



UNIVERSIDADE
ESTADUAL DE LONDRINA

GUSTAVO HENRIQUE NUNES

**ANÁLISE DE INCERTEZAS PARA AVALIAR O
DESEMPENHO TÉRMICO E ENERGÉTICO DE
HABITAÇÕES DE INTERESSE SOCIAL
CONSIDERANDO AS MUDANÇAS CLIMÁTICAS**

LONDRINA

2024

GUSTAVO HENRIQUE NUNES

**ANÁLISE DE INCERTEZAS PARA AVALIAR O
DESEMPENHO TÉRMICO E ENERGÉTICO DE
HABITAÇÕES DE INTERESSE SOCIAL
CONSIDERANDO AS MUDANÇAS CLIMÁTICAS**

Tese apresentada ao Programa de Pós-graduação em Engenharia Civil da Universidade Estadual de Londrina, como requisito parcial para obtenção do título de Doutor em Engenharia Civil.

Orientadora: Profa. Dra. Thalita Gorban Ferreira Giglio

Coorientador: Prof. Dr. João Gabriel Ribeiro Damian

LONDRINA

2024

Ficha de identificação da obra elaborada pelo autor, através do Programa de Geração Automática do Sistema de Bibliotecas da UEL

N972a Nunes, Gustavo Henrique.

Análise de incertezas para avaliar o desempenho térmico e energético de habitações de interesse social considerando as mudanças climáticas / Gustavo Henrique Nunes. - Londrina, 2024.

216 f. : il.

Orientador: Thalita Gorban Ferreira Giglio.

Coorientador: João Gabriel Ribeiro Damian.

Tese (Doutorado em Engenharia Civil) - Universidade Estadual de Londrina, Centro de Tecnologia e Urbanismo, Programa de Pós-Graduação em Engenharia Civil, 2024.

Inclui bibliografia.

1. Engenharia civil - Tese. 2. Construção civil - Tese. 3. Desempenho térmico e energético de edificações - Tese. 4. Simulação computacional - Tese. I. Giglio, Thalita Gorban Ferreira. II. Damian, João Gabriel Ribeiro. III. Universidade Estadual de Londrina. Centro de Tecnologia e Urbanismo. Programa de Pós-Graduação em Engenharia Civil. IV. Título.

CDU 62

GUSTAVO HENRIQUE NUNES

**ANÁLISE DE INCERTEZAS PARA AVALIAR O DESEMPENHO
TÉRMICO E ENERGÉTICO DE HABITAÇÕES DE INTERESSE
SOCIAL CONSIDERANDO AS MUDANÇAS CLIMÁTICAS**

Tese apresentada ao Programa de Pós-graduação em Engenharia Civil da Universidade Estadual de Londrina, como requisito parcial para obtenção do título de Doutor em Engenharia Civil.

BANCA EXAMINADORA

Orientadora

Profa. Dra. Thalita Gorban Ferreira Giglio
Universidade Estadual de Londrina

Profa. Dra. Camila Gregório Atem
Universidade Estadual de Londrina

Prof. Dr. Hemerson Donizete Pinheiro
Universidade Estadual de Londrina

Prof. Dr.-Ing. Marlon Leão
Universidade do Estado de Mato Grosso

Prof. Dr. Martin Gabriel Ordenes Mizgier
Universidade Federal de Santa Catarina

Londrina, 23 de agosto de 2024.

Dedico este trabalho à Lucelia, à Olíria e à Rafaela.

AGRADECIMENTOS

A Deus, por tudo.

À minha noiva, Rafaela, pela vida mais feliz.

À minha mãe, Lucelia (minha maior e melhor referência), pelo amor.

À minha vó, Olíria, pelo cuidado.

À minha excelente orientadora, Profa. Dra. Thalita Giglio, e ao meu excelente coorientador, Prof. Dr. João Gabriel, por acreditarem no meu trabalho, por compartilharem seu tempo e conhecimento, e, principalmente, pela dedicação, compreensão e amizade.

Ao Guilherme, pela parceria e por disponibilizar o modelo calibrado usado nesta tese.

Aos membros das bancas examinadoras de qualificação e de defesa do trabalho, Prof. Dr. Arthur Silva, Profa. Dra. Camila Atem, Prof. Dr. Hemerson Pinheiro, Profa. Dra. Joyce Carlo, Prof. Dr.-Ing. Marlon Leão e Prof. Dr. Martin Mizgier, pela disponibilidade e pelas considerações e contribuições.

À Emeli, pela gentileza e ajuda na organização da defesa do trabalho.

Aos meus amigos e às minhas amigas, sempre presentes, mesmo que distantes.

Ao Laboratório de Eficiência Energética e Sustentabilidade em Edificações e Programa de Pós-graduação em Engenharia Civil da UEL, e à UEL como um todo, pela oportunidade de conhecimento e por me proporcionar uma nova formação e experiência de vida.

À Suporte Engenharia e, em especial, ao meu grande amigo/irmão Wdson, pelo trabalho e pela compreensão que me permitiram cursar o doutorado e conciliar publicações durante os mais de 128.000 m² de obra executados em 2021.

À Universidade do Estado de Mato Grosso, que me introduziu ao mundo da engenharia e à carreira docente. Meu agradecimento à instituição, pelo trabalho, e aos professores e demais profissionais, pelas oportunidades e pela ajuda em várias disciplinas ministradas entre 2021 e 2024.

À Escola Municipal Prefeito Duílio Ribeiro Braga e à Escola Estadual Senador Filinto Müller, pela minha base escolar.

À CAPES, pela bolsa de doutorado concedida nos últimos nove meses deste trabalho.

À Estação Meteorológica do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo, por, gentilmente (e por várias vezes), disponibilizar dados obtidos em seu importante trabalho de monitoramento meteorológico.

Finalmente, agradeço a todos e à todas que contribuíram para que este trabalho fosse possível.

“Tenho-vos dito isto, para que em mim tenhais paz; no mundo tereis aflições, mas tende bom ânimo, eu venci o mundo.”

João 16:33

NUNES, Gustavo Henrique. **Análise de incertezas para avaliar o desempenho térmico e energético de habitações de interesse social considerando as mudanças climáticas**. 2024. 216p. Tese (Doutorado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2024.

RESUMO

As alterações no clima têm evidenciado a necessidade de se construir edificações confortáveis ambientalmente e eficientes energeticamente, com resiliência em seu desempenho. As análises de desempenho de edificações, geralmente, têm uma natureza determinística (ao invés de probabilística), que configura uma prática insuficiente para a avaliação térmica e energética do ambiente construído, por causa das incertezas envolvidas, que são intensificadas pelas questões climáticas. Nesse âmbito, nota-se uma lacuna consoante a métodos ou parâmetros que possibilitem melhor consideração sobre as variáveis de desempenho de edificações, direcionem estratégias de conforto térmico e eficiência energética diante de incertezas, e que deem embasamento acertado e, eventualmente, sejam oportunos às atualizações em regulamentações da construção civil. Esta tese contempla o estudo das incertezas de desempenho térmico e energético (considerando o uso de ventilação natural e ar-condicionado) de habitações de interesse social em São Paulo, abordando o desenvolvimento de um procedimento de análise e classificação de desempenho em diferentes períodos climáticos. Por meio de simulações computacionais com o software EnergyPlus e análise de incertezas em parâmetros construtivos, buscou-se compreender os efeitos das mudanças climáticas em habitações, com um método ajustado às condições ambientais dinâmicas, e propondo-se parâmetros de classificação de desempenho para os indicadores graus-hora para resfriamento (condicionamento natural) e consumo para resfriamento (condicionamento artificial). Para as progressões climáticas, foi utilizada a ferramenta CCWorldWeatherGen, obtendo-se dados para curto prazo (2020, que representa o período de 2011 a 2040), médio prazo (2050, que representa o período de 2011 a 2070) e longo prazo (2080, que representa o período de 2071 a 2100). Na análise de incertezas, as estatísticas descritivas para os diferentes períodos climáticos são acompanhadas de estimativas de função de densidade de probabilidade calculadas por meio de mecanismos inovadores de inferência bayesiana, para resultados mais assertivos. Por último, determinaram-se quatro níveis de desempenho nos diferentes horizontes de tempo: insatisfatório, mínimo, intermediário e superior, observando-se a influência das principais propriedades termofísicas da envoltória no desempenho. Os resultados demonstram que os efeitos das incertezas causam diferenças de desempenho importantes, os efeitos das alterações climáticas são mais intensos no período 2080, e as verificações e estratégias de desempenho devem incorporar medidas de resiliência baseadas em incertezas. De modo geral, em todos os cenários (curto, médio e longo prazo), habitações com baixa absorptância solar na envoltória (0,2 e 0,4), baixa transmitância térmica (0,27 e 1,65 W/m²K), alta capacidade térmica (330 e 445 kJ/m²K) e alto fator de ventilação das janelas (0,67 e 0,9) alcançaram melhores classificações de desempenho térmico e energético. Adicionalmente, observou-se que habitações mais eficientes em um contexto atual, são mais suscetíveis a impactos (variações de desempenho) decorrentes de alterações no clima. Dessa maneira, o procedimento de análise desenvolvido e aplicado permitiu o estudo de variáveis de projeto e a consideração da imprevisibilidade de climas futuros, contribuindo com parâmetros de desempenho térmico e energético de habitações de interesse social no clima de São Paulo. Afinal, a melhor maneira de lidar com as mudanças e incertezas envolvidas é analisar, projetar e construir sob a influência delas.

Palavras-chave: Arquivos climáticos futuros. CCWorldWeatherGen. Edificações residenciais. Habitações resilientes. Simulação computacional.

NUNES, Gustavo Henrique. **Análise de incertezas para avaliar o desempenho térmico e energético de habitações de interesse social considerando as mudanças climáticas** [Uncertainty analysis to evaluate the thermal and energy performance of low income housing under climate change conditions]. 2024. 216p. Tese (Doutorado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2024. (PhD Thesis, in Portuguese)

ABSTRACT

Climate change has made it evident that buildings must be constructed to provide environmental comfort and energy efficiency, while also demonstrating resilient performance. Building performance analysis often takes a deterministic approach (rather than probabilistic), which is insufficient for thermal and energy evaluation due to inherent uncertainties, further intensified by climate issues. There is a gap for methods or parameters that better consider building performance variables, guide thermal comfort and energy efficiency strategies in the face of uncertainties, and provide a timely basis for updates to building regulations. This thesis explores the uncertainties in the thermal and energy performance (considering the use of natural ventilation and air conditioning) of Brazilian low-income housing located in São Paulo city, addressing the development of a performance analysis and classification procedure under different climate periods. It also develops a method for analyzing and classifying performance in different climate scenarios. Through a systematic EnergyPlus simulations procedure varying thermophysical parameters and climate conditions, the study investigates the effects of climate change on buildings, with a method adapted to dynamic environmental conditions, and proposing performance classification parameters for degree-hours of cooling (natural ventilation) and cooling energy consumption (air-conditioning). The Climate Change World Weather Generator tool, or CCWorldWeatherGen, was used to obtain climate data for the short-term (2020, representing 2011-2040), medium-term future (2050, representing 2041-2070), and long-term future (2080, representing 2071-2100). In the uncertainty analysis, the study uses statistical measures for the different climate periods, accompanied by probability density functions estimated through innovative Bayesian inference mechanisms, for more reliable results. Four performance levels are determined: unsatisfactory, minimum, intermediate, and superior, with consideration given to how the thermophysical properties of the building envelope influence performance. The results show that the effects of uncertainties cause important performance differences, the effects of climate change are more intense in the 2080s, and performance checks and strategies should incorporate resilience measures based on uncertainties. In general, in all scenarios (short, medium and long term), dwellings with low solar absorptance in the envelope (0.2 and 0.4), low thermal transmittance (0.27 and 1.65 W/m²K), high thermal capacity (330 and 445 kJ/m²K) and high window ventilation factor (0.67 and 0.9) achieved better performance ratings. Additionally, it was observed that more efficient dwellings in a current context are more susceptible to impacts (variations in performance) resulting from changes in the climate. The procedure developed and applied made it possible to investigate design variables and consider the unpredictability of future climates, contributing to improve thermal and energy performance parameters for Brazilian dwellings. The most effective way to deal with these changes and uncertainties is to analyze, design, and build while considering their influence.

Keywords: Future weather files. CCWorldWeatherGen. Residential buildings. Resilient housing. Building simulation.

LISTA DE FIGURAS

Figura 1 – Quantidade de publicações em cada ano, conforme os 141 trabalhos da amostra..	46
Figura 2 – Tipos de publicações, conforme os 141 trabalhos da amostra	46
Figura 3 – Principais periódicos revisados, conforme os 141 trabalhos da amostra	47
Figura 4 – Análise das palavras-chave mais utilizadas em pesquisas correlatas ao tema estudado	48
Figura 5 – Rede de grupos com as palavras-chave mais utilizadas em pesquisas correlatas ao tema estudado	49
Figura 6 – Processo de pesquisa e avaliação de trabalhos.....	50
Figura 7 – Eventos que ocorrem durante o ciclo de vida de edificações.....	53
Figura 8 – Esquema de desempenho do ambiente construído sob diferentes condições climáticas	56
Figura 9 – Evolução do forçamento radioativo total para os cenários SRES e RCP	62
Figura 10 – Evolução do forçamento radioativo total para os cenários RCP e SSP	62
Figura 11 – Evolução da elevação da temperatura, em relação a 1850-1900, para os cenários RCP e SSP	63
Figura 12 – Abordagens para obtenção de arquivos climáticos	66
Figura 13 – Definições de resiliência integrada em diferentes áreas	71
Figura 14 – Estrutura de critérios para edificações com resfriamento resiliente.....	73
Figura 15 – Síntese do processo de pesquisa e avaliação dos trabalhos da revisão bibliográfica sistemática.....	98
Figura 16 – Processo de desenvolvimento do método aplicado na tese.....	107
Figura 17 – Planta baixa e corte transversal da edificação residencial adotada (medidas em metros).....	109
Figura 18 – Mapa mundial da classificação climática Köppen-Geiger, e situação de São Paulo	110
Figura 19 – Modelo da habitação para as simulações computacionais	112
Figura 20 – Rotina de ocupação da habitação para as simulações computacionais	114
Figura 21 – Rotina de acionamento da iluminação da habitação para as simulações computacionais (0 significa desligada e 1 significa ligada)	114
Figura 22 – Fluxograma do algoritmo de controle do sistema de ventilação natural para os dormitórios.....	116

Figura 23 – Fluxograma do algoritmo de controle do sistema de ventilação natural para a sala/cozinha	116
Figura 24 – Fluxograma do algoritmo de controle da integração do sistema de condicionamento artificial e da ventilação natural para os dormitórios	117
Figura 25 – Fluxograma do algoritmo de controle da integração do sistema de condicionamento artificial e da ventilação natural para a sala/cozinha	118
Figura 26 – Limites de conforto térmico adaptativo	121
Figura 27 – Intervalos genéricos de classificação de desempenho, de acordo com os quartis definidos	126
Figura 28 – Relação entre o graus-hora para resfriamento da habitação, em São Paulo, de acordo com as simulações para o período TRY e para as progressões dos períodos climáticos 2020, 2050 e 2080.....	128
Figura 29 – Diagramas de caixa para o graus-hora para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080	129
Figura 30 – Funções de densidade de probabilidade de graus-hora para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080	130
Figura 31 – Inferência bayesiana para o graus-hora para resfriamento, para o arquivo TRY (1954)	132
Figura 32 – Inferência bayesiana de graus-hora para resfriamento, para o período 2020	133
Figura 33 – Inferência bayesiana de graus-hora para resfriamento, para o período 2050	134
Figura 34 – Inferência bayesiana de graus-hora para resfriamento, para o período 2080	135
Figura 35 – Inferência bayesiana e níveis de desempenho definidos para o graus-hora para resfriamento, considerando os experimentos para curto prazo (2020), em São Paulo.....	136
Figura 36 – Níveis de desempenho definidos para o graus-hora para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto prazo (2020), em São Paulo.....	137
Figura 37 – Inferência bayesiana e níveis de desempenho definidos para o graus-hora para resfriamento, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo	137

Figura 38 – Níveis de desempenho definidos para o consumo de energia para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo	138
Figura 39 – Análise de desempenho para os graus-hora para resfriamento, de acordo com as cinco variáveis termofísicas mais influentes, considerando os experimentos para curto (2020) prazo.....	139
Figura 40 – Análise de desempenho para os graus-hora para resfriamento, de acordo com as cinco variáveis termofísicas mais influentes, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo	139
Figura 41 – Correlação entre as variáveis termofísicas mais influentes nos graus-hora para resfriamento e o desvio padrão relativo de desempenho das amostras simuladas, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo.....	141
Figura 42 – Relação entre o consumo para resfriamento da habitação, em São Paulo, de acordo com as simulações para o período TRY e para as progressões dos períodos climáticos 2020, 2050 e 2080	142
Figura 43 – Diagramas de caixa para o consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080.....	143
Figura 44 – Funções de densidade de probabilidade de consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080.....	144
Figura 45 – Inferência bayesiana para o consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY (1954).....	145
Figura 46 – Inferência bayesiana de consumo de energia para resfriamento, para o período 2020	146
Figura 47 – Inferência bayesiana de consumo de energia para resfriamento, para o período 2050	147
Figura 48 – Inferência bayesiana de consumo de energia para resfriamento, para o período 2080	148

Figura 49 – Inferência bayesiana e níveis de desempenho definidos para o consumo de energia para resfriamento, considerando os experimentos para curto prazo (2020), em São Paulo.....	149
Figura 50 – Níveis de desempenho definidos para o consumo de energia para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto prazo (2020), em São Paulo.....	150
Figura 51 – Inferência bayesiana e níveis de desempenho definidos para o consumo de energia para resfriamento, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo.....	150
Figura 52 – Níveis de desempenho definidos para o consumo de energia para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo	150
Figura 53 – Análise de desempenho para o consumo de energia para resfriamento, de acordo com as três variáveis termofísicas mais influentes, em São Paulo, considerando os experimentos para curto (2020) prazo.....	151
Figura 54 – Análise de desempenho para o consumo de energia para resfriamento, de acordo com as três variáveis termofísicas mais influentes, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo	152
Figura 55 – Correlação entre as variáveis termofísicas mais influentes no consumo de energia para resfriamento e o desvio padrão relativo de desempenho das amostras simuladas, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo.....	153
Figura 56 – Anomalia de temperatura na Terra no ano de 2023, em relação a 1951–1980 ...	186
Figura 57 – Emissões de CO ₂ e anomalia de temperatura global anual: 1880 a 2022.....	187
Figura 58 – Temperatura do ar (bulbo seco) de São Paulo	193
Figura 59 – Umidade relativa do ar de São Paulo.....	194
Figura 60 – Radiação solar global de São Paulo.....	195
Figura 61 – Velocidade do vento de São Paulo	196
Figura 62 – Variáveis climáticas de São Paulo, em médias mensais horárias, de acordo com o arquivo climático TRY e as progressões para 2020, 2050 e 2080	198
Figura 63 – Diagramas de caixa para variáveis climáticas de São Paulo, de acordo com o arquivo climático TRY e as progressões para 2020, 2050 e 2080	199

Figura 64 – Histogramas de frequência para variáveis climáticas de São Paulo, de acordo com o arquivo climático TRY e progressões para 2020, 2050 e 2080.....	200
Figura 65 – Temperatura de bulbo seco de São Paulo, conforme os períodos climáticos	208
Figura 66 – Umidade relativa do ar de São Paulo, conforme os períodos climáticos	209
Figura 67 – Radiação solar global de São Paulo, conforme os períodos climáticos	210
Figura 68 – Velocidade do vento de São Paulo, conforme os períodos climáticos.....	211

LISTA DE QUADROS

Quadro 1 – Primeira busca de trabalhos	44
Quadro 2 – Segunda busca de trabalhos	44
Quadro 3 – Terceira busca de trabalhos	44
Quadro 4 – Quarta busca de trabalhos	45
Quadro 5 – Resumo dos RCP apresentados no IPCC AR5; com base na mudança média de 20 anos	59
Quadro 6 – Resumo dos SPP apresentados no IPCC AR6; com base na mudança média de 20 anos	61
Quadro 7 – Abordagens para obtenção de dados climáticos futuros.....	65
Quadro 8 – Definições de quatro intervalos de índices de calor	69
Quadro 9 – Sensações térmicas e estados fisiológicos para diferentes faixas SET	70
Quadro 10 – Principais variáveis fontes de incerteza e seus efeitos no ambiente construído..	82
Quadro 11 – Métodos de análise de incertezas aplicados ao desempenho de edificações	84
Quadro 12 – Principais conclusões em pesquisas que compararam os métodos DDS e ESD .	96
Quadro 13 – Definições de parâmetros e configurações computacionais	113
Quadro 14 – Parâmetros de fontes de calor para as simulações computacionais.....	115
Quadro 15 – Variáveis independentes para a criação da amostra	120
Quadro 16 – Parâmetros estatísticos de incerteza no graus-hora para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080.....	129
Quadro 17 – Parâmetros estatísticos de incerteza no consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080.....	143
Quadro 18 – Indicadores de erros mensais e anual da temperatura de bulbo seco dos arquivos climáticos, em relação às observações da EM-IAG-USP	194
Quadro 19 – Indicadores de erros mensais e anual da umidade relativa do ar dos arquivos climáticos, em relação às observações da EM-IAG-USP	195
Quadro 20 – Indicadores de erros mensais e anual da radiação solar global dos arquivos climáticos, em relação às observações da EM-IAG-USP	195
Quadro 21 – Indicadores de erros mensais e anual da velocidade do vento dos arquivos climáticos, em relação às observações da EM-IAG-USP	196

