) propôs um método de amostragem que reduz o erro

dos cálculos nos métodos de análise de sensibilidade global baseados em variância, incluindo as sequências de Sobol. Ao alterar a fórmula de cálculo da quantidade de amostras, o autor estabeleceu uma amostragem com custo computacional até 50% menor do que outros métodos de análise de sensibilidade global.

Em um estudo de um arquétipo representativo de edifícios de escritórios com características construtivas típicas do Irã, Delgarm et al. (2018) compararam os resultados de análises de sensibilidade local (*one-factor-at-a-time* - OFAT) e global (índices de sensibilidade de Sobol) na determinação dos fatores mais significativos para a determinação do desempenho energético da tipologia analisada. Os autores determinaram que o tamanho das aberturas, a orientação do edifício e a transmitância solar dos vidros eram as variáveis mais importantes para a determinação do consumo de energia para resfriamento do modelo estudado. As variáveis de entrada que apresentaram comportamento, aproximadamente, linear com o parâmetro de saída foram classificadas em níveis de importância semelhantes tanto pela análise de sensibilidade local quanto pela análise de Sobol. Destaca-se a importância da utilização de métodos de análise de sensibilidade global para a verificação de variáveis de entrada que não apresentam comportamento linear no processo de modelagem energética de edificações.

Ao realizar a análise de sensibilidade de Sobol para o metamodelo de edificações de escritórios ventilados naturalmente, Olinger (2019) verificou que o fator de abertura das janelas mostrou-se, significativamente, mais influente do que os demais parâmetros. Gunay et al. (2019) realizaram uma análise de sensibilidade em parâmetros operacionais de edifícios de escritórios no Canadá, e observaram que possíveis mudanças no comportamento dos usuários e da configuração dos sistemas de condicionamento de ar influenciaria na melhoria da eficiência energética das edificações analisadas.

Em uma análise de sensibilidade das variáveis envolvidas no desenvolvimento de um *benchmark* para escolas do Reino Unido, Hong et al. (2014) identifica que o número de alunos, assim como a área construída, são os parâmetros mais impactantes sobre o consumo de energia elétrica de edifícios dessa tipologia, enquanto que a compactidade e o ano de construção são as variáveis mais importantes para o consumo de gás para aquecimento. A compactidade tem relação com o perímetro da edificação exposto ao ambiente externo, e indica a superfície pela qual há perda de calor de aquecimento no inverno, o que corrobora a importância dessa variável para o consumo de gás. Nessa mesma lógica, o ano de construção é indicativo de possíveis vazamentos e ineficiências dos sistemas de aquecimento, impactando no consumo de gás dos edifícios mais antigos.

Com o objetivo de avaliar quais os parâmetros mais significativos sobre o consumo de edificações habitacionais sociais unifamiliares e térreas localizados em Florianópolis com operação mista, Silva e Ghisi (2020) realizaram, primeiramente, uma análise de sensibilidade local, e em seguida uma análise de sensibilidade

global pelo método de Morris. Os resultados indicaram uma grande influência da absorvância solar e da transmitância térmica da cobertura sobre os graus-hora de resfriamento e aquecimento. Já para o consumo de energia elétrica para resfriamento, o parâmetro de entrada mais influente foi a capacidade térmica da cobertura. Com isso, aponta-se a importância da escolha dos parâmetros térmicos da cobertura para o conforto dos ocupantes dessa tipologia ao se utilizar ventilação natural, assim como para reduzir o consumo energético com a implantação de condicionamento artificial.

2.6. Síntese

Neste capítulo de revisão bibliográfica, foram apresentados os principais tópicos relacionados ao tema deste trabalho. Primeiramente, foram citadas as definições de *benchmark*, suas características e sua importância para a eficiência energética em edificações. Evidencia-se a utilização de *benchmarks* como parâmetro de comparação entre edifícios semelhantes em uso, com o objetivo de selecionar os edifícios que apresentam maior potencial para a aplicação de medidas de eficiência energética. Em seguida, foram apresentados exemplos internacionais de utilização de *benchmark* e as dificuldades e esforços relacionados a implantação de *benchmarks* brasileiros. Percebe-se a lacuna de dados e estudos relacionados ao desenvolvimento de *benchmarks* nacionais, e os esforços recentes do CBCS no âmbito dos programas DEO e Cidades Eficientes, além da parceria com a Eletrobras no âmbito do DEO que resultou no desenvolvimento de *benchmarks* para 15 tipologias, inclusive para centros de saúde.

Posteriormente, os principais métodos de *benchmark* foram apresentados. Destacando os métodos mais tradicionais, como estatística descritiva e cálculos de engenharia, que são a base de *benchmarks* já consagrados como o ECON19 e o TM46 do CIBSE, até a aplicação de conceitos relativamente modernos como o aprendizado de máquina. As possibilidades de metodologias de *benchmark* são amplas e dependem das condições de disponibilidade de dados de edifícios em operação, da capacidade de processamento disponível e da relação entre complexidade e exatidão do *benchmark* desenvolvido. O método de simulação tem sua importância evidenciada quando não há muitos dados disponíveis do estoque de edificações, pois permite a elaboração de um banco de dados virtual. No entanto, surgem preocupações quanto a adequada calibração dos modelos de simulação, pois os resultados de consumo obtidos podem não corresponder ao consumo real das edificações. Além disso, a elaboração de modelos com muitos parâmetros de entrada dificulta a utilização da escala de *benchmark*, na medida que exige uma grande quantidade de medições no local.

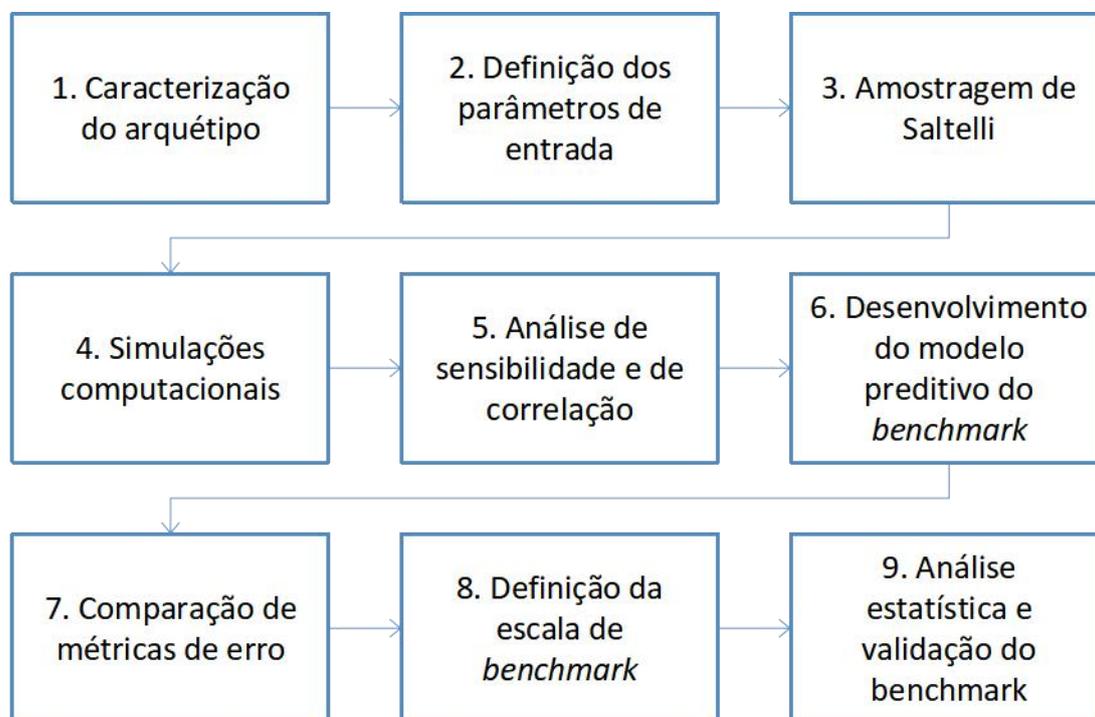
O diagnóstico energético de edifícios em operação torna-se uma etapa importante no desenvolvimento de um *benchmark*, na medida em que oferece o banco de dados necessário para a aplicação dos diferentes métodos. No entanto, fatores técnicos e econômicos podem inviabilizar a obtenção de uma amostra representativa de um conjunto de edifícios.

Por fim, a análise de sensibilidade é caracterizada como uma ferramenta importante para a análise de eficiência energética em edificações. Por meio de diversas técnicas estatísticas, é possível determinar as variáveis mais impactantes sobre o desempenho energético das edificações, o que auxilia na identificação dos parâmetros mais importantes a serem avaliados na elaboração de uma classificação de *benchmark*.

3. Método

Neste capítulo, é descrito o processo adotado para o desenvolvimento de *benchmark* para centros de saúde. Primeiramente, foi caracterizado o arquétipo da tipologia de centros de saúde. Após essa etapa, foram definidos os parâmetros de entrada fixos e variados para as simulações computacionais. O próximo passo foi a realização de uma amostragem de Saltelli (2002) para a definição dos parâmetros a serem simulados. Em seguida, as simulações computacionais foram realizadas, com a posterior análise de sensibilidade e de correlação, com o objetivo de identificar as variáveis mais significativas no modelo. As simulações foram realizadas utilizando os dados climáticos de oito cidades representativas dos diferentes climas brasileiros: Campos do Jordão/SP, São Paulo/SP, Florianópolis/SC, Campinas/SP, Rio de Janeiro/RJ, Vitória/ES, Recife/PE e Fortaleza/CE. Posteriormente, foi desenvolvido o modelo preditivo do *benchmark*, com os parâmetros que apresentaram maior influência no dado de saída estabelecido. Finalmente, a validação do *benchmark* foi realizada, por meio da comparação dos resultados do modelo desenvolvido com os dados de consumo de energia elétrica de edifícios reais de centros de saúde de Florianópolis. Para a validação do modelo, foram ainda utilizados dois projetos de edifícios de centros de saúde de Florianópolis, fornecidos pela Prefeitura da cidade. O fluxograma da metodologia utilizada neste trabalho é apresentado na Figura 1.

Figura 1 – Fluxograma da metodologia utilizada neste trabalho.

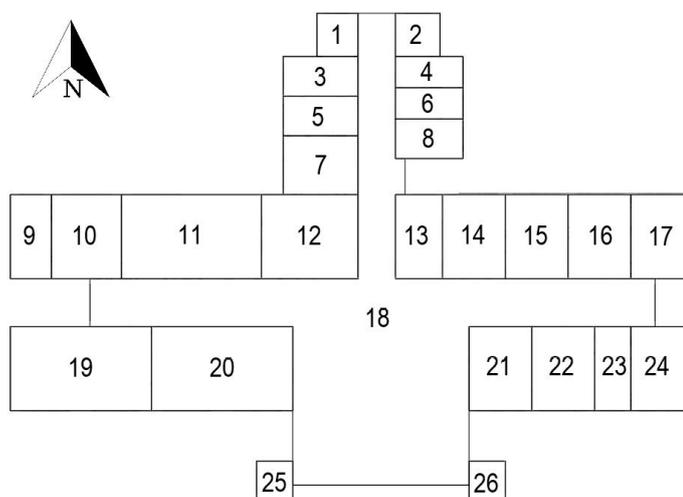


3.1. Caracterização do arquétipo

Define-se arquétipo como um modelo de simulação que representa as características típicas de uma tipologia, incluindo fatores construtivos e de utilização. Para a caracterização do arquétipo de postos de saúde, adotou-se o padrão do Ministério da Saúde (BRASIL, 2013) para Unidades Básicas de Saúde (UBS), no âmbito do programa Requalifica UBS. Nesse programa, foram propostas quatro tipologias de UBS, em razão do tamanho da equipe de saúde necessária para atender a população do entorno. O projeto utilizado neste trabalho é o UBS II, com 321,0 m² de área construída em um pavimento térreo. Esse arquétipo é o mesmo utilizado no estudo do CBCS em andamento para o desenvolvimento de *benchmark* de centros de saúde (VELOSO et al., 2021), com diferenças relacionadas às simplificações de zonas térmicas. Nas simulações, cada ambiente foi considerado como uma zona térmica.

A divisão da área construída do arquétipo em zonas térmicas é indicada na Figura 2. A descrição dos ambientes das zonas térmicas, assim como suas respectivas áreas, é apresentada na Tabela 1. A edificação é caracterizada por dois grupos de zonas térmicas com tipologias distintas. No primeiro grupo, representado pelas zonas térmicas 1 a 7, evidencia-se a ocupação administrativa, com tipologia semelhante aos edifícios de escritórios. No segundo grupo, simbolizado pelas zonas térmicas 8 a 19, configura-se a utilização para atendimento de pacientes, apresentando salas de consultórios e laboratórios. Observa-se que a maior área se encontra na zona térmica 18 (circulação e sala de espera) e corresponde a 112,8 m², seguida pelas zonas 19 e 20 (consultórios odontológicos), que correspondem a 20,5 m². As menores áreas se encontram nas zonas térmicas 25 e 26 (sanitários), e correspondem a 2,5 m², seguidas pela zona térmica 1 (almoxarifado), de 3,1 m².

Figura 2 – Planta baixa do projeto padrão de postos de saúde UBS II, com a separação em zonas térmicas.



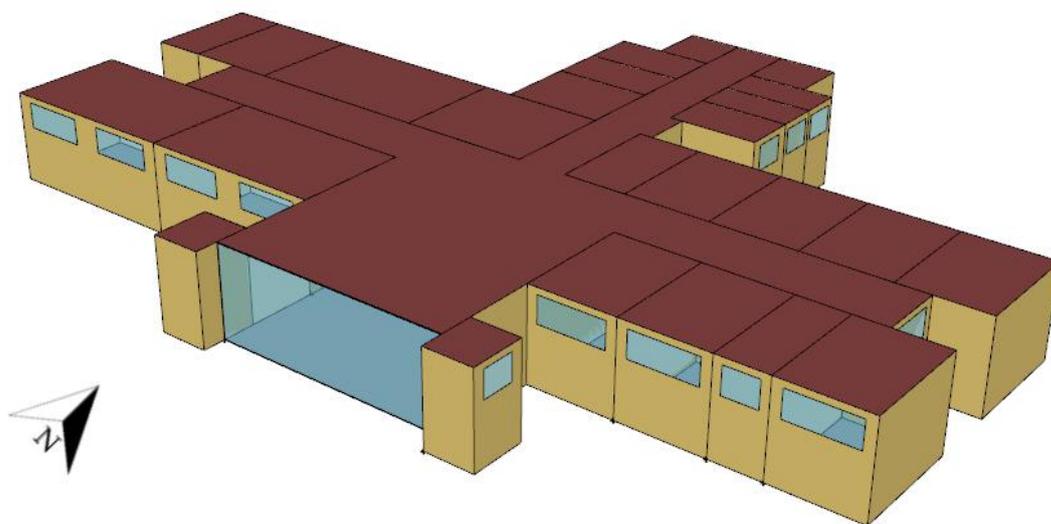
Fonte: (BRASIL, 2013).

Tabela 1 – Descrição das zonas térmicas.

Nº da zona térmica	Ambiente da zona térmica	Área (m²)
1	Almoxarifado	3,1
2	Depósito	3,3
3	Expurgo	5,1
4	Sanitário	3,6
5	Sala de esterilização	5,1
6	Sanitário	3,6
7	Sala de administração	7,6
8	Copa	4,6
9	Sanitário	5,9
10	Sala de coleta	10,1
11	Sala coletiva	20,3
12	Sala de medicamentos	14,0
13	Sala de inalação	6,8
14	Consultório médico	9,1
15	Consultório médico	9,1
16	Consultório médico	9,1
17	Consultório médico	9,1
18	Circulação e sala de espera	112,8
19	Consultório odontológico	20,5
20	Consultório odontológico	20,5
21	Sala de vacinação	9,1
22	Consultório médico	9,1
23	Sanitário	5,2
24	Consultório médico	9,1
25	Sanitário	2,6
26	Sanitário	2,6

O modelo do arquétipo em três dimensões é apresentado na Figura 3. A edificação apresenta largura total de 29,5 m e comprimento de 20,7 m, com pé-direito de 2,80 m.

Figura 3 – Arquétipo em 3D.



Fonte: Autor.

3.2. Definição dos parâmetros de entrada

No desenvolvimento de um *benchmark*, destaca-se a importância de avaliar quais os parâmetros de entrada apresentam maior influência sobre os parâmetros de saída. Para realizar essa avaliação, determina-se os parâmetros que serão perturbados e os parâmetros adotados para a análise de sensibilidade e de correlação. Neste trabalho, os parâmetros de entrada selecionados como fixos são a geometria da edificação, a densidade de potência de equipamentos, os parâmetros de contato da edificação com o solo e a taxa de infiltração de ar. Os parâmetros variados estão relacionados à orientação da edificação e aos seus materiais construtivos, assim como a densidade de potência de iluminação, a densidade e o período de ocupação, as características do sistema de condicionamento de ar e os dados climáticos para diferentes cidades. Foi considerada a variação de 12 parâmetros.

3.2.1. Parâmetros de entrada fixos

Para o desenvolvimento das simulações computacionais, foi utilizado o programa EnergyPlus, versão 9.2.0. (DOE, 2019), em conjunto com o programa OpenStudio, em sua versão 2.9.1 (NREL, 2019). A atividade realizada pelos visitantes no centro de saúde é considerada leve, portanto, a taxa metabólica para esse tipo de atividade é definida como 93 W por metro quadrado de pele, conforme valores obtidos na norma ISO 7730 (ISO, 2005). Cada pessoa tem, em média, 1,8 m² de pele, resultando em uma taxa metabólica de 167 W/pessoa. A fração radiante considerada é de 30%.

A partir da análise de projetos de centros de saúde fornecidos pela prefeitura de Florianópolis, ficou estabelecida a densidade de potência de equipamentos (DPE) no valor de 10 W/m². A partir da avaliação de projetos de edifícios de centros de saúde, verificou-se pouca variação nos equipamentos instalados, sendo este considerado como fixo e, aproximadamente, o mesmo valor utilizado pelo *benchmark* de centros de saúde do CBCS. O modelo de simulação do CBCS considerou valores diferentes de potência de equipamentos para cada zona térmica, baseando-se em valores obtidos pelo projeto META e por diagnósticos energéticos. O valor utilizado neste trabalho para a densidade de potência de equipamentos é aproximadamente a média da potência desses equipamentos para toda a área da edificação.

A taxa de infiltração de ar especificada para todas as zonas é de 0,5 trocas de ar por hora, incluído no objeto *ZoneVentilation:DesignFlowRate* do programa EnergyPlus.

A influência da temperatura do solo foi modelada por meio dos objetos *Site:GroundTemperature* e *Ground Domain*, utilizando o método de diferenças finitas e seguindo os procedimentos descritos no manual específico do Laboratório de Eficiência Energética em Edificações (ELI et al., 2019). Ainda com relação ao contato da edificação com o solo, foi simulado um elemento construtivo composto de piso cerâmico e contrapiso de 5 cm, com as características resultantes de 4,53 W/(m².K) para a transmitância térmica e 114 kJ/(m².K) para a capacidade térmica.

Como parâmetro de saída foi utilizado o consumo de energia elétrica total da edificação, definido no programa EnergyPlus como *Electricity: Facility*. Além disso, para obter os consumos por uso final da edificação, separadamente, foram incluídos os objetos *InteriorLights:Electricity*, *InteriorEquipment:Electricity*, *Fans:Electricity*, *Heating:Electricity* e *Cooling:Electricity*. Com esses dados de saída, foi possível calcular o Indicador de Uso de Energia (*Energy Use Intensity* – EUI) para o consumo total de energia e para o consumo de energia por uso final, por metro quadrado da edificação.

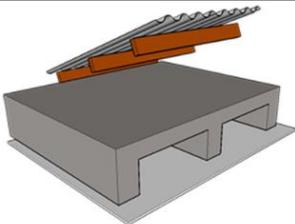
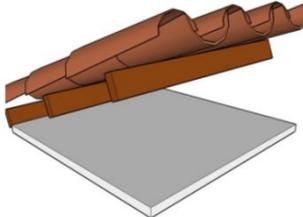
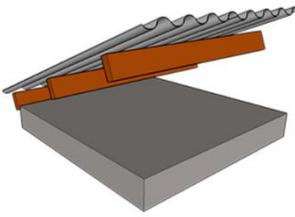
3.2.2. Parâmetros de entrada variados

Para o desenvolvimento das simulações computacionais, foram selecionados os valores mínimo, máximo ou o caso intermediário, conforme metodologia de amostragem mencionada no item 3.3. Os extremos escolhidos visam abranger valores típicos de materiais construtivos utilizados em centros de saúde, levando em consideração os valores utilizados no *benchmark* de centros de saúde do CBCS e ajustando com informações obtidas por meio de conversas com a projetista de centros de saúde da Prefeitura de Florianópolis, assim como projetos fornecidos dessa tipologia.