Quadro 22 – Variáveis termofísicas mais influentes no desempenho térmico e energético de habitações, de acordo com cada período climático, em São Paulo	202
Quadro 23 – Propriedades termofísicas de cada modelo da amostra (continua)	204
Quadro 24 – Estatísticas para a temperatura de bulbo seco [°C] de São Paulo, conforme os períodos climáticos.....	212
Quadro 25 – Estatísticas para a umidade relativa do ar [%] de São Paulo, conforme os períodos climáticos.....	213
Quadro 26 – Estatísticas para a radiação solar global [W/m ²] de São Paulo, conforme os períodos climáticos.....	214
Quadro 27 – Estatísticas para a velocidade do vento [m/s] de São Paulo, conforme os períodos climáticos	215

LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
AR	<i>Assessment Report</i> (Relatório de Avaliação)
ASC II	<i>American Standard Code for Information Interchange</i> (Código Padrão Americano para o Intercâmbio de Informação)
ASHRAE	<i>American Society of Heating, Refrigerating and Air-Conditioning Engineers</i> (Sociedade Americana de Engenheiros de Aquecimento, Refrigeração e Ar Condicionado)
BEM	<i>Building Energy Model</i> (Modelo de energia da edificação)
CA	Consumo de Energia para Aquecimento
CCWorldWeatherGen	<i>Climate Change World Weather File Generator</i> (Gerador de Arquivos Climáticos Mundiais para as Mudanças Climáticas)
CO ₂	Dióxido de Carbono
CR	Consumo de Energia para Resfriamento
DATec	Documento de Avaliação Técnica
DDS	<i>Dynamical downscaling</i> (Redução de Escala Dinâmica)
DOE	<i>United States Department of Energy</i> (Departamento de Energia dos Estados Unidos)
EM-IAG-USP	Estação Meteorológica do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo
EMS	<i>Energy Management System</i> (Sistema de Gerenciamento de Energia)
EPE	Empresa de Pesquisa Energética
EPW	<i>EnergyPlus Weather File</i> (Arquivo climático para o EnergyPlus)
ESD	<i>Empirical-Statistical Downscaling</i> (Redução de Escala Empírico-Estatística)
FAST	<i>Fourier Amplitude Sensitivity Test</i> (Teste de Amplitude de Sensibilidade de Fourier)
FJP	Fundação João Pinheiro
GCM	<i>General Circulation Models</i> ou <i>Global Climate Models</i> (Modelos de Circulação Geral ou Modelos Climáticos Globais)
GEE	Gases de Efeito Estufa
GHA	Graus-hora para Aquecimento

GHR	Graus-hora para Resfriamento
HadCM3	<i>Hadley Centre Coupled Model version 3</i> (Modelo Acoplado do Centro Hadley versão 3)
HVAC	<i>Heating, Ventilation and Air Conditioning</i> (Aquecimento, Ventilação e Condicionamento de ar)
IDF	<i>Input Data File</i> (Arquivo de dados de entrada)
IEA	<i>International Energy Agency</i> (Agência Internacional de Energia)
IPCC	<i>Intergovernmental Panel on Climate Change</i> (Painel Intergovernamental sobre Mudanças Climáticas)
ISO	<i>International Organization for Standardization</i> (Organização Internacional de Normalização)
LI	Limite Inferior
LS	Limite Superior
MAE	<i>Mean Absolute Error</i> (Erro Absoluto Médio),
MAPE	<i>Mean Absolute Percentage Error</i> (Erro Percentual Absoluto Médio)
MARS	<i>Multivariate Adaptive Regression Splines</i> (Linhas de Regressão Adaptativa Multivariada)
MBE	<i>Mean Bias Error</i> (Erro de Viés Médio)
MCMC	<i>Markov chain Monte Carlo</i> (Monte Carlo via Cadeias de Markov)
NASA	<i>National Aeronautics and Space Administration</i> (Administração Nacional norte-americana da Aeronáutica e Espaço)
NBR	Norma Brasileira
NOAA	<i>National Oceanic and Atmospheric Administration</i> (Administração Nacional norte-americana Oceânica e Atmosférica)
ODS	Objetivos de Desenvolvimento Sustentável
PROCEL	Programa Nacional de Conservação da Energia Elétrica
RCM	Modelos climáticos regionais (<i>Regional Climate Models</i> – RCM)
RCP	<i>Representative Concentration Pathway</i> (Patamares de Concentração Representativos)
RMSE	<i>Root Mean Squared Error</i> (Raiz Quadrada do Erro-Médio)
RRMSE	<i>Relative Root Mean Square Error</i> (Raiz Quadrada Relativa do Erro-Médio)

SERG	<i>Sustainable Energy Research Group</i> (Grupo de Pesquisa em Energia Sustentável)
SINAT	Sistema Nacional de Avaliação Técnica
SRC	<i>Standardized Regression Coefficients</i> (Coeficientes de Regressão Padronizados)
SRES	<i>Special Report on Emissions Scenarios</i> (Relatório Especial sobre Cenários de Emissões)
SRRC	<i>Standardized Rank Regression Coefficient</i> (Coeficientes de Regressão Padronizados Ordenados)
SSP	<i>Shared Socio-Economic Pathways</i> (Caminhos Socioeconômicos Compartilhados)
SVM	<i>Support Vector Machine</i> (Máquina de Vetores de Suporte)
TMY	Typical Meteorological Year (Ano Meteorológico Típico)
TRY	<i>Test Reference Year</i> (Ano Climático de Referência)
UNEP	<i>United Nations Environmental Programme</i> (Programa das Nações Unidas para o Meio Ambiente)
WMO	<i>World Meteorological Organization</i> (Organização Meteorológica Mundial)

LISTA DE SÍMBOLOS

acob	Absortância solar da cobertura [-]
apar	Absortância solar das paredes externas [-]
Az	Orientação solar (azimute) [°]
CTcob	Capacidade térmica da cobertura [kJ/m ² K]
CTpar	Capacidade térmica das paredes [kJ/m ² K]
CTpis	Capacidade térmica do piso [kJ/m ² K]
ecob	Emissividade da face interna da cobertura [-]
Fsomb	Fator de sombreamento (venezianas) das janelas [-]
FSvid	Fator solar dos vidros das janelas [-]
Fvent	Fator de ventilação das janelas [-]
Ucob	Transmitância térmica da cobertura [W/m ² K]
Upar	Transmitância térmica das paredes externas [W/m ² K]
Upis	Transmitância térmica do piso [W/m ² K]

SUMÁRIO

1	INTRODUÇÃO.....	35
1.1	ASPECTOS DE INEDITISMO.....	37
1.2	HIPÓTESE	40
1.3	OBJETIVOS	40
1.3.1	Objetivo Geral.....	40
1.3.2	Objetivos Específicos.....	40
1.4	ESTRUTURA DA TESE	41
2	REVISÃO BIBLIOGRÁFICA SISTEMÁTICA.....	43
2.1	MUDANÇAS CLIMÁTICAS E MUDANÇAS NAS EDIFICAÇÕES.....	51
2.1.1	As Edificações e os Desafios do Clima Futuro e dos Eventos Extremos	54
2.1.2	Dados Climáticos para Simulações de Desempenho Térmico e Energético de Edificações	57
2.1.2.1	Modelos e cenários climáticos	58
2.1.2.2	Obtenção de arquivos climáticos futuros	63
2.1.3	Índices de Avaliação Térmica e Energética e Resiliência em Edificações	69
2.2	SIMULAÇÕES TERMOENERGÉTICAS DE EDIFICAÇÕES E ANÁLISE DE INCERTEZA....	76
2.2.1	Fontes de Incerteza.....	80
2.2.2	Abordagens de Análise de Incertezas e Sensibilidade	83
2.2.2.1	Avaliação quantitativa de efeitos das incertezas climáticas no desempenho da edificação	85
2.2.2.2	Análise de incertezas por meio de técnicas bayesianas	87
2.2.2.3	Análise de sensibilidade.....	89
2.2.2.4	Contribuições envolvendo análise de incertezas e mudanças climáticas.....	90
2.2.2.5	Recomendações de projeto.....	93
2.2.2.6	Considerações sobre os dados climáticos	95
2.3	SÍNTESE E DISCUSSÃO DA REVISÃO BIBLIOGRÁFICA SISTEMÁTICA	97
2.3.1	O Estado da Arte e as Oportunidades de Pesquisa.....	101
2.3.2	Limitações da Revisão Bibliográfica Sistemática.....	103

3	DESENVOLVIMENTO DO MÉTODO	105
3.1	CARACTERIZAÇÃO DA BASE DE DADOS.....	108
3.1.1	Objeto de Estudo	108
3.1.2	Clima Analisado	109
3.1.3	Simulações de Desempenho Térmico e Energético	111
3.1.3.1	Modelo.....	111
3.1.3.2	Definições de parâmetros e configurações do EnergyPlus.....	112
3.1.3.3	Definições de ocupação e uso, cargas internas e sistemas de ventilação	113
3.1.3.3.1	<i>Sistema natural de condicionamento (ventilação natural)</i>	115
3.1.3.3.2	<i>Sistema híbrido de condicionamento (ventilação natural combinada com uso de ar-condicionado)</i>	116
3.1.4	Parâmetros do Experimento	118
3.1.4.1	Variáveis independentes (parâmetros de ‘entrada’)	119
3.1.4.2	Variáveis dependentes (parâmetros de ‘saída’)	120
3.2	ANÁLISE DE INCERTEZAS DE DESEMPENHO TÉRMICO E ENERGÉTICO	122
3.2.1	Quantificação das Incertezas	123
3.2.2	Inferência Bayesiana	123
3.3	CLASSIFICAÇÃO DE DESEMPENHO E INFLUÊNCIA DAS PRINCIPAIS VARIÁVEIS TERMOFÍSICAS.....	125
4	RESULTADOS E ANÁLISES	127
4.1	ESTUDO NO CLIMA DE SÃO PAULO.....	127
4.1.1	Graus-hora para Resfriamento (Sistema de Ventilação Natural)	127
4.1.1.1	Estatística descritiva dos efeitos das incertezas.....	129
4.1.1.2	Classificação de desempenho	136
4.1.1.3	Influência de variáveis termofísicas na classificação de desempenho	138
4.1.2	Consumo de Energia para Resfriamento (Sistema de Ventilação Natural Combinada com Uso de Ar-Condicionado).....	142
4.1.2.1	Estatística descritiva dos efeitos das incertezas.....	143
4.1.2.2	Classificação de desempenho	149
4.1.2.3	Influência de variáveis termofísicas na classificação de desempenho	151
4.1.3	Considerações Gerais sobre o Desempenho Térmico e Energético de Habitações para o Futuro.....	154

5	CONCLUSÕES	157
5.1	LIMITAÇÕES DO TRABALHO	158
5.2	SUGESTÕES PARA TRABALHOS	159
	REFERÊNCIAS	161
	APÊNDICE A – CONCEITOS BÁSICOS	186
A.1	Mudanças Climáticas	186
A.2	Análise de Incertezas	187
A.3	Inferência Estatística	188
A.4	Estatística Frequentista	188
A.5	Estatística Bayesiana	189
	ANEXO A – INFLUÊNCIA DAS MUDANÇAS CLIMÁTICAS NA SENSIBILIDADE GLOBAL DE VARIÁVEIS TERMOFÍSICAS DE HABITAÇÕES DE INTERESSE SOCIAL EM SÃO PAULO	192
A.1	Eficácia da Ferramenta de Progressão de Arquivos Climáticos CCWorldWeatherGen	192
A.2	Progressões Climáticas de São Paulo	197
A.3	Sensibilidade de Variáveis Termofísicas em Cenários de Mudanças Climáticas	201
	ANEXO B – AMOSTRA SIMULADA	204
	ANEXO C – PROGRESSÕES CLIMÁTICAS	208

1 INTRODUÇÃO

O desempenho térmico e energético de edificações é um tema substancial devido ao crescente consumo de energia e emissão de poluentes associados à construção e operação de edificações (Brasil, 2023a; Brasil, 2024; IEA, 2023). Como relatam Canepa *et al.* (2022), Ramon *et al.* (2023) e Triana, Lamberts e Sassi (2016), o consumo de energia, bem como as emissões de poluentes que provocam o efeito estufa, caracterizam um dos principais focos dos impactos ambientais causado pelas construções. A Agência Internacional de Energia (IEA, 2023), em acompanhamento do consumo energético anual, aponta um aumento global ao longo dos anos. Os dados da IEA (2023) mostram que, atualmente, as edificações são responsáveis por cerca de 30% do consumo energético mundial, com expectativa de aumento nos próximos anos. No Brasil, a eletricidade é a fonte energética prioritária no setor de edificações – usada na iluminação, refrigeração de ambientes e uso de eletrodomésticos em geral –, que corresponde à 50,80% do consumo elétrico nacional (Brasil, 2023a). De acordo com Brasil (2023a), as edificações residenciais se destacam porque consomem a maior parte da eletricidade produzida no país, correspondendo a 26,60% do total. Quanto às tipologias residenciais que definem esse consumo, estima-se que cerca de 84,8% da população brasileira mora em casas, 12,5% em apartamentos e 2,4% em casas de vila ou em condomínios (IBGE, 2024).

Embora o Brasil possua uma matriz elétrica consideravelmente limpa, 18,70% da eletricidade nacional é produzida por usinas termelétricas (Brasil, 2024), que estão associadas às emissões de gases de efeito estufa, causadores de danos que refletem a maior preocupação ambiental atualmente: as mudanças no clima do planeta e suas consequências (Berrang-Ford *et al.*, 2021; Burke; Hynds; Priyadarshini, 2023; Fujimoto *et al.*, 2023). Nesse aspecto, a síntese dos dados do balanço energético nacional (Brasil, 2024) mostra que há um crescimento nas emissões totais antrópicas associadas à matriz energética brasileira – apesar de o setor de transportes ser o mais significativo nessas emissões –, implicando no aquecimento global. Por outro lado, como aspecto positivo, é importante comentar que o relatório nacional atual também indica queda do uso de eletricidade proveniente de gás natural e de óleo diesel, a manutenção da geração hidráulica e o aumento expressivo da geração solar fotovoltaica e eólica (Brasil, 2024).

Segundo a Administração Nacional norte-americana da Aeronáutica e do Espaço (NASA, 2024a), o ano de 2023 foi o mais quente da história, compondo a série dos últimos anos com recordes de altas temperaturas. De acordo com a NASA (2024a), a temperatura em 2023 foi 1,17 °C maior do que a média do século XX, representada pelo período de 1951–1980.

Além disso, os registros da NASA (2024b) e da Administração Nacional norte-americana Oceânica e Atmosférica (NOAA, 2024a) mostram que os cinco anos mais quentes do registro global ocorreram a partir de 2016, sendo 2016 e 2020 o segundo e terceiro anos mais quentes da série. Adicionalmente, as últimas três décadas foram as mais quentes desde 1850. Se os padrões de emissões continuarem, em associação às tendências mais pessimistas, a temperatura média do ar no período de 2081 a 2100 poderá ser até 4,85 °C mais alta do que a do período de referência 1995–2014, segundo o relatório de avaliação atual (AR6) do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2021).

As mudanças climáticas têm evidenciado a necessidade de se construir edificações mais confortáveis ambientalmente e eficientes energeticamente, com resiliência em seu desempenho. Segundo Moazami, Carlucci e Geving (2019), a resiliência de uma edificação consiste na sua capacidade de cumprir seus requisitos funcionais, resistindo a perturbações em seu desempenho. Considerando a situação habitacional brasileira e a expectativa de novas edificações para suprir a demanda, percebe-se o problema do gerenciamento de uso de energia, além da exigência de procedimentos alinhados ao uso racional da energia disponível, ao desenvolvimento de estratégias sustentáveis, às inovações e ao fomento de avanços contínuos no setor. Segundo a Fundação João Pinheiro (FJP, 2021a; 2021b), há, respectivamente, 5.876.699 e 24.893.961 de domicílios em situação de déficit e inadequação habitacional. Nesse contexto, edificações com características térmicas e energéticas adequadas ao clima são necessárias para se reduzir o consumo de energia e os custos de operação e manutenção, além de contribuir para a mitigação das emissões de poluentes e melhoria do conforto ambiental dos ocupantes.

O Programa Nacional de Conservação de Energia Elétrica (PROCEL) estabelece que o uso de ar-condicionado tem alta participação no consumo elétrico (PROCEL/Eletrobras, 2013; Rodrigues, 2021). Recentemente, o consumo de energia para conforto ambiental apresentou crescimento no Brasil, principalmente nas regiões sudeste e sul, segundo Abrahão e Souza (2021). As autoras observaram aumento do consumo com ar-condicionado de 3 a 6 vezes entre 2005 e 2019, exceto no Nordeste, enfatizando a expansão de uso dos aparelhos no país. Mesmo nas classes econômicas mais baixas (C2, D e E), já é relativamente comum a presença desses aparelhos, visto que, segundo o PROCEL (2019), aproximadamente 17% das residências dessas classes somadas possuem ar-condicionado instalado. Para Rodrigues (2021), com o desenvolvimento social, a diminuição dos preços dos aparelhos e a construção de edificações inadequadas, o uso de ar-condicionado será cada vez maior.

Diversas variáveis podem influenciar no desempenho térmico e energético de edificações, como as condições climáticas, parâmetros de ocupação, e disposições arquitetônicas e construtivas. Porém, Williams *et al.* (2012) constataram que as alterações no clima configuram um fator que pode apresentar maior influência durante a vida útil longa do ambiente construído. Nesse sentido, estudos apontam que a vida útil das edificações varia entre 35 e 70 anos (McKinsey & Company, 2009), mas admitindo-se 55 a 100 anos ou mais (Yassaghi; Hoque, 2019), com média global de 60 anos para residências (Andersen; Negendahl, 2023; Deetman *et al.*, 2020). No Brasil, a NBR 15575 (ABNT, 2024) preconiza uma vida útil mínima para edificações residenciais entre 50 (desempenho mínimo) e 75 (desempenho superior) anos. É interessante observar que a referida norma brasileira estabelece que considerar “um período de vida útil de 50 anos implica que anualmente devem ser construídas mais de 1,2 milhão de habitações somente para repor o estoque habitacional existente” (ABNT, 2024, p. 80).

Entendendo que a resposta termoenergética do ambiente construído está estreitamente relacionada ao clima, e tendo como principal motivação a preocupação mundial associada, muitas pesquisas começaram a buscar compreender os efeitos das mudanças climáticas nas edificações, visando contribuir com avanços que mitiguem problemas ambientais atrelados à construção civil e possibilitem edificações resilientes (Casagrande; Alvarez, 2013; Gupta; Gregg, 2012; Kershaw; Eames; Coley, 2011; Nakicenovic; Swart, 2000; Olonscheck; Holsten; Kropp, 2011; van Hooff *et al.*, 2014). Vários estudos se baseiam na avaliação de desempenho térmico e energético para projeções de climas futuros, considerando parâmetros relacionados, como materiais de construção, projetos arquitetônicos, sistemas construtivos, padrões de uso e ocupação, uso de energia solar e outras estratégias de eficiência energética em edificações. Em geral, os resultados dos pesquisadores comprovam que o clima futuro modificará o desempenho das edificações, com impactos expressivos no conforto térmico dos usuários e no consumo energético do ambiente construído (Alves; Duarte; Gonçalves, 2016; Casagrande; Alvarez, 2013; Guarda *et al.*, 2020; Guarda, 2023; Invidiata; Ghisi, 2016; Machard *et al.*, 2024; Nunes; Giglio, 2020; 2022a; 2022b).

1.1 ASPECTOS DE INEDITISMO

Em estudos prévios, Nunes (2021) e Nunes e Giglio (2021; 2022a; 2022b) desenvolveram pesquisas focadas em determinar a influência das mudanças climáticas na sensibilidade global de parâmetros termofísicos de habitações brasileiras. Por meio de

simulações computacionais para o clima do passado e para projeções de climas atual e futuros, em diferentes regiões do país, as pesquisas permitiram identificar as variáveis mais sensíveis, ou seja, as mais importantes para o desempenho, em diferentes períodos climáticos. Todavia, as conclusões deixaram uma lacuna no sentido de, conhecendo as principais variáveis em condições alteradas de clima, entender: como considerar essas mudanças, durante a etapa de projeto de edificações?; como incluir os efeitos das mudanças climáticas na análise de desempenho de edificações?; ou, ainda, como relacionar essas variáveis à resiliência do ambiente construído?. Nesse aspecto, percebe-se o mérito da análise de incertezas como ferramenta de auxílio na melhoria do processo de concepção de edificações, com base em seu desempenho (Silva, 2016).

De modo resumido, enquanto a análise de sensibilidade permite identificar a influência das variáveis no desempenho do ambiente construído, a análise de incertezas permite quantificar a variabilidade desse desempenho, conforme as características das variáveis envolvidas. Assim, a análise de incertezas pode permitir, por exemplo, a consideração da imprevisibilidade de climas futuros, de modo a estabelecer intervalos de confiança, assegurando a análise com validação científica (De Wit; Augenbroe, 2002; Fürbringer; Roulet, 1999). Silva (2016) enfatiza a necessidade da consideração de incertezas no desempenho de edificações, para que tomadores de decisão, como os projetistas, definam medidas racionais que, de fato, promovam o conforto térmico e a eficiência energética em edificações. Conforme relata Silva (2016), uma vez que o bom desempenho de edificações é fundamental em perspectivas atuais e futuras, o projeto (ou mesmo o *retrofit*) demanda ferramentas e métodos de avaliação quantitativa e comparativa capazes de suprirem o objetivo pretendido. O autor desenvolveu uma pesquisa valiosa nesse sentido e sugeriu estudos complementares para identificar como o desempenho da edificação é alterado conforme diferentes períodos de clima – o que está alinhado com a lacuna observada em Nunes (2021), como relatado anteriormente.

A bibliografia internacional também sublinha os desafios de adequação da modelagem dos impactos das mudanças climáticas e os riscos de eventos extremos (Yang; Javanroodi; Nik, 2021). As pesquisas apontam que é necessário incluir o clima futuro em análises de desempenho de edificações; para tanto, fatores de incertezas climáticas devem ser incrementados a partir de atualizações no setor, de acordo com o desenvolvimento de orientações normativas (Yassaghi; Gurian; Hoque, 2020). Segundo Chaturvedi e Rajasekar (2022), esse cuidado é ainda mais importante em países em desenvolvimento, com grande déficit habitacional, como é o caso do Brasil. Embora diretrizes e requisitos normativos recentes tenham contribuído muito para

progressos no setor, as normas brasileiras não contemplam aspectos de alterações de desempenho de edificações, decorrentes das mudanças climáticas, por exemplo.

Diante do exposto até aqui, percebe-se que mais avanços científicos, que abordem o comportamento de edificações sob diferentes condições climáticas, são necessários para o aperfeiçoamento e consolidação de estratégias de mitigação de impactos. Mais especificamente, avanços em ferramentas, parâmetros e métodos de análise de desempenho mais abrangentes e adequados à vida útil do ambiente construído podem ser a contribuição mais efetiva no setor das edificações, para assegurar construções resilientes às mudanças climáticas e que mitiguem os impactos globais. As abordagens devem ser baseadas em múltiplos critérios e variáveis, que tornam as simulações computacionais imprescindíveis, tendo em vista que elas são capazes de representar situações reais, por meio de modelos, que possibilitam cálculos avançados e condizentes com a complexidade das edificações (Silva, 2016; Wang; Mathew; Pang, 2021). Nota-se, também, que o uso de simulações concomitantes à análise de incertezas se apresentam como técnicas promissoras para se estabelecer intervalos de confiança e resultados mais adequados frente à incerteza de clima, restando, então, serem estudadas a elaboração e sistematização de procedimentos e critérios para avaliação de desempenho. Afinal, a melhor maneira de lidar com as incertezas envolvidas é analisar e projetar edificações sob a influência delas (Moazami *et al.*, 2019).

Em estudos de desempenho térmico e energético de edificações, mesmo que técnicas de otimização sempre sejam visadas, as simulações paramétricas têm considerado amostras muito grandes. Embora se busque obter o maior volume de dados possível, existem muitas limitações práticas na área de engenharia (restrições computacionais, econômicas, físicas e de tempo) que impedem a cobertura de todas as possibilidades reais ou a obtenção de grandes amostras (He *et al.*, 2021; van de Schoot; Depaoli; King, 2021). Além disso, considerando a aplicação prática por profissionais do setor, análises demasiadamente exaustivas de milhares de modelos são impraticáveis em escritórios de arquitetura e engenharia. Neste contexto, em termos estatísticos, a inferência bayesiana pode ser considerada para determinação de probabilidades, independentemente de qual seja a razão das amostras reduzidas, sendo abordada neste estudo como uma maneira inovadora de otimização das análises probabilísticas para uma amostra relativamente pequena no escopo da área de estudo.

Analisando a bibliografia, sobretudo no Brasil, há o anseio por métodos ou parâmetros que possibilitem, por exemplo, entendimento mais aprofundado sobre as variáveis de desempenho de edificações, permitam estratégias de conforto térmico e eficiência energética que considerem incertezas, e que deem embasamento acertado e sejam oportunos às

atualizações em regulamentações do setor. Desse modo, percebe-se uma oportunidade de contribuição científica no campo da engenharia civil, que sugere ser relevante para os profissionais envolvidos e para a sociedade em geral. As colocações previamente elencadas esclarecem e justificam esta tese, que abrange o desenvolvimento de um procedimento de análise de desempenho térmico e energético de edificações residenciais brasileiras, considerando mudanças climáticas ao longo da vida útil das habitações.

1.2 HIPÓTESE

A análise de incertezas de desempenho térmico e energético oferece resultados mais precisos, quando se consideram as mudanças climáticas.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

Propor um método de análise de incertezas de parâmetros de desempenho térmico e energético de habitações de interesse social, considerando o uso de ventilação natural e ar-condicionado sob condições de mudanças climáticas em São Paulo.

1.3.2 Objetivos Específicos

- a) Analisar variações no desempenho térmico e energético de uma habitação de interesse social, diante das mudanças climáticas;
- b) Aplicar mecanismos inovadores de inferência bayesiana para calcular e analisar estimativas de função de densidade de probabilidade de desempenho, considerando uma amostra relativamente pequena de modelos computacionais;
- c) Desenvolver uma classificação de desempenho térmico e energético de uma habitação de interesse social, de acordo com condições ambientais dinâmicas;
- d) Investigar um procedimento de análise de desempenho térmico e energético que permita identificar propriedades termofísicas importantes para habitações resilientes.

1.4 ESTRUTURA DA TESE

De modo a organizar a exposição do conteúdo, a tese está estruturada em seis capítulos que conduzem a sequência de temas e discussões introdutórios, objetivos de pesquisa, revisão bibliográfica, procedimentos metodológicos, resultados e conclusões.

No capítulo 1, tem-se a introdução do tema abordado na tese, justificando sua realização e apresentando a hipótese e os objetivos de pesquisa.

O capítulo 2 apresenta-se por uma revisão sistemática, que explora criticamente estudos que investigaram o desempenho térmico e energético de edificações, considerando incertezas de clima, para validar a importância do tema, embasar os argumentos que compõem o estudo com o conhecimento atual, e direcionar a abordagem da tese.

No capítulo 3, descrevem-se os procedimentos de desenvolvimento do método de análise de desempenho proposto, com vistas a alcançar os objetivos da pesquisa. Este quarto capítulo inicia com a apresentação do objeto de estudo, depois, avança para a descrição do clima estudado, e, por último, segue para as etapas de desenvolvimento, que contemplam as configurações de simulações térmicas e energéticas, bem como os parâmetros e procedimentos relacionados ao experimento e análise de incertezas.

No capítulo 4, apresentam-se os resultados e as análises da aplicação do método.

No capítulo 5, apresentam-se as conclusões da tese, além das limitações e sugestões para trabalhos.

Ao fim, são apresentados as referências e os apêndices e anexos.

2 REVISÃO BIBLIOGRÁFICA SISTEMÁTICA

Uma revisão sistemática foi desenvolvida, de modo a explorar criticamente o maior número possível de estudos que tenham investigado o desempenho térmico e energético de edificações, considerando incertezas de clima. Nesse sentido, convém esclarecer que, no âmbito da revisão realizada, ‘desempenho térmico e energético de edificações’ associam-se a fatores como consumo de energia e eficiência energética, enquanto ‘incertezas de clima’ associam-se às mudanças climáticas, análises e quantificação de incertezas decorrentes, bem como edificações resilientes ao clima.

Askie e Offringa (2015), Kitchenham (2009), Rañenes *et al.* (2021), e Shamseer *et al.* (2015) explicam que, diferentemente de uma revisão bibliográfica convencional, uma revisão sistemática tem um processo e protocolo de busca, identificação, seleção, avaliação e sintetização da bibliografia de interesse. O método de revisão sistemática é valioso para fornecer uma avaliação confiável de estudos a partir da qual os pesquisadores podem compreender mais profundamente o tema, formar conclusões, identificar lacunas científicas na área, e tomar decisões de pesquisa. Todavia, o método não é perfeito, tendo em vista os vieses no processo: os critérios determinados para a busca e seleção de trabalhos está sujeito à opinião de quem os avalia; logo, alguns artigos relevantes na comunidade científica, eventualmente, podem não atender aos critérios do autor da revisão sistemática e serem excluídos (Kitchenham *et al.*, 2009).

Os fatores associados ao tema desta pesquisa foram considerados como termos de busca, em inglês, combinados, por meio de operadores Booleanos, para incluir várias combinações, considerando possibilidades pertinentes à área de pesquisa. Inicialmente, buscaram-se combinações mais específicas, que retornassem resultados mais inerentes ao tema, e, depois, procedeu-se às combinações mais abrangentes, que retornassem maior quantidade de resultados, até alcançar número total próximo de 500 trabalhos. A revisão sistemática foi conduzida a partir de trabalhos disponíveis nas bases Scopus e Science Direct, em setembro de 2022, sem limitação de período específico de publicação, considerando as expressões para pesquisa¹ – também designadas, em inglês, como *queries* (ou *query*, no singular) –

¹ Tendo em vista que os mecanismos de busca das bases Science Direct e Scopus operam de maneiras diferentes, as expressões para pesquisa (*queries*) foram ajustadas/adaptadas conforme cada fonte, para atender limitações de quantidade máxima de operadores Booleanos e/ou modo de inserção de termos, por exemplo.

discriminadas nos Quadros 1 a 4, por meio dos quais também se apresentam as quantidades de trabalhos obtidos na busca.

Quadro 1 – Primeira busca de trabalhos

Fonte de pesquisa	Query 1	Resultados
Science Direct	("climatic uncertainty" OR "climate uncertainty" OR "weather uncertainty") AND ("resilient building" OR "resilience in building") AND ("thermal performance" OR "energy performance" OR "energy consumption" OR "energy efficiency")	10
Scopus	("climat* uncertain*" OR "weather ucertain*") AND ("resilient building*" OR "resilience in building*") AND ("therm* performance" OR "energ* performance" OR "energ* consumption" OR "consumption of energy" OR "energy efficien*")	14
Total de pesquisas não duplicadas		24

Fonte: o autor; desenvolvido a partir de busca realizada em setembro de 2022

Quadro 2 – Segunda busca de trabalhos

Fonte de pesquisa	Query 2	Resultados
Science Direct	("climate change") AND ("resilient building" OR "resilience in building") AND ("thermal performance" OR "energy performance" OR "energy consumption" OR "energy efficiency") AND ("uncertainty analysis" OR "uncertainty quantification")	5
Scopus	("climat* chang*") AND ("resilient building*" OR "resilience in building*") AND ("therm* performance" OR "energ* performance" OR "energ* consumption" OR "consumption of energy" OR "energy efficien*") AND ("uncertain* analy*" OR "uncertain* quantif*")	39
Total de pesquisas não duplicadas		43

Fonte: o autor; desenvolvido a partir de busca realizada em setembro de 2022

Quadro 3 – Terceira busca de trabalhos

Fonte de pesquisa	Query 3	Resultados
Science Direct	("climatic uncertainty" OR "climate uncertainty") AND ("building") AND ("energy efficiency" OR "energy consumption") AND ("uncertainty quantification" OR "uncertainty analysis")	28
Scopus	("climat* uncertain*") AND ("building*") AND ("energy efficien*" OR "energy consumption") AND ("uncertain* quantif*" OR "uncertain* analy*")	52
Total de pesquisas não duplicadas		79

Fonte: o autor; desenvolvido a partir de busca realizada em setembro de 2022

Quadro 4 – Quarta busca de trabalhos

Fonte de pesquisa	Query 4	Resultados
Science Direct	("climate change") AND ("building") AND ("thermal performance" OR "energy performance" OR "energy consumption" OR "energy efficiency") AND ("uncertainty quantification")	163
Scopus	("climat* chang*") AND ("building*") AND ("therm* performance" OR "energ* performance" OR "energ* consumption" OR "consumption of energy" OR "energy efficien*") AND ("uncertain* quantif*")	186
Total de pesquisas não duplicadas		333

Fonte: o autor; desenvolvido a partir de busca realizada em setembro de 2022

Os operadores Booleanos e a simbologia utilizados definem as seguintes regras:

“ ”: especificar o(s) termo(s) exato(s) contido(s) nos trabalhos;

(): definir a prioridade/ordem das regras;

*: substituir múltiplos caracteres, completando as palavras conforme várias possibilidades (por exemplo: *climat** = *climate*, *climatic*);


AND: apresentar apenas trabalhos que contêm todos os termos;

OR: apresentar todos os trabalhos que contêm qualquer um dos termos entre parênteses.

As quatro buscas nas bases Science Direct e Scopus resultaram em 418 trabalhos não duplicados, sendo que os três mais antigos eram de 2001, 2006 e 2009. Posteriormente, a amostra com 418 trabalhos foi refinada, a partir da leitura dos títulos e resumos, para excluir trabalhos pouco relacionados ao tema. Este refinamento culminou na eliminação de trabalhos anteriores a 2009, além de pesquisas muito focadas em assuntos econômicos e ambientais, como créditos de carbono, desenvolvimento de patentes e emissões de poluentes, e muito concentradas em infraestrutura, ciências sociais e políticas públicas. É interessante observar que o período a partir de 2009 representa a consolidação do debate mundial, com expressivo aumento de pesquisas sobre o tema, conforme observado por Nunes (2021); além disso, a pesquisa de De Wilde e Tian (2009) – primeiro trabalho a correlacionar incerteza no desempenho térmico de edificações e mudanças climáticas, e com notório destaque na comunidade científica, especialmente no contexto desta tese – também condiz com esse período.


A amostra refinada contou com 141 artigos publicados entre 2009 e 2022, como ilustra-se na Figura 1, podendo ser classificados em capítulos de livros, anais de eventos científicos e diferentes periódicos, como ilustra-se na Figura 2.

Figura 1 – Quantidade de publicações em cada ano, conforme os 141 trabalhos da amostra



Fonte: o autor; desenvolvido a partir de busca realizada em setembro de 2022


Figura 2 – Tipos de publicações, conforme os 141 trabalhos da amostra



Fonte: o autor; desenvolvido a partir de busca realizada em setembro de 2022

Por meio da Figura 3, destacam-se 11 periódicos com três ou mais publicações, e observa-se que a maior parte dos trabalhos foram publicados nos periódicos *Energy and Buildings* (25 artigos), *Applied Energy* (18 artigos), e *Building and Environment* (14 artigos). À esquerda, tem-se uma visão geral, onde é possível perceber que quase 65% dos trabalhos foram publicados nos onze periódicos listados; e, à direita, quantificam-se os trabalhos em cada um desses periódicos científicos.

Figura 3 – Principais periódicos revisados, conforme os 141 trabalhos da amostra



Fonte: o autor; elaborada a partir de busca realizada em setembro de 2022

A partir da amostra, com auxílio dos programas Mendeley 2.75.0 e VOSviewer 1.6.18, as publicações foram criticamente reunidas e uma análise bibliométrica foi conduzida, para verificar a correlação entre desempenho térmico e energético de edificações e incertezas de clima. Assim, o Mendeley foi utilizado para criar a seleção de pesquisas da amostra e o VosViewer foi utilizado para construir esquemas gráficos, incluindo conexões entre palavras-chave, por exemplo. A dimensão das bolhas indica as palavras-chave mais utilizadas, a largura das linhas expressa o número de citação e conexão de uma palavra-chave selecionada. Os tópicos são organizados por cluster: cada cor primária, baseada no modelo RGB, identifica um cluster específico, definido pelo algoritmo do programa (van Eck; Waltman, 2022).

Nas Figuras 4 e 5 apresentam-se, respectivamente, os mapas de visualização em densidade e rede de grupos, tendo como critério de elaboração as palavras-chave com ocorrência mínima de três vezes.





Figura 5 – Rede de grupos com as palavras-chave mais utilizadas em pesquisas correlatas ao tema estudado



Fonte: o autor; elaborada a partir de busca realizada em setembro de 2022


No centro da Figura 4, em fundo de coloração amarelada, podem ser observadas as palavras-chave mais utilizadas, enquanto outras, menos utilizadas, podem ser vistas ao redor, com fundo “desbotado”. Em complemento, por meio da Figura 5, é possível perceber o agrupamento das palavras, com uma visualização de como elas se correlacionam, conforme as diferentes cores e ligações representadas.

Entre as informações dispostas nos mapas de análise bibliométrica, é possível notar que “mudanças climáticas” e “análises de incertezas e sensibilidade” se destacam, no centro, evidenciando que são os conteúdos mais mencionados na amostra de artigos selecionada para a revisão. Além disso, é interessante observar a ligação de alguns termos importantes, inerentes à análise de desempenho térmico e energético, como edificações residenciais, projeto arquitetônico, conforto térmico e modelo energético de edificações (circulados em azul na Figura 4); e outros termos como Método de Monte Carlo e Estatística Bayesiana (circulados

em branco na Figura 4), destacando algumas técnicas de investigação e análise estatística aplicadas a esse tópico.

A análise mais aprofundada dos 141 trabalhos permitiu mais um refinamento, de 46 trabalhos mais relacionados à esta tese, e que subsidiaram melhor o conteúdo apresentado neste capítulo. Na Figura 6 resume-se o processo de pesquisa e avaliação de trabalhos.

Figura 6 – Processo de pesquisa e avaliação de trabalhos



Fonte: o autor

Alguns estudos têm investigado sistematicamente os impactos das mudanças climáticas nas edificações, em termos de conforto térmico, produtividade, demanda de eletricidade para condicionamento ambiental, aspectos econômicos, técnicas de estimativas de condições climáticas futuras, entre outros. No entanto, considerando a amplitude e as dificuldades que circundam o tema, métodos ou parâmetros para incorporar as incertezas climáticas em análises de desempenho térmico e energético de edificações ainda são pouco estabelecidos na bibliografia, carecendo uma discussão maior sobre definições, conceitos e técnicas de análises para construções resilientes às mudanças climáticas.

Nesse contexto, este capítulo da tese subsidia informações necessárias, por meio de uma avaliação crítica dos trabalhos inclusos revisão sistemática, para contribuir com o preenchimento dessa lacuna de conhecimento. Primeiramente, apresentam-se tópicos abrangendo as mudanças climáticas e as mudanças nas edificações, incluindo referências complementares que esclarecem os trabalhos da revisão sistemática, quando necessário.

Depois, descrevem-se contribuições da revisão que incluem análise de incertezas com simulações termoeenergéticas de edificações. E, por último, tem-se uma síntese e discussão do estado da arte, conforme os trabalhos da revisão sistemática, direcionando o desenvolvimento da tese.

2.1 MUDANÇAS CLIMÁTICAS E MUDANÇAS NAS EDIFICAÇÕES

A urbanização possibilita benefícios significativos para as sociedades, mas carrega como ônus os desafios ambientais, em termos de sustentabilidade: alteração de paisagens, degradação ambiental, aumento da demanda energética, esgotamento de recursos, mudanças climáticas, além de ilhas e ondas de calor (Devuyst; Hens; De Lannoy, 2001; Van Staden; Musco, 2010; Georgiadou; Hacking; Guthrie, 2012). As mudanças climáticas surgem como um dos maiores desafios que a sociedade enfrenta, tendo como agravante o fato de que o impacto é muito amplo, indo desde inundações repentinas causadas por chuvas torrenciais até a erosão costeira e ondas de calor (Bengtsson; Hargreaves; Page, 2007; Ren; Chen; Wang, 2021).

De acordo com o IPCC (2007), em comparação com outros setores poluentes, como transporte e indústria, o setor de edificações tem o maior potencial para oferecer reduções significativas, de longo prazo e economicamente viáveis, nas emissões de gases de efeito estufa causadores de alterações no clima, sendo um ponto importante em termos de sustentabilidade. Segundo Georgiadou, Hacking e Guthrie (2012), aplicando a definição do Relatório Brundtland (WCED, 1987), tem-se que: edificações sustentáveis são aquelas que atendem às necessidades dos atuais usuários sem comprometer as necessidades dos futuros usuários, em termos de conforto térmico, segurança, eficiência energética, e custo.

O ciclo de vida longo do estoque de edificações, os impactos das mudanças climáticas e as exigências para o desenvolvimento sustentável destacam a necessidade de um pensamento de longo prazo no setor. Para Bosher *et al.* (2007), Georgiadou, Hacking e Guthrie (2013), Malmqvist *et al.* (2011) e Sharma *et al.* (2011), as edificações possuem uma vida útil de projeto de 40 a 100 anos, sendo que sua utilização efetiva, geralmente, tem maior longevidade (especialmente para estruturas históricas). A longevidade de uso de edificações associa-se, por exemplo, aos custos de reforma, às dificuldades práticas de reforma, desconstrução e/ou demolição e à ligação afetiva dos usuários às edificações, por razões históricas ou culturais (Georgiadou; Hacking; Guthrie, 2012; Hacking, 2009).