Os parâmetros de entrada variados relativos às características dos materiais construtivos da edificação são os tipos construtivos da cobertura e das paredes

externas, assim como o fator solar dos vidros das aberturas. Para os tipos construtivos da cobertura, tem-se o limite inferior de transmitância térmica caracterizado por uma cobertura de telhas de fibrocimento em associação com uma câmara de ar, uma laje nervurada sem preenchimento de 22,5 cm de espessura e forro de gesso de 1 cm de espessura. Esse tipo construtivo apresenta transmitância térmica de 1,55 W/(m².K) e capacidade térmica de 237 kJ/(m².K). O caso intermediário de transmitância térmica é representado por uma cobertura de telhas cerâmicas de 1 cm de espessura, associada a uma câmara de ar e forro de gesso de 3 cm de espessura, com as características de transmitância térmica de 1,94 W/(m².K) e capacidade térmica de 37 kJ/(m².K). Já o limite superior de transmitância térmica é composto por uma cobertura de telhas de fibrocimento de 0,8 cm de espessura, associada a uma câmara de ar e laje maciça de concreto de 10 cm de espessura. Esse tipo construtivo apresenta transmitância térmica de 2,06 W/(m².K) e capacidade térmica de 233 kJ/(m².K). O tipo construtivo equivalente ao limite superior é o mais encontrado nas edificações da tipologia de centros de saúde, e os demais casos considerados têm como objetivo caracterizar possíveis variações na transmitância e na capacidade térmica. As características dos casos considerados para os tipos construtivos da cobertura são resumidas na Tabela 2.

Tabela 2 – Materiais construtivos da cobertura para o limite inferior, o caso intermediário e o limite superior.

	Limite inferior	Caso intermediário	Limite superior
Tipo de cobertura			
Transmitância térmica [W/(m².K)]	1,55	1,94	2,06
Capacidade térmica [kJ/(m².K)]	237	37	233

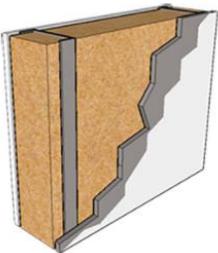
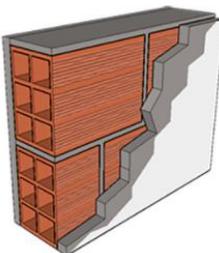
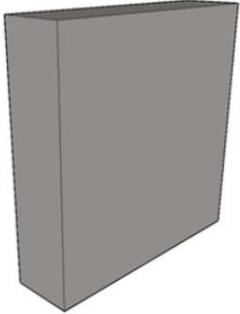
Fonte: (INMETRO, 2013a).

Com relação aos tipos construtivos das paredes externas, para o limite inferior de transmitância térmica foi adotado um tipo de parede de drywall composta de uma placa de gesso de 1,25 cm de espessura, uma camada de lã de rocha de 9 cm de espessura e uma placa cimentícia externa de 1 cm de espessura. Esse tipo construtivo apresenta transmitância térmica de 0,45 W/(m².K) e capacidade térmica de 33 kJ/(m².K). Para o caso intermediário de transmitância térmica foi adotada uma parede composta por bloco cerâmico de 9 cm de espessura, revestida por

argamassa interna e externa de 2,5 cm de espessura, com as características de transmitância térmica de 2,46 W/(m².K) e capacidade térmica de 150 kJ/(m².K). Já para o limite superior de transmitância térmica, foi adotada a parede de concreto maciço de 10 cm de espessura, com as características de transmitância térmica de 4,40 W/(m².K) e capacidade térmica de 240 kJ/(m².K). As características dos tipos construtivos das paredes externas são resumidas na Tabela 3.

As absorptâncias das superfícies da edificação foram variadas para as paredes e a cobertura. Foram adotados os limites de 0,3, representando uma cor clara próxima a cor branca, e 0,8, que representa uma cor escura, como o verde musgo. Os mesmos valores de absorptância foram utilizados para a cobertura. Já para o fator solar dos vidros das aberturas, foi adotado um valor máximo de 0,82, relativo ao vidro simples incolor de 6 mm de espessura, e um valor mínimo de 0,45 representando o vidro laminado verde de 8 mm de espessura, de acordo com o Anexo Geral V dos Requisitos de Avaliação da Conformidade (INMETRO, 2013a). A transmitância térmica dos vidros não foi incluída nos parâmetros variados, pois não é comum a utilização de vidros duplos ou triplos na tipologia de centros de saúde. O valor fixo adotado foi de 5,7 W/(m².K). Para a modelagem dos materiais das aberturas, foi utilizado o objeto *Simple Glazing System* no programa EnergyPlus, que se utiliza dos valores de transmitância térmica e fator solar do vidro para a simulação.

Tabela 3 – Materiais construtivos das paredes externas para o limite inferior, o caso intermediário e o limite superior.

	Limite inferior	Caso intermediário	Limite superior
Tipo de parede externa			
Transmitância térmica [W/(m ² .K)]	0,45	2,46	4,40
Capacidade térmica [kJ/(m ² .K)]	33	150	240

Fonte: (INMETRO, 2013a).

Para o parâmetro de densidade de potência de iluminação (DPI), os limites estabelecidos são de 7,5 W/m² para o limite inferior, e de 16,5 W/m² para o limite

superior. O limite inferior considera a utilização de lâmpadas LED em toda a edificação, calculado com base na quantidade de luminárias presentes no projeto elétrico padrão do Ministério da Saúde. Já o limite superior representa a utilização da mesma quantidade de lâmpadas, mas com a consideração do tipo fluorescente. No caso intermediário foi utilizada uma potência intermediária de 12,0 W/m², considerando um cenário de transição entre os dois tipos de lâmpadas considerados, assim como possíveis diferenças de projetos luminotécnicos e de eficiência das lâmpadas. Essa faixa de variação de DPI considerada inclui valores de classificação A e D da Instrução Normativa Inmetro para a Classificação de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas (INI-C) (INMETRO, 2021).

O limite inferior de ocupação, de 5,0 m²/pessoa, é o adotado na INI-C para o edifício de referência da tipologia de clínicas médicas. Esse valor também é relacionado a aproximadamente 85% de ocupação no projeto padrão do Ministério da Saúde, considerando a quantidade de assentos disponíveis nos consultórios e na sala de espera. O limite superior desse parâmetro, de 20 m²/pessoa, é estabelecido como 20% de ocupação no projeto padrão. Para o caso intermediário, foi adotado um valor intermediário de 10 m²/pessoa, relativo a 40% de ocupação no projeto padrão.

Para a caracterização dos horários de ocupação, foram considerados três cenários de turnos: funcionamento durante 4 horas apenas pelo período da manhã (das 8h00 às 12h00), funcionamento durante 8 horas (das 9h00 às 17h00) e funcionamento durante 10 horas (das 8h00 às 18h00). Em todos os cenários, considera-se a utilização total das densidades de potência de equipamentos (DPE) e de iluminação (DPI). As zonas 1, 2, 3 e 8 (almoxarifado, depósito, expurgo e copa), assim como as zonas 4, 6, 9, 23, 25 e 26 (sanitários) foram consideradas de uso esporádico e, portanto, não foram consideradas para o consumo de iluminação e equipamentos.

Para a simulação do sistema de condicionamento de ar, foram adotados aparelhos do tipo split. Para a variação do parâmetro de eficiência do sistema de condicionamento de ar, considerando que os aparelhos de condicionamento de ar na tipologia de centros de saúde já se encontram em operação desde antes da atualização dos valores de Coeficientes de Performance (COP) (INMETRO, 2013b), adotou-se a classificação anteriormente em vigor para o estabelecimento do valor mínimo de COP de 2,7, relativo ao nível D, e do caso intermediário de 3,24, relativo ao nível A. Para as simulações desses dois casos, foi utilizado o objeto *HVACTemplate:Zone:PTHP* no programa EnergyPlus. Também foi considerado o novo limite de classe A de eficiência do Procel, em vigor a partir de 2021 (INMETRO, 2020). Adotou-se o valor de Índice de Desempenho de Resfriamento Sazonal (IDRS) 5,5, mínimo valor relativo a splits do tipo inverter para a obtenção no nível A de eficiência energética na nova classificação. Esse sistema foi simulado pelo objeto *HVACTemplate:Zone:VRF* no programa EnergyPlus, que simula aparelhos de condicionamento de ar com fluidos de refrigeração variáveis. Os *setpoints* adotados para o início do funcionamento dos sistemas de condicionamento de ar adotados

são de 18°C para aquecimento e 26°C para resfriamento. A taxa de renovação de ar especificada para todas as zonas condicionadas é de 0,0075 m³/s. Foram considerados três possíveis cenários de ambientes condicionados. O cenário 1, indicado na Figura 4, considera uma situação de modificação do comportamento dos usuários durante a pandemia COVID-19, e inclui apenas os ambientes de medicamentos e administração como condicionados artificialmente. O cenário 2, mostrado na Figura 5, é o cenário padrão de ambientes condicionados utilizado pelo CBCS em seu estudo de *benchmark* e é constituído, além dos ambientes do cenário 1, pelos consultórios odontológicos e pela sala de vacinas. O cenário 3, caracterizado na Figura 6, inclui, além dos ambientes do cenário 2, as salas de consultórios médicos. Os demais ambientes não foram considerados como ambientes condicionados em nenhum cenário.

Figura 4 – Cenário 1 de áreas condicionadas.

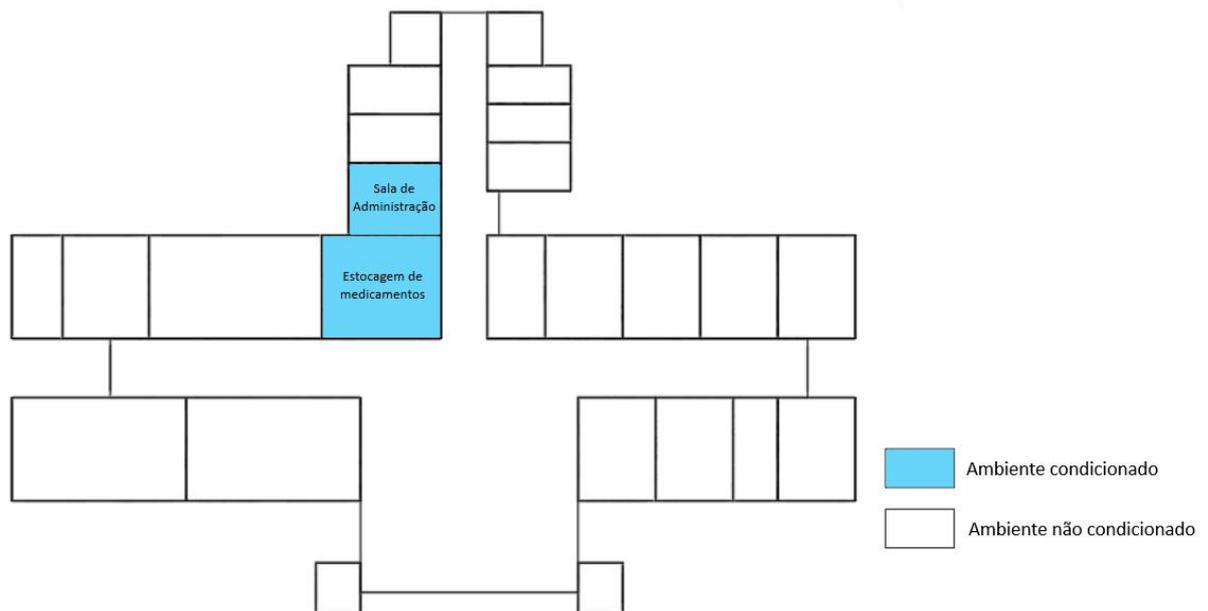


Figura 5 – Cenário 2 de áreas condicionadas.

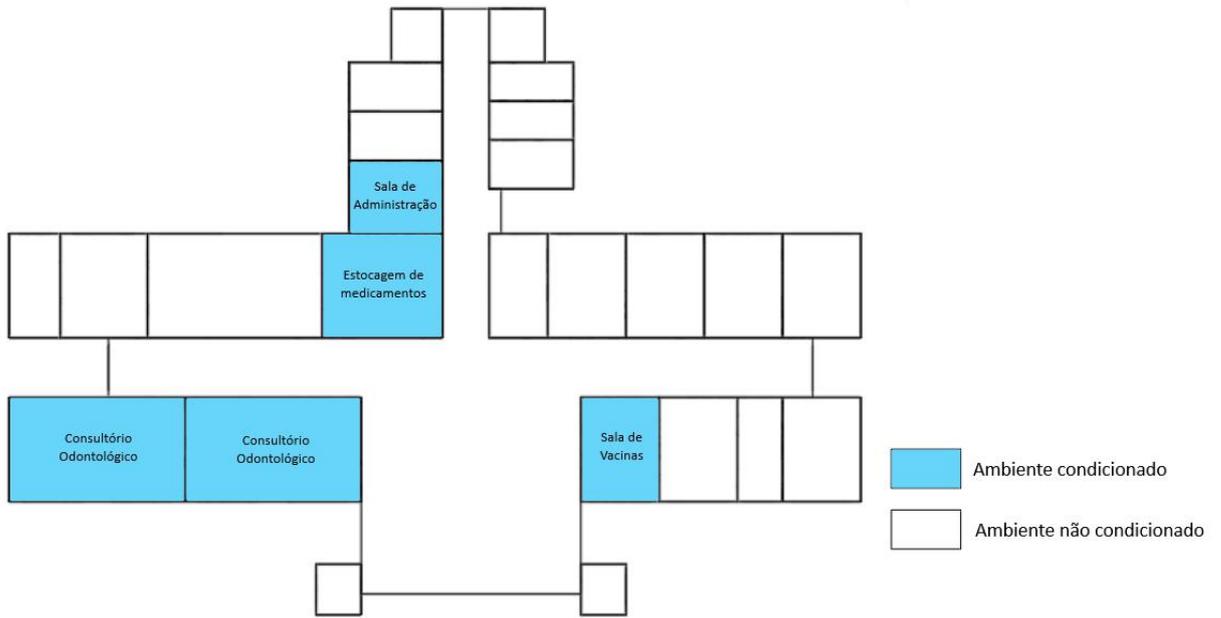
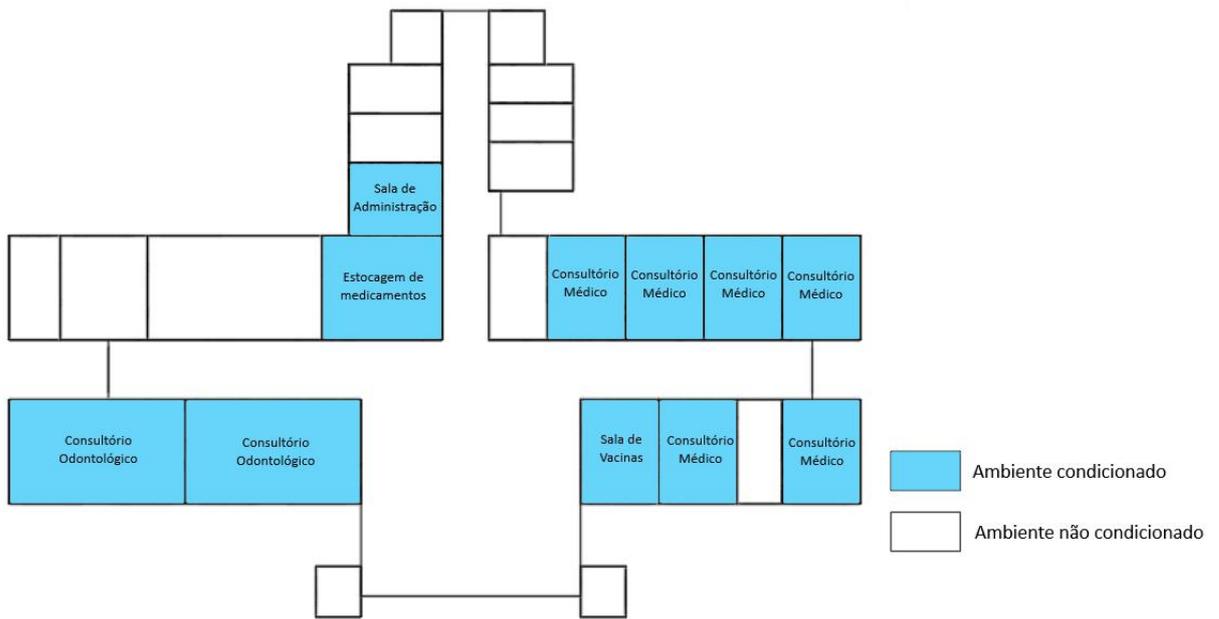


Figura 6 – Cenário 3 de áreas condicionadas.



Os valores utilizados nos parâmetros variados citados anteriormente são resumidos na Tabela 4.

Tabela 4 – Parâmetros de entrada variados.

Parâmetro	Limite inferior	Caso intermediário	Limite superior
Transmitância térmica da cobertura [W/(m ² .K)]	1,55	1,94	2,06
Transmitância térmica das paredes externas [W/(m ² .K)]	0,45	2,46	4,40
Absortância da cobertura	0,3	0,5	0,8
Absortância das paredes externas	0,3	0,5	0,8
Fator solar dos vidros	0,45	0,82	-
Densidade de potência de iluminação (DPI) [W/m ²]	7,5	12	16,5
Ocupação [m ² /pessoa]	5	10	20
Funcionamento [h]	4	8	10
Eficiência do sistema de condicionamento de ar	2,7	3,24	5,5
Ambientes condicionados *	Cenário 1	Cenário 2	Cenário 3

* Cenário 1 - Medicamentos e sala de administração.

Cenário 2 - Medicamentos, sala de administração, consultórios odontológicos e sala de vacinas.

Cenário 3 - Medicamentos, sala de administração, consultórios odontológicos, sala de vacinas e consultórios médicos.

O parâmetro de orientação indica a rotação da edificação com relação ao norte. Foram consideradas as orientações 0°, 90°, 180° e 270°, inseridas no valor de *North Axis* no objeto *Building* do programa EnergyPlus, o que ocasiona a rotação do edifício simulado como um todo.

Com o objetivo de incluir as diferenças climáticas de diferentes cidades, também foi considerado como parâmetro variado o valor de graus-hora de resfriamento (GHR), calculado por meio do somatório das diferenças entre as temperaturas de bulbo úmido e a temperatura base de 15°C, para cada hora do arquivo climático local (CBCS, 2014). O GHR é um parâmetro de correção climática, que auxilia na análise do consumo do sistema de condicionamento de ar para diferentes climas. Foram utilizados os dados climáticos típicos para as seguintes cidades: Campos do Jordão/SP, São Paulo/SP, Florianópolis/SC, Campinas/SP, Rio de Janeiro/RJ, Vitória/ES, Recife/PE e Fortaleza/CE. Foram utilizados os arquivos climáticos fornecidos pelo Instituto Nacional de Meteorologia (INMET), em formato EPW (ONEBUILDING, 2021). Cada uma das cidades representa uma faixa de GHR, incluindo assim uma diversidade de climas brasileiros. As cidades escolhidas para representar as faixas de GHR são as mesmas utilizadas no estudo do CBCS, com

exceção da faixa de GHR entre 20.001 e 30.000, em que foi selecionada a cidade de Florianópolis para possibilitar a comparação com dados de edifícios reais. As cidades consideradas e seus respectivos valores de GHR são mostrados na Tabela 5.

Tabela 5 – Faixas de GHR consideradas e cidades simuladas.

Faixa de Graus-Hora de Resfriamento	Cidade	Graus-Hora de Resfriamento
Entre 0 e 10.000	Campos do Jordão	3495
Entre 10.001 e 20.000	São Paulo	14172
Entre 20.001 e 30.000	Florianópolis	28602
Entre 30.001 e 40.000	Campinas	31412
Entre 40.001 e 50.000	Rio de Janeiro (Vila Militar)	45016
Entre 50.001 e 60.000	Vitória	54061
Entre 60.001 e 70.000	Recife	63550
Entre 70.001 e 80.000	Fortaleza	71394

3.3. Amostragem de Saltelli

Para uma adequada avaliação da importância dos parâmetros de entrada, torna-se necessário executar um grande número de simulações, representando a variação dos parâmetros de entrada desejados. Caso fossem simuladas todas as possibilidades de permutação dos parâmetros variados, seria necessário realizar mais de 1,2 milhão de simulações, o que tornaria inviável o presente trabalho nas condições atuais de capacidade disponível de processamento. Com isso, evidencia-se a necessidade de realizar uma amostragem, de forma que os resultados estejam bem distribuídos no espaço amostral. Para realizar as mudanças das diferentes propriedades nos arquivos de simulação, foi desenvolvido um código de programação na linguagem Python. Foram utilizadas as bibliotecas SALib (HERMAN; USHER, 2017) e Eppy (PHILIP, 2019) para a composição de amostras, confecção dos arquivos no formato IDF, utilizado pelo programa EnergyPlus, e posterior execução da simulação. Foi utilizado um banco de dados SQLite para armazenamento dos dados de entrada e saída.

Foi utilizada a amostragem de Saltelli (2002), um método derivado da sequência de Sobol que reduz o erro no cálculo dos índices de sensibilidade. De forma a incluir os efeitos de segunda ordem, o número de amostras a serem obtidas é calculado por meio da Equação 1, sendo S o número de simulações a serem realizadas, N o número de amostras para cada variável e D o número de variáveis.

Para os resultados finais, foram realizadas 64 amostras para cada parâmetro. Os parâmetros de COP do sistema de condicionamento de ar e de GHR foram excluídos da amostragem, pois deseja-se comparar todos os tipos de COP para cada amostra em todas as cidades. Com isso, considera-se um total de 10 parâmetros variados a serem amostrados, resultando em 1408 amostras ao total.

$$S = N \cdot (2D + 2) \quad (1)$$

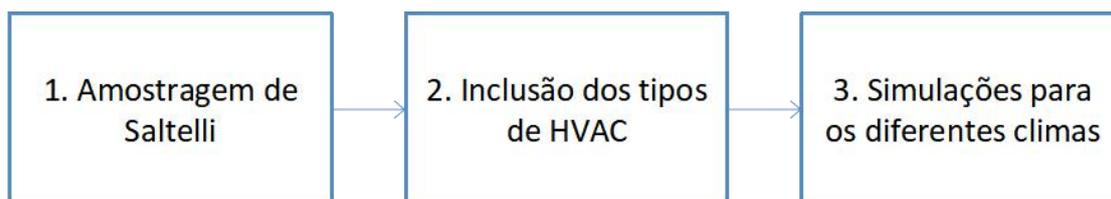
Sendo:

- S: Número de simulações a serem realizadas;
- N: Número de amostras para cada variável;
- D: Número de variáveis.

3.4. Simulações computacionais

Os arquivos de simulação no programa EnergyPlus foram gerados a partir da amostragem obtida anteriormente. Para cada amostra, foram simulados os três tipos de COP, e os oito arquivos climáticos relativos aos diferentes climas. Portanto, as 1408 amostras foram ramificadas em 4224 arquivos de simulações com os três diferentes níveis de eficiência do sistema de condicionamento de ar e, ao simular para os oito diferentes arquivos climáticos, foram realizadas 33792 simulações, utilizando o programa EnergyPlus. A Figura 7 indica o fluxograma que foi seguido para a realização das simulações computacionais.

Figura 7 – Fluxograma das simulações computacionais.



3.5. Análise de sensibilidade e de correlação

Para classificar o impacto de cada parâmetro de entrada sobre o parâmetro de saída, foi aplicada a análise de sensibilidade de Sobol, que tem como resultado o índice de sensibilidade para cada variável. Utilizando o método *sobol.analyze*, da biblioteca SALib, são inseridos os valores das variáveis de entrada e as respectivas variáveis de saída, obtidas após a execução de todas as simulações dos arquivos IDF (formato do programa EnergyPlus) gerados durante a amostragem. O resultado obtido contém os índices de sensibilidade de primeira ordem, que indicam a contribuição direta de cada variável sobre o parâmetro de saída, e de segunda ordem, que caracterizam a influência da interação entre duas variáveis de entrada sobre a variável de saída.

A biblioteca Eppy não permite selecionar diferentes arquivos climáticos para cada simulação computacional em seu código automatizado de execução das simulações, portanto não foi possível incluir o parâmetro de GHR na amostragem, tornando necessário definir uma cidade para a realização das simulações da análise de sensibilidade. Foi realizada uma nova amostragem, dessa vez com apenas 32 amostras para cada parâmetro. Os diferentes valores de eficiência do sistema de condicionamento de ar foram incluídos na amostragem, e foram realizadas as simulações apenas para a cidade de Florianópolis. Com isso, foram realizadas 768 novas simulações para a análise de sensibilidade. Adicionalmente, com o objetivo de representar os impactos dos parâmetros variados em climas mais quentes, foi realizada também uma análise de sensibilidade para a cidade de Fortaleza, com o mesmo tamanho de amostragem.

Para identificar o impacto do parâmetro de GHR sobre o consumo total da edificação, foram também calculados os coeficientes de correlação de Pearson sobre a amostragem total de 33792 simulações realizada no item 3.4. Com isso, é possível identificar a influência de todos os parâmetros de entrada sobre o consumo total da edificação.

3.6. Desenvolvimento do modelo preditivo do *benchmark*

Para o desenvolvimento do modelo de *benchmark*, foram utilizados os métodos de Máquinas de Vetor de Suporte (*Support Vector Machine* - SVM) e de Redes Neurais Artificiais (*Artificial Neural Network* - ANN), utilizando a biblioteca SciKit-Learn, desenvolvida para a linguagem de programação Python. Esses dois métodos de aprendizado de máquina foram empregados devido à ampla aceitação e disseminação no meio acadêmico. O método de SVM é uma técnica de aprendizado de máquina que se destaca por estabelecer modelos com boas métricas de erro a partir de um banco de dados reduzido, e o método de ANN se sobressai pela rapidez de treinamento dos modelos (DONG; CAO; LEE, 2005).

Para a correta aplicação dos algoritmos de aprendizado de máquina SVM e ANN, os dados da base obtidos anteriormente por simulação computacional devem ser separados, aleatoriamente, entre dados de treinamento (75% do tamanho da amostra) e de teste (25% do tamanho da amostra). Em seguida, as variáveis devem ser normalizadas, de forma que se encontrem no intervalo de $[0, 1]$. Esse procedimento tem como objetivo evitar que o modelo apresente maior peso para as variáveis que possuem maior valor numérico, assim como eliminar a possibilidade de erros de arredondamento nas operações matemáticas desenvolvidas.

Para o correto ajuste do modelo desenvolvido pelo algoritmo de SVM, deve ser realizada a otimização de parâmetros. Para isso, utiliza-se a função *GridSearchCV*, da biblioteca *SciKit-Learn*, que executa o teste de diversos valores de parâmetros em intervalos logarítmicos. Os modelos de SVM necessitam de dois parâmetros a serem definidos pelo usuário: 1. O parâmetro épsilon, que define o raio de influência de cada amostra sobre o resultado, e 2. O coeficiente de regularização

(C), que identifica a tolerância de separação das amostras entre os hiperplanos definidos pelo modelo. Foram utilizados ainda na otimização dos modelos de SVM os núcleos linear e polinomial. Já com relação aos parâmetros do algoritmo de ANN, foram otimizados os parâmetros alfa e taxa de aprendizado, que interferem na convergência do treinamento do modelo, assim como o número de nós na camada oculta.

Inicialmente, foram treinados modelos preditivos com todos os parâmetros variados. Posteriormente, o número de parâmetros de entrada foi ajustado, conforme o impacto desses parâmetros sobre o consumo total de energia, obtido pelas análises de sensibilidade e de correlação do item 3.5. Com isso, foi selecionado o modelo preditivo mais acurado para o desenvolvimento do *benchmark* de centros de saúde, conforme métricas de erro estabelecidas no item 3.7. Adicionalmente, foi selecionado um modelo preditivo com menor quantidade de parâmetros de entrada, para comparação dos resultados.

3.7. Comparação de métricas de erro

Para que seja possível verificar a aderência do modelo aos dados de teste e selecionar o modelo preditivo com mais acurácia para o desenvolvimento do *benchmark*, torna-se necessário utilizar métricas de erro, que indicam os desvios dos valores de saída preditos com relação aos valores obtidos na simulação. Foram utilizadas as seguintes métricas: raiz do erro quadrático médio (RMSE) e erro absoluto médio (MAE). Os resultados foram comparados com as métricas obtidas por uma regressão linear multivariada. A regressão linear é considerada um método simples para o desenvolvimento de um modelo preditivo, e foi utilizado como parâmetro de comparação com os modelos preditivos de aprendizado de máquina desenvolvidos, com o objetivo de avaliar se o método de aprendizado de máquina capturou adequadamente as relações não lineares entre os parâmetros. O RMSE é calculado por meio da Equação 2, e o MAE, por meio da Equação 3. Também foi calculado o coeficiente de determinação (R^2) para a comparação dos dois modelos obtidos, de acordo com a Equação 4.

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

Sendo:

- y_i : o parâmetro de saída obtido na simulação;
- \hat{y}_i : o parâmetro de saída estimado pelo modelo;
- n : o número total de dados;

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

Sendo:

- y_i : o parâmetro de saída obtido na simulação;
- \hat{y}_i : o parâmetro de saída estimado pelo modelo;
- n : o número total de dados;

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (4)$$

Sendo:

- y_i : o parâmetro de saída obtido na simulação;
- \hat{y}_i : o parâmetro de saída estimado pelo modelo;
- n : o número total de dados;
- \bar{y} : A média dos parâmetros de saída obtidos nas simulações.

3.8. Estabelecimento da escala de *benchmark*

Para a classificação da edificação em estudo, deve-se comparar o valor de consumo energético predito pelo modelo preditivo com uma escala de *benchmark* estabelecida. Essa escala é estabelecida a partir de valores mínimos e máximos de consumo energético obtidos pela inserção de valores mínimos e máximos para os parâmetros variados no modelo preditivo. Os parâmetros de ocupação, período de funcionamento, cenário de ambientes condicionados, orientação e GHR são característicos do edifício em estudo e, portanto, são mantidos fixos e iguais aos valores reais dos parâmetros em todos os cenários de consumo. Os demais parâmetros têm os valores mínimo e máximo estabelecidos de acordo com os valores utilizados nas simulações computacionais, realizadas no item 3.4, que obtiveram os consumos mínimos e máximos.

A partir dos valores máximos e mínimos de consumo energético obtidos anteriormente, é calculado o valor i , que representa a divisão do intervalo em 3 partes, conforme Equação 5. Com isso, determina-se a escala de classificação do *benchmark* conforme Tabela 6, considerando um edifício eficiente com um consumo de 0 a 33,3% desse intervalo (consumo menor do que o consumo mínimo + i), um edifício típico com um consumo de 33,3% a 66,7% do intervalo, e um edifício ineficiente com um consumo de 66,7% a 100% do intervalo (consumo maior do que o consumo mínimo + $2i$). Com isso, determina-se um *benchmark bottom-up*, ou seja, um *benchmark* que utiliza dados de simulações computacionais para a classificação dos edifícios.

$$i = \frac{\text{consumo máximo} - \text{consumo mínimo}}{3} \quad (5)$$

Tabela 6 – Escala de classificação do *benchmark* desenvolvido neste trabalho.

Classificação	Eficiente	Típico	Ineficiente
Consumo	< Consumo mínimo + i	>= Consumo mínimo + i e <= Consumo mínimo + 2i	> Consumo mínimo + 2i

3.9. Análise estatística e validação do *benchmark*

Para a consideração de um *benchmark* para a classificação do desempenho energético de edifícios reais em operação, recomenda-se a validação de seus resultados com um banco de dados de consumo de edifícios reais. Para a validação do *benchmark* desenvolvido, foi utilizado um banco de dados fornecido pela prefeitura de Florianópolis, com informações de área construída e consumo de energia elétrica de 40 centros de saúde presentes na cidade. Com isso, determina-se um *benchmark top-down*, que tem como objetivo estabelecer uma referência para a aderência do modelo de *benchmark* desenvolvido a partir do arquétipo, assim como estabelecer valores de referência de consumo energético de maneira simplificada para os edifícios que não apresentem os dados detalhados necessários para a aplicação do *benchmark* desenvolvido.

Adicionalmente, foi realizada a validação do *benchmark* desenvolvido com dados de projetos de dois centros de saúde de Florianópolis, fornecidos pela prefeitura da cidade: Centro de Saúde de João Paulo e Novo Continente. Por meio desses projetos, foram obtidos dados de características construtivas, de ocupação e do sistema de iluminação. Os dois edifícios foram classificados pelos *benchmarks top-down* e *bottom-up* desenvolvidos, assim como pela equação de *benchmark* desenvolvida pelo CBCS (VELOSO et al., 2021). O consumo predito por esse *benchmark* é obtido por meio da aplicação de uma regressão linear multivariada. Em seguida, são calculados os valores mínimo e máximo, e, posteriormente, o valor *i* e a tabela de classificação de *benchmark* são calculados. A escala de *benchmark* estabelecida pelo CBCS considera um edifício eficiente quando o valor de consumo predito pela equação de *benchmark* se situa entre 0 e 20% do intervalo entre os valores mínimo e máximo. Um edifício típico apresenta consumo predito entre 20% e 60% do intervalo, e um edifício ineficiente apresenta entre 60% e 100% do intervalo.

Ainda com o objetivo de validar o *benchmark* desenvolvido, foram simuladas cinco amostras de validação, com valores de parâmetros variados não utilizados para o treinamento dos modelos. Os resultados de consumo total das simulações

foram comparados com os valores de consumo obtidos pelo modelo preditivo e pela equação de *benchmark* desenvolvida pelo CBCS.

Por fim, foi realizada a aplicação do metamodelo de conforto por ventilação natural da INI-C, com os parâmetros de entrada das simulações que apresentaram menor e maior consumo energético total, com o objetivo de avaliar a possibilidade de utilização apenas da ventilação natural, dispensando a utilização de aparelhos de condicionamento de ar.

3.9.1. Estoque de edificações de centros de saúde de Florianópolis

Primeiramente, foi realizada uma análise estatística descritiva para explorar as principais características de distribuição dos dados de consumo real dos centros de saúde de Florianópolis. Foram excluídos da análise estatística valores atípicos, que apresentaram valores com distância maior do que dois desvios-padrões da média da amostra. Em seguida, foram determinados os valores mínimo e máximo de consumo energético dessa tipologia, dividindo este intervalo em três partes iguais, representando edifícios eficientes, típicos e ineficientes dessa tipologia para a cidade de Florianópolis.

3.9.2. Projeto 1: Centro de Saúde de João Paulo

O Centro de Saúde de João Paulo, apresentado na Figura 8, possui 382,6 m² de área construída. Construído em 2011, apresenta cobertura de telhas de fibrocimento com a cor natural da telha, com laje de concreto. A absorvância da cobertura é estimada em 0,6, devido ao aspecto escurecido das telhas já envelhecidas. As paredes externas são de tijolos com reboco externo e interno, e a pintura externa da edificação é predominantemente na coloração branca, com absorvância estimada de 0,4. Os vidros das aberturas têm o fator solar de 0,82. A partir da análise do projeto elétrico e do memorial descritivo da edificação, foi verificada a presença de 11 luminárias com duas lâmpadas de 80 W, 15 luminárias com duas lâmpadas de 40 W, 4 luminárias com uma lâmpada de 60 W, 24 luminárias com uma lâmpada de 40 W e 2 luminárias com uma lâmpada de 20 W, resultando em uma potência de iluminação de 4200 W e um valor de DPI de 11,0 W/m². Ainda verificando o projeto do edifício, foi determinada a ocupação de 7,6 m²/pessoa. O período de ocupação ocorre das 8h00 às 18h00 (10 horas). A eficiência dos equipamentos de ar condicionado é de 3,24, considerando que a prefeitura obteve splits com classificação A na classificação antiga do Inmetro (2013b). A partir das conversas com a prefeitura, foi considerado o cenário 3 de ambientes condicionados. O edifício foi construído, aproximadamente, a 90 graus da direção norte do projeto padrão do Ministério da Saúde.

Figura 8 – Centro de Saúde de João Paulo.



3.9.3. Projeto 2: Centro de Saúde Novo Continente

O Centro de Saúde Novo Continente, apresentado na Figura 9, possui 452,0 m² de área construída. Construído em 2014, apresenta cobertura de telhas de fibrocimento com a cor natural da telha, com laje de concreto. A absorvância da cobertura é estimada em 0,6. As paredes externas são de tijolos com reboco externo e interno, e a pintura externa da edificação é predominantemente na coloração branca, com absorvância estimada de 0,4. Os vidros das aberturas têm o fator solar de 0,82. A partir da análise do projeto elétrico da edificação, foi verificada a presença de 74 luminárias com duas lâmpadas de 40 W cada, 23 luminárias com uma lâmpada de 20 W e 4 luminárias com uma lâmpada de 40 W, resultando em uma potência de iluminação de 6540 W e um valor de DPI de 14,5 W/m². Ainda verificando o projeto do edifício, foi determinada a ocupação de 11,3 m²/pessoa. O período de ocupação ocorre das 8h00 às 18h00 (10 horas). A eficiência dos equipamentos de ar condicionado é de 3,24. Foi considerado o cenário 3 de ambientes condicionados para a classificação desse edifício. O edifício foi construído, aproximadamente, a 0 graus da direção norte do projeto padrão do Ministério da Saúde.

Figura 9 – Centro de Saúde Novo Continente.



3.9.4. Casos simulados de validação

Ainda com o objetivo de validar o *benchmark* desenvolvido, foram simulados cinco casos com valores de parâmetros variados não considerados durante o treinamento do modelo. Os valores do consumo total obtidos pelas simulações foram comparados com os consumos totais obtidos pelos modelos preditivos selecionados, assim como o consumo estimado pela equação do CBCS.

3.9.5. Aplicação do metamodelo de avaliação da utilização de ventilação natural da INI-C

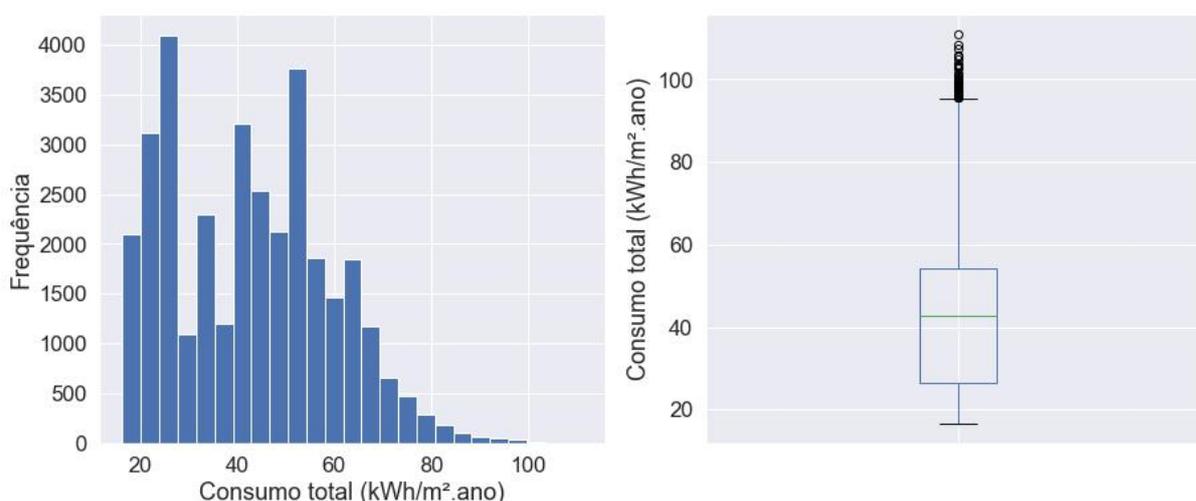
Com os resultados das simulações, foram realizadas verificações relacionadas a possibilidade de utilização da ventilação natural para reduzir o consumo energético do sistema de condicionamento de ar. Foram separadas as amostras com o menor e o maior consumo energético total de cada uma das oito cidades utilizadas nas simulações. Em seguida, foi utilizado o metamodelo de avaliação da utilização de ventilação natural da INI-C (INMETRO, 2021), que estima a fração de horas excedentes por calor ao ano (FH_{desc}). Como parâmetros de entrada do metamodelo, foi considerado o fator de correção do vento equivalente a áreas urbanas, os obstáculos do entorno como proteção local leve com poucas obstruções, a forma das janelas como 2,5 de relação entre largura e altura, o fator de abertura como janela de correr e ausência de ventiladores. De acordo com a INI-C, caso a edificação apresente um percentual de horas ocupadas em conforto térmico maior que 90%, o que equivale a um valor de FH_{desc} menor do que 10%, a envoltória assume a classificação A, a mais eficiente da escala de eficiência energética estabelecida pela norma. Apesar de o metamodelo apresentar estimativas de horas de desconforto apenas para as tipologias de escritórios e edifícios educacionais, a avaliação da utilização de ventilação natural pode ser extrapolada para outras tipologias não residenciais que apresentem características construtivas semelhantes.