A concepção das edificações abrange custos relacionados ao investimento de capital inicial, gerenciamento, e às questões de qualidade do ar e conforto térmico dos usuários. Em

complemento, as edificações são responsáveis pelo uso de energia, consumo de água e geração de resíduos. Logo, os impactos financeiros, ambientais e socioeconômicos relacionados ao ambiente construído conduzem preocupação significativa, requerendo medidas de mitigação alinhada às circunstâncias das mudanças globais (Georgiadou; Hacking; Guthrie, 2013; Jewell *et al.*, 2010).

As mudanças climáticas afetam tanto a média quanto a variabilidade de parâmetros climáticos fundamentais para o desempenho de edificações, como temperatura, precipitação, umidade, radiação solar e velocidade e direção do vento. Nesse contexto, De Wilde e Tian (2011) alegam que o uso de energia para aquecimento e resfriamento fornece um ponto de partida claro para avaliar o comportamento das edificações sob as mudanças climáticas.

Segundo Tian e De Wilde (2011), em estudo desenvolvido no Reino Unido, à medida que o clima do planeta aquecerá, a energia anual de aquecimento diminuirá, enquanto a energia anual de resfriamento aumentará. Considerando um cenário de emissões médias, até 2050, a energia média de aquecimento será reduzida em cerca de 40%, enquanto a energia média de resfriamento aumentará em cerca de 122%. A combinação dessas mudanças na energia de aquecimento e resfriamento resulta em um aumento geral nas emissões médias de carbono de cerca de 14%. Isso está atrelado ao fato de que as emissões são mais afetadas pela energia de resfriamento, uma vez que, na Europa, o fator de conversão de emissão para eletricidade (usada para refrigerar) é quase três vezes maior do que o do gás natural (usado para aquecer).


A IEA (2018) estima que, até 2050, dois terços da população mundial utilizarão sistemas de ar-condicionado, o que deve resultar em um aumento de 300% na demanda global de energia para resfriamento de ambientes. Nesse sentido, Rysanek, Nuttall e McCarty (2021) relatam que a IEA identifica o resfriamento ambiental como o segmento de maior crescimento no consumo de energia nas edificações em nível global, reconhecendo as mudanças climáticas como um motivo para isso. Além da pouca expectativa de que os esforços para mitigar as mudanças climáticas evitem uma grande adoção de aparelhos de ar-condicionado, existem incertezas sobre quando exatamente e em que medida essa adoção ocorrerá em cidades com climas mais amenos (Davis; Gertler, 2015; De Cian *et al.*, 2019; Rysanek; Nuttall; McCarty, 2021).

Ademais, é importante considerar a vulnerabilidade de domicílios em situação de pobreza energética, conforme explicam Booth, Choudhary e Spiegelhalter (2012). Os autores esclarecem que as principais causas da pobreza energética são: baixos níveis de renda, altos preços de energia, e baixa eficiência energética das habitações. Portanto, melhorar a eficiência energética das habitações existentes poderia ajudar a minimizar esse problema, reduzindo os

custos com condicionamento ambiental e permitindo o direcionamento das economias em outras necessidades básicas.

As decisões relacionadas à concepção das edificações precisam ser ‘à prova do futuro’, levando em consideração a sua vida útil e as mudanças ambientais, econômicas, sociais, tecnológicas etc. Esse conceito vem sendo promovido cada vez mais, por meio de legislação ambiental e regulamentos e normas de construção mais rigorosas, que estabelecem metas de sustentabilidade mais elevadas e introduzem a necessidade de um pensamento de longo prazo (Georgiadou; Hacking; Guthrie, 2012).

Georgiadou, Hacking e Guthrie (2012) sintetizam que as três principais implicações relacionadas à necessidade de adoção de pensamento de longo prazo no projeto de edificações são: i) seguir um processo de projeto holístico que abranja critérios financeiros, ambientais e socioeconômicos (WCED, 1987); ii) adotar perspectivas de ciclo de vida completo, para minimizar o impacto ambiental das soluções ao longo de sua vida útil (Hacking, 2009); e iii) adaptar-se a um futuro incerto, devido à ocorrência de eventos imprevisíveis de alto impacto (Bhimji, 2009). As edificações devem ser projetadas para mitigar impactos de eventos que ocorrem durante o ciclo de vida (de longa duração, durante a fase de uso, e para um futuro distante), representados na Figura 7; é possível visualizar que o projeto é o evento com maior potencial de impacto no ciclo de vida.



Fonte: adaptada de Georgiadou, Hacking e Guthrie (2012)

Embora bem estabelecido que as edificações devem ser preparadas para o futuro, as abordagens convencionais de análise energética de edificações não levam em consideração as mudanças climáticas. É necessário desenvolver novas estratégias e métodos para promover a resiliência das edificações e a sustentabilidade do ambiente construído. Segundo Moazami *et al.* (2019) e Hu e Qiu (2019), é fundamental realizar uma avaliação abrangente dos diferentes tipos de edificações em condições extremas, a fim de orientar o desenvolvimento de normas e regulamentações para a construção civil. Ademais, Mata *et al.* (2019), Sánchez-García (2019)

e Shen, Braham e Yi (2019), esclarecem que esses esforços também devem abranger a compreensão da capacidade de adaptação em condições adversas, bem como avaliações de viabilidade econômica dos possíveis fatores de resposta. O avanço na tomada de decisões preparadas para o clima promoverá processos e políticas de resiliência para as edificações diante das mudanças climáticas, de modo a mitigar os riscos e vulnerabilidades associadas (Shen *et al.*, 2019).

2.1.1 As Edificações e os Desafios do Clima Futuro e dos Eventos Extremos

No último século, a população humana em áreas urbanas aumentou rapidamente. Mais de 55% da população mundial vive em áreas urbanas, e essa porcentagem deve aumentar para 67% até 2050. Nesse sentido, considerando os desafios climáticos, a mitigação e adaptação climática é fundamental para a sustentabilidade da civilização. A mitigação envolve a redução da velocidade do aquecimento global, diminuindo as emissões de poluentes na atmosfera, enquanto a adaptação envolve ações de preparação e se adaptação ao clima futuro (Yang; Javanroodi; Nik, 2021).

As cidades e edificações são impactadas pelas mudanças climáticas, que podem ser em grande parte atribuídas ao consumo de energia proveniente delas mesmas. As cidades enfrentam desastres climáticos em rápida expansão, situação agravada pelo fato de a maioria dos locais mais populosos estarem localizados em regiões costeiras de baixa altitude – mais expostas às ameaças do aumento do nível do mar e a eventos de tempestades e inundações mais frequentes. Muitas cidades têm sofrido desastres climáticos, com eventos extremos ocorrendo com maior frequência, afetando principalmente os setores de saúde e moradia residencial, recursos e agricultura, e infraestrutura de transporte e energia (Ye *et al.*, 2021). A maior ocorrência de riscos climáticos pode afetar muitos aspectos de uma cidade, direta ou indiretamente (Mora *et al.*, 2018), sendo que o aumento dos eventos climáticos aumenta tanto a instabilidade quanto o custo de manutenção do sistema de energia urbana, e isso pode desencadear riscos secundários para outros sistemas (Schaeffer *et al.*, 2012).

Entre as construções, as habitações são as mais vulneráveis. O clima extremo pode ter um impacto severo nas condições térmicas do ambiente construído, especialmente na forma de impactos na saúde dos seus usuários, durante ondas de calor (De Wilde; Tian, 2011; McMichael; Woodruff; Hales, 2006). Segundo Rañases *et al.* (2021) e Stewart *et al.* (2015), as altas temperaturas podem levar ao superaquecimento de uma casa desprovida de instalações adequadas, e, de acordo com Maller e Strengers (2011), em alguns casos, o calor extremo pode


resultar em problemas de saúde e até mesmo na morte de seus moradores. Alguns trabalhos enfatizam que muitas cidades estão enfrentando um aumento na mortalidade devido ao aumento da temperatura (Research Highlights, 2017; Mora *et al.*, 2017), à deterioração da qualidade do ar (West; Smith; Silva, 2013) e às doenças infecciosas (Paz; Semenza, 2016) induzidas pelas mudanças climáticas. Por causa disso, estratégias para combater essa situação têm sido tomadas (Ye *et al.*, 2021).

À medida que a ocorrência de condições climáticas extremas se torna mais frequente, a durabilidade e a integridade das edificações podem ser comprometidas (Lacasse; Gaur; Moore, 2020). Nesse âmbito, a robustez se apresenta como um parâmetro importante. Segundo Moazami, Carlucci e Geving (2019), a ideia fundamental de robustez, no contexto de proteção contra as mudanças climáticas, consiste em tratar a difícil previsibilidade climática (eventos extremos um futuro distante) como um ‘ruído’ (perturbação) durante a fase de projeto; assim, o objetivo é alcançar uma solução cujo desempenho seja menos sensível a esse ruído. Taguchi, Chowdhury e Taguchi (1999, p. 4) definem robustez como “o estado em que o desempenho da tecnologia, produto ou processo é minimamente sensível a fatores que causam variabilidade (seja na fabricação ou no ambiente do usuário) e envelhecimento a um custo mínimo de fabricação da unidade”.

A resiliência é um outro conceito muito importante aplicado às edificações preparadas para os desafios do clima futuro; o termo é apresentado como uma evolução da robustez, conforme as definições de Moazami, Carlucci e Geving (2019): uma ‘edificação robusta’ é aquela que, durante sua operação, pode atender aos requisitos de desempenho com o mínimo de variação em um ambiente em constante mudança; uma ‘edificação resiliente’ é aquela que, não apenas é robusta, mas também pode cumprir seus requisitos funcionais (resistir) durante uma grande perturbação (ruído) – seu desempenho pode até ser afetado, mas deve se recuperar para um nível aceitável de maneira adequada.

Em outras palavras, pode-se dizer que as edificações robustas têm um desempenho com baixa sensibilidade em condições típicas e previsíveis, mas sua funcionalidade está em risco durante eventos extremos imprevisíveis; por outro lado, as edificações resilientes resistem a eventos extremos imprevisíveis, além de serem capazes de se recuperar, com nível de desempenho aceitável, e continuar seu serviço (Moazami; Carlucci; Geving, 2019). Estes conceitos são ilustrados no gráfico da Figura 8, que relaciona o desempenho do ambiente construído sob diferentes condições climáticas ao longo do seu tempo de uso.

Figura 8 – Esquema de desempenho do ambiente construído sob diferentes condições climáticas



Fonte: adaptada de Moazami, Carlucci e Geving (2019)

As edificações projetadas com base em condições típicas podem operar conforme o esperado durante essas condições, mas seu desempenho será significativamente perturbado durante condições extremas. Adicionalmente, há até risco de falha completa de funcionalidade durante eventos extremos imprevisíveis, sem possibilidade de reocupação (fim de serviço). Isso ocorre devido à sua sensibilidade às condições externas (Moazami; Carlucci; Geving, 2019).

A indústria da construção civil está adotando diversas ações para alcançar o desenvolvimento sustentável, implementar estratégias de conservação de energia e contribuir para a mitigação das mudanças climáticas, por meio de edificações eficientes e resilientes. Porém, ainda existem desafios na compreensão e modelagem dos impactos das mudanças climáticas e os consequentes riscos de eventos extremos (Yang; Javanroodi; Nik, 2021).

De acordo com Yang, Javanroodi e Nik (2021), nas últimas três décadas, foram feitos esforços significativos para reduzir as demandas de energia em edificações. Esses esforços contribuem para a mitigação das mudanças climáticas, reduzindo as demandas de energia. Para desenvolver soluções adaptativas adequadas, é necessário avaliar corretamente os impactos prováveis das mudanças climáticas. Isso requer a investigação das variações de curto e longo prazo no clima futuro e a consideração de diferentes cenários futuros e incertezas envolvidas; o que será discutido nos tópicos seguintes.

2.1.2 Dados Climáticos para Simulações de Desempenho Térmico e Energético de Edificações

Para análises e tomadas de decisão sobre o desempenho térmico e energético de edificações, uma das melhores ferramentas disponíveis para os profissionais de construção civil são as simulações de modelos computacionais BEM, com programas capazes de simular detalhadamente a física (troca de calor) das edificações (Rysanek; Choudhary, 2013).

Segundo De Wilde e Tian (2012), o uso de abordagens com simulações computacionais é a única opção disponível para realizar comparações equivalentes entre as condições climáticas atuais e futuras, com base em dados climáticos desenvolvidos por especialistas em meteorologia e mudanças climáticas. As simulações em regime transiente, por meio de programas como o EnergyPlus, são necessárias, uma vez que o interesse se concentra em dois aspectos-chave de desempenho térmico: o uso de energia para aquecimento e resfriamento (associado às emissões de gases de efeito estufa) e o risco de superaquecimento. Nesse sentido, as análises a serem desenvolvidas e o risco a ser quantificado estão relacionados às flutuações nos fluxos de calor e nas temperaturas internas e externas ao longo do tempo; assim, métodos mais genéricos, como médias mensais, são inadequados (De Wilde; Tian, 2012).

O EnergyPlus é amplamente utilizado em simulações de edificações, devido à sua constante validação, capacidade de modelagem de sistemas e componentes de edificações avançados, e disponibilidade gratuita. Além disso, tem a vantagem de acesso a um amplo conjunto mundial de arquivos climáticos (*EnergyPlus Weather Files – EPW*) e de acesso a uma série de modelos de referência detalhados (De Wilde; Tian, 2012).

O planejamento para adaptação às mudanças climáticas é um desafio aos projetistas de edificações, devido aos longos períodos a serem considerados, visto que os impactos das variações climáticas e suas incertezas podem ocorrer em diferentes escalas de tempo, e à difícil previsibilidade da intensidade de aquecimento e sua velocidade (WEForum, 2016; Nik; Mata; Kalagasidis, 2015; Nik; Kalagasidis, 2013). Segundo De Masi *et al.* (2021), no âmbito do conceito de resiliência das edificações, as incertezas sobre as mudanças climáticas e como elas podem afetar o consumo de energia de edificações, podem ser estudadas a partir de projeções climáticas aplicadas em simulações computacionais. No entanto, não existem métodos para eliminar as incertezas, uma vez que o nível previsto de emissões de gases de efeito estufa (GEE) não é totalmente preciso (De Masi *et al.*, 2021; Hallegatte, 2009).

As projeções climáticas são geradas a partir das saídas de modelos e cenários futuros, baseados em emissões e concentrações de gases de efeito estufa e poluentes atmosféricos e uso

do solo (IPCC, 2014). E, a partir dessas projeções, é possível a obtenção de arquivos climáticos futuros usados em simulações de BEM.

2.1.2.1 Modelos e cenários climáticos

Geralmente, a avaliação dos impactos das mudanças climáticas é realizada por meio de dados climáticos gerados por Modelos de Circulação Gerais (*General Circulation Model* – GCM), ou Modelos Climáticos Globais (*Global Climate Models* – GCM) (Nik, 2016). Os GCM contêm modelos atmosféricos, modelos oceânicos, esquemas de superfície terrestre e modelos de gelo marinho, simulando condições climáticas sob diferentes condições de contorno (possibilidades de desenvolvimento futuro). Os GCM simulam condições climáticas futuras com resolução espacial de 100 a 300 km² (IPCC, 2007), o que não pode ser considerado como dados meteorológicos, sendo grosseiro para fins de avaliação de impacto, embora possam ser aplicados como uma base de estimativa para variáveis meteorológicas futuras.

O IPCC define possíveis cenários futuros de desenvolvimento em seus relatórios de avaliação publicados periodicamente, desde 1990. Os cenários de mudanças climáticas são modelados utilizando possíveis panoramas de emissões de gases de efeito estufa. Considerando os primeiros relatórios publicados neste século, o AR3 (IPCC, 2001) e AR4 (IPCC, 2007) – que são aplicados em vários trabalhos para estimativas climáticas até o ano de 2100 – utilizavam cenários de um Relatório Especial em Cenários de Emissão (SRES) desenvolvido em 1996. O penúltimo relatório do IPCC, o AR5 (IPCC, 2014), utilizou um novo conjunto de cenários desenvolvido pela comunidade científica, baseado nos Patamares de Concentração Representativos (*Representative Concentration Pathway* – RCP). Por sua vez, o último relatório, o AR6 (IPCC, 2021), implementou um conjunto de cenários impulsionados por diferentes Caminhos Socioeconômicos Compartilhados (*Shared Socio-Economic Pathways* – SSP), que incluem atualizações com cenários que consideram emissões negativas de dióxido de carbono (CO₂), por meio da captura de GEE (sequestro de carbono).

Os cenários SRES são representações de possíveis futuros, baseadas em diferentes hipóteses sobre a evolução demográfica, econômica e tecnológica. Essas hipóteses foram divididas em quatro famílias: A1, A2, B1 e B2, cada uma com diferentes características. A família A1 representa um futuro globalizado, com rápido crescimento econômico e tecnológico. A família A2 representa um futuro com diferentes níveis de evolução entre nações e culturas, sendo apontado como a perspectiva mais provável. A família B1 representa um futuro

sustentável, com crescimento econômico moderado e uso eficiente de recursos. E a família B2 representa um futuro intermediário entre os cenários A1 e B1 (IPCC, 2007).

O conjunto de cenários denominado RCP, é baseado em emissões e concentrações de gases de efeito estufa e poluentes atmosféricos e uso do solo (IPCC, 2014). O relatório foi desenvolvido a partir de quatro RCP elaborados em função do seu caminho de força radioativa². No Quadro 5 apresentam-se os quatro cenários previstos, associados às anomalias de temperatura esperadas.

Quadro 5 – Resumo dos RCP apresentados no IPCC AR5; com base na mudança média de 20 anos

Cenário	Forçamento radiativo até 2100 [W/m ²]	Anomalia* de temperatura provável de 2081 a 2100 [°C]	Descrição
RCP2.6	2,6	1,0 (0,3 a 1,7)	Cenário de mitigação rigoroso. Pico na força radioativa, com declínio antes de 2050; único que manteria o aquecimento global abaixo** de 2 °C.
RCP4.5	4,5	1,8 (1,1 a 2,6)	Cenário de mitigação intermediário. Estabilização da força radioativa em 4,5 W/m ² após 2100; prevê-se que o aquecimento global exceda** 1,5 °C.
RCP6.0	6,0	2,2 (1,4 a 3,1)	Cenário de mitigação intermediário. Estabilização da força radioativa em 6,0 W/m ² após 2100; prevê-se que o aquecimento global exceda** 1,5 °C.
RCP8.5	8,5	3,7 (2,6 a 4,8)	Cenário com emissões elevadas. Crescente da força radioativa, alcançando 8,5 W/m ² em 2100; prevê-se que o aquecimento global exceda** 1,5 °C.

* Em relação a 1986-2005

** Em relação a 1850-1900

Fonte: Nunes (2021); elaborado com dados de IPCC (2014)

Assim, vários desses cenários foram selecionados para conduzir os modelos climáticos do CMIP6. Como dito anteriormente, o IPCC AR5 apresentou os quatro RCPs que examinaram diferentes possíveis emissões futuras de GGE os quais tem novas versões no CMIP6.

No AR6, os cenários atualizados são cinco: SSP1-1.9, SSP1-2.6, SSP2-4.5, SSP3-7.0 e SSP5-8.5, com níveis de forçamento radiativo semelhantes aos do AR5 em 2100. O relatório

² Força radiativa é uma medida das emissões humanas de gases de efeito estufa, em Watts por metro quadrado (W/m²). A energia solar recebida pelo planeta é equilibrada pela radiação terrestre devolvida, e uma mudança no equilíbrio entre a radiação de entrada e saída para a atmosfera pode afetar o clima – essa alteração na energia disponível para o sistema global Terra/atmosfera é denominada forçamento radiativo (IPCC, 2014).

considera abordagens de remoção de carbono baseadas no uso da terra, incluindo florestamento e reflorestamento, bioenergia com captura e armazenamento de carbono, carbono do solo, biocarvão, entre outros. No Quadro 6 apresentam-se os cinco cenários previstos, associados às anomalias de temperatura esperadas.

Quadro 6 – Resumo dos SPP apresentados no IPCC AR6; com base na mudança média de 20 anos

Cenário	Forçamento radiativo até 2100 [W/m ²]	Anomalia* de temperatura provável de 2081 a 2100 [°C]	Descrição
SSP1-1.9	1,9	0,6 (0,2 a 1,0)	Cenário otimista, com um mundo em que as emissões globais de CO ₂ são reduzidas a zero por volta de 2050. As sociedades prezam por práticas mais sustentáveis, com o foco sendo o bem-estar geral, e não o crescimento econômico. Único que cumpre a meta do Acordo de Paris de manter o aquecimento global em torno de 1,5 °C**, com o aquecimento atingindo 1,5 °C**, mas depois diminuindo e se estabilizando em torno de 1,4 °C** até o final do século.
SSP1-2.6	2,6	0,9 (0,5 a 1,5)	As emissões globais de CO ₂ são reduzidas severamente, mas não tão rapidamente, chegando a zero após 2050. Supõe as mesmas mudanças socioeconômicas em direção à sustentabilidade que o SSP1-1.9, mas a elevação da temperatura se estabiliza em torno de 1,8 °C**.
SSP2-4.5	4,5	1,8 (1,2 a 2,6)	Cenário intermediário. As emissões de CO ₂ oscilam em torno dos níveis atuais antes de começar a cair em 2050; mas não atingem zero líquido até 2100. Neste cenário, a temperatura média global aumenta 2,7 °C** até o final do século.
SSP3-7.0	7,0	2,8 (2,0 a 3,7)	As emissões e as temperaturas aumentam constantemente; até 2100, as emissões de CO ₂ praticamente dobram em relação aos níveis atuais. No final do século, a temperatura média global aumenta 3,6 °C**.
SSP5-8.5	8,5	3,5 (2,4 a 4,8)	A pior condição, que precisa ser substancialmente evitada. Neste cenário, os níveis de emissões de CO ₂ atuais praticamente dobram até 2050. Em 2100, a temperatura média global aumenta 4,4 °C**.