4. Resultados e discussão

4.1. Amostragem de Saltelli e simulações computacionais

A realização das simulações computacionais é a etapa que demandou mais tempo para sua conclusão. Cada simulação levou cerca de dois minutos para ser concluída, totalizando cerca de três dias para executar todas as amostras obtidas pela amostragem de Saltelli, em um computador com processador de 20 núcleos. O consumo energético total de centros de saúde para todas as cidades simuladas é mostrado na Figura 10. A média desse conjunto é de 42,8 kWh/(m².ano), com o desvio padrão de 16,8 kWh/(m².ano). O valor mínimo de consumo simulado é de 16,4 kWh/(m².ano), e o valor máximo, de 111,0 kWh/(m².ano).

Figura 10 – Consumo energético de centros de saúde para todas as cidades simuladas.



As simulações obtiveram como parâmetros de saída os consumos energéticos separados por uso final (sistemas de iluminação e de equipamentos, e consumos de *fans*, aquecimento e resfriamento do sistema de condicionamento de ar), indicados na Figura 11. Verifica-se o baixo consumo de energia para aquecimento e para os *fans*, em comparação com os demais usos finais. Também se percebe a elevada amplitude do consumo energético para resfriamento, devido à variedade de climas simulados. Apesar de a densidade de potência de equipamentos ter sido mantida fixa para as simulações, o consumo energético de equipamentos é alterado devido aos diferentes períodos de funcionamento considerados. Parte da variação de consumo energético de iluminação também é explicada pelos diferentes períodos de funcionamento considerados, e pela variação dos valores de densidade de potência de iluminação considerados.

A distribuição do consumo energético das amostras simuladas, separadas por tempo de funcionamento, é visualizada na Figura 12. É possível verificar agrupamentos distintos de consumo para os diferentes períodos de funcionamento,

em especial para o período de 4h de funcionamento, em comparação com os períodos de funcionamento de 8h e 10h.

Figura 11 – Consumo energético separado por uso final das amostras simuladas.

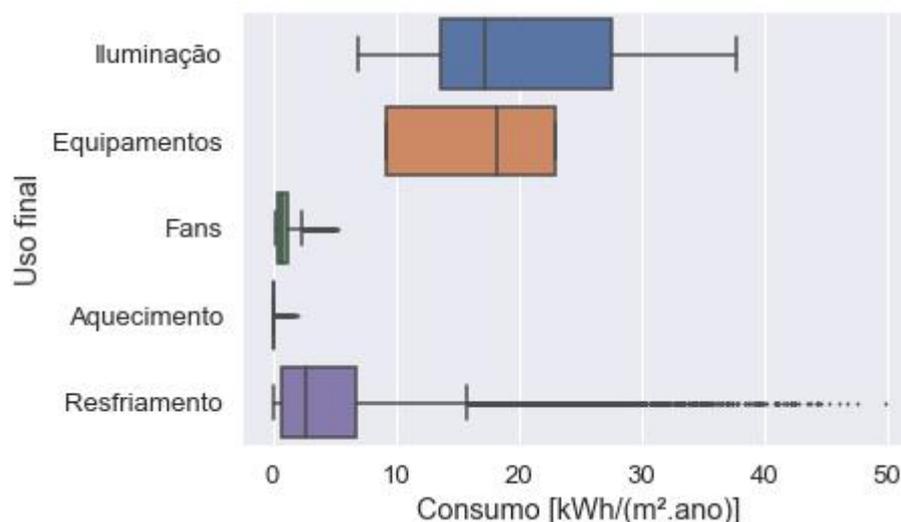
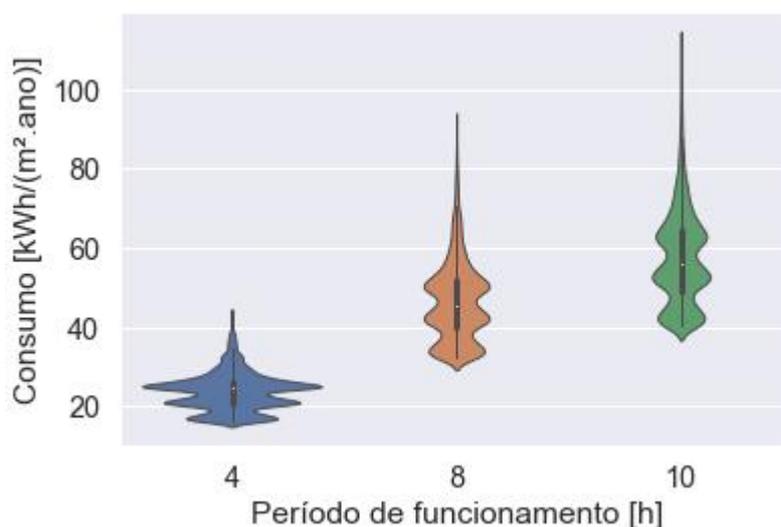
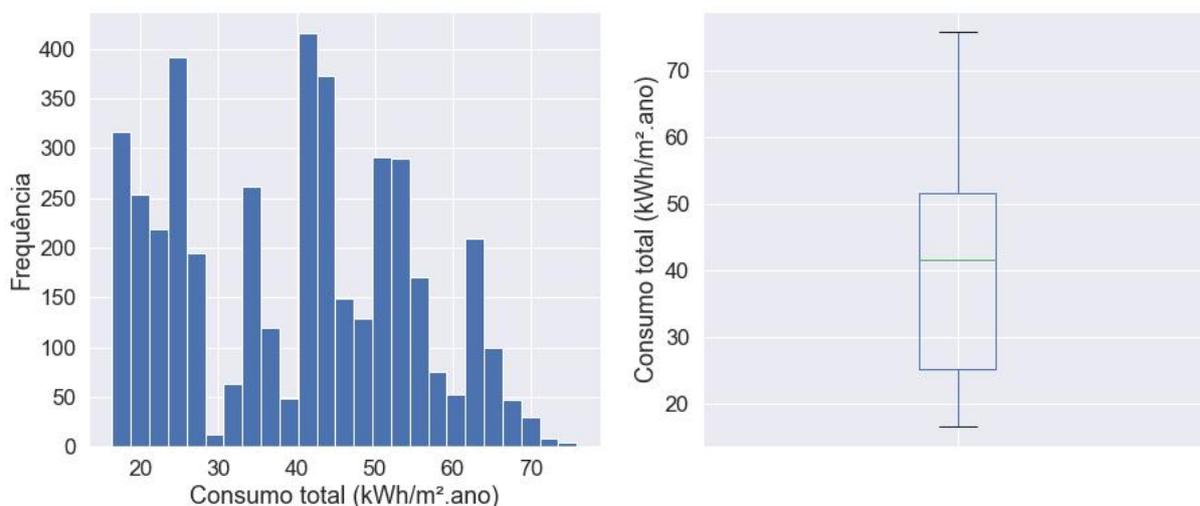


Figura 12 – Distribuição dos consumos totais das simulações agrupados por período de funcionamento.



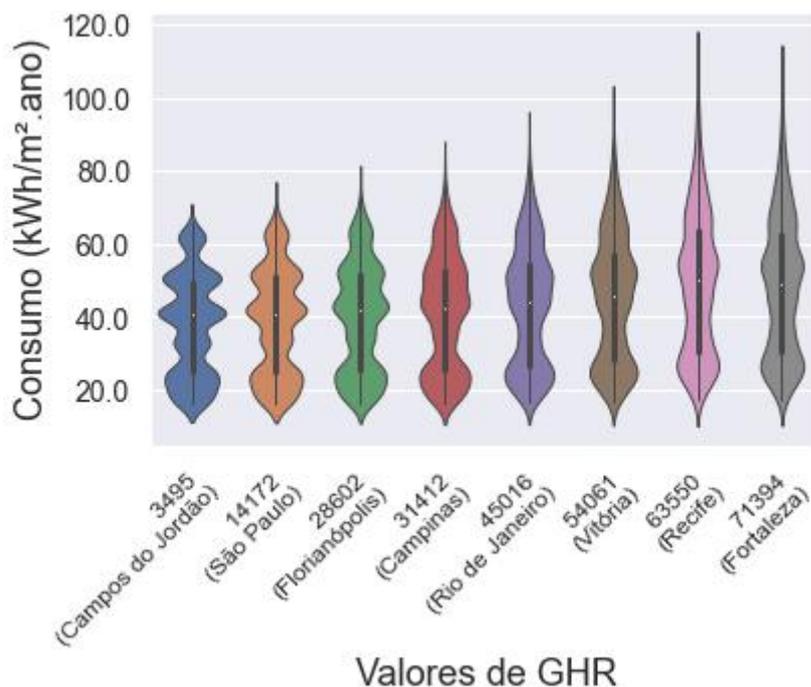
Com o objetivo de comparar os consumos energéticos simulados com os dados reais de consumo, utilizados na etapa de validação do *benchmark* desenvolvido, foram consideradas as simulações somente para a cidade de Florianópolis na distribuição visualizada na Figura 13. Foi obtida a média de 39,7 kWh/(m².ano), com o desvio padrão de 14,7 kWh/(m².ano). O valor mínimo de consumo simulado para Florianópolis é de 16,4 kWh/(m².ano), e o valor máximo, de 75,9 kWh/(m².ano).

Figura 13 – Consumo energético simulado de centros de saúde para Florianópolis.



Similarmente, foram obtidas as distribuições dos consumos totais simulados para todas as cidades, visualizadas na Figura 14. Verifica-se o consumo total simulado entre 16,4 e 65,8 kWh/(m².ano) para a cidade de Campos do Jordão, que possui o menor valor de Graus-Hora de Resfriamento (GHR), de 3495. Já para a cidade de Fortaleza, que apresenta GHR equivalente a 71394, o maior valor considerado nas simulações realizadas, o consumo total simulado apresenta valores entre 17,3 e 107,4 kWh/(m².ano).

Figura 14 – Distribuição do consumo energético total simulado de centros de saúde para todos os Graus-Hora de Resfriamento considerados.



Considerando que o período de funcionamento determina grupos bem definidos de simulações, torna-se necessário estratificar os resultados para uma melhor classificação do *benchmark* desenvolvido. Os valores de consumo total das simulações foram separados por cidade e por período de funcionamento, e os limites eficiente e típico foram definidos como 33,3% e 66,7%, respectivamente, considerando a divisão da escala de *benchmark* utilizada neste trabalho. Os resultados se encontram na Tabela 7, para os três períodos de funcionamento (4 horas, 8 horas e 10 horas). Percebe-se o aumento do consumo total com o aumento de GHR das cidades simuladas para os mesmos períodos de funcionamento, o que é explicado pelo maior consumo do sistema de condicionamento de ar por refrigeração. Ainda é possível verificar as diferenças nas faixas de consumo total para os diferentes períodos de funcionamento em cada cidade.

Tabela 7 – Limites de consumo energéticos das faixas de edificações de centros de saúde eficientes e típicos, para os períodos de funcionamento considerados nas simulações.

Cidade	Períodos de funcionamento [h]	Nível eficiente [kWh/(m ² .ano)]	Nível típico [kWh/(m ² .ano)]	Nível ineficiente [kWh/(m ² .ano)]
Campos do Jordão	4	16,4 a 19,9	19,9 a 23,3	23,3 a 26,8
	8	32,4 a 39,8	39,8 a 47,1	47,1 a 54,5
	10	40,4 a 48,9	48,9 a 57,3	57,3 a 65,8
São Paulo	4	16,4 a 20,3	20,3 a 24,3	24,3 a 28,2
	8	32,4 a 41,3	41,3 a 50,2	50,2 a 59,1
	10	40,4 a 50,8	50,8 a 61,2	61,2 a 71,6
Florianópolis	4	16,4 a 20,9	20,9 a 25,4	25,4 a 29,9
	8	32,5 a 41,4	41,4 a 50,3	50,3 a 62,2
	10	40,7 a 52,4	52,4 a 64,2	64,2 a 75,9
Campinas	4	16,4 a 21,3	21,3 a 26,1	26,1 a 31,0
	8	32,7 a 44,4	44,4 a 56,2	56,2 a 67,9
	10	40,9 a 54,7	54,7 a 68,4	68,4 a 82,2
Rio de Janeiro (Vila Militar)	4	16,7 a 22,7	22,7 a 28,7	28,7 a 34,7
	8	33,1 a 46,7	46,7 a 60,3	60,3 a 73,9
	10	41,4 a 57,6	57,6 a 73,8	73,8 a 90,0
Vitória	4	16,8 a 23,7	23,7 a 30,5	30,5 a 37,4
	8	33,5 a 48,8	48,8 a 64,1	64,1 a 79,4
	10	41,9 a 60,2	60,2 a 78,5	78,5 a 96,8
Recife	4	17,3 a 25,9	25,9 a 34,6	34,6 a 43,2

	8	34,3 a 53,2	53,2 a 72,1	72,1 a 91,0
	10	42,9 a 62,6	62,6 a 88,3	88,3 a 111,0
Fortaleza	4	17,3 a 25,3	25,3 a 33,4	33,4 a 41,4
	8	34,3 a 52,0	52,0 a 69,7	69,7 a 87,4
	10	42,8 a 64,3	64,3 a 85,9	85,9 a 107,4

Com o objetivo de selecionar os casos de maior consumo energético do sistema de condicionamento de ar, foram selecionados os casos de funcionamento durante 10 horas e cenário 3 de ambientes condicionados. Nessa situação, verificou-se que os casos de consumo mínimo e máximo apresentaram parâmetros de entrada iguais para todas as cidades. Os casos de consumo mínimo possuem a cobertura com transmitância térmica de 2,06 W/(m².K), as paredes externas com transmitância térmica de 4,40 W/(m².K), absorvâncias térmicas de 0,3 para a cobertura e para as paredes externas, fator solar dos vidros de 0,45, DPI de 7,5 W/m² e eficiência do sistema de condicionamento de ar de 5,5. Os casos de consumo máximo apresentam cobertura com transmitância térmica de 1,55 W/(m².K), paredes externas com transmitância térmica de 0,45 W/(m².K), absorvâncias térmicas de 0,8 para a cobertura e para as paredes externas, fator solar de 0,82, DPI de 16,5 W/m² e eficiência do sistema de condicionamento de ar de 2,7. Os valores de parâmetros de entrada para os casos de consumo mínimo e máximo, resumidos na Tabela 8, foram utilizados para a avaliação de conforto por ventilação natural por meio do metamodelo da INI-C, assim como para a definição dos limites da escala de *benchmark*.

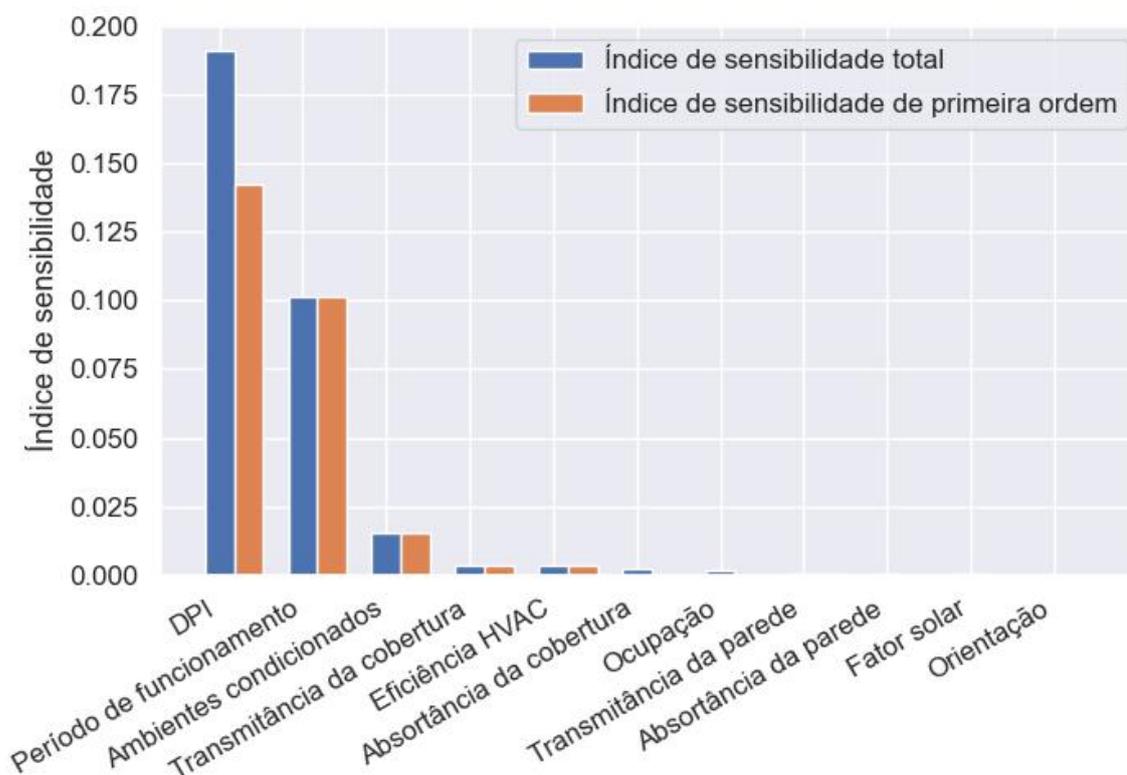
Tabela 8 – Valores dos parâmetros equivalentes aos consumos mínimo e máximo para o estabelecimento da escala de classificação do *benchmark* desenvolvido neste trabalho.

Parâmetro	Mínimo	Máximo
Transmitância da cobertura [W/(m².K)]	2,06	1,55
Transmitância das paredes externas [W/(m².K)]	4,40	0,45
Absortância da cobertura	0,3	0,8
Absortância das paredes externas	0,3	0,8
Fator solar dos vidros	0,45	0,82
Densidade de potência de iluminação (DPI) [W/m²]	7,5	16,5
Eficiência do sistema de condicionamento de ar	5,5	2,7

4.2. Análise de sensibilidade e de correlação

Com a tabela de valores dos parâmetros de entrada variados e os respectivos consumos totais das amostras simuladas, foram obtidos os índices de sensibilidade por meio da análise de sensibilidade de Sobol, para a cidade de Florianópolis. A Figura 15 indica os índices de sensibilidade total e de primeira ordem para os parâmetros variados. O parâmetro relativo ao DPI resalta-se sobre os demais, o que evidencia sua influência direta sobre o consumo energético do arquétipo. Além disso, as variáveis de período de funcionamento e de cenários de ambientes condicionados apresentam elevado impacto sobre o consumo total da edificação, apesar de não apresentarem relação com a eficiência energética da edificação. Portanto, essas duas variáveis funcionam como uma categorização dos tipos de centros de saúde em diferentes grupos. Por exemplo, a variável de período de funcionamento separa os centros de saúde em três grupos: 4h de ocupação, 8h e 10h, conforme verificado anteriormente. Os parâmetros de transmitância da cobertura e de eficiência do sistema de HVAC apresentaram o quarto e o quinto maior índice de sensibilidade, respectivamente, influenciando a eficiência energética da edificação.

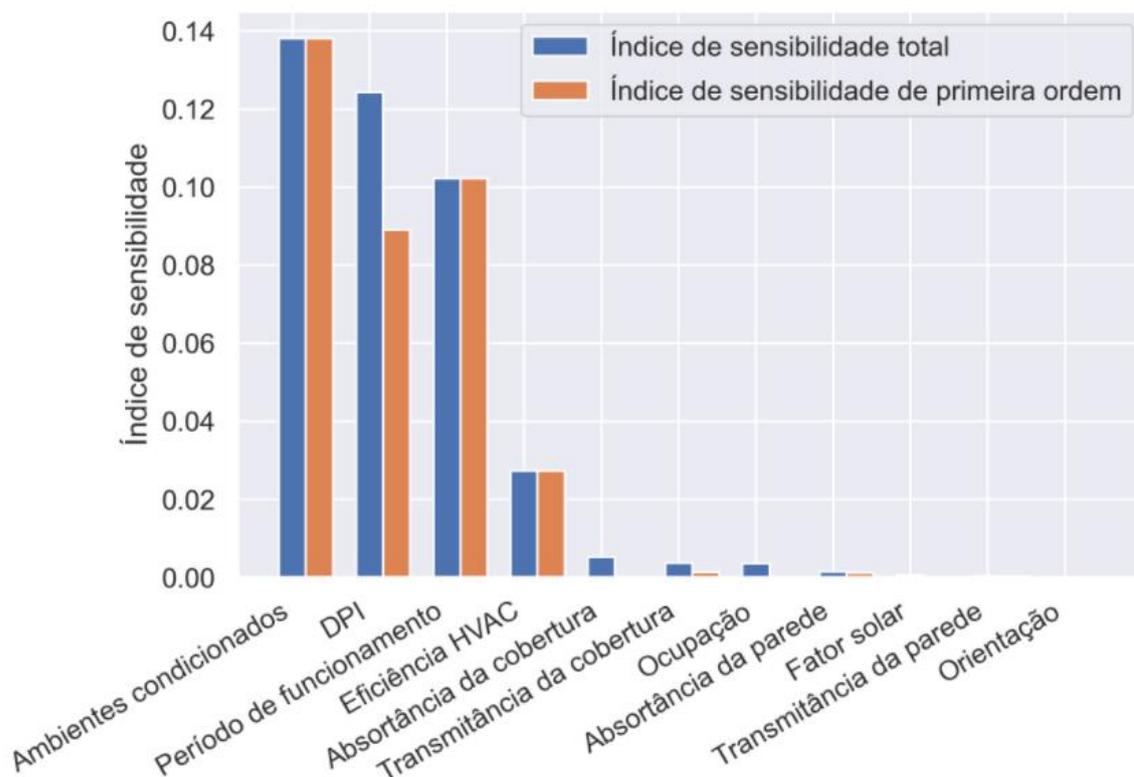
Figura 15 – Índices de sensibilidade total e de primeira ordem para os parâmetros variados na cidade de Florianópolis.



A análise de sensibilidade para a cidade de Fortaleza, visualizada na Figura 16, evidencia uma maior importância das variáveis relacionadas ao consumo do

sistema de condicionamento de ar em climas mais quentes. O parâmetro relacionado aos cenários de ambientes condicionados apresentou os maiores índices de sensibilidade, seguido do DPI, do período de funcionamento e da eficiência do sistema de condicionamento de ar. A absorvância da cobertura apresentou o quinto maior índice de sensibilidade, evidenciando a importância desse parâmetro em climas quentes. A elevada incidência de radiação solar acarreta em uma maior troca de calor em edificações com maiores valores de absorvância da cobertura em climas quentes, o que influencia no consumo do sistema de condicionamento de ar, principalmente em edificações térreas, como é o caso do arquétipo em estudo.

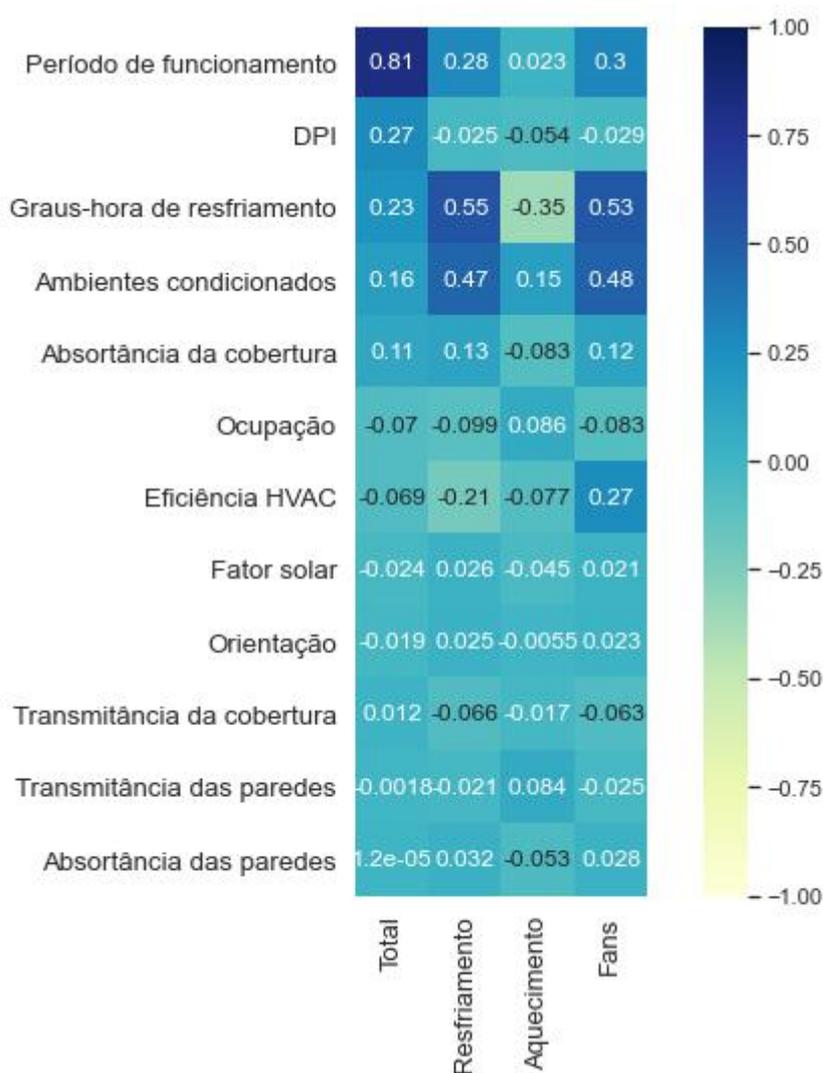
Figura 16 – Índices de sensibilidade total e de primeira ordem para os parâmetros variados na cidade de Fortaleza.



Os coeficientes de correlação de Pearson, calculados para os 12 parâmetros variados e ordenados pelo valor absoluto do coeficiente sobre o consumo total, são observados na Figura 17. É possível verificar a presença dos parâmetros que apresentaram os maiores índices de sensibilidade, para as duas cidades analisadas anteriormente, também com os maiores coeficientes de correlação: período de funcionamento, DPI, cenários de ambientes condicionados, absorvância da cobertura e eficiência do sistema de HVAC. Adicionalmente, percebe-se a presença do parâmetro de GHR como um dos que mais influenciam no consumo energético total. Verifica-se também a correlação negativa da densidade de ocupação com o consumo total, ou seja, o consumo energético aumenta com a redução do valor da

densidade de ocupação, pois há uma menor área disponível para cada pessoa, o que significa mais ocupantes em um mesmo local. Evidencia-se, ainda, a correlação entre o parâmetro de eficiência do sistema de condicionamento de ar e o consumo dos fans desse sistema, pois a alteração do tipo de sistema utilizado nas simulações (PTHP e VRF) influencia significativamente no perfil de consumo desse uso final. O tipo de cobertura, apesar de apresentar coeficiente de Pearson de apenas 0,012 sobre o consumo total, possui o coeficiente de $-0,066$ sobre o consumo de resfriamento, o que evidencia a importância desse parâmetro sobre o consumo do sistema de condicionamento de ar.

Figura 17 – Coeficientes de correlação de Pearson.



4.3. Desenvolvimento do modelo preditivo do *benchmark* e comparação de métricas de erro

Inicialmente, foram treinados três tipos de modelos preditivos, com todos os parâmetros variados de entrada e apresentando como parâmetro de saída os

resultados de consumo total das simulações: regressão linear, Máquinas de Vetor de Suporte (SVM) e Redes Neurais Artificiais (ANN). Os resultados das métricas de erro para os três modelos treinados são visualizados na Tabela 9. O algoritmo de ANN apresentou os menores valores de métricas de erro, com RMSE de 0,91 kWh/(m².ano) e MAE de 0,65 kWh/(m².ano), indicando que esse modelo preditivo é o que mais se adequou aos dados obtidos.

Tabela 9 – Modelos preditivos com todos os parâmetros variados.

Tipo de Modelo Preditivo	RMSE [kWh/(m².ano)]	MAE [kWh/(m².ano)]	R²
Linear	4,13	3,07	0,94
Máquinas de Vetor de Suporte	1,46	0,88	0,99
Redes Neurais Artificiais	0,91	0,65	0,99

Com o objetivo de otimizar o número de parâmetros de entrada do modelo preditivo, foram considerados três pontos de corte para o coeficiente de correlação de Pearson: 0,01, 0,025 e 0,1. Para cada ponto de corte estabelecido, foram eliminados os parâmetros que apresentaram coeficiente de Pearson abaixo do ponto de corte. Para o ponto de corte de 0,01, foram eliminados os parâmetros de absorvância e transmitância das paredes externas. Já para o ponto de corte de 0,025, foram eliminados, adicionalmente, os parâmetros de transmitância da cobertura, orientação e fator solar dos vidros. Para o ponto de corte de 0,1, foram eliminados, adicionalmente, os parâmetros de eficiência do sistema de condicionamento de ar e a densidade de ocupação. Os valores das métricas de erro obtidos pelos modelos preditivos desenvolvidos com os diferentes pontos de corte do coeficiente de Pearson são visualizados na Tabela 10.

O modelo preditivo de ANN com os 12 parâmetros variados foi o que apresentou as menores métricas de erro, com RMSE de 0,91 kWh/(m².ano), MAE de 0,65 kWh/(m².ano) e R² de 0,99. No entanto, pode ser discutida a necessidade de reduzir a complexidade dos modelos para aumentar a facilidade de utilização do *benchmark*, ainda que ao custo da redução da acurácia do modelo preditivo. Por exemplo, a ANN com 7 parâmetros (ponto de corte 0,025) apresentou RMSE de 1,40 kWh/(m².ano), MAE de 0,87 kWh/(m².ano) e R² de 0,99, valores que podem ser considerados aceitáveis em troca da eliminação de 5 parâmetros. Os modelos preditivos desenvolvidos com o ponto de corte 0,1 eliminam o parâmetro de eficiência do sistema de condicionamento de ar, uma variável que foi identificada com índice de sensibilidade elevado para a cidade de Fortaleza. A partir dessas considerações, os modelos preditivos selecionados para posterior desenvolvimento e validação do *benchmark* foram a ANN com os 12 parâmetros de entrada (ponto de corte 0) e a ANN com 7 parâmetros de entrada (ponto de corte 0,025).

Tabela 10 – Modelos preditivos desenvolvidos de acordo com pontos de corte dos coeficientes de correlação de Pearson.

Ponto de Corte	Número de parâmetros	Modelo preditivo	RMSE [kWh/(m ² .ano)]	MAE [kWh/(m ² .ano)]	R ²
0	12	Linear	4,13	3,07	0,94
		SVM	1,46	0,88	0,99
		ANN	0,91	0,65	0,99
0,01	10 (exceto absorvância e transmitância das paredes)	Linear	4,18	3,10	0,94
		SVM	1,56	0,96	0,99
		ANN	1,31	0,87	0,99
0,025	7 (exceto absorvância e transmitância das paredes, transmitância da cobertura, orientação e fator solar dos vidros)	Linear	4,27	3,17	0,94
		SVM	1,77	1,08	0,99
		ANN	1,40	0,87	0,99
0,1	5 (exceto absorvância e transmitância das paredes e da cobertura, orientação, fator solar dos vidros, eficiência do HVAC e ocupação)	Linear	4,44	3,28	0,93
		SVM	2,66	1,54	0,98
		ANN	2,71	1,85	0,97

A Figura 18 indica a relação entre o consumo predito e o consumo simulado para a ANN com 12 parâmetros. Verifica-se valores próximos de consumo predito e simulado pela aderência a diagonal que indica valores preditos iguais aos valores simulados, e valores de erro abaixo de 5%, em sua maioria.

A Figura 19 indica a relação entre o consumo predito e o consumo simulado para a ANN com 7 parâmetros. A figura indica uma maior dispersão em relação a diagonal que indica valores preditos iguais aos valores simulados, em especial para os maiores consumos. Percebe-se uma maior distribuição de erros acima de 5% para os valores preditos, em comparação com o modelo preditivo ANN com 12 parâmetros.

Figura 18 – Relação entre consumo predito e simulado e histograma de erros para a ANN com 12 parâmetros

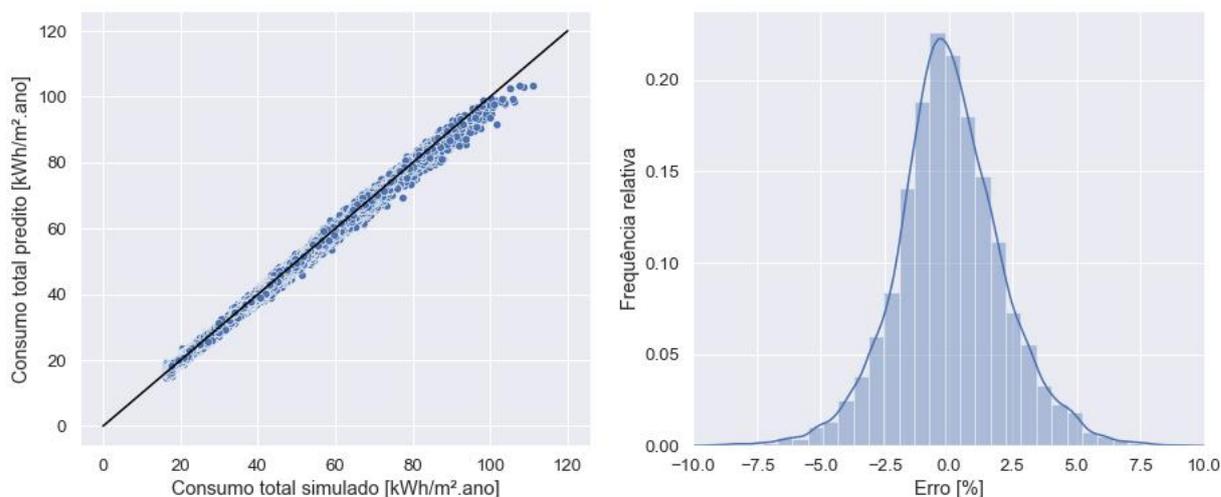
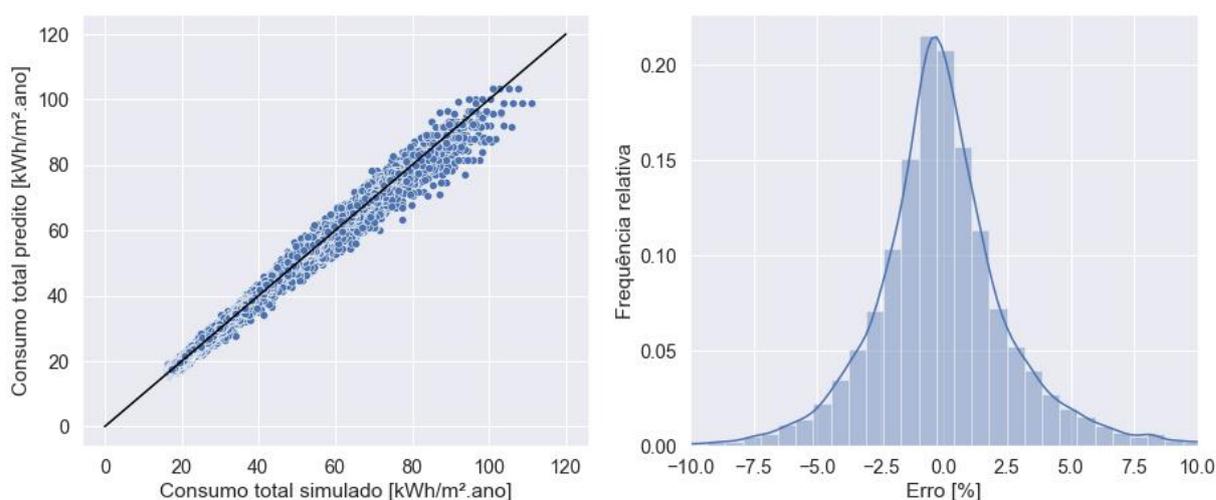


Figura 19 – Relação entre consumo simulado e o consumo predito, e histograma de erros para a ANN com 7 parâmetros

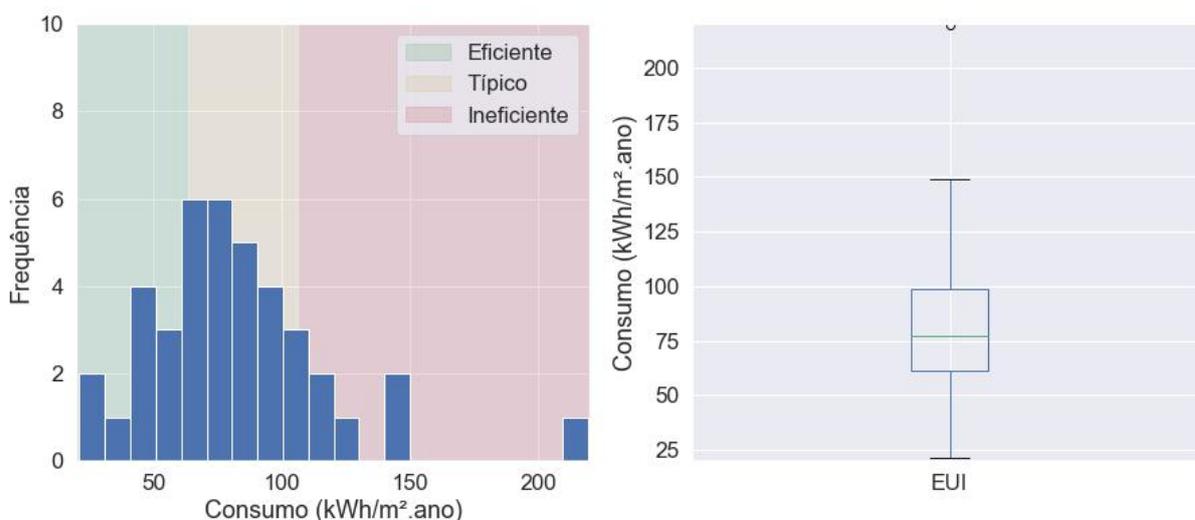


4.4. Análise estatística e validação do *benchmark*

4.4.1. Estoque de edificações de centros de saúde de Florianópolis

A distribuição do consumo energético real dos centros de saúde de Florianópolis no ano de 2019 é apresentada na Figura 20. Verifica-se que a média do banco de dados possui o valor de 82,1 kWh/(m².ano), com o desvio padrão de 36,3 kWh/(m².ano). O valor mínimo é de 21,3 kWh/(m².ano), e o valor máximo é de 219,2 kWh/(m².ano). No entanto, ao eliminar os valores discrepantes, foram removidos os valores acima de 154,7 kWh/(m².ano), equivalente a distância de 2 desvios-padrões da média. Com isso, foi eliminado um valor discrepante, e o novo valor máximo foi definido como 148,9 kWh/(m².ano).

Figura 20 – Distribuição do consumo energético real dos centros de saúde de Florianópolis em 2019.



Ao dividir o intervalo entre os valores mínimo e máximo em três faixas para estabelecer um *benchmark top-down*, classificam-se como eficientes 12 centros de saúde de Florianópolis, que apresentam consumo energético menor que 63,8 kWh/(m².ano). Foram considerados típicos 22 centros de saúde, com consumo energético entre 63,8 e 106,4 kWh/(m².ano). São classificados como ineficientes 6 centros de saúde, com consumo energético acima de 106,4 kWh/(m².ano). A escala de classificação do *benchmark top-down* dos centros de saúde de Florianópolis para o ano de 2019 é visualizada na Tabela 11.

Tabela 11 – Escala de classificação do *benchmark top-down* dos centros de saúde de Florianópolis para o ano de 2019.

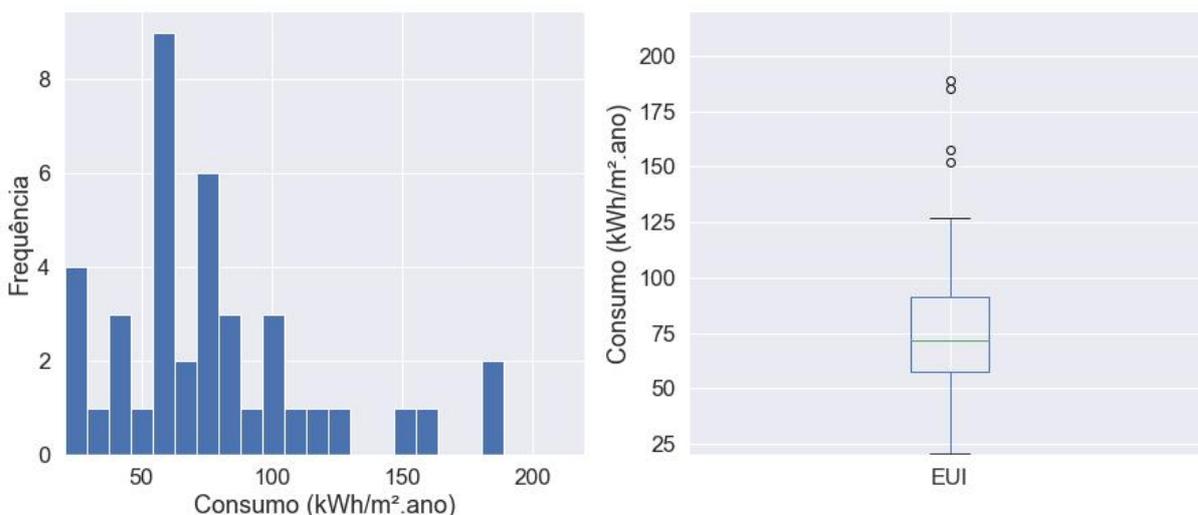
Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m ² .ano)]	< 63,8	>= 63,8 e <= 106,4	> 106,4

O consumo energético total máximo das amostras simuladas para a cidade de Florianópolis apresentou o valor de 75,9 kWh/(m².ano). Verificou-se 21 centros de saúde com consumo real em 2019 superior a esse valor, o que pode indicar, além das incertezas relacionadas ao processo de simulação computacional, diferentes períodos de funcionamento, diferenças nos equipamentos instalados ou ineficiências relacionadas a iluminação e equipamentos sendo utilizados fora do período de funcionamento do edifício. Para uma maior aderência dos resultados simulados de consumo energético aos dados reais de consumo energético, torna-se necessário um maior detalhamento dos dados dos edifícios reais, por meio de diagnósticos energéticos, principalmente nos edifícios que apresentam maior consumo. Os diagnósticos energéticos podem evidenciar se os maiores consumos energéticos

são devidos a ineficiências ou a características particulares desses edifícios, como equipamentos especiais instalados. Apesar de as simulações não providenciarem um valor calibrado de consumo energético previsto para os casos reais de maior consumo, o posicionamento do consumo previsto dentro da escala de *benchmark* estabelecida indica a eficiência energética do edifício em estudo em relação aos demais casos simulados e evidencia características importantes para a melhoria do desempenho energético.