* Em relação a 1995-2014 (a temperatura média global do ar na superfície neste período de referência foi 0,85 [0,67 a 0,98] °C maior do que no período 1850-1900)


** Em relação a 1850-1900

Fonte: o autor; elaborado com dados de IPCC (2021) e Januta (2021)

Embora não exista uma correspondência direta entre as metodologias SRES e RCP para cenários futuros, pode-se fazer uma comparação da variação de aumento da temperatura no futuro, como ilustra-se na Figura 9. Analogamente, é possível relacionar o forçamento radioativo e elevações de temperatura dos cenários RCP e SSP, como ilustram-se nas Figuras


9 e 10; os indicadores de forçamento radiativo nos cenários RCP e SSP são aproximados e permitem agregações, caracterizando diferentes cenários por um único número (IPCC, 2021).

Figura 9 – Evolução do forçamento radiativo total para os cenários SRES e RCP




Fonte: Nunes (2021); adaptada de IPCC (2014)

Figura 10 – Evolução do forçamento radiativo total para os cenários RCP e SSP



Fonte: o autor; adaptada de IPCC (2021)

Figura 11 – Evolução da elevação da temperatura, em relação a 1850-1900, para os cenários RCP e SSP



Finalmente, considerando a difícil previsibilidade do futuro, convém frisar que os cenários atualizados periodicamente não são, necessariamente, mais capazes de representar os desenvolvimentos futuros do que os cenários iniciais SRES. Portanto, para fins de pesquisa, entende-se que tanto o uso de cenários mais recentes, quanto dos SRES, é apropriado (De Masi *et al.*, 2021; IPCC, 2013).

2.1.2.2 Obtenção de arquivos climáticos futuros

A maioria das ferramentas de simulação de edificações requer arquivos climáticos como dados de entrada (Fiocchi; Hoque; Weil, 2014). Arquivos climáticos *Test Reference Year* (TRY) ou *Typical Meteorological Year* (TMY), que representam observações meteorológicas passadas típicas, ainda são comumente usados. Todavia, se percebem cada vez mais esforços na comunidade científica para a obtenção de dados climáticos futuros adequados às simulações de desempenho de edificações.

Vários métodos têm sido amplamente utilizados para integrar os impactos das mudanças climáticas em arquivos para simulações computacionais (Guan, 2009; Berardi; Jafarpur, 2020). A criação de um arquivo climático futuro para simulação de desempenho de edificações pode ser classificada em duas categorias, de acordo com a abordagem utilizada: i) a primeira categoria depende de dados meteorológicos históricos e inclui o método estatístico de extrapolação, o método de compensação imposto e o modelo climático estocástico; ii) a segunda categoria depende do uso de modelos climáticos como uma alternativa à abordagem de dados meteorológicos históricos. Na bibliografia, é comum a classificação dessas categorias como Redução de Escala Empírico-Estatística (*Empirical-Statistical Downscaling* – ESD) e Redução de Escala Dinâmica (*Dynamical downscaling* – DDS).

No Quadro 7, sintetizam-se essas abordagens, e na Figura 12, ilustra-se um esquema de acordo com as classificações metodológicas ESD e DDS.


Quadro 7 – Abordagens para obtenção de dados climáticos futuros

Abordagem	Descrição	Considerações
Método estatístico de extrapolação (método graus-dia)	Consiste em extrapolar dados meteorológicos históricos para prever condições meteorológicas futuras. Como exemplo de aplicação, cita-se a previsão das tendências de consumo energético usando graus-dia, ou seja, estima-se o indicador para prever a compensação de energia para equilibrar a variação na temperatura exterior, supondo um equilíbrio para manter uma determinada temperatura interior.	A vantagem do graus-dia é que é simples e rápido. Contudo, as estimativas podem ser muito grosseiras, visto que só é apropriado se o uso da edificação e a eficiência do equipamento de HVAC forem constantes. O método só considera o efeito da temperatura de bulbo seco, limitando demasiadamente sua aplicação. E, ainda, como a radiação solar ou a umidade não são consideradas, a análise de graus-dia pode levar a grandes desvios na simulação de energia em edificações, limitando sua aplicação.
Método de compensação imposto (<i>morphing</i>)	Impõe a informação climática futura prevista a partir dos modelos climáticos complexos, “atualizando” os dados de um ano de referência. Empregado na ferramenta CCWorldWeatherGen, é o mais aplicado na bibliografia para gerar arquivos climáticos futuros para simulações computacionais.	Dentre as vantagens, as alterações climáticas são baseadas na comunidade científica e no IPCC; dados dos anos de referência estão disponíveis; as condições meteorológicas atuais e futuras estão em uma base consistente. Dentre as limitações, seria necessária uma abordagem mais sistemática (precisão); assume-se que a temperatura horária aumenta constantemente; possíveis mudanças na insolação são ignoradas.
Modelo climático estocástico	Foram propostos por van Paassen e Luo (2002) e Adelard <i>et al.</i> (2000). Sugere-se que este modelo poderia gerar uma base de vários dados meteorológicos artificiais. Alguns geradores de dados meteorológicos utilizam algoritmos matemáticos que criam parâmetros meteorológicos semelhantes aos dados de estações meteorológicas locais.	A aplicação de modelos meteorológicos estocásticos na geração de dados meteorológicos futuros é significativa, principalmente em áreas onde não existem dados históricos. Porém, devido à natureza estocástica (aleatoriedade), seriam necessários dados meteorológicos ao longo de muitos anos, para se apresentar representatividade do período desejado; possui dificuldades de modelagem das variáveis climáticas; requer muita potência computacional.
Modelos climáticos numéricos	Método complexo e aprofundado, desenvolvido por meteorologistas. Leva em consideração os mecanismos de transferência de energia entre uma atmosfera tridimensional turbulenta e radioativa e superfícies espacialmente heterogêneas de terra, oceano e criosfera. Dada a natureza complexa e caótica do sistema	Requer a geração de dados meteorológicos de vários anos para encontrar um padrão meteorológico representativo para um período desejado, o que é uma tarefa difícil e cara. Além disso, as alterações nas condições meteorológicas em diferentes anos podem ser muito grandes, e, se não for definido um ano adequado para representar o

Abordagem	Descrição	Considerações
	climático global, várias aproximações e simplificações têm sido adotadas. Para exemplificar, os GCM são usados para gerar arquivos climáticos locais futuros utilizando redução de escala dinâmica ou Modelo Climático Regional (MCR).	período desejado, erros graves e resultados enganosos podem ser produzidos.

Fonte: Nunes (2021); elaborado a partir de Berardi e Jafarpur (2020) e Guan (2009)

Figura 12 – Abordagens para obtenção de arquivos climáticos



Fonte: o autor; adaptada de Yaqubi *et al.* (2022)

Na Figura 12 mostram-se algumas ferramentas associadas às abordagens aplicadas (CCWorldWeatherGen, WeatherShift, Meteonorm) – que serão detalhadas na sequência. Também se apresenta o modelo de projeções de mudanças climáticas do Reino Unido, de 2009 (UKCP09), que é uma das referências fundamentais no estado-da-arte em previsões de mudanças climáticas (Murphy *et al.*, 2009). Lançado em junho de 2009, oferecem projeções probabilísticas para diversas variáveis climáticas. O UKCP09 leva em consideração três tipos de incertezas: a variabilidade climática natural, a incerteza nos modelos climáticos e a incerteza nas emissões futuras (De Wilde; Tian, 2011).

Entre os métodos apresentados, Berardi e Jafarpur (2020), Farah *et al.* (2019) e Guan (2009) esclarecem que a compensação imposta é o método mais prático para desenvolver dados meteorológicos futuros, uma vez que o método estatístico de extrapolação considera apenas a medida de graus-dia, e o modelo climático estocástico requer alta potência computacional. De

acordo com Berardi e Jafarpur (2020) e Moazami *et al.* (2017), após seis GCM, no âmbito do AR3, e 23 GCM, no âmbito do AR4, terem sido revisados, chegou-se à conclusão de que o GCM mais adequado para aplicar a técnica de *morphing* é o *Hadley Centre Coupled Model version 3* (HadCM3) para o cenário de emissão A2, proposto pelo AR3; que representa um caso de pouca iniciativa de mudanças comportamentais, com aumento da população global e crescimento econômico regionalmente orientado.

Segundo Yassaghi e Hoque (2019), os geradores de arquivos climáticos podem ser usados para produzir dados suficientes para análises sob condições futuras. Os autores revisaram métodos de desenvolvimento de arquivos climáticos com alta resolução espacial e temporal que incorporam cenários de emissões e listam algumas ferramentas para geração de dados climáticos horários:

- Advanced Weather Generator (AWE-GEN) (Fatichi; Ivanov; Caporali, 2011a; Fatichi; Ivanov; Caporali, 2011b): foi criado por pesquisadores da Universidade de Michigan, em 2007, e é capaz de gerar dados horários para dez locais dos Estados Unidos e um local da Itália, a partir de informações de estações meteorológicas nos Estados Unidos (Ivanov; Bras; Curtis, 2007). A ferramenta é baseada no MATLAB e pode reproduzir as características de baixa e alta frequência dos parâmetros meteorológicos. Os dados são produzidos sem formatação prévia e precisam ser convertidos em arquivos TMY ou EPW para simulações;
- Climate Change World Weather File Generator (CCWorldWeatherGen) (Jentsch, 2012; Jentsch *et al.*, 2013): os resultados dos cenários climáticos desenvolvidos no Modelo de Circulação Geral (GCM) Hadley Centre Coupled Model version 3 (HadCM3) para o cenário SRES-A2 do IPCC, em relação ao período 1961-1990, são tidos como base (Jentsch *et al.*, 2013). Jentsch, Bahaj e James (2012) criaram a ferramenta CCWorldWeatherGen – disponibilizada gratuitamente pelo Grupo de Pesquisa em Energia Sustentável (SERG) da Universidade de Southampton (University of Southampton, 2023) – para adaptar os arquivos EnergyPlus Weather (EPW) aplicando o método *morphing* desenvolvido por Belcher, Hacker e Powell (2005). A ferramenta, que funciona como uma extensão para o Microsoft Excel, foi projetada de modo a permitir a geração de arquivos climáticos futuros para três períodos, ou *time slices*, representativos: 2020 (representa o período de 2011 a 2040), 2050 (representa o período de 2041 a 2070) e 2080 (representa o período de 2071 a 2100) para qualquer parte do mundo (Jentsch *et al.*, 2013). Observa-se que o CCWorldWeatherGen considera arquivos climáticos de 1961 a 1990 para gerar arquivos climáticos futuros, e o uso de

outros dados, sobretudo, mais recentes, podem superestimar os impactos das mudanças climáticas (Jentsch; Bahaj; James, 2012; Jentsch *et al.*, 2013).

- **Meteonorm** (Remund *et al.*, 2020; Remund; Salvisberg; Kunz, 1998): é um gerador de dados climáticos estocástico, que utiliza uma média de todos os modelos climáticos disponíveis no IPCC AR4. Ele contém um banco de dados climáticos derivado do Arquivo do Balanço Energético Global (GEBA) e da WMO e Centro Nacional de Dados Climáticos (NCDC) e pode gerar arquivos meteorológicos típicos para dois períodos de 1981-1990 e 1991-2010, extrapolando dados horários a partir de dados meteorológicos estatísticos, em todo o mundo. A ferramenta utiliza vários cenários de emissões do IPCC e produz arquivos em formatos TMY e EPW para diversos períodos futuros (2020-2100). Segundo Ebrahimpour e Maerefat (2010), o TMY gerado pelo *software* Meteonorm tem boa concordância com os dados médios de longo prazo.
- **Urban Weather Gen (UWG)** (Bueno *et al.*, 2013; Urban Microclimate, 2016): baseado no MATLAB, estima a temperatura do ar urbano e a umidade horária usando dados meteorológicos de estações meteorológicas locais, sendo, também, capaz de capturar os efeitos da ilha de calor urbano;
- **WeatherShift** (Maloney, 2016; Troup; Fannon, 2016; De Masi *et al.*, 2021): utiliza uma abordagem probabilística para desenvolver arquivos meteorológicos futuros, conforme o arquivo TMY de entrada, usando cenários de emissões (RCP4.5 e RCP8.5) do IPCC AR5 para três períodos futuros (2035, 2065 e 2090). A ferramenta permite a aplicação do método de transformação nos deslocamentos de 14 GCM (de um total de 40 modelos disponíveis). Porém, ao contrário do CCWorldWeatherGen, a ferramenta não está disponível gratuitamente.

Yassaghi e Hoque (2019) concluem que diversas pesquisas têm usado essas técnicas para avaliar o desempenho de edificações sob condições climáticas futuras, com destaque para o CCWorldWeatherGen, que é aplicado em estudos do mundo todo. As ferramentas comerciais como WeatherShift e Meteonorm permitem gerar arquivos de clima futuro para cidades em todo o mundo (Dickinson; Brannon, 2016), porém limitadas à aquisição de licença.

A área de geração ou progressão de arquivos climáticos futuros para simulação de desempenho térmico e energético de edificações ainda está em desenvolvimento (Rysanek; Nuttall; McCarty, 2021). E, nesse contexto, destaca-se que a criação, modificação e avaliação de dados meteorológicos futuros para uso no ambiente construído exigem atenção, sendo importante estudos para eliminar (ou diminuir) as incertezas geradas pelas variabilidades climáticas.

2.1.3 Índices de Avaliação Térmica e Energética e Resiliência em Edificações

Ao longo dos anos, pesquisadores propuseram métodos para descrever o superaquecimento interno – fenômeno dinâmico, relacionado ao conforto térmico – mas ainda não existe um consenso sobre como avaliá-lo por meio de simulação ou medição (Lomas; Porritt, 2017). Yaqubi *et al.* (2022) listam quatro famílias de índices relacionadas à satisfação térmica humana: (1) índices percentuais, que demonstram conforto como uma porcentagem de tempo dentro de uma faixa, como o voto médio predito (PMV); (2) índices cumulativos, como os graus-hora para aquecimento ou resfriamento; (3) índices de risco, como o risco de superaquecimento de Nicol *et al.* (2009), que sugere que o desconforto térmico está relacionado à diferença entre a temperatura operativa e os limites adaptativos, e o risco de superaquecimento de Robinson e Hadi (2008), que propõe um modelo matemático simples para prever o risco de superaquecimento dado um conjunto de condições ambientais medidas; e (4) índices de média, como a média prevista percentual de insatisfação (PPD) e a diferença entre a temperatura máxima e a média anual.

No Quadro 8 apresentam-se intervalos de índices de calor, usados em estudos de estresse térmico, indicando as prováveis consequências (avaliação do risco à saúde) relacionadas à exposição à essas condições de calor. A Temperatura Efetiva Padrão (SET) (ASHRAE, 2017a) é outro indicador relevante para o estresse térmico dos usuário, que tem sido elogiado, no sentido de apresentar uma boa correspondência da resposta fisiológica dos usuários (Tavakoli *et al.*, 2022); no Quadro 9 listam-se os diferentes estados fisiológicos, de acordo com os valores do SET.

Quadro 8 – Definições de quatro intervalos de índices de calor

Índice de calor	Nível de risco
abaixo de 26,7 °C	Seguro: sem risco de superaquecimento.
26,7 °C – 32,2 °C	Cuidado: possível fadiga. Atividades físicas nessas condições podem resultar em câibras.
32,2 °C – 39,4 °C	Cuidado extremo: câibras e exaustão por calor são possíveis. Atividades físicas nessas condições podem resultar em insolação.
39,4 °C – 51,7 °C	Perigo: câibras e exaustão por calor são prováveis. Atividades físicas nessas condições, muito provavelmente, causarão insolação.
acima de 51,7 °C	Perigo extremo: insolação.

Fonte: o autor; adaptado de DOE (2021) e Tavakoli *et al.* (2022)

Quadro 9 – Sensações térmicas e estados fisiológicos para diferentes faixas SET

SET	Sensação térmica	Estado fisiológico
acima de 37,5 °C	Muito calor	Falha de termorregulação
34,5 °C – 37,5 °C	Calor	Suor abundante
30,0 °C – 34,5 °C	Quente	Suor
25,6 °C – 30,0 °C	Ligeiramente quente	Suor leve, vasodilatação
22,2 °C – 25,6 °C	Neutralidade térmica	Neutro

Fonte: o autor; adaptado de Laouadi *et al.* (2022) e Tavakoli *et al.* (2022)

Para Yang, Javanrood e Nik (2021), a maioria dos estudos de conforto térmico foca no conforto térmico adaptativo, enquanto poucos consideraram cenários climáticos futuros. Hosseini, Javanrood e Nik (2022), em análise conduzida para duas edificações residenciais multifamiliares no sudeste da Suécia, constataram que, considerando condições meteorológicas típicas entre períodos de 30 anos, o indicador graus-dia para resfriamento aumenta em 45%, e o graus-dia para aquecimento diminui em 8%. Segundo os autores, as diferenças podem se tornar muito mais significativas durante condições meteorológicas extremas: o graus-dia para resfriamento pode aumentar em 500% em um julho extremamente quente, em comparação com um julho típico. Os resultados também indicam que, em 2040-2069 e 2070-2099, a demanda de resfriamento anual fica, respectivamente, quatro e cinco vezes maior do que em 2010-2039. Na ausência de sistemas de resfriamento durante dias extremamente quentes, a temperatura interna permanece acima de 26°C continuamente ao longo de uma semana e atinge mais de 29,2°C. Além disso, as horas anuais de superaquecimento podem aumentar até 140% no futuro. Todos esses elementos sugerem que não levar em conta as variações climáticas pode resultar em má adaptação ou adaptação insuficiente das áreas urbanas às mudanças climáticas.

As áreas urbanas abrigam mais da metade da população mundial, esperando-se que aumente para mais de dois terços até 2050 (Sethi; Sharma; Mohapatra, 2021). Políticas públicas locais e internacionais têm sido implementadas para controlar e reduzir os impactos ambientais da urbanização. O Objetivo de Desenvolvimento Sustentável (ODS) 11 – cidades e comunidades sustentáveis – da Agenda 2030 das Nações Unidas (ONU, 2015) define a redução dos impactos ambientais (Meta 11.6) e a eficiência de recursos e resiliência das cidades (Meta 11.b) como indicadores para alcançar os objetivos definidos. O ODS 3 (saúde e bem-estar) e o ODS 7 (energia acessível e limpa) estão fortemente conectados a soluções de energia urbana e transição sustentável. Nesse contexto, o Acordo de Paris obriga os países a agirem em direção aos objetivos climáticos (Rogelj *et al.*, 2016), explicitado no ODS 13 – ação climática.

De acordo com Perera *et al.* (2020) e Yang *et al.* (2021), eventos climáticos influenciam o desempenho dos sistemas de energia urbana, tanto na demanda quanto no fornecimento. Embora avançar para uma maior integração de fontes de energia renovável contribua

efetivamente para a sustentabilidade da área urbana, adaptar-se às mudanças climáticas é essencial, pois a produção de energia renovável é altamente influenciada por variações climáticas (Nik, 2016; Perera *et al.*, 2020). Como parte significativa da demanda energética, as edificações desempenham um papel significativo para alcançar soluções de energia urbanas resilientes. Portanto, é necessário ter uma avaliação de desempenho energético das edificações, com índices confiáveis, para planejar adequadamente a adaptação às mudanças climáticas em áreas urbanas (Nik; Moazami, 2021).

A resiliência deriva do verbo latino *resilire*, que significa “voltar atrás”, ou ainda “capaz de resistir ou se recuperar rapidamente de condições difíceis” (Tavakoli *et al.*, 2022). Este conceito é amplamente aplicado na gestão de riscos de desastres, e pode ser entendido como a “capacidade de um sistema e suas partes componentes de antecipar, absorver, acomodar ou se recuperar dos efeitos de um evento perigoso, de maneira oportuna e eficiente, incluindo garantir a preservação, restauração ou melhoria de suas estruturas e funções básicas essenciais” (IPCC, 2012, p. 5). Ademais, as definições abrangem várias áreas integradas, como ilustra-se na Figura 13.

Figura 13 – Definições de resiliência integrada em diferentes áreas



Fonte: o autor; adaptada de Tavakoli *et al.* (2022)

De modo geral, o conceito de resiliência em edificações (engenharia) refere-se à capacidade da construção e seus sistemas continuarem adequados, diante de ameaças impostas pelas mudanças climáticas (Alfraidi; Boussabaine, 2015; Zhang *et al.*, 2021). Todavia, no contexto do ambiente construído, as definições de resiliência disponíveis na bibliografia podem ser mais abrangentes e divididas em cinco fatores, segundo Tavakoli *et al.* (2022): cidades resilientes (capacidade de manter a temperatura interna de edificações, conforme determinados intervalos); projetos de edificações resilientes (envolvendo flexibilidade em estratégias passivas, resposta passiva, durabilidade e longevidade, recuperação, e uma maneira de prever e enfrentar desastres em complemento à normas de construção); sistemas resilientes (continuidade da função de um sistema, como a envoltória, diante de mudanças e perturbações); resfriamento resiliente (capacidade de absorver impactos, adaptação, remediação, restauração, velocidade de recuperação e sensibilidade ao risco); e comportamento resiliente dos usuários (resistência, capacidade de lidar com a mudança, e capacidade de recuperação).