Já com relação aos consumos para o ano de 2020, observados na Figura 21, verifica-se os impactos da pandemia de COVID-19, com a redução da média de consumo, com o valor de 77,5 kWh/(m².ano), com o desvio padrão de 40,6 kWh/(m².ano). A média de redução no consumo entre 2020 e 2019 é de 4,6%. Esse dado corrobora com a tendência de redução nos ambientes condicionados artificialmente durante a pandemia, o que foi considerado neste trabalho para a elaboração do cenário 1 de ambientes condicionados. O valor mínimo de consumo em 2020 é de 20,6 kWh/(m².ano), e o valor máximo é de 188,7 kWh/(m².ano). Os dados de consumo energético de 2020 não foram considerados para a elaboração do *benchmark top-down*, por ser considerado um ano atípico.

Figura 21 – Distribuição do consumo energético real dos centros de saúde de Florianópolis em 2020.



4.4.2. Projeto 1: Centro de Saúde de João Paulo

O Centro de Saúde de João Paulo apresentou consumo energético de 44,3 kWh/(m².ano) no ano de 2019. Com isso, classifica-se essa edificação como eficiente no *benchmark top-down* desenvolvido com os dados reais de consumo energético da tipologia em Florianópolis.

Ao aplicar os parâmetros relativos aos limites mínimos e máximos da tabela de classificação de benchmark no modelo preditivo de ANN com 12 parâmetros, obtém-se um consumo mínimo de 44,4 kWh/(m².ano), e de 76,6 kWh/(m².ano) para o consumo máximo, conforme apresentado na Tabela 12. A partir desses valores,

calcula-se que o valor de i é de 10,7 kWh/(m².ano), e estabelece-se a escala de *benchmark* na Tabela 13. O consumo energético do edifício em estudo foi estimado em 56,2 kWh/(m².ano). Assim, classifica-se o edifício como típico no *benchmark bottom-up* com 12 parâmetros de entrada.

Tabela 12 – Características do Centro de Saúde de João Paulo e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 12 parâmetros para a realização da tabela de classificação de *benchmark*, e os respectivos consumos energéticos.

Parâmetro	Mínimo	Máximo	Edifício em estudo
Transmitância da cobertura	2,06	1,55	2,06
Transmitância das paredes externas	4,40	0,45	2,46
Absortância da cobertura	0,3	0,8	0,6
Absortância das paredes externas	0,3	0,8	0,4
Fator solar dos vidros	0,45	0,82	0,82
Densidade de potência de iluminação (DPI) [W/m²]	7,5	16,5	11,0
Ocupação [m²/pessoa]	7,6		
Funcionamento [h]	10		
Eficiência do sistema de condicionamento de ar	5,5	2,7	3,24
Ambientes condicionados	Cenário 3		
Orientação	90		
Graus-Hora de Resfriamento	28602 (Florianópolis)		
Consumo predito ANN 12 parâmetros [kWh/(m².ano)]	44,4	76,6	56,2

Tabela 13 – Escala de classificação do *benchmark* desenvolvido a partir da ANN com 12 parâmetros.

Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m ² .ano)]	< 55,1	>= 55,1 e <= 65,9	> 65,9

O modelo preditivo de ANN com 7 parâmetros obteve um consumo mínimo de 43,7 kWh/(m².ano) e 76,1 kWh/(m².ano) para o consumo máximo, conforme apresentado na Tabela 14. A partir desses valores, calcula-se que o valor de *i* é de 10,8 kWh/(m².ano), e se estabelece a escala de *benchmark* na Tabela 15. O consumo energético do edifício em estudo foi estimado em 56,9 kWh/(m².ano). Assim, classifica-se o edifício também como típico no *benchmark bottom-up* com 7 parâmetros.

Tabela 14 – Características do Centro de Saúde de João Paulo e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 7 parâmetros para a realização da tabela de classificação de *benchmark*, e os respectivos consumos energéticos.

Parâmetro	Mínimo	Máximo	Edifício em estudo
Absortância da cobertura	0,3	0,8	0,6
Densidade de potência de iluminação (DPI) [W/m ²]	7,5	16,5	11,0
Ocupação [m ² /pessoa]	7,6		
Funcionamento [h]	10		
Eficiência do sistema de condicionamento de ar	5,5	2,7	3,24
Ambientes condicionados	Cenário 3		
Graus-Hora de Resfriamento	28602 (Florianópolis)		
Consumo predito ANN 7 parâmetros [kWh/(m ² .ano)]	43,7	76,1	56,9

Tabela 15 – Escala de classificação do *benchmark* desenvolvido a partir da ANN com 7 parâmetros.

Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m ² .ano)]	< 54,5	>= 54,5 e <= 65,3	> 65,3

A aplicação da equação de *benchmark* do CBCS para centros de saúde apresentou um consumo predito de 101,7 kWh/(m².ano) para o edifício em estudo, e resultou em um consumo mínimo de 98,4 kWh/(m².ano) e um consumo máximo de 120,1 kWh/(m².ano) no processo de estabelecimento da escala de *benchmark*, conforme apresentado na Tabela 16. A partir desses valores, calcula-se que o valor de *i*, de acordo com a divisão por 5 estabelecida pelo CBCS, é de 4,3 kWh/(m².ano), e se estabelece a escala de *benchmark* na Tabela 17, conforme a divisão da escala proposta pelo CBCS. Verifica-se, portanto, que a edificação se classificaria como eficiente nesse procedimento de *benchmark*.

Tabela 16 – Limites mínimo, máximo e consumo do edifício em estudo obtidos pela equação do CBCS para a realização da tabela de classificação de *benchmark*.

Parâmetro	Mínimo	Máximo	Edifício em estudo
Consumo [kWh/(m ² .ano)]	98,4	120,1	101,7

Tabela 17 – Escala de classificação do *benchmark* estabelecido pelo CBCS.

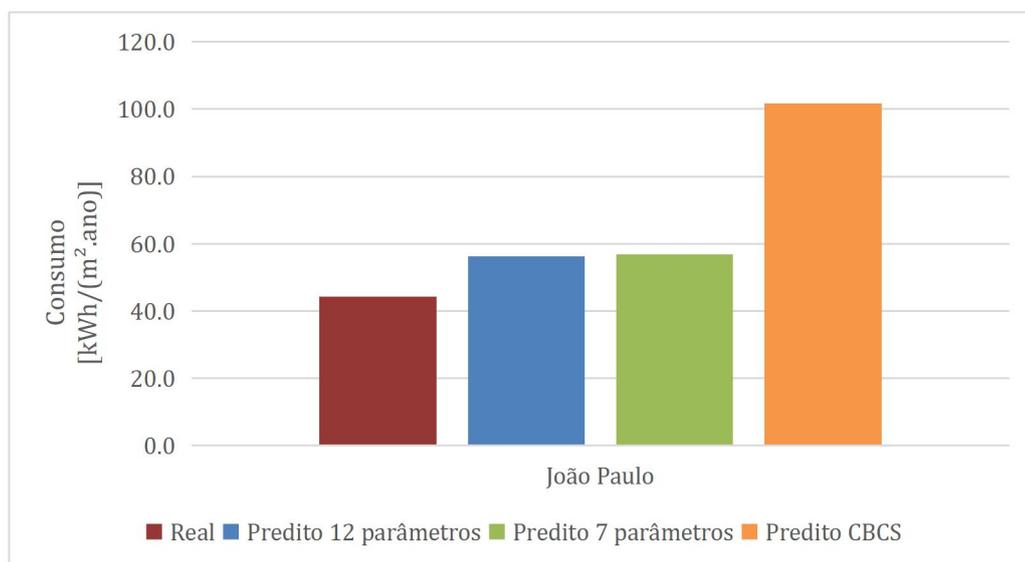
Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m ² .ano)]	< 102,7	>= 102,7 e <= 111,4	> 111,4

Verifica-se que, para a validação do Centro de Saúde João Paulo, a equação do CBCS classificou o edifício de forma mais coerente quanto comparada ao *benchmark top-down*, apresentando classificação eficiente. Ambos os modelos preditivos de ANN apresentaram classificação típica para o centro de saúde em estudo.

A Figura 22 compara os consumos energéticos preditos para o Centro de Saúde Novo Continente pelos modelos preditivos avaliados anteriormente. O erro de predição do consumo energético, com relação ao consumo energético real, é de 26,9% para a ANN com 12 parâmetros, 28,4% para a ANN com 7 parâmetros e 129,6% para a equação de *benchmark* do CBCS. Os modelos preditivos de ANN

selecionados apresentaram valores de consumo energético estimado com menor erro em relação a equação do CBCS.

Figura 22 – Consumo energético real e predito para o Centro de Saúde João Paulo.



4.4.3. Projeto 2: Centro de Saúde Novo Continente

O Centro de Saúde Novo Continente apresentou consumo energético de 79,9 kWh/(m².ano) no ano de 2019. Com isso, classifica-se essa edificação como típica, em um *benchmark top-down* desenvolvido com os dados reais de consumo energético da tipologia em Florianópolis.

Ao aplicar os parâmetros relativos aos limites mínimos e máximos da tabela de classificação de *benchmark* no modelo preditivo de ANN com 12 parâmetros, obtém-se um consumo mínimo de 44,1 kWh/(m².ano), e de 75,3 kWh/(m².ano) para o consumo máximo, conforme apresentado na Tabela 18. A partir desses valores, calcula-se que o valor de i é de 10,4 kWh/(m².ano), e se estabelece a escala de *benchmark* na Tabela 19. O consumo energético do edifício em estudo foi estimado em 63,9 kWh/(m².ano). Assim, classifica-se o edifício também como típico no *benchmark bottom-up* com 12 parâmetros.

Tabela 18 – Características do Centro de Saúde Novo Continente e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 12 parâmetros para a realização da tabela de classificação de benchmark, e os respectivos consumos energéticos.

Parâmetro	Mínimo	Máximo	Edifício em estudo
Transmitância da cobertura	2,06	1,55	2,06

Transmitância das paredes externas	4,40	0,45	2,46
Absortância da cobertura	0,3	0,8	0,6
Absortância das paredes externas	0,3	0,8	0,4
Fator solar dos vidros	0,45	0,82	0,82
Densidade de potência de iluminação (DPI) [W/m²]	7,5	16,5	14,5
Ocupação [m²/pessoa]	11,3		
Funcionamento [h]	10		
Eficiência do sistema de condicionamento de ar	5,5	2,7	3,24
Ambientes condicionados	Cenário 3		
Orientação	0		
Graus-Hora de Resfriamento	28602 (Florianópolis)		
Consumo predito ANN 12 parâmetros [kWh/(m².ano)]	44,1	75,3	63,9

Tabela 19 – Escala de classificação do *benchmark* desenvolvido a partir da ANN com 12 parâmetros.

Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m².ano)]	< 54,5	>= 54,5 e <= 64,9	> 64,9

O modelo preditivo de ANN com 7 parâmetros obteve um consumo mínimo de 43,5 kWh/(m².ano) e 74,5 kWh/(m².ano) para o consumo máximo, conforme apresentado na Tabela 20. A partir desses valores, calcula-se que o valor de *i* é de 10,3 kWh/(m².ano), e se estabelece a escala de *benchmark* na Tabela 21. O consumo energético do edifício em estudo foi estimado em 64,5 kWh/(m².ano). Assim, classifica-se o edifício como ineficiente no *benchmark bottom-up* com 7 parâmetros.

Tabela 20 – Características do Centro de Saúde Novo Continente e dos limites mínimo e máximo, inseridas no modelo preditivo ANN com 7 parâmetros para a realização da tabela de classificação de benchmark, e os respectivos consumos energéticos.

Parâmetro	Mínimo	Máximo	Edifício em estudo
Absortância da cobertura	0,3	0,8	0,6
Densidade de potência de iluminação (DPI) [W/m ²]	7,5	16,5	14,5
Ocupação [m ² /pessoa]	11,3		
Funcionamento [h]	10		
Eficiência do sistema de condicionamento de ar	5,5	2,7	3,24
Ambientes condicionados	Cenário 3		
Graus-Hora de Resfriamento	28602 (Florianópolis)		
Consumo predito ANN 7 parâmetros [kWh/(m ² .ano)]	43,5	74,5	64,5

Tabela 21 – Escala de classificação do *benchmark* desenvolvido a partir da ANN com 7 parâmetros.

Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m ² .ano)]	< 53,8	>= 53,8 e <= 64,2	> 64,2

A aplicação da equação de *benchmark* do CBCS para centros de saúde apresentou um consumo predito de 112,1 kWh/(m².ano) para o edifício em estudo, e resultou em um consumo mínimo de 98,4 kWh/(m².ano) e um consumo máximo de 120,1 kWh/(m².ano) no processo de estabelecimento da escala de *benchmark*, conforme apresentado na Tabela 22. A partir desses valores, calcula-se que o valor de *i*, de acordo com a divisão por 5 estabelecida pelo CBCS, é de 4,3 kWh/(m².ano), e se estabelece a escala de *benchmark* na Tabela 23, conforme a divisão da escala proposta pelo CBCS. Verifica-se, portanto, que a edificação se classificaria como ineficiente nesse procedimento de *benchmark*.

Tabela 22 – Limites mínimo, máximo e consumo do edifício em estudo obtidos pela equação do CBCS para a realização da tabela de classificação de *benchmark*.

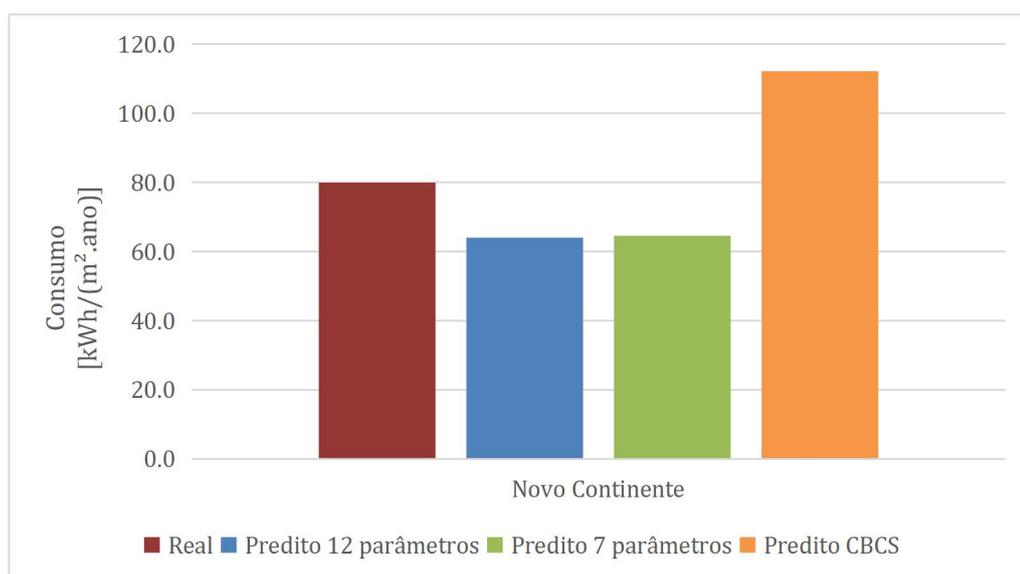
Parâmetro	Mínimo	Máximo	Edifício em estudo
Consumo [kWh/(m ² .ano)]	98,4	120,1	112,1

Tabela 23 – Escala de classificação do *benchmark* estabelecido pelo CBCS.

Classificação	Eficiente	Típico	Ineficiente
Consumo [kWh/(m ² .ano)]	< 102,7	>= 102,7 e <= 111,4	> 111,4

A partir dos resultados obtidos anteriormente, verifica-se que, para o Centro de Saúde Novo Continente, o modelo preditivo desenvolvido com 12 parâmetros de entrada classificou mais adequadamente o edifício quando comparado à classificação do *benchmark top-down*, sendo que ambas as classificações apresentaram consumo típico para a edificação. O modelo preditivo com 7 parâmetros de entrada e a equação do CBCS classificaram o edifício como ineficiente. A Figura 23 compara os consumos energéticos preditos para o Centro de Saúde Novo Continente pelos modelos preditivos avaliados anteriormente. O erro de predição do consumo energético, com relação ao consumo energético real, é de -20% para a ANN com 12 parâmetros, -19,3% para a ANN com 7 parâmetros e 40,3% para a equação de benchmark do CBCS. Os modelos preditivos apresentaram consumo energético estimado para o Centro de Saúde Novo Continente com menor erro em relação a equação do CBCS.

Figura 23 – Consumo energético real e predito para o Centro de Saúde Novo Continente.



4.4.4. Casos simulados de validação

Para fins de validação do modelo preditivo, foram simulados cinco casos diferentes dos utilizados na amostragem e no treinamento dos modelos. Os parâmetros dessas simulações são apresentados na Tabela 24. Os resultados das simulações, assim como os resultados da aplicação dos parâmetros de cada caso aos modelos preditivos utilizados para o desenvolvimento dos benchmarks bottom-up e o resultado da aplicação da equação desenvolvida pelo CBCS, são mostradas na Figura 24. Verifica-se, na Tabela 25, que os modelos preditivos do benchmark desenvolvido apresenta métricas de erro significativamente menores do que a equação de benchmark do CBCS, o que é explicado pela maior quantidade de parâmetros de entrada considerados no modelo preditivo. O benchmark do CBCS considera apenas o GHR, o tipo do sistema de condicionamento de ar, a densidade de potência de iluminação e a absorvância solar da fachada no estabelecimento da equação de previsão de consumo energético para centros de saúde. Portanto, desconsidera parâmetros identificados pela análise de sensibilidade como importantes para a definição do consumo total da edificação, como o período de funcionamento, os cenários de ambientes condicionados e a absorvância da cobertura.

Tabela 24 – Características dos casos de validação simulados.

Parâmetro	Caso 1	Caso 2	Caso 3	Caso 4	Caso 5
Transmitância da cobertura	2,06	2,06	1,94	2,06	2,06
Transmitância das paredes externas	2,46	0,45	4,40	4,40	2,46
Absortância da cobertura	0,4	0,8	0,3	0,6	0,4
Absortância das paredes externas	0,3	0,6	0,5	0,5	0,5
Fator solar dos vidros	0,76	0,52	0,67	0,56	0,59
Densidade de potência de iluminação (DPI) [W/m ²]	16,4	14,4	13,5	9,3	9,7
Ocupação [m ² /pessoa]	5	12	7	17	19
Funcionamento [h]	10	10	8	8	4
Eficiência do sistema de condicionamento de ar	3,24	2,7	3,24	3,24	5,5

Ambientes condicionados	Cenário 1	Cenário 1	Cenário 3	Cenário 3	Cenário 2
Orientação	270	180	270	0	0
Graus-Hora de Resfriamento	63550 (Recife)	45016 (RJ)	31412 (Campinas)	71394 (Fortaleza)	14172 (São Paulo)

Figura 24 – Comparação dos resultados de consumo energético das simulações de validação.

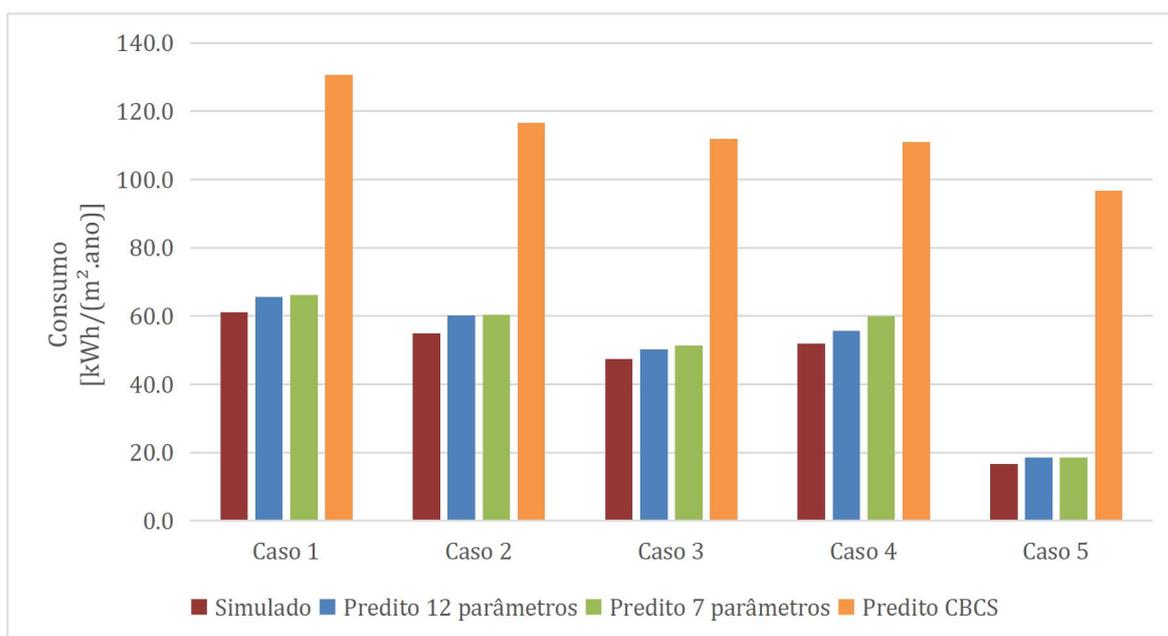


Tabela 25 – Valores das métricas de erro para as predições de consumo das simulações de validação.

	RMSE	MAE
Predito 12 parâmetros	3,78	3,62
Predito 7 parâmetros	5,22	4,82
Predito CBCS	67,4	66,9

4.4.5. Aplicação do metamodelo de conforto por ventilação natural da INI-C

Na Tabela 26, verifica-se a avaliação do conforto por ventilação natural para os casos de consumo mínimo e máximo nas oito cidades consideradas nas simulações. Verifica-se o progressivo aumento do percentual de horas em desconforto para climas mais quentes, atingindo valores acima de 90% de horas de desconforto para as cidades de Vitória, Recife e Fortaleza, o que é explicado pela

utilização de materiais construtivos mais isolantes na cobertura e altas absorções solares nas simulações dos casos de consumo máximo, características que prejudicam o conforto térmico em climas mais quentes. Observa-se que Campos do Jordão apresentou valores de FH_{desc} abaixo de 10% para os casos mínimo e máximo, caracterizando uma envoltória com classificação A para essa cidade em ambos os casos. Adicionalmente, os casos de consumo mínimo das cidades de São Paulo, Florianópolis e Campinas também apresentaram valores de FH_{desc} abaixo de 10%. Os valores de horas de desconforto abaixo de 10% indicam a possibilidade de uma redução significativa do consumo do sistema de condicionamento de ar com a utilização da ventilação natural em edificações com essas características, desde que sejam realizados estudos que favoreçam o conforto térmico na ausência de condicionamento artificial de ar. Com isso, verifica-se a importância de se considerar a ventilação natural na operação das edificações e, conseqüentemente, nos *benchmarks* desenvolvidos.

Tabela 26 – Estimativas da fração de horas excedentes por calor ao ano (FH_{desc}) obtidas pela aplicação do metamodelo de avaliação do uso da ventilação natural da INI-C.

Cidade	Consumo	Resultado [%]
Campos do Jordão	Mínimo	0
	Máximo	8
São Paulo	Mínimo	1
	Máximo	26
Florianópolis	Mínimo	3
	Máximo	34
Campinas	Mínimo	7
	Máximo	67
Rio de Janeiro (Vila Militar)	Mínimo	12
	Máximo	78
Vitória	Mínimo	25
	Máximo	91
Recife	Mínimo	61
	Máximo	100
Fortaleza	Mínimo	61
	Máximo	99

5. Conclusões

Os *benchmarks* energéticos são importantes ferramentas para comparação da eficiência energética de edificações em uso de determinada tipologia. O presente trabalho teve como objetivo o desenvolvimento de um *benchmark* energético em centros de saúde.

Para a realização das simulações computacionais que forneceram os dados de consumo energético para o desenvolvimento do *benchmark*, foi utilizado um arquétipo baseado em um projeto padrão do Ministério da Saúde. Foram variados os parâmetros de transmitância térmica e absorvância térmica da cobertura e das paredes externas, fator solar dos vidros das aberturas, densidade de potência de iluminação (DPI), ocupação, período de funcionamento, eficiência do sistema de condicionamento de ar, ambientes condicionados, orientação do edifício e arquivos climáticos. Foi utilizada a amostragem de Saltelli para estabelecer os parâmetros de entrada das simulações realizadas, com o objetivo de obter uma representação do espaço amostral com a quantidade de simulações possível de ser realizada com a capacidade de processamento disponível.

Com a análise de sensibilidade realizada, percebe-se que os parâmetros de densidade de potência de iluminação, período de funcionamento e cenários de ambientes condicionados foram os que mais impactaram o consumo total do arquétipo para a cidade de Florianópolis. Para Fortaleza, adiciona-se entre os parâmetros mais impactantes sobre o consumo total do arquétipo a eficiência do sistema de condicionamento de ar e a absorvância da cobertura. Adicionalmente, a análise de correlação de Pearson incluiu o parâmetro de Graus-Hora de Resfriamento entre os mais impactantes sobre o consumo total.

Para a realização dos modelos preditivos de consumo total, foram utilizados os métodos de aprendizado de máquina Máquinas de Vetor de Suporte e Redes Neurais Artificiais. Com o objetivo de otimizar a quantidade de parâmetros de entrada do modelo preditivo, foram considerados três pontos de corte para o coeficiente de correlação de Pearson. O ponto de corte 0,01 considerou 10 parâmetros de entrada, o ponto de corte 0,025 determinou 7 parâmetros de entrada, e o ponto de corte 0,1 contemplou 5 parâmetros de entrada. Dentre os modelos preditivos treinados, foram selecionados dois modelos para posterior validação. O modelo preditivo de ANN com os 12 parâmetros variados foi o que apresentou as menores métricas de erro, com RMSE de 0,91 kWh/(m².ano) e MAE de 0,65 kWh/(m².ano). Adicionalmente, foi selecionada a ANN com 7 parâmetros, que apresentou RMSE de 1,40 kWh/(m².ano) e MAE de 0,87 kWh/(m².ano).

A partir dos dados reais de consumo energético de centros de saúde de Florianópolis, foi estabelecida uma escala de *benchmark top-down*. As edificações que apresentaram consumo inferior a 63,8 kWh/(m².ano) foram considerados os mais eficientes dessa tipologia e podem ser considerados como referência para a identificação de boas práticas de projeto e uso. Já os edifícios com consumo superior a 106,4 kWh/(m².ano) foram considerados ineficientes, e devem ser o foco de futuras análises de aplicação de medidas de eficiência energética.

O Centro de Saúde de João Paulo, com consumo energético real de 44,3 kWh/(m².ano), foi classificado como eficiente no *benchmark top-down*. O modelo preditivo com 12 parâmetros de entrada estimou o consumo total da edificação em 56,2 kWh/(m².ano), e a classificou como típica. O modelo preditivo com 7 parâmetros de entrada estimou o consumo total da edificação em 56,9 kWh/(m².ano), e também a classificou como típica. A equação de *benchmark* obtida pelo estudo do CBCS (VELOSO et al., 2021) estimou o consumo da edificação em 101,7 kWh/(m².ano), e a classificou como eficiente. Portanto, percebe-se que, apesar de a equação do CBCS apresentar o consumo estimado com maior erro em relação ao modelo preditivo desenvolvido, classificou o edifício de forma mais coerente quanto comparada ao *benchmark top-down*. Os modelos preditivos de ANN selecionados apresentaram valores de consumo energético estimado com menor erro em relação a equação do CBCS.

O Centro de Saúde Novo Continente apresentou consumo real de 79,9 kWh/(m².ano), sendo classificado como típico no *benchmark top-down*. O modelo preditivo com 12 parâmetros de entrada estimou o consumo total da edificação em 63,9 kWh/(m².ano), e a classificou também como típica. O modelo preditivo com 7 parâmetros de entrada estimou o consumo total da edificação em 64,5 kWh/(m².ano), e a classificou também como ineficiente. A equação do CBCS estimou o consumo da edificação em 112,1 kWh/(m².ano), e a classificou como ineficiente. Nesse caso, o modelo preditivo desenvolvido com 12 parâmetros de entrada classificou mais adequadamente o edifício do que o modelo preditivo com 7 parâmetros de entrada e a equação do CBCS, quanto comparado a classificação do *benchmark top-down*. Os modelos preditivos também apresentaram consumo energético estimado com menor erro em relação a equação do CBCS.

Os resultados de consumo predito obtidos a partir dos modelos preditivos analisados apresentaram erros abaixo de 30% para o Centro de Saúde de João Paulo e abaixo de 20% para o Centro de Saúde Novo Continente, em relação ao consumo real. Esses valores de erro são consideravelmente inferiores aos erros obtidos pela equação de *benchmark* do estudo do CBCS, o que indica uma maior aderência dos modelos preditivos desenvolvidos neste trabalho para a tipologia de centros de saúde para a cidade de Florianópolis. Os valores de consumo predito e os erros de predição dos modelos preditivos de 12 e 7 parâmetros não apresentaram diferenças significativas, o que indica que a utilização de um modelo mais simples, com menos variáveis de entrada, não impacta significativamente na predição do consumo e permite que o *benchmark* desenvolvido seja utilizado mais facilmente, com a necessidade de menos medições nos edifícios em uso. O modelo preditivo deve ser melhor calibrado para as faixas de maior consumo energético, de acordo com futuros diagnósticos energéticos que sejam realizados.

A partir dos resultados de consumo energético dos centros de saúde analisados, assim como da análise de sensibilidade realizada, evidencia-se a possibilidade de redução do consumo energético com a redução da densidade de potência de iluminação, um dos parâmetros mais importantes sobre o consumo

energético de acordo com a análise de sensibilidade, com a substituição das lâmpadas fluorescentes por LED.

Os consumos preditos pelo modelo preditivo para os casos simulados de validação apresentaram métricas de erro consideravelmente menores em comparação com as métricas de erro obtidas pela equação do CBCS. Isso se deve ao fato de a equação do CBCS não ter considerado parâmetros importantes para a determinação do consumo total dessa tipologia, como os ambientes condicionados, o horário de funcionamento e a absorvância da cobertura.

Por fim, a aplicação do metamodelo de avaliação do uso de ventilação natural da Instrução Normativa Inmetro para a Classificação de Eficiência Energética de Edificações Comerciais, de Serviços e Públicas (INI-C) indicou que o arquétipo em estudo tem condições de apresentar alta eficiência energética de envoltória com a utilização de ventilação natural nos climas mais frios simulados, o que é sinalizado por valores de fração de horas excedentes por calor ao ano abaixo de 10%. A cidade de Campos do Jordão apresentou valores de 0% e 8% de horas excedentes por calor ao ano para os casos de consumo mínimo e máximo, respectivamente. As cidades de São Paulo, Florianópolis e Campinas apresentou valores de 1%, 3% e 7% de horas excedentes por calor ao ano para os casos de consumo mínimo. Com isso, identifica-se a possibilidade de redução significativa do consumo energético do sistema de condicionamento de ar com a utilização da ventilação natural nessas cidades.

5.1. Sugestões de trabalhos futuros

Para possíveis trabalhos futuros que evoluam a partir deste trabalho, sugere-se a realização de medições detalhadas da quantidade de atendimentos nos edifícios de centros de saúde. Esse é um parâmetro que pode sofrer muita variação durante a operação de edifícios dessa tipologia e, inclusive, pode ser utilizado o indicador de consumo energético por quantidade de atendimento em vez do consumo energético por área construída, de forma semelhante ao indicador de consumo energético por quantidade de alunos em edifícios educacionais.

Adicionalmente, sugere-se a realização de diagnósticos energéticos para melhor calibração dos parâmetros de consumo dos equipamentos nas simulações computacionais. Nos projetos elétricos costuma-se apresentar apenas a quantidade de tomadas de energia. Com isso, há uma falta de dados mais detalhados nos projetos sobre os equipamentos instalados e a sua frequência de utilização. Deve-se ponderar se a avaliação mais criteriosa da DPE real, com a medição dos consumos dos equipamentos, tornaria mais complexa a implementação e utilização do *benchmark* desenvolvido.

A influência do entorno não foi considerada nas simulações computacionais desse trabalho, e pode ser considerada em futuros aprimoramentos do *benchmark* para centros de saúde.

6. Referências bibliográficas

ABNT. ISO 50002. **Diagnósticos energéticos — Requisitos com orientação para uso**. Rio de Janeiro, 2014.

AHMAD, T.; CHEN, H.; GUO, Y.; WANG, J. A comprehensive overview on the data driven and large scale based approaches for forecasting of building energy demand: A review. **Energy and Buildings**, [s. l.], v. 165, p. 301–320, 2018. Disponível em: <https://doi.org/10.1016/j.enbuild.2018.01.017>.

ANDRÉ, M. A. **Potencial de incremento do conforto térmico dos usuários em escritórios com o uso de ventiladores de mesa durante o verão**. Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2019

ASHRAE - American Society of Heating, Refrigerating and Air-Conditioning Engineers. **ASHRAE Launches New Building Energy Quotient Portal**. 2017. Disponível em: <https://www.ashrae.org/about/news/2017/ashrae-launches-new-building-energy-quotient-portal>

_____. **Procedures for Commercial Building Energy Audits**. 2011.

BANNISTER, P. NABERS: Lessons from 12 years of performance-based ratings in Australia. **Energy Systems Laboratory**, [S. l.], n. Eu 2002, 2012.

BOEMI, S. N.; SLINI, T.; PAPADOPOULOS, A. M.; MIHALAKAKOU, Y. A statistical approach to the prediction of the energy performance of hotel stock. **International Journal of Ventilation**, [s. l.], v. 10, n. 2, p. 163–172, 2011.

BORGSTEIN, E. H.; LAMBERTS, R. Developing energy consumption benchmarks for buildings: Bank branches in Brazil. **Energy and Buildings**, [S. l.], v. 82, p. 82–91, 2014. Disponível em: <https://doi.org/10.1016/j.enbuild.2014.07.028>

BORGSTEIN, E. H.; LAMBERTS, R.; HENSEN, J. L. M. Mapping failures in energy and environmental performance of buildings. **Energy and Buildings**, [S. l.], v. 158, p. 476–485, 2018. Disponível em: <https://doi.org/10.1016/j.enbuild.2017.10.038>

BORGSTEIN, E. H.; LAMBERTS, R.; HENSEN, J. L. M. Evaluating energy performance in non-domestic buildings: A review. **Energy and Buildings**, [S. l.], v. 128, p. 734–755, 2016. Disponível em: <https://doi.org/10.1016/j.enbuild.2016.07.018>

BP – British Petroleum. **Energy Outlook: Country insight – Brazil**. 2019. Disponível em: <https://www.bp.com/en/global/corporate/energy-economics/energy-outlook/country-and-regional-insights/brazil-insights.html#>

BRASIL. Ministério da Saúde. **Programa de Requalificação de Unidades Básicas de saúde**. 2013. Disponível em: <https://aps.saude.gov.br/ape/requalificaUbs>

BRUHNS, H.; JONES, P.; COHEN, R. **CIBSE Review of Energy Benchmarks for Display Energy Certificates**. CIBSE Technical Symposium, 2011.

BUCK, J.; YOUNG, D. The potential for energy efficiency gains in the Canadian commercial building sector: A stochastic frontier study. **Energy**, [S. l.], v. 32, n. 9, p. 1769–1780, 2007. Disponível em: <https://doi.org/10.1016/j.energy.2006.11.008>

BURHENNE, S.; JACOB, D.; HENZE, G. P. Sampling based on sobol' sequences for monte carlo techniques applied to building simulations. **Proceedings of Building Simulation 2011: 12th Conference of International Building Performance Simulation Association**, [s. l.], n. January 2011, p. 1816–1823, 2011.

BURMAN, E.; HONG, S. M.; PATERSON, G.; KIMPIAN, J.; MUMOVIC, D. A comparative study of benchmarking approaches for non-domestic buildings: Part 2 – Bottom-up approach. **International Journal of Sustainable Built Environment**, [s. l.], v. 3, n. 2, p. 247–261, 2014. Disponível em: <http://dx.doi.org/10.1016/j.ijbsbe.2014.12.001>.

CARBONBUZZ. **Summary of audits performed on CarbonBuzz by the UCL Energy Institute**. 2013.

CBCS – Conselho Brasileiro de Construção Sustentável. **Benchmarking e etiquetagem energética em uso**. 2013. Disponível em: <http://www.cbcs.org.br/website/benchmarking-energia/show.asp>

_____. **Comunicação técnica: Desenvolvimento de benchmarks nacionais de consumo energético de edificações em operação**. 2014.

_____. **Cidades Eficientes**. 2018. Disponível em: <http://cidadeeficientes.cbcs.org.br/>

_____. **Plataforma de Gestão de Energia e Água**. 2020. Disponível em: <https://cidadeeficientes.shinyapps.io/florianopolis/>

_____. **Guia Prático para Realização de Diagnósticos Energéticos em Edificações**. 2016.

_____. **Grau-horas de resfriamento – GHR**. Publicadas para 413 municípios no Brasil, para uso em cálculos de correção climática. 2014.

CHALAL, M. L.; BENACHIR, M.; WHITE, M.; SHRAHILY, R. Energy planning and forecasting approaches for supporting physical improvement strategies in the building sector: A review. **Renewable and Sustainable Energy Reviews**, [s. l.], v. 64, p. 761–776, 2016. Disponível em: <http://dx.doi.org/10.1016/j.rser.2016.06.040>.

CHOU, J. S.; BUI, D. K. Modeling heating and cooling loads by artificial intelligence for energy-efficient building design. **Energy and Buildings**, [S. l.], v. 82, n. 2014, p. 437–446, 2014. Disponível em: <https://doi.org/10.1016/j.enbuild.2014.07.036>

CHUNG, W. Review of building energy-use performance benchmarking methodologies. **Applied Energy**, [S. l.], v. 88, n. 5, p. 1470–1479, 2011. Disponível em: <https://doi.org/10.1016/j.apenergy.2010.11.022>

CHUNG, W.; HUI, Y. V.; LAM, Y. M. Benchmarking the energy efficiency of commercial buildings. **Applied Energy**, [S. l.], v. 83, n. 1, p. 1–14, 2006. Disponível em: <https://doi.org/10.1016/j.apenergy.2004.11.003>

CIBSE - Chartered Institution of Building Services Engineers. **Energy Consumption Guide 19**. Londres, 2003.

_____. **Energy Assessment and Reporting Method, CIBSE TM22**. Londres, 2006.

_____. **Energy Benchmarks, CIBSE TM46**. Londres, 2008.

_____. **Energy Efficiency in Buildings, CIBSE Guide F**. Londres, 2004.

CMMAD - COMISSÃO MUNDIAL SOBRE MEIO AMBIENTE E DESENVOLVIMENTO. **Nosso futuro comum**: comissão mundial sobre meio ambiente e desenvolvimento. 2.ed. Rio de Janeiro: Fundação Getúlio Vargas, 1991.

COHEN, R.; BORDASS, B. Mandating transparency about building energy performance in use. **Building Research and Information**, [S. l.], v. 43, n. 4, p. 534–552, 2015. Disponível em: <https://doi.org/10.1080/09613218.2015.1017416>

COTTAFAVA, D.; SONETTI, G.; GAMBINO, P.; TARTAGLINO, A. Explorative multidimensional analysis for Energy Efficiency: Dataviz versus clustering algorithms. **Energies**, [s. l.], v. 11, n. 5, p. 1–18, 2018.

D'OCA, S.; HONG, T.; LANGEVIN, J. The human dimensions of energy use in buildings: A review. **Renewable and Sustainable Energy Reviews**, [s. l.], v. 81, n. May 2017, p. 731–742, 2018.

DELGARM, N.; SAJADI, B.; AZARBAD, K.; DELGARM, S. Sensitivity analysis of building energy performance: A simulation-based approach using OFAT and variance-based sensitivity analysis methods. **Journal of Building Engineering**, [s. l.], v. 15, n. November 2017, p. 181–193, 2018. Disponível em: <https://doi.org/10.1016/j.jobbe.2017.11.020>.

DOE – U. S. Department of Energy. **Commercial Reference Buildings**. 2012. Disponível em: <https://www.energy.gov/eere/buildings/commercial-reference-buildings>

DONG, B.; CAO, C.; LEE, S. E. Applying support vector machines to predict building energy consumption in tropical region. **Energy and Buildings**, [s. l.], v. 37, n. 5, p. 545–553, 2005.