O recente Programa de Edificações e Comunidades da Agência Internacional de Energia (EBC-IEA), denominado ‘Anexo 80: Resfriamento resiliente de edificações, aborda essa necessidade ao desenvolver, avaliar e comunicar estratégias para resfriamento resiliente e proteção contra superaquecimento diante das mudanças climáticas (IEA-EBC, 2019). O Programa define o resfriamento resiliente como uma capacidade do sistema de resfriamento integrado à edificação, que permite resistir ou se recuperar de perturbações como ondas de calor e falta de energia, e adotar estratégias apropriadas após falhas para mitigar a degradação do desempenho do ambiente construído (redução da qualidade ambiental interna e/ou aumento da demanda de energia para resfriamento) (Attia *et al.*, 2021).

Zhang *et al.* (2021), por meio de um estudo bibliográfico, constataram que, para alcançar um resfriamento resiliente, quatro critérios devem ser considerados na fase de projeto de um edifício ou durante o planejamento de *retrofits*: capacidade absorvente, capacidade adaptativa, capacidade restaurativa e velocidade de recuperação, conforme o esquema estruturado na Figura 14. O autor elenca as seguintes considerações para cada uma delas da seguinte maneira:

- capacidade absorvente: é o grau em que um sistema é capaz de absorver os impactos de eventos disruptivos e minimizar suas consequências com pouco esforço. Por exemplo, uma elevada massa térmica (capacidade térmica) pode absorver ganho solar indesejado e pode minimizar e/ou atrasar o aumento da temperatura do ar no edifício sem o uso de energia de resfriamento;

- capacidade adaptativa: é a capacidade de ajustar situações indesejáveis passando por algumas mudanças. O sistema pode aprender com o evento, avaliar o desempenho do sistema e modificar suas configurações, tornando-se mais flexível. A capacidade adaptativa se distingue da capacidade absorvente pelo fato de que os sistemas adaptativos mudam em resposta a impactos adversos, especialmente se a capacidade absorvente tiver sido excedida. Por exemplo, uma sombra solar na fachada pode ser ativada quando a temperatura do ar no edifício começa a aumentar, porque a capacidade de armazenamento da massa térmica foi excedida;
- capacidade restaurativa: é a capacidade de retornar à operação normal ou aprimorada. Por exemplo, o resfriamento noturno pode remover o ganho de calor indesejado acumulado na massa térmica durante o dia e fornecer um reservatório de calor para o próximo dia;
- velocidade de recuperação: é a velocidade do processo de recuperação. A recuperação pode ser acelerada se as atividades de absorção forem bem implementadas e o sistema puder mobilizar e usar efetivamente todos os recursos disponíveis. Por exemplo, a velocidade com que o resfriamento noturno pode remover o calor da massa térmica do edifício e restaurar o edifício à condição desejada depende da taxa de fluxo de ventilação e da temperatura do ar externo.

Figura 14 – Estrutura de critérios para edificações com resfriamento resiliente



Fonte: o autor; adaptada de Zhang *et al.* (2021)

O desempenho de sistemas de ventilação em eventos extremos está fortemente correlacionado aos tipos de ventilação (natural ou mecânica), às características da edificação, ao clima local e ao comportamento dos ocupantes (Campaniço *et al.*, 2019; Geros *et al.*, 1999). Alessandrini *et al.* (2019) investigaram o risco de superaquecimento em uma habitação naturalmente ventilada durante ondas de calor em Paris, França, e observaram que, por meio de ventilação natural, a temperatura operativa interna máxima poderia ser mantida 6 a 9 °C mais baixa do que a temperatura externa máxima, que atingiu 39 °C durante cinco dias de ondas de calor. A pesquisa demonstra que um sistema de ventilação natural bem projetado pode mitigar a crescente demanda de resfriamento durante um evento extremo de calor. Nesse sentido, Lomas e Ji (2009) demonstraram que edificações com elementos arquitetônicos como fachada ventilada, pé-direito duplo ou efeito chaminé integrados a controles avançados de ventilação podem proporcionar maior resiliência às mudanças climáticas do que o uso de ventilação natural unilateral (Zhang *et al.*, 2021).

No entanto, Hamby *et al.* (2017) esclarecem que o resfriamento por meio de ventilação natural será menos benéfico quando as mudanças climáticas tornarem os eventos de ondas de calor mais frequentes. Por sua vez, considerando o impacto das mudanças climáticas na incerteza do conforto térmico de usuários de escritórios, Breesch e Janssens (2010) mostraram que probabilidade de desconforto aumenta significativamente quando conjuntos de dados climáticos recentes (mais quentes) são considerados. Para reduzir o risco de superaquecimento, a ventilação natural noturna deve ser combinada com medidas adicionais, como ventilação mecânica ou estratégias de resfriamento passivo (troca de calor solo-ar e resfriamento evaporativo indireto, por exemplo). Zhang *et al.* (2021) ponderam que ventilação mecânica aumenta a resiliência, por outro lado, aumenta o consumo de energia.

De acordo com Rañeses *et al.* (2021), as estratégias de adaptação climática frequentemente listadas na bibliografia incluem estratégias passivas para melhorar o (ou reduzir o uso de) sistema de ar-condicionado (Dan *et al.*, 2016), a incorporação de conceitos de resiliência no projeto de edifícios (Charoenkit; Kumar, 2017) e o uso de tecnologias para melhorar o conforto térmico (Javad; Navid, 2019; Obrecht; Premrov; Leskovar, 2019; Rañeses *et al.*, 2021).

Makantasi e Mavrogianni (2016) identificaram que, sob um cenário de emissões elevadas, apartamentos sem ventilação podem superaquecer no clima de Londres; enquanto apartamentos com ventilação natural conseguem manter o período de superaquecimento em um nível aceitável. Além disso, os autores destacam a importância de as soluções construtivas serem executadas corretamente, uma vez que paredes com isolamento aplicado internamente,

combinadas com baixa ventilação, também podem resultar em uma maior probabilidade de superaquecimento; assim como o sombreamento pode reduzir o superaquecimento no verão, mas pode aumentar a demanda de aquecimento no inverno. Esses exemplos ilustram a importância da análise de desempenho em diversas condições climáticas, para o planejamento de medidas adaptativas (Rañeses *et al.*, 2021).

Embora exista uma necessidade urgente de soluções de resfriamento resilientes em edificações, com vistas a manter o conforto dos usuários (IEA-EBC, 2019), o desenvolvimento de pesquisas sobre resiliência associada às interações entre os seres humanos e a natureza ainda está em estágio exploratório, com poucos métodos práticos para aplicações no mundo real (Attia *et al.*, 2021). Segundo Attia *et al.* (2021) e Nelson *et al.* (2019), a maioria dos estudos investigaram o termo “resiliência” na escala urbana – no âmbito de problemas como furacões, inundações, terremotos – com menos foco na escala das edificações.

Em algumas pesquisas que avaliam a resiliência de edificações, métricas simplificadas típicas tem sido introduzidas no contexto da resiliência térmica com base em resultados de simulação, sendo que o risco de superaquecimento (Burman; Kimpian; Mumovic, 2014; Lomas; Porritt, 2017) e o índice de calor (Flores-Larsen; Filippín, 2021; Sun; Specian; Hong, 2020) são os mais utilizados no campo de mudanças climáticas e ondas de calor. De acordo com Homaei e Hamdy (2021), o principal problema apontado para essas métricas simplificadas é que elas precisam ser usadas na escala de uma zona térmica e não conseguem desdobrar a resiliência no nível do edifício, denominado resiliência térmica global, que considera todas as zonas do edifício. Para solucionar esse problema, Hamdy *et al.* (2017) introduziram um índice chamado grau de superaquecimento interno, que considera diferentes limites de conforto térmico dependendo da zona e leva em conta a intensidade e frequência de superaquecimento.

No sentido de propor parâmetros que permitam a caracterização da resiliência de edificações, Homaei e Hamdy (2021) desenvolveram um *benchmarking* de avaliação de resiliência térmica em relação às características do edifício (envelope e sistemas do edifício) e à ocupação, considerando casas norueguesas. Os resultados fornecem uma referência para os projetistas avaliarem a resiliência térmica do ambiente construído e constituírem medidas de aprimoramento.

Em relação às métricas de desempenho no campo das incertezas, por meio da aplicação de métodos estatísticos, Chaturvedi e Rajasekar (2022) definem que o desvio padrão relativo (RSD) de desempenho é um indicador fundamental de resiliência, pois um edifício com um RSD pequeno apresenta desvios de desempenho menores quando enfrenta mudanças

climáticas, físicas e operacionais. Este conceito é aprofundado na sequência deste trabalho, no item 2.2.2.1.

Os estudos da área se concentram na qualidade ambiental interna e nos problemas de superaquecimento. De modo geral, eles confirmam que as mudanças climáticas aumentam a frequência e a magnitude das ondas de calor, o que reforça a importância da resiliência como uma abordagem integral para o projeto e operação de edificações em termos de conforto ambiental, neutralidade de carbono e sustentabilidade (Attia *et al.*, 2021). Em síntese, destacam-se as seguintes recomendações da bibliografia para melhorar a resiliência de edificações:

- os projetos devem sempre ser testados em condições futuras extremas;
- uso de múltiplas intervenções passivas;
- integração de intervenções passivas com medidas ativas;
- busca por mais evidências (estudos) de projetos resilientes.

2.2 SIMULAÇÕES TERMOENERGÉTICAS DE EDIFICAÇÕES E ANÁLISE DE INCERTEZA

Existem duas metodologias estabelecidas para determinar o desempenho energético e ambiental de edificações: simulação baseada em física (transferência de calor) e regressão estatística ou inferência baseada em dados (Rysanek; Nuttall; McCarty, 2021). A abordagem de simulação envolve a estimativa de métricas de desempenho do edifício, como o uso de energia, estabelecendo processos de transferência de calor do ambiente construído em um modelo numérico de balanço de energia. Por sua vez, a previsão baseada em dados e a regressão estatística do desempenho do edifício tem recebido mais atenção ultimamente, como uma alternativa (ou complementação) à simulação de desempenho de edifícios. Essas abordagens estatísticas dependem da correlação de dados de consumo de energia, condições interiores do edifício, informações de ocupação e/ou dados meteorológicos (Castaldo; Pisello, 2018; Rysanek; Choudhary, 2013).

Segundo De Wilde e Tian (2009), o uso de simulações é adequado para analisar o comportamento futuro de edificações e quantificar os riscos para funções essenciais, como a produtividade e saúde dos ocupantes ou o consumo de energia. Além do mais, as simulações são úteis para quantificar os riscos que as mudanças climáticas representam para a resposta térmica das edificações, e que possam ajudar os projetistas a prepararem edificações para o futuro. As ferramentas de simulação têm sido utilizadas para analisar o desempenho de edificações e descrever padrões de uso de energia, visando beneficiar o projeto e a operação de construções energeticamente eficientes. No entanto, os programas de simulação, como o

EnergyPlus, consideram o comportamento térmico dinâmico do edifício como determinístico e ignoram as variações nas condições meteorológicas e outros fatores, como o comportamento dos ocupantes. Assim, a influência da aleatoriedade nos parâmetros do ambiente interno, como variação no calor interno e/ou infiltração de ar, por exemplo, torna-se bastante modesta (Brohus *et al.*, 2012).

Pratavia *et al.* (2022) esclarecem que a resposta térmica de um edifício e seu consumo de energia estão fortemente correlacionados a diversos fenômenos, como condições meteorológicas, propriedades dos materiais da envoltória, uso de sistemas de ar-condicionado, desempenho de equipamentos elétricos e seu padrão de uso. E tendo em vista que, raramente, todas as condições de contorno são conhecidas ou exatas, na prática podem ocorrer várias imprecisões nas simulações – não por incapacidade das ferramentas, mas pela natureza estocástica dos parâmetros.

Nota-se que uma limitação da modelagem de edificações é a incapacidade de exibir a incerteza associada às entradas do modelo e propagar essa incerteza para que os tomadores de decisão possam ver seus efeitos no desempenho. Booth, Choudhary e Spiegelhalter (2012) e Kavgić *et al.* (2010) consideram que a falha mais importante nos modelos é a falta de transparência e quantificação de incertezas inerentes. Igualmente, Pratavia *et al.* (2022) explicam que os principais desafios para a utilização eficaz de modelos de energia de edificações relacionam-se à incerteza nos seus parâmetros de entrada e na escassez de dados sobre o consumo de energia. Isso faz com que simulações determinísticas sejam pouco confiáveis, com abordagens de calibração impraticáveis para a maioria das cidades. Para contornar isso, uma solução consiste em aplicar métodos estatísticos para considerar o efeito das incertezas nos dados de entrada.

A análise de incertezas tem sido adotada em aplicações de simulações, proporcionando um quadro metodológico para caracterizar variações nos dados de entrada e avaliar a robustez e confiabilidade das simulações (Pratavia *et al.*, 2022). Para tanto, cumpre frisar que a parametrização e automatização no desenvolvimento e processamento dos modelos BEM é essencial, dada a necessidade de simulações exaustivas para a quantificação de incertezas. Tian *et al.* (2018) apontam que programas como o EnergyPlus, ESP-r, TRNSYS, SAP 2009, DOE-2, e VA 114 são aplicados nesse processo, enfatizando, contudo, o maior uso do EnergyPlus, devido ao formato de arquivo de dados de entrada (*Input Data File – IDF*) em código padrão americano para o intercâmbio de informação (*American Standard Code for Information Interchange – ASCII*); esse formato facilita edições nos parâmetros do modelo, por meio de linguagens de programação (Zhu *et al.*, 2022).

A precisão das simulações de desempenho termoenergético de edificações depende de muitas variáveis. Hosseini, Javanrood e Nik (2022) listam os três principais: (1) condições meteorológicas externas (Erba; Causone; Armani, 2017), (2) modelagem energética de edifícios (BEM, na sigla em inglês) (Menberg; Heo; Choudhary, 2016) e (3) modelagem urbana (Javanroodi; Mahdavinejad; Nik, 2018). Entender o impacto desses dados de entrada em simulações de edificações é uma tarefa complexa, pois envolve uma variedade de fenômenos físicos e estocásticos, desde condições meteorológicas até transferência de calor e comportamento dos usuários (Prataviera *et al.*, 2022).

A qualidade dos dados meteorológicos define a precisão da condição externa como a condição de contorno primária para o modelo. Dados meteorológicos típicos de um determinado local são comumente usados para simulações, representando as condições mais comuns ao longo de vários anos (geralmente 30 anos) (Hosseini; Javanroodi; Nik, 2022), apesar de essas informações diferirem dos dados observados ao longo do tempo (Tsoka *et al.*, 2017). Uma desvantagem do uso de dados típicos é que eles não conseguem abordar condições climáticas extremas (Crawley; Lawrie, 2015), e, segundo Nik (2016) e Nik, Perera e Chen (2021), isso se torna crítico quando o plano é aumentar a adaptação às mudanças climáticas.

Existe uma lacuna de conhecimento sobre o desempenho de edificações no futuro e as ferramentas de simulação podem contribuir para entender as condições futuras do ambiente construído, fornecendo uma compreensão geral do desempenho energético e térmico (Yassaghi; Hoque, 2019). Uma dúvida comum, que fomenta as pesquisas na área, é “quais são as estratégias mais eficazes para garantir a conservação de energia ou o conforto térmico?”. Para respondê-la, a análise de incertezas pode fornecer confiabilidade aos parâmetros de projeto que compõem as estratégias. Segundo Yassaghi e Hoque (2019), a incerteza da variabilidade climática pode ser descrita por meio de abordagens probabilísticas. Assim, o uso de técnicas estatísticas, associado às abordagens dinâmicas de avaliação de desempenho da construção, pode fornecer uma variedade de resultados possíveis levando em consideração as incertezas.

Os cenários futuros podem ser usados para lidar com a incerteza, explorando situações possíveis, ao invés de depender de considerações únicas (determinísticas). O setor de construção é acometido por uma escassez de dados de energia e clima medidos em alta acuidade, bem como previsões confiáveis das condições ambientais, especialmente durante eventos climáticos extremos, como explicam Hosseini, Javanrood e Nik (2022). Quanto mais incertos forem os dados de entrada, mais inconsistentes serão os resultados e as análises, o que pode causar discrepâncias de 30% a 100% no desempenho real do consumo de energia, conforme Ioannou e Itard (2015).

Vários estudos têm discutido a sustentabilidade ambiental e a mitigação das mudanças climáticas, no campo das edificações. Segundo Yang, Javanrood e Nik (2021), isso se deve aos principais desafios e incertezas associados à natureza do clima e seus comportamentos estocásticos, o que torna difícil prever o grau e a velocidade do aquecimento. Isso resulta em múltiplos cenários climáticos futuros e uma grande quantidade de dados, tornando essas avaliações de impacto dispendiosas. Além disso, a transferência lenta de conhecimento do campo da meteorologia (modelagem climática) para o da engenharia (desempenho de edificações) tem prejudicado progressos pragmáticos na área (Yang; Javanroodi; Nik, 2021).

Segundo De Wilde e Tian (2011), até meados de 2010, a maioria dos estudos sobre o tema possuíam uma natureza predominantemente determinística. A partir de 2011, estudos sobre as mudanças climáticas tiveram um avanço, por meio das primeiras projeções probabilísticas para variáveis climáticas, lançadas no Reino Unido, em 2009 (UKCP09) (Murphy *et al.*, 2009). O UKCP09 leva em consideração três tipos de incerteza: a variabilidade climática interna natural, a incerteza nos modelos climáticos e a incerteza nas emissões futuras (De Wilde; Tian, 2011). A variação nas incertezas climáticas ao longo do tempo e a diversidade de tipos de edificações e estratégias construtivas introduzem desafios significativos na análise e interpretação dos resultados das simulações (Nik; Mata; Kalagasidis, 2015). Essa complexidade pode resultar em decisões menos claras e mais sujeitas a equívocos, destacando a necessidade de desenvolvimento de métodos que levem em conta essas incertezas.

Nesse contexto, o projeto de edificações de alto desempenho tem sido questionado quanto ao seu desempenho real em operação, onde o impacto de perturbações externas, como o comportamento dos ocupantes e o clima, provou ser proeminente. Essas fontes de variabilidade, denominadas incertezas aleatórias, são variações inerentes de sistemas não determinísticos. Uma das principais abordagens para lidar com essas incertezas é considerá-las como uma perturbação durante a fase de projeto, de modo que o objetivo seja alcançar uma solução cujo desempenho seja menos vulnerável. O primeiro passo em direção à proteção contra a incerteza de clima é identificar as condições climáticas que um edifício pode enfrentar durante sua vida útil (Moazami; Carlucci; Geving, 2019).

A preparação para o futuro envolve testar soluções construtivas em relação a uma variedade de futuros plausíveis, para garantir que as construções permaneçam funcionais ao longo do ciclo de vida, evitando reformas disruptivas ou desocupações prematuras e onerosas. Cumpre destacar, no entanto, que o objetivo não é projetar uma obra assumindo que as previsões sobre cenários futuros sejam 100% confiáveis, mas sim ter um processo que garanta uma reflexão sistemática sobre cenários estimados e levar isso em conta nas tomadas de

decisões. Georgiadou, Hacking e Guthrie (2012) listam quatro tipos principais de abordagens para o projeto de edificações, variando desde métodos convencionais e financeiramente viáveis até estratégias mais avançadas que incorporam uma gama mais ampla de considerações futuras:

- Tipo Direto: Considera o estado atual das coisas, envolvendo processos convencionais e estreitamente focados para a construção de edificações de baixo custo e baixo consumo de energia, sem consideração significativa para o pensamento futuro.
- Tipo Orientado para o Ciclo de Vida: Promove o pensamento ao longo do ciclo de vida, considerando a energia operacional, a longevidade do projeto e o uso de métodos estabelecidos de avaliação de ciclo de vida e análise de custo do ciclo de vida.
- Tipo Orientado para a Incerteza: Demonstra um projeto de energia que vai além do atual quadro político, melhorando a adaptabilidade para permanecer funcional a longo prazo. Utiliza modelos dinâmicos e explora futuros plausíveis, com exemplos divididos em resiliência contra o superaquecimento e adaptabilidade às mudanças nas circunstâncias, tanto na estrutura da construção quanto nas necessidades e preferências dos usuários.
- Tipo Abrangente: Visa combinar todos os critérios de projeto, integrando ferramentas separadas para considerar tanto o pensamento ao longo do ciclo de vida quanto o ajuste de riscos e incertezas. Enfatiza a necessidade de pesquisas adicionais para desenvolver ferramentas integradas capazes de acomodar um espectro mais amplo de critérios de projeto.

As melhores soluções construtivas podem ser diferentes se avaliadas com dados climáticos presentes e futuros; no entanto, De Masi *et al.* (2021) esclarecem que ainda há poucos artigos que propõem essa análise. Para encontrar soluções capazes de mitigar os efeitos das condições climáticas, a sensibilidade da intervenção construtiva deve ser investigada, levando em consideração diferentes climas e o estoque de edificações. Além disso, é importante considerar o efeito de eventos extremos e não apenas mudanças de longo prazo, a fim de evidenciar melhores estratégias de eficiência energética.

2.2.1 Fontes de Incerteza

A incerteza pode ser dividida, basicamente, em duas categorias: incerteza epistêmica ou epistemológica (incluindo o erro, classificado como uma incerteza independente no referencial descrito no item A.2 do Apêndice A), devido à falta de conhecimento, informações incompletas ou imprecisões nas informações – pode ser quantificada ou eliminada pela coleta de mais informações (Swiler; Paez; Mayes, 2009); e incerteza aleatória (também chamada de

variabilidade, estocástica, irreduzível e incerteza do tipo A), causada por mudanças inerentes ou naturais – este tipo de incerteza não pode ser eliminado ou controlado, sendo necessários experimentos ou observações adicionais para sua caracterização (Fonseca; Nevat; Peters, 2020; Helton, 2009; Pastor *et al.*, 2020).

Tanto a incerteza epistêmica quanto a aleatória são fundamentais na análise energética de edificações (Tian *et al.*, 2018), mas Wang, Mae e Taniguchi (2022) complementam que, comparada à incerteza epistêmica, a incerteza aleatória é mais difícil de ser reproduzida completamente e com precisão na fase de projeto e, por isso, é mais provável que cause lacunas de desempenho durante a fase de uso. Pode-se dizer, ainda, que a principal razão para lacunas de desempenho é que muitos fatores incertos, não abrangidos na fase de simulação, afetam o desempenho do ambiente construído durante a fase de operação (Tian *et al.*, 2018).

A possibilidade de um ambiente confortável para os ocupantes é influenciada por diversos elementos de projeto, tais como as características da envoltória, os sistemas de condicionamento de ar, as cargas internas e as condições ambientais externas, como relaciona-se no Quadro 10 (Cetin; Manuel; Novoselac, 2016). Estes fatores podem variar consideravelmente entre diferentes edificações, atuando como fontes de incerteza importantes para o desempenho do ambiente construído; eles também exercem impacto nas cargas instantâneas e no consumo energético das edificações.

Quadro 10 – Principais variáveis fontes de incerteza e seus efeitos no ambiente construído

Parâmetros de projeto	Variáveis	Efeitos no ambiente construído quando as variáveis aumentam
Condições climáticas	Temperatura do ar externo (°C)	Aumento nos ganhos internos de calor (temperatura)
	Umidade do ar externo (%)	Aumento na umidade interna
	Radiação solar (W/m ²)	Aumento nos ganhos internos de calor (temperatura)
Cargas internas	Ocupação, equipamentos, iluminação, aquecedores de água (W)	Aumento nos ganhos internos de calor (temperatura) e/ou umidade
Envoltória	Taxa de trocas de ar (m ³ /h)	Aumento na entrada de ar externo no interior da edificação
	Transmitância térmica de janelas, portas, paredes, piso, cobertura (W/m ² K)	Aumento na transferência de calor entre as condições internas e externas
	Capacidade térmica (kJ/m ² K)	Aumento do efeito dos ganhos de calor solar (temperatura) para o interior
	Área de janela/sombreamento (%)	Diminuição e atenuação do efeito das condições externas sobre as condições internas
HVAC	Temperatura de esfriamento/aquecimento (°C)	Aumento/diminuição da temperatura interna
	Temperatura do termostato (°C)	Aumento da variação de temperatura permitida acima/abaixo do <i>setpoint</i>
	Capacidade do sistema (kW)	Aumento da capacidade de remoção de calor interno

Fonte: o autor; adaptado de Cetin, Manuel e Novoselac (2016)

Prataviera *et al.* (2022) relatam que as pesquisas iniciais envolvendo análise de incertezas se concentravam em fontes de incertezas na simulação da edificação em diferentes condições, e incertezas relacionadas às propriedades do envelope da edificação, tais como transmitância e capacidade térmica, absorptância solar, emissividade etc. Os trabalhos mais recentes também têm se preocupado sobre a incerteza das condições climáticas futuras; para analisar as incertezas nos dados meteorológicos, geralmente, usam-se vários arquivos climáticos, obtidos a partir de dados históricos e/ou diferentes locais.

Wang, Mae e Taniguchi (2022) destacam que a incerteza aleatória das condições climáticas (dados meteorológicos) afeta significativamente o desempenho térmico e energético de edificações, o conforto térmico dos usuários e a eficiência da geração de energia solar, por exemplo, gerando discrepâncias entre o desempenho real e os valores simulados (Chaturvedi; Rajasekar, 2022). Convém compreender que a incerteza climática não pode ser eliminada e é difícil quantificá-la com precisão devido ao comportamento complexo que o clima possui (Wang; Mae; Taniguchi, 2022).

Nesse sentido, Hong *et al.* (2013), em estudo sobre o impacto das condições climáticas no consumo de energia de edificações, observaram que o arquivo meteorológico do ano meteorológico típico (TMY) não é suficiente para representar as condições médias (30 anos) do conjunto real histórico de dados meteorológicos. Para resolver essa limitação, alguns estudos – além dos que utilizam ferramentas de progressão climáticas abordadas anteriormente – sugerem algumas técnicas, como a utilização de mais de um arquivo climático: Rodríguez *et al.* (2013) usaram três arquivos meteorológicos históricos para representar anos extremamente frios, médios e extremamente quentes; Sun *et al.* (2014) usaram 32 arquivos históricos; e Lee *et al.* (2012) desenvolveram um modelo estocástico com base na autoregressão vetorial para gerar um grande número de anos meteorológicos estocásticos a partir de dados meteorológicos históricos.

Para Chaturvedi e Rajasekar (2022), diante das fontes de incerteza, avaliar e relatar resultados de simulação sem intervalos de confiança oferece pouco valor científico. Os autores argumentam que as abordagens probabilísticas, como análise de incertezas e análise de sensibilidade, se mostram mais adequadas para compreender o desempenho energético, a partir de funções de distribuição de probabilidade para diferentes saídas do modelo, relacionando a variabilidade da saída às incertezas nos parâmetros de entrada. Essas abordagens são apresentadas no item a seguir.

2.2.2 Abordagens de Análise de Incertezas e Sensibilidade

Chaturvedi e Rajasekar (2022), Prativiera *et al.* (2022) e Tian *et al.* (2018) apresentam um panorama abrangente sobre análise de incertezas e sensibilidade na avaliação energética de edificações. Alguns conceitos descritos nos trabalhos dos autores são relatados a seguir.

A análise de incertezas na avaliação de desempenho térmico e energético de edificações é dividida em duas categorias: quantificação direta e quantificação inversa. A análise direta concentra-se em quantificar a incerteza nas saídas do sistema, propagada a partir de variáveis de entrada incertas por meio de modelos matemáticos. Já a análise inversa de incerteza determina variáveis desconhecidas a partir de dados conhecidos. Embora haja mais pesquisas com a análise direta, os dois métodos estão interligados, sendo a propagação direta essencial para a análise inversa (Tian *et al.*, 2018).

Segundo Chaturvedi e Rajasekar (2022), Prativiera *et al.* (2022) e Tian *et al.* (2018), a propagação de incertezas pode ser dividida em métodos probabilísticos e não probabilístico. As abordagens probabilísticas baseiam-se na teoria de probabilidade de forma rigorosa, desde que

haja dados suficientes, enquanto as abordagens não probabilísticas são desenvolvidas para lidar com a falta de informação ou dados. A propagação probabilística de incertezas pode ser ainda categorizada em métodos baseados em amostragem e não baseados em amostragem. Os métodos baseados em amostragem fazem parte dos métodos externos, tratando um modelo determinístico original como uma caixa preta e executando esse modelo determinístico com diferentes amostras várias vezes. Por outro lado, os métodos não baseados em amostragem incluem métodos de perturbação, equações de momentos, representações espectrais (métodos de Galerkin e Colocação) e equações diferenciais estocásticas clássicas. Tian *et al.* (2018) explicam que a vantagem da propagação de incertezas por meio de amostragem é a capacidade de manter dados de um modelo bem validado, apesar do maior custo computacional. Já a vantagem dos métodos não baseados em amostragem reside na capacidade de fornecer resultados de alta precisão e eficiência, embora exijam modificações extensas no código do sistema computacional para a propagação de incertezas.

No Quadro 11, esquematizam-se os métodos, subtipos e classificações de análise de incertezas identificados na literatura técnica. No âmbito da análise direta, três abordagens (baseada em amostragem com Monte Carlo, não amostragem e não probabilística) costumam ser consideradas, conforme o propósito e aplicação específica do projeto. No campo da análise inversa, recentemente, as pesquisas têm se concentrado na Estatística Bayesiana, dada a capacidade dos métodos Bayesianos inversos de aproveitar ao máximo as informações prévias sobre variáveis desconhecidas (Tian *et al.*, 2018).

Quadro 11 – Métodos de análise de incertezas aplicados ao desempenho de edificações

Quadro 11 – Métodos de análise de incertezas aplicados ao desempenho de barragens			
Método	Subtipos e classificações		
Análise direta	Probabilística	Baseada em amostragem	Monte Carlo unidimensional
			Monte Carlo bidimensional
			Amostragem incremental
		Sem amostragem	-
	Não probabilística	-	-
Inversa	Frequentista	-	-
	Bayesiana	-	-

Fonte: o autor; adaptado de Tian *et al.* (2018)

Geralmente, a análise de incertezas aplicada às simulações de desempenho térmico e energético de edificações segue uma abordagem probabilística para gerar uma ampla variedade

de condições que um edifício pode enfrentar, devido à dinâmica nas características climáticas, físicas e operacionais (Chaturvedi; Rajasekar, 2022; Pang *et al.*, 2020).

O método de Monte Carlo de amostragem aleatória é largamente aplicado na bibliografia, criando muitas amostras para as simulações de desempenho. A ideia do método Monte Carlo baseia-se em um algoritmo estocástico que gera amostras aleatórias, a partir de um conjunto de entrada predefinido, para um problema que não tem uma solução analítica. Retiram-se amostras arbitrariamente de todo o espaço de entrada; no entanto, ocorre aglomeração local e convergência lenta devido à seleção aleatória. A abordagem de Monte Carlo é a escolha predominante para a propagação de incertezas na avaliação do consumo energético de edificações. Isso se deve à sua natureza intuitiva e à facilidade de implementação quando comparada a outras técnicas de propagação de incertezas, como integração numérica fatorial completa, Galerkin estocástico e projeção discreta (Kim; Ahn; Park, 2014; Tian *et al.*, 2018; Yi; Braham, 2015).

Outras alternativas de amostragem incluem a aplicação do método de sequência de Sobol, que permite criar amostras discretas reduzidas e mais estáveis; de Monte Carlo 2D, que necessita de um número maior de simulações, mas pode separar o efeito das incertezas epistêmicas e aleatórias, aninhando duas amostragens de Monte Carlo, uma para o componente aleatório e outra para o epistêmico; e de Hipercubo Latino, para reduzir a carga computacional por meio de divisão de todo o espaço de entrada em vários intervalos iguais para selecionar amostras com igual probabilidade, garantindo estratificação imparcial e convergência mais rápida (Chaturvedi; Rajasekar, 2022; Pang *et al.*, 2020; Pratavia *et al.*, 2022; Tian, 2013).

2.2.2.1 Avaliação quantitativa de efeitos das incertezas climáticas no desempenho da edificação

Com a definição das variáveis de entrada, conforme a abordagem definida, todos os modelos aleatórios elaborados são simulados para a obtenção das variáveis de saída e para o desenvolvimento de funções de distribuição de probabilidade. De acordo com Chaturvedi e Rajasekar (2022), as funções de distribuição de probabilidade de saída permitem a estimativa da faixa de variação térmica e energética da edificação, que é um indicador útil para avaliar a resiliência de edificações. Ao consultar os resultados da análise de incerteza, os projetistas podem tomar decisões para que a edificação apresente variação mínima de desempenho sob cenários incertos (Chaturvedi; Rajasekar; Natarajan, 2020).

A avaliação de riscos das mudanças climáticas busca quantificar a incerteza no impacto das alterações no clima urbano futuro. As pesquisas atuais costumam adotar funções de densidade de probabilidade para descrever as principais incertezas nas mudanças climáticas, no desenvolvimento socioeconômico e na vulnerabilidade. O objetivo é modelar como as incertezas nas entradas podem se propagar para incertezas no desempenho (Ye *et al.*, 2021).

De acordo com Chaturvedi e Rajasekar (2022), os resultados da análise de incertezas possuem relevância para entendimento da resiliência do projeto da edificação por meio dos intervalos de confiança (IC) de saída e dos desvios padrão relativos (RSD). Segundo os autores, o RSD, particularmente, é um indicador de resiliência importante, pois uma edificação com um RSD pequeno apresenta desvios de desempenho menores quando enfrenta mudanças climáticas, físicas e operacionais (Chaturvedi; Rajasekar, 2022).

O IC, de 95%, para a demanda de energia anual e de pico para resfriamento é calculado como se demonstra na Equação (1). E, por meio da Equação (2), os valores percentuais para o desvio padrão relativo permitem avaliar a dispersão dos dados em torno do valor médio da saída (Chaturvedi; Rajasekar, 2022).

$$IC = UL_i - LL_i \quad \text{Equação (1)}$$

$$RSD = \frac{SD}{\bar{x}} \quad \text{Equação (2)}$$

Em que:

IC representa a amplitude do intervalo de confiança de 95%;

UL_i corresponde ao limite superior da i -ésima distribuição com 95% de confiança;

LL_i corresponde ao limite inferior da i -ésima distribuição com 95% de confiança;

RSD representa o desvio padrão relativo;

SD é o desvio padrão da i -ésima distribuição;

$\bar{x}$ é a média dos valores da i -ésima distribuição.

De acordo com Ye *et al.* (2021), há uma crescente de estudos que buscam técnicas mais sofisticadas para aprimorar a estimativa dos parâmetros de distribuição de variáveis incertas, como as Cadeias de Markov e Monte Carlo via Cadeias de Markov. Ao considerar as características de variação temporal e saltos da incerteza, tem-se uma aproximação do comportamento real de eventos climáticos, facilitando uma quantificação mais realista dos riscos (Ye *et al.*, 2021), visto que esses modelos mais avançados destacam-se pela eficiência ao

lidar com amplas dimensões de espaço incerto e simular eventos de probabilidade pequena, como extremos climáticos (Song; Wang, 2016).

2.2.2.2 Análise de incertezas por meio de técnicas bayesianas

A análise de incertezas inversa, ou calibração de modelo, calcula os parâmetros de entrada incertos a partir de dados de saída fornecidos. A aplicação do método se dá por meio de diferentes técnicas de otimização de probabilidade, visando minimizar a discrepância entre dados medidos e simulados (Prataviera *et al.*, 2022). Percebe-se na bibliografia que as técnicas bayesianas têm ganhado destaque crescente na estimativa de parâmetros desconhecidos em modelos de energia de edificações (Tian *et al.*, 2018; Fonseca; Nevat; Peters, 2020; Ma *et al.*, 2021; Wang; Mathew; Pang, 2021; Booth; Choudhary; Spiegelhalter, 2012; Heo; Choudhary; Augenbroe, 2012).

Langevin, Wen, Gurian (2013) implementaram modelos de regressão linear bayesiana com diferentes métodos de amostragem para prever distribuições de sensação térmica de sete pontos, aceitabilidade e preferência para ocupantes de escritórios. Wong, Mui e Cheung (2014) utilizaram a técnica para analisar respostas de conforto térmico dos ocupantes e compará-las com as previsões do modelo de Fanger. Wang e Hong (2020) também utilizaram a mesma técnica para aproximar faixas de temperatura de conforto e investigar *setpoints* adequados no termostato de escritórios. Ma *et al.* (2021) aplicaram um algoritmo de Rede Neural Bayesiana (BNN) para construir um modelo preditivo das preferências térmicas dos ocupantes usando o Banco de Dados Global de Conforto Térmico ASHRAE II.

De acordo com Tian *et al.* (2018), a quantificação inversa de incertezas desempenha um papel importante na análise de desempenho de edificações, ao inferir parâmetros de entrada desconhecidos com base em dados conhecidos. Os métodos estatísticos utilizados para essa quantificação inversa são governados pela equação fundamental apresentada na Equação (3) (Smith, 2013; Tian *et al.*, 2018).

$$E=f(x, \theta) + \delta + \varepsilon \quad \text{Equação (3)}$$

Em que:

E representa as observações reais, como os dados termoenergéticos da edificação;

x são os parâmetros conhecidos;

- θ são os parâmetros desconhecidos;
- $f(x, \theta)$ indica as saídas do modelo geradas pelas simulações;
- δ captura as discrepâncias entre o desempenho previsto e o real da edificação;
- ε representa os erros de medição.

A análise de incertezas inversa por meio de Estatística Bayesiana explora informações prévias (dados de saída fornecidos), e a otimização é orientada pela verossimilhança entre os resultados do modelo e as funções de distribuição de probabilidade disponíveis (Lim; Zhai, 2018; Prata-viera *et al.*, 2022; Ma *et al.*, 2021); isso proporciona resultados mais realistas, mas exigem maior esforço computacional (Tian *et al.*, 2018). As distribuições anteriores são atualizadas por meio do teorema de Bayes, descrito na Equação (4), onde a probabilidade de as observações coincidirem com as previsões do modelo orienta o processo de atualização. Esse procedimento de atualização combina o conhecimento prévio com as novas informações observadas, resultando em distribuições posteriores aprimoradas dos parâmetros desconhecidos (Tian *et al.*, 2018).

$$P(\theta|D) = \frac{P(D|\theta) \times P(\theta)}{P(D)} \quad \text{Equação (4)}$$

Em que:

- θ representa um conjunto de parâmetros que precisam ser calibrados;
- D representa o conjunto de dados usados para a calibração dos parâmetros;
- $P(\theta|D)$ denominada distribuição posterior, resume as quantidades de incerteza nos valores dos parâmetros que melhor explicam os dados observados;
- $P(D|\theta)$ expressa a probabilidade de o conjunto de dados observado D ser dado por uma configuração diferente de θ ;
- $P(\theta)$ representa uma distribuição prévia sobre θ , e essa distribuição representa o conhecimento sobre como os dados são gerados;
- $P(D)$ normaliza a distribuição posterior com uma densidade de probabilidade válida.

Tian *et al.* (2018) destacam que, como distribuições posteriores não podem ser derivadas analiticamente para modelos de energia de edificações, métodos de Monte Carlo via Cadeias de Markov (*Markov Chain Monte Carlo* – MCMC) têm sido empregados para aproximar distribuições de probabilidade posteriores teóricas, gerando amostras aleatórias através do

espaço de parâmetros. Dessa maneira é possível aproveitar os dados de energia disponíveis, aprimorando a confiabilidade do modelo de estoque de edificações e alcançar resultados mais confiáveis (Tian; Choudhary, 2012; Tian *et al.*, 2015; Tian *et al.*, 2018).

Percebe-se, ainda, que os métodos convencionais, que adotam apenas abordagens determinísticas, possuem menor capacidade de contribuir para o projeto de edificações, e a abordagem bayesiana surge como uma ferramenta interessante para suprir essa deficiência (Ma *et al.*, 2021).

Com relação à amostragem, o tamanho da amostra dificulta a interpretação dos resultados dos testes de significância clássicos da Estatística Frequentista em termos das estimativas de parâmetros de interesse do pesquisador (Nelson; Kim, 1993; Raudys; Jain, 1991; Royall, 1986). Os modelos preditivos estabelecidos com base em amostras escassas podem depender muito do método de estimativa escolhido (Fan; Thompson; Wang, 1999; McNeish, 2016). Nesses casos, a abordagem probabilística é geralmente preferida à determinística (Du *et al.*, 2020; Gao *et al.*, 2022; He; Chen; Guan, 2020; Melchers; Beck, 2018; Winkler, 1971; Zhou *et al.*, 2021), merecendo destaque a inferência bayesiana. A regra de Bayes fornece um dispositivo matemático consistente e racional para incorporar informações relevantes de conhecimento prévio para inferência probabilística, conhecidas popularmente como *prioris* informativas.

Assim, independente de qual seja a razão das amostras reduzidas, é possível valer-se da abordagem bayesiana para realizar a inferência e estimar o parâmetro de interesse com eficácia. Isso porque a disponibilidade de *prioris* informativas na inferência bayesiana acaba por dispensar um grande volume de dados para a quantificação de incertezas, uma vez que a influência que a amostra exerce sobre a *posteriori* é proporcional ao seu tamanho (van de Schoot; Miočević, 2020).

2.2.2.3 Análise de sensibilidade

Embora intimamente relacionadas, a análise de sensibilidade distingue da análise de incerteza. A análise de incertezas concentra-se na avaliação da variação de saída derivada da incerteza de entrada (incerteza direta) ou na obtenção de incerteza de entrada a partir de dados conhecidos (incerteza inversa). Já a análise de sensibilidade permite a identificação dos parâmetros de entrada que controlam a maior variação de saída, ou seja, indicam os parâmetros de entrada que possuem maior influência nos parâmetros de saída. Com isso, os projetistas podem focar nesses parâmetros mais influentes para decisões projetuais otimizadas (Heiselberg

et al. 2009). Tian (2013) e Tian *et al.* (2018) explicam que os métodos de análise de sensibilidade são divididos em abordagens de análise local e análise global.