_____. **EnergyPlus 9.2.0**. 2019. Disponível em: <https://energyplus.net>

EIA - Energy Information Administration, **Commercial Energy Consumption Survey (CBECS)**, 2003. Disponível em:
<https://www.eia.gov/consumption/commercial/>

ELI, L. G.; KRELLING, A. F.; MENDES, L. S.; SILVA, R. M.; MAZZAFERRO, L.; MELO, A. P.; LAMBERTS, R. **Manual de simulação computacional de edifícios com o uso do objeto ground domain no programa energyplus – versão 9.0.1**. Florianópolis, 2019.

EPA. **Energy Star Portfolio Manager**. 2020. Disponível em:
<https://www.energystar.gov/buildings/facility-owners-and-managers/existing-buildings/use-portfolio-manager>

EPE - Empresa De Pesquisa Energética. **Balço Energético Nacional 2021: ano base 2020**. MME: Rio de Janeiro: 2021.

_____. **TDR nº 16 - Pesquisa do Consumo de Energia no Setor de Serviços**. 2015. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/projeto-de-assistencia-tecnica-dos-setores-de-energia-e-mineral-projeto-meta>

FEDERSPIEL, C.; ZHANG, Q.; ARENS, E. Model-based benchmarking with application to laboratory buildings. **Energy and Buildings**, [S. l.], v. 34, n. 3, p. 203–214, 2002. Disponível em: [https://doi.org/10.1016/S0378-7788\(01\)00092-5](https://doi.org/10.1016/S0378-7788(01)00092-5)

FILIPPÍN, C. Benchmarking the energy efficiency and greenhouse gases emissions of school buildings in central Argentina. **Building and Environment**, [S. l.], v. 35, n. 5, p. 407–414, 2000. Disponível em: [https://doi.org/10.1016/S0360-1323\(99\)00035-9](https://doi.org/10.1016/S0360-1323(99)00035-9)

FUMO, N.; MAGO, P.; LUCK, R. Methodology to estimate building energy consumption using EnergyPlus Benchmark Models. **Energy & Buildings**, [S. l.], v. 42, n. 12, p. 2331–2337, 2010. Disponível em:
<https://doi.org/10.1016/j.enbuild.2010.07.027>

GAO, X.; MALKAWI, A. A new methodology for building energy performance benchmarking: An approach based on intelligent clustering algorithm. **Energy and Buildings**, [S. l.], v. 84, p. 607–616, 2014. Disponível em:
<https://doi.org/10.1016/j.enbuild.2014.08.030>

GERALDI, M. S.; BAVARESCO, M. V.; TRIANA, M. A.; MELO, A. P.; LAMBERTS, R. Addressing the impact of COVID-19 lockdown on energy use in municipal buildings: a case study in Florianópolis, Brazil. **Sustainable cities and society**, [s. l.], v. 69, n. December 2020, p. 102823, 2021.

GERALDI, M. S.; GHISI, E. Building-level and stock-level in contrast: A literature review of the energy performance of buildings during the operational stage. **Energy and Buildings**, [S. l.], v. 211, p. 109810, 2020. Disponível em: <https://doi.org/10.1016/j.enbuild.2020.109810>

GERALDI, M. S.; GHISI, E. Data-driven framework towards realistic bottom-up energy benchmarking using an Artificial Neural Network. **Applied Energy**, [s. l.], v. 306, n. PA, p. 117960, 2022. Disponível em: <https://doi.org/10.1016/j.apenergy.2021.117960>.

GNECCO, V. M. **Desenvolvimento de um modelo de benchmarking local para as escolas públicas de ensino infantil de Florianópolis**. Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2021.

GONÇALVES, J. C. S.; BODE, K. **Edifício ambiental**. São Paulo: Oficina de Textos, 2015.

GUNAY, H. B.; OUF, M.; NEWSHAM, G.; O'BRIEN, W. Sensitivity analysis and optimization of building operations. **Energy and Buildings**, [s. l.], v. 199, p. 164–175, 2019. Disponível em: <https://doi.org/10.1016/j.enbuild.2019.06.048>.

HARISH, V. S. K. V.; KUMAR, A. A review on modeling and simulation of building energy systems. **Renewable and Sustainable Energy Reviews**, [s. l.], v. 56, p. 1272–1292, 2016. Disponível em: <http://dx.doi.org/10.1016/j.rser.2015.12.040>.

HERMAN, J.; USHER, W. SALib: An open-source Python library for Sensitivity Analysis. **The Journal of Open Source Software**, The Open Journal, v. 2, n. 9, jan 2017. Disponível em: <<https://doi.org/10.21105/joss.00097>>.

HONG, S. M.; PATERSON, G.; BURMAN, E.; STEADMAN, P.; MUMOVIC, D. A comparative study of benchmarking approaches for non-domestic buildings: Part 1 – Top-down approach. **International Journal of Sustainable Built Environment**, [s. l.], v. 2, n. 2, p. 119–130, 2013.

HONG, S. M.; PATERSON, G.; MUMOVIC, D.; STEADMAN, P. Improved benchmarking comparability for energy consumption in schools. **Building Research and Information**, [s. l.], v. 42, n. 1, p. 47–61, 2014.

HSU, D. How much information disclosure of building energy performance is necessary? **Energy Policy**, [S. l.], v. 64, p. 263–272, 2014. Disponível em: <https://doi.org/10.1016/j.enpol.2013.08.094>

IEA - International Energy Agency. **Global Status Report for Buildings and Construction**. 2019.

IEA - International Energy Agency. **Capturing the Multiple Benefits of Energy Efficiency**. 2014.

IEA - International Energy Agency. **Total Energy Use in Buildings Analysis and Evaluation Methods (Annex 53)**. 2016.

INMETRO - Instituto Nacional de Metrologia, Qualidade e Tecnologia. **Portaria nº 42, de 24 de fevereiro de 2021**. Instrução normativa Inmetro para a classificação de eficiência energética de edificações comerciais, de serviços e públicas, 2021. Disponível em: <http://www.inmetro.gov.br/legislacao/rtac/pdf/RTAC002707.pdf>

_____. **Portaria nº 234, de 29 de junho de 2020**. 2020.

_____. **Portaria nº 50, de 2013**. 2013a. Disponível em: https://labeee.ufsc.br/sites/default/files/disciplinas/AnexoVRAC_CatalogoPropriedadesTermicas%20v03SET2013.pdf

_____. **Portaria n.º 410, de 16 de agosto de 2013**. 2013b.

ISO - International Organization for Standardization. **ISO 7730: Ergonomics of the thermal environment- Analytical determination and interpretation of thermal comfort using calculation of the PMV and PPD indices and local thermal comfort criteria**. 2005

KALOGIROU, S. A. Artificial neural networks in energy applications in buildings. **International Journal of Low Carbon Technologies**, [S. l.], v. 15, n. 2, p. 133–137, 2005. Disponível em: <https://doi.org/10.1097/01.mou.0000160629.81978.7a>

KATAFYGIOTOU, M. C.; SERGHIDES, D. K. Analysis of structural elements and energy consumption of school building stock in Cyprus: Energy simulations and upgrade scenarios of a typical school. **Energy and Buildings**, [S. l.], v. 72, p. 8–16, 2014. Disponível em: <https://doi.org/10.1016/j.enbuild.2013.12.024>

LEE, W. S. Benchmarking the energy efficiency of government buildings with data envelopment analysis. **Energy and Buildings**, [S. l.], v. 40, n. 5, p. 891–895, 2008. Disponível em: <https://doi.org/10.1016/j.enbuild.2007.07.001>

LEE, W. S. Benchmarking the energy performance for cooling purposes in buildings using a novel index-total performance of energy for cooling purposes. **Energy**, [S. l.], v. 35, n. 1, p. 50–54, 2010. Disponível em: <https://doi.org/10.1016/j.energy.2009.08.026>

LI, J. S. M. A study of energy performance and efficiency improvement procedures of Government Offices in Hong Kong Special Administrative Region. **Energy and**

Buildings, [S. l.], v. 40, n. 10, p. 1872–1875, 2008. Disponível em: <https://doi.org/10.1016/j.enbuild.2008.04.011>

LI, Z.; HAN, Y.; XU, P. Methods for benchmarking building energy consumption against its past or intended performance: An overview. **Applied Energy**, [S. l.], v. 124, p. 325–334, 2014. Disponível em: <https://doi.org/10.1016/j.apenergy.2014.03.020>

MARTIN, C. Generating low-cost national energy benchmarks: A case study in commercial buildings in Cape Town, South Africa. **Energy and Buildings**, [S. l.], v. 64, p. 26–31, 2013. Disponível em: <https://doi.org/10.1016/j.enbuild.2013.04.008>

MASSANA, J.; POUS, C.; BURGAS, L.; MELENDEZ, J.; COLOMER, J. Short-term load forecasting in a non-residential building contrasting models and attributes. **Energy and Buildings**, [s. l.], v. 92, p. 322–330, 2015.

MCKINSEY. **Unlocking Energy Efficiency in the U.S. Economy**. Technical Report. 2009.

MENEZES, A. C.; CRIPPS, A.; BOUCHLAGHEM, D.; BUSWELL, R. Predicted vs. actual energy performance of non-domestic buildings: Using post-occupancy evaluation data to reduce the performance gap. **Applied Energy**, [s. l.], v. 97, p. 355–364, 2012. Disponível em: <http://dx.doi.org/10.1016/j.apenergy.2011.11.075>.

MENEZES, A. C.; CRIPPS, A.; BUSWELL, R. A.; BOUCHLAGHEM, D. Benchmarking small power energy consumption in office buildings in the United Kingdom: A review of data published in CIBSE Guide F. **Building Services Engineering Research and Technology**, [s. l.], v. 34, n. 1, p. 73–86, 2013.

MME – Ministério de Minas e Energia. **Projeto META – Institucional**. 2018. Disponível em: <http://www.mme.gov.br/web/guest/secretaria-executiva/projeto-meta>.

MORRIS, M. D. Factorial Sampling Plans for Preliminary Computational Experiments Max. **Technometrics**, [S. l.], v. 9, n. 5, p. 409–418, 1991. Disponível em: <https://doi.org/10.1177/001872086700900503>

NABERS - National Australian Built Environment Rating System. **Annual report 2019/20**. 2020. Disponível em: <https://nabers.info/annual-report/2019-2020/>

NIKOLAOU, T. G.; KOLOKOTSA, D. S.; SKIAS, I. D.; STAVRAKAKIS, G. S. Asset and operational benchmarking for office buildings in Greece. **International Journal of Sustainable Energy**, [s. l.], v. 28, n. 1–3, p. 77–91, 2009a.

NIKOLAOU, T.; SKIAS, I.; KOLOKOTSA, D.; STAVRAKAKIS, G. Virtual Building Dataset for energy and indoor thermal comfort benchmarking of office buildings in Greece. **Energy and Buildings**, [s. l.], v. 41, n. 12, p. 1409–1416, 2009b.

NRCAN – Natural Resources Canada. **Canadian Energy Use Intensity by Property Type**. 2018. Disponível em:

<https://www.nrcan.gc.ca/sites/www.nrcan.gc.ca/files/energy/pdf/Canadian%20National%20Median%20Tables-EN-Aug2018-7.pdf>

NREL - National Renewable Energy Laboratory. **OpenStudio 2.9.1**. National Renewable Energy Laboratory. 2019. Disponível em: <https://www.openstudio.net>

OLINGER, M. S. **Predição de conforto térmico em escritórios ventilados naturalmente por meio de redes neurais artificiais**. Dissertação (mestrado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2019

OLOFSSON, T.; MEIER, A.; LAMBERTS, R. Rating the Energy Performance of Buildings. **International Journal**, [S. l.], p. 18, 2004. Disponível em:

<http://escholarship.org/uc/item/52j7d39x>

ONEBUILDING. **Repository of free climate data for building performance simulation**. 2021. Disponível em: <http://climate.onebuilding.org/>

O'NEILL, Z.; PANG, X.; SHASHANKA, M.; HAVES, P.; BAILEY, T. Model-based real-time whole building energy performance monitoring and diagnostics. **Journal of Building Performance Simulation**, [s. l.], v. 7, n. 2, p. 83–99, 2014.

PAPADOPOULOS, S.; BONCZAK, B.; KONTOKOSTA, C. E. Pattern recognition in building energy performance over time using energy benchmarking data. **Applied Energy**, [S. l.], v. 221, n. February, p. 576–586, 2018. Disponível em:

<https://doi.org/10.1016/j.apenergy.2018.03.079>

PAPADOPOULOS, S.; KONTOKOSTA, C. E. Grading buildings on energy performance using city benchmarking data. **Applied Energy**, [S. l.], v. 233–234, n. July 2018, p. 244–253, 2019. Disponível em:

<https://doi.org/10.1016/j.apenergy.2018.10.053>

PARK, H. S.; LEE, M.; KANG, H.; HONG, T.; JEONG, J. Development of a new energy benchmark for improving the operational rating system of office buildings using various data-mining techniques. **Applied Energy**, [s. l.], v. 173, p. 225–237, 2016. Disponível em: <http://dx.doi.org/10.1016/j.apenergy.2016.04.035>.

PÉREZ-LOMBARD, L.; ORTIZ, J.; GONZÁLEZ, R.; MAESTRE, I. R. A review of benchmarking, rating and labelling concepts within the framework of building energy certification schemes. **Energy and Buildings**, [s. l.], v. 41, n. 3, p. 272–278, 2009.

PHILIP, S. **Eppy documentation**. 2019. Disponível em:

https://eppy.readthedocs.io/_/downloads/en/latest/pdf/

PNNL – Pacific Northwest National Laboratory. **A guide to energy audits**. 2011.

SABAPATHY, A.; RAGAVAN, S. K. V.; VIJENDRA, M.; NATARAJA, A. G. Energy efficiency benchmarks and the performance of LEED rated buildings for Information Technology facilities in Bangalore, India. **Energy and Buildings**, [s. l.], v. 42, n. 11, p. 2206–2212, 2010. Disponível em: <http://dx.doi.org/10.1016/j.enbuild.2010.07.014>.

SALTELLI, A. Making best use of model evaluations to compute sensitivity indices. **Computer Physics Communications**, [S. l.], v. 145, n. 2, p. 280–297, 2002. Disponível em: [https://doi.org/10.1016/S0010-4655\(02\)00280-1](https://doi.org/10.1016/S0010-4655(02)00280-1)

SALTELLI, A.; TARANTOLA, S.; CAMPOLONGO, F. Sensitivity Analysis as an Ingredient of Modeling. **Statistical Science**, [S. l.], v. 15, n. 4, p. 377–395, 2000.

SCHAEFER, A.; GHISI, E. Method for obtaining reference buildings. **Energy and Buildings**, [S. l.], v. 128, p. 660–672, 2016. Disponível em: <https://doi.org/10.1016/j.enbuild.2016.07.001>

SCOFIELD, J. H. Efficacy of LEED-certification in reducing energy consumption and greenhouse gas emission for large New York City office buildings. **Energy and Buildings**, [S. l.], v. 67, p. 517–524, 2013. Disponível em: <https://doi.org/10.1016/j.enbuild.2013.08.032>

SCOFIELD, J. H.; DOANE, J. Energy performance of LEED-certified buildings from 2015 Chicago benchmarking data. **Energy and Buildings**, [S. l.], v. 174, p. 402–413, 2018. Disponível em: <https://doi.org/10.1016/j.enbuild.2018.06.019>

SHARP, T. Energy Benchmarking In Commercial Office Buildings. **ACEEE Summer Study on Energy Efficiency in Buildings**, [S. l.], v. 4, p. 321–329, 1995.

SILVA, H. L. N. **Benchmarking de consumo energético em edifícios comerciais multiusuários de alto padrão na região metropolitana de São Paulo**. [Dissertação de Mestrado] Universidade Federal do ABC, 2013.

SILVA, A. S.; GHISI, E. Estimating the sensitivity of design variables in the thermal and energy performance of buildings through a systematic procedure. **Journal of Cleaner Production**, [s. l.], v. 244, p. 118753, 2020. Disponível em: <https://doi.org/10.1016/j.jclepro.2019.118753>.

SOBOL, I. M. Global sensitivity indices for nonlinear mathematical models and their Monte Carlo estimates. **Mathematics and Computers in Simulation**, [S. l.], v. 55, n. 1–3, p. 271–280, 2001. Disponível em: [https://doi.org/10.1016/S0378-4754\(00\)00270-6](https://doi.org/10.1016/S0378-4754(00)00270-6)

TAYLOR, J.; LIU, Y.; LIN, B.; BURMAN, E.; HONG, S. M.; YU, J.; WANG, Z.; MUMOVIC, D.; SHRUBSOLE, C.; VERMEER, D.; DAVIES, M. Towards a framework to evaluate the ‘total’ performance of buildings. **Building Services Engineering Research and Technology**, [s. l.], v. 39, n. 5, p. 609–631, 2018.

TIAN, W. A review of sensitivity analysis methods in building energy analysis. **Renewable and Sustainable Energy Reviews**, [S. l.], v. 20, p. 411–419, 2013. Disponível em: <https://doi.org/10.1016/j.rser.2012.12.014>

TORRES, T. R.; SOARES, G. L.; COELHO, T. M. M.; PEREIRA, S. C.; MOREIRA, E. T.; MARTINS, C. A. P. S. Métricas para avaliação da eficiência energética em instituições da área da saúde: um estudo de caso para entidades filantrópicas de Belo Horizonte. **Proceedings XXII Congresso Brasileiro de Automática**, [s. l.], 2018. Disponível em: <https://doi.org/10.20906/cps/cba2018-0273>

TSANAS, A.; XIFARA, A. Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. **Energy and Buildings**, [S. l.], v. 49, p. 560–567, 2012. Disponível em: <https://doi.org/10.1016/j.enbuild.2012.03.003>

VAN DRONKELAAR, C.; DOWSON, M.; SPATARU, C.; MUMOVIC, D. A Review of the Regulatory Energy Performance Gap and Its Underlying Causes in Non-domestic Buildings. **Frontiers in Mechanical Engineering**, [s. l.], v. 1, n. January, p. 1–14, 2016.

VELOSO, A. C. D. O. **Avaliação do Consumo de Energia Elétrica de Edificações de Escritório e sua Correlação com as Decisões de Projeto**. p. 125, 2017.

VELOSO, A. C.; DEGANI, C.; MELO, A. P.; AMARAL, D.; LETTI, A.; KANASHIRO, E.; CURSINO, A.; LAMBERTS, R.; SUIZU, C.; MOURA, K. Relatório interno: **Convênio de cooperação técnico-financeira entre a Eletrobrás e o CBCS, destinado ao desenvolvimento de benchmarks energéticos no âmbito do PROCEL**, 2021.

VEIGA, R. K.; VELOSO, A. C.; MELO, A. P.; LAMBERTS, R. Application of machine learning to estimate building energy use intensities. **Energy and Buildings**, [s. l.], v. 249, p. 111219, 2021. Disponível em: <https://doi.org/10.1016/j.enbuild.2021.111219>.

VERSAGE, R. S. **Metamodelo para estimar a carga térmica de edificações condicionadas artificialmente**. 2015. 191 f. Tese (Doutorado) - Curso de Programa de Pós-Graduação em Engenharia Civil, Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2015.

WILDE, P. The gap between predicted and measured energy performance of buildings: A framework for investigation. **Automation in Construction**, [S. l.], v. 41, p. 40–49, 2014. Disponível em: <https://doi.org/10.1016/j.autcon.2014.02.009>

YALCINTAS, M. An energy benchmarking model based on artificial neural network method with a case example for tropical climates. **International Journal of Energy Research**, [s. l.], v. 30, n. 14, p. 1158–1174, 2006.

YALCINTAS, M.; OZTURK, U. A. An energy benchmarking model based on artificial neural network method utilizing US Commercial Buildings Energy Consumption Survey (CBECS) database. **International Journal of Energy Research**, [S. l.], v. 31, p. 412–421, 2007. Disponível em: <https://doi.org/10.1002/er>

YANG, Z.; ROTH, J.; JAIN, R. K. DUE-B: Data-driven urban energy benchmarking of buildings using recursive partitioning and stochastic frontier analysis. **Energy and Buildings**, [S. l.], v. 163, p. 58–69, 2018. Disponível em: <https://doi.org/10.1016/j.enbuild.2017.12.040>

YU, Z.; HAGHIGHAT, F.; FUNG, B. C. M.; YOSHINO, H. A decision tree method for building energy demand modeling. **Energy & Buildings**, [s. l.], v. 42, n. 10, p. 1637–1646, 2010. Disponível em: <http://dx.doi.org/10.1016/j.enbuild.2010.04.006>.