A análise de sensibilidade local é focada nos efeitos pontuais de uma variável apenas, mantendo-se as outras fixas. Esse tipo de investigação caracteriza a abordagem *one-at-a-time* (OAT) na simulação, na qual um objeto do modelo é variado por vez. Essa abordagem é mais rápida, porém explora regiões limitadas dentro do espaço de entrada total. Ademais, os métodos locais assumem uma relação linear entre entradas e saídas e ignoram correlações de entrada (interação entre as variáveis); por isso, a análise local é inadequada para avaliar modelos termoenergéticos de edificações (Chaturvedi; Rajasekar, 2022; Sun, 2015). As abordagens estatísticas que lidam simultaneamente com o conjunto completo de incertezas nos parâmetros em uma única simulação (análise global), como aquelas que utilizam Monte Carlo, são mais adequadas (Song; Wang, 2016).

Por sua vez, a análise de sensibilidade global é focada nos efeitos totais das variáveis em todo o espaço amostral do modelo, por meio de combinações simultâneas entre si, fazendo com que o método seja mais confiável. A análise de sensibilidade global pode ser realizada usando métodos de regressão (*Standardized Regression Coefficients* – SRC; *Standardized Rank Regression Coefficient* – SRRC), triagem (Morris), variância (*Fourier Amplitude Sensitivity Test* – FAST; Sobol) e meta-modelagem (*Multivariate Adaptive Regression Splines* – MARS; *Adaptive Component Selection and Smoothing Operator* – ACOSSO; *Support Vector Machine* – SVM) (Chaturvedi; Rajasekar, 2022; Tian, 2013; Tian *et al.*, 2018).

2.2.2.4 Contribuições envolvendo análise de incertezas e mudanças climáticas

Neste item e em seus subitens, destacam-se contribuições científicas relacionadas às análises de incertezas e mudanças climáticas, relatando-se as principais considerações e os principais resultados notados nos trabalhos selecionados na revisão sistemática.

É consenso na literatura científica que as preocupações e os esforços de pesquisa abrangendo incertezas em análises de desempenho de edificações são necessários. Adicionalmente, as mudanças climáticas compõem um fator adicional nesse sentido, contribuindo para as limitações em modelos de edificações. Essas limitações são agrupadas em cinco áreas distintas, segundo Booth, Choudhary e Spiegelhalter (2012):

- Precisão: a capacidade de modelar com precisão os processos reais que definem o consumo de energia é limitada. Os modelos, embora mais flexíveis, não atingem total precisão,

e os modelos estatísticos, embora mais precisos, têm menos flexibilidade em suas capacidades preditivas.

- Coleta de dados: a quantidade de dados necessários para os modelos estatísticos pode ser desafiadora. Ao mesmo tempo, modelos completos de engenharia urbana demandam um processo demorado de coleta de dados.

- Tempo computacional: modelos que buscam simular processos dinâmicos de transferência de energia demandam maior esforço computacional. Modelos em estado quase-estacionário oferecem uma alternativa para reduzir o tempo de processamento, mas isso pode impactar a precisão.

- Tomada de decisão: a incapacidade dos modelos comuns de propagar incertezas limita a capacidade de mostrar aos projetistas o impacto dessas incertezas.

- Flexibilidade: modelos estatísticos têm menos flexibilidade ao avaliar reformas, pois dependem muito de dados históricos para formulação. Para implementar políticas eficazes de demanda de energia, é necessário contar com modelos capazes de incorporar incertezas.

Para contornar as limitações relacionadas, sobretudo no que se refere à tomada de decisão e flexibilidade, Booth, Choudhary e Spiegelhalter (2012) examinaram fontes de incerteza envolvidas em modelos de estoque habitacional. Eles propuseram uma abordagem integrada, utilizando análise probabilística de sensibilidade e calibração bayesiana, como um método promissor para quantificar a incerteza (Booth; Choudhary; Spiegelhalter, 2012).

Nik e Kalagasidis (2013) alegam que a relevância das fontes de incerteza climática nos resultados de simulação energética, levando em consideração variações tanto nas médias quanto nos desvios-padrão, segue a seguinte ordem: modelos climáticos globais (*Global Climate Models* – GCM), modelos climáticos regionais (*Regional Climate Models* – RCM), cenários de emissões, e as condições iniciais do clima. Além disso, concluíram que a estratégia primordial de resfriamento para as edificações residenciais existentes em Estocolmo deveria ser o resfriamento natural; considerando, ainda, que as decisões finais acerca da implementação de sistemas de resfriamento mecânico dependem de regulamentações futuras, adoção de medidas eficientes de energia, condições humanas e adaptabilidade.

Nik (2016) destaca algumas abordagens de pesquisa sobre as incertezas devido às mudanças climáticas, que combinam fatores importantes. Zhou *et al.* (2014) estudaram as incertezas relacionadas às mudanças climáticas e políticas, e ao crescimento populacional e do PIB ao modelar os efeitos das mudanças climáticas nas demandas de energia de edificações nos Estados Unidos; eles mostraram que os efeitos e as incertezas associadas não se limitam ao desempenho energético das construções, mas se estendem aos sistemas de energia e

infraestrutura. Analogamente, Mirasgedis *et al.* (2007) avaliaram a sensibilidade às mudanças climáticas e à socioeconomia da demanda de eletricidade no sistema grego; os autores destacaram que o que é mais preocupante nas mudanças climáticas, em termos de infraestrutura, é o aumento na variabilidade sazonal de consumo. Ahmed, Muttaqi e Agalgaonkar (2012) utilizaram um modelo baseado em regressão para analisar a demanda futura de eletricidade induzida pelo clima em Nova Gales do Sul, Austrália, estimando que a demanda per capita, associada apenas às mudanças climáticas, no verão e na primavera pode aumentar em 6,14% e 11,3%, respectivamente, em 2100.

Em cenários de incertezas e mudanças tecnológicas, econômicas e demográficas, Fonseca, Nevat e Peters (2020) consideraram previsões para diferentes cenários climáticos nos Estados Unidos, para lidar com a incerteza aleatória. No que diz respeito à incerteza epistêmica, analisaram as máximas discrepâncias possíveis entre as estimativas de modelos matemáticos desenvolvidos. A partir das estimativas da pesquisa e de seus intervalos de credibilidade, os autores concluíram que as edificações comerciais em climas quentes e úmidos devem ser priorizadas nas iniciativas climáticas do setor de edificações nos Estados Unidos. Segundo os autores, edificações de cidades em zonas climáticas quentes e úmidas podem experimentar as maiores taxas de crescimento no consumo de energia, enquanto edificações de cidades em climas frios podem ter um decréscimo.

Yang, Javanrood e Nik (2021) realizaram um estudo dos impactos das mudanças climáticas no conforto térmico dos usuários e no desempenho energético de edificações residenciais europeias. Para considerar as incertezas climáticas e eventos extremos, consideraram um conjunto de dados climáticos de 90 anos (2010–2099). Os resultados sugerem que haverá uma necessidade maior de resfriar edificações no futuro e menos demanda por aquecimento; no entanto, existem diferenças de acordo com as localidades analisadas. As horas de desconforto aumentarão consideravelmente em cidades localizadas em zonas mais quentes, mas não serão afetadas de modo significativo em cidades localizadas em zonas mais frias. Além das mudanças de longo prazo, temperaturas extremas podem afetar consideravelmente as demandas futuras de energia, especialmente a demanda por resfriamento.

Chaturvedi e Rajasekar (2022) investigaram as limitações da abordagem determinística para análises de desempenho de edificações, ao compará-la com uma abordagem de simulação probabilística de incerteza e sensibilidade. Utilizando amostragem de hipercubo latino, foram geradas 15.000 configurações para avaliar os efeitos de incertezas climáticas, físicas e operacionais nas demandas anuais e de pico de resfriamento de uma edificação residencial localizada em uma região climática quente e seca. Em comparação com a simulação

determinística, as simulações probabilísticas tiveram variações na ordem de 0,22 a 2,17 vezes, na demanda anual de resfriamento, e 0,45 a 1,62 vezes, na demanda de pico de resfriamento.

2.2.2.5 Recomendações de projeto

O principal desafio abordado na bibliografia é projetar construções que sejam eficientes ao longo de sua vida útil, levando em consideração as condições climáticas atuais e futuras. Desde as primeiras pesquisas, observa-se que os efeitos das mudanças climáticas têm um impacto maior nas edificações em climas quentes, pois aumentam ainda mais o uso de energia para resfriamento. Para edificações em climas amenos/temperados, o uso de energia para aquecimento será trocado pelo uso para resfriamento (Crawley, 2008; De Wilde; Tian, 2011). Além disso, segundo Scott, Wrench e Hadley (1994), edificações menores são mais sensíveis às variações climáticas do que edificações maiores, que geralmente têm ganhos internos de calor mais elevados e uma relação área de envoltória e volume da edificação mais favorável – tornando-as menos suscetíveis às variações da temperatura externa (De Wilde; Tian, 2011).

De Masi *et al.* (2021) desenvolveram um estudo de caso residencial, por meio de simulações, em Benevento, Itália. Projeções climáticas foram geradas a médio prazo (década de 2050) e a longo prazo (década de 2080), considerando diferentes cenários de emissão. Com a projeção de longo prazo, os graus-dia de aquecimento reduzem 21%, enquanto os graus-dia de resfriamento mais do que dobram em comparação com a condição atual. Os resultados sugerem uma transição para um clima dominante de resfriamento.

Nik *et al.* (2016) pesquisaram 13 estratégias de reforma para os estoques residenciais em Estocolmo, Gotemburgo e Lund, na Suécia, considerando incertezas derivadas de cinco cenários climáticos futuros. Com base na análise realizada, observaram que é viável confiar em um único período de 20 anos (por exemplo, 2081–2100, ao invés de sete períodos de 20 anos para o intervalo de 1960–2100) para avaliar o desempenho relativo em várias escalas temporais, caso a diferença de desempenho entre uma edificação avaliada e uma de referência seja praticamente a mesma em qualquer período ou em qualquer outro cenário climático. Essa abordagem reduz o esforço computacional e tempo para pós-processamento e análise dos resultados das simulações.

Song e Wang (2016) selecionaram 15 parâmetros de edificações e ambientes urbanos (térmicos, hidrológicos, dimensionais e atmosféricos) para uma análise de incertezas usando uma abordagem com simulações de Monte Carlo e MCMC e definiram estratégias de mitigação para melhoria de desempenho do ambiente urbano, como: modificar a geometria do cânion

urbano, caracterizada pelo aspecto de altura de edifícios; modificar propriedades térmicas, como uso de telhados para refletir mais radiação solar; e acrescentar espaços verdes, como telhados verdes, para incrementar a evapotranspiração na área urbana. Os autores notaram que a implementação de telhados brancos emerge como método eficaz para reduzir a temperatura ambiental não apenas na camada superficial urbana, mas também na camada mista subjacente. Além disso, a modificação nos comprimentos de rugosidade ou propriedades térmicas dos telhados, como por meio de diferentes espécies de vegetação para telhados verdes ou uso de materiais porosos para telhados convencionais, também representa uma abordagem efetiva para reduzir as temperaturas ambientais urbanas.

Roshan, Oji e Attia (2019) revisaram recomendações bioclimáticas de projeto para dois períodos: 1986–2015 e 2020–2050. Os autores mostraram que o uso de estratégias de aquecimento diminuirá, enquanto o uso de estratégias de resfriamento aumentará, e definiram um gráfico bioclimático ajustado para o Irã, quantificando as medidas de adaptação às mudanças climáticas para reduzir o consumo de energia e evitar o superaquecimento. Eles concluíram que o uso de aquecimento e resfriamento passivos com energia solar é uma estratégia importante para o projeto de edificações atuais e futuras em diferentes cidades do Irã.

Tavakoli *et al.* (2022) estabelecem que o uso de ventilação pode ser uma opção muito eficiente em termos de energia; no entanto, é provável que não seja suficiente em vários locais do mundo. Assim, os ambientes mais vulneráveis, provavelmente, serão aqueles que adotam resfriamento por ventilação (ventilação natural). Como uma medida para lidar com os efeitos das mudanças climáticas, Thevenard (2010) recomenda que sejam somados 0,13 °C à temperatura de projeto para resfriamento, para cada 10 anos de expectativa de vida do sistema; sem alterações na temperatura de projeto para aquecimento (De Wilde; Tian, 2011).

Os resultados de Yaqubi *et al.* (2022) mostraram que os ganhos de calor solar pelas janelas, a superfície de contato de uma zona térmica com o ambiente externo e a orientação desempenham um papel significativo na vulnerabilidade ao superaquecimento no verão. Os autores também observaram que edificações localizadas em áreas com baixa densidade de construções no entorno podem ser ainda mais vulneráveis às temperaturas extremas de verão, em comparação com aqueles localizados em áreas urbanas densamente construídas, tendo em vista que recebem menos irradiação solar direta.

2.2.2.6 Considerações sobre os dados climáticos

Como descrito ao longo deste capítulo, as edificações costumam ser projetadas para atender a condições climáticas passadas, com arquivos TMY, que são obtidos por métodos que não incluem ondas de calor ou os efeitos de ilhas de calor (Lauzet *et al.*, 2018; Yaqubi *et al.*, 2022). Isso implica que os arquivos climáticos típicos criados a partir de registros históricos, coletados em estações meteorológicas rurais ou aeroportos, por exemplo, não são mais adequados para avaliar as edificações. A bibliografia demonstra que é necessário levar em conta as mudanças climáticas para projetar tanto as construções novas, quanto as medidas de melhoria energética das edificações existentes. Isso significa que a adoção de arquivos climáticos atualizados é um tópico importante em simulações.

Embora os arquivos TMY sejam aplicados para representar o comportamento climático típico de uma localidade, é necessário considerar uma faixa razoável de eventos climáticos extremos – que estão se tornando cada vez mais frequentes e intensos – que uma construção pode experimentar ao longo de sua vida útil. Além disso, as preocupantes mudanças climáticas obrigam os projetistas a considerarem o desempenho do ambiente construído sob uma perspectiva futura. No entanto, em muitos casos, os arquivos climáticos fornecidos em bancos de dados como o EnergyPlus (DOE. U.S., 2023), possuem dados que não representam as condições atuais e futuras (De Masi *et al.*, 2021). Em relação aos cenários de mudanças climáticas, a bibliografia sugere que o cenário RCP 8.5 abrange a previsão mais crível até meados do século 21, devido à falta de avanço significativo nas atividades de redução das emissões globais de gases de efeito estufa (Schwalm; Spencer; Duffy, 2020).

Segundo De Masi *et al.* (2021), a adequação dos arquivos climáticos adotados diz respeito não apenas ao período de referência disponível, mas também à metodologia usada para a sua elaboração. Estudos que abordaram métodos de obtenção de dados futuros foram analisados por Yaqubi *et al.* (2022) e são apresentados no Quadro 12, relacionando as principais conclusões conforme a diferença relativa na aplicação de Redução de Escala Empírico-Estatística (ESD) e Redução de Escala Dinâmica (DDS), explicados no item 2.1.2.

Quadro 12 – Principais conclusões em pesquisas que compararam os métodos DDS e ESD

Pesquisa	Principais conclusões
Moazami <i>et al.</i> (2019)	Arquivos climáticos gerados usando o método DDS, que levam em consideração condições climáticas típicas e extremas, são mais confiáveis para avaliar a robustez energética, no contexto das incertezas climáticas.
Ramon <i>et al.</i> (2019)	O método ESD é mais adequado para investigar o desempenho médio de energia em condições futuras, mas menos adequado para avaliar condições extremas; O método DDS pode ser usado para fins de avaliação tanto da média quanto das condições extremas.
Tootkabani <i>et al.</i> (2021)	Arquivos climáticos baseados em ESD têm operações relativamente semelhantes na previsão de conforto térmico e consumo de energia em edificações em comparação com arquivos climáticos baseados em DDS; O método ESD pode fornecer informações suficientes para realizar análises comparativas sobre variações de longo prazo no consumo de energia de edificações, mas inconsistências existentes dentro do método podem levar a erros significativos de previsão; O método DDS é mais confiável quando o objetivo do estudo é investigar e comunicar a resiliência das edificações às condições climáticas futuras.

Fonte: o autor

Narowski, Janicki e Heim (2013) propuseram a criação de dados climáticos extremos, chamados Anos Meteorológicos Atípicos (*Untypical Meteorological Years* – UMY), de modo a complementar as análises com dados TMY. A partir de simulações realizadas com os arquivos UMY e TMY, observaram diferenças máximas de 24% e 46% na demanda de energia para aquecimento e resfriamento, respectivamente. Crawley e Lawrie (2015) também propuseram uma metodologia para arquivos de anos climáticos extremos (*Extreme Meteorological Year* – XMY). O método proposto prevê a construção de vários anos extremos (pelo menos quatro) para seis variáveis meteorológicas, com base nos valores máximos e mínimos diários e máximos e mínimos horários em cada mês. Os autores sugerem que os projetistas devem usar arquivos climáticos típicos e com eventos extremos para avaliar a variabilidade do desempenho térmico e energético de edificações (De Masi *et al.*, 2021).

Nik (2016) sugere uma abordagem para avaliar o impacto das mudanças climáticas no desempenho energético de edificações, com base em três conjuntos de dados meteorológicos a partir das saídas de um ou mais RCM: ano típico reduzido (TDY), ano extremamente frio (ECY) e ano extremamente quente (EWY). O método foi aplicado para avaliar diferentes cenários climáticos futuros em um edifício de escritórios, em Genebra, e no estoque de edificações residenciais, em Estocolmo. O autor concluiu que uma combinação de conjuntos de dados típicos e extremos permite uma melhor distribuição de probabilidades das condições futuras.


Moazami *et al.* (2019) forneceram uma visão geral das principais abordagens para criar conjuntos de dados meteorológicos futuros com base em redução estatística e dinâmica de modelos climáticos e os testaram em 16 edifícios de referência ASHRAE, considerando o clima de Genebra, Suíça. A pesquisa mostra que, em comparação com as condições típicas, o aumento relativo na carga máxima de resfriamento pode chegar a 28,5% em condições extremas. Os autores concluíram que apenas os arquivos climáticos gerados por redução dinâmica, que levam em consideração condições típicas e extremas, são confiáveis para fornecer condições representativas para testar a robustez energética de edificações em condições de incerteza climática futura.

Yaqubi *et al.* (2022) analisaram a distribuição estatística mensal de variáveis climáticas e a presença de ondas de calor futuras, por meio da ferramenta UWG aplicada em dois arquivos climáticos. Conforme análise comparativa dos arquivos climáticos, eles observaram que a temperatura em um ano climático futuro típico, no futuro médio (2040–2070), provavelmente, não será tão intensa quanto a onda de calor de 2003, em Nantes. Os autores concluíram que é melhor usar dois arquivos climáticos e, pelo menos, dois indicadores de desempenho de superaquecimento para obter resultados confiáveis. Além disso, perceberam que o superaquecimento não está limitado a áreas densamente construídas, onde o impacto de ilhas de calor é maior; edifícios isolados, localizados em bairros pouco construídos também estão em risco.

2.3 SÍNTESE E DISCUSSÃO DA REVISÃO BIBLIOGRÁFICA SISTEMÁTICA

Com os trabalhos reunidos, esta revisão apresentou definições, métodos, contribuições, limitações e oportunidades de estudo de desempenho térmico e energético de edificações, especialmente em termos da incerteza associada às mudanças climáticas. Na Figura 15 sintetizam-se os principais tópicos desenvolvidos, conforme as abordagens e as etapas e os conteúdos de pesquisa observados nos trabalhos e, na sequência, discutem-se as percepções e contribuições para esta tese e para o aprimoramento de pesquisas futuras.

Figura 15 – Síntese do processo de pesquisa e avaliação dos trabalhos da revisão bibliográfica sistemática



Fonte: o autor

Na última década, o número de estudos publicados sobre mudanças climáticas aumentou significativamente, tendo sido acelerado em 2019 (Figura 1). Desde então, nota-se que o interesse nos efeitos das mudanças climáticas no desempenho térmico e energético de edificações está em ascensão. Os trabalhos abrangem várias disciplinas de arquitetura e engenharia civil, que cobrem conforto térmico, qualidade ambiental interna, resfriamento passivo, ventilação natural e eficiência energética.

De modo geral, as pesquisas se concentram na necessidade de estudos em diferentes condições ambientais, na análise do desempenho energético que as edificações terão em cenários futuros, e na definição de dados climáticos e métodos para simulações em climas futuros. Vários esforços de pesquisa confirmaram o impacto das mudanças climáticas no conforto térmico e na eficiência energética de edificações. Além disso, os estudos avaliaram e quantificaram alguns aspectos da resiliência de edificações e os métodos e parâmetros de desempenho se apresentaram como um tópico relevante.

As simulações computacionais são largamente aplicadas nas pesquisas, para entender como as variáveis de projeto impactam o desempenho das edificações, especialmente no que se refere ao conforto térmico e à eficiência energética. Essa abordagem usa ferramentas computacionais para criar modelos que simulam o desempenho da edificação em determinado local ao longo do tempo. Contudo, ressalta-se que realizar várias simulações para avaliar diferentes cenários é demorado, especialmente quando se quer considerar as incertezas nas variáveis de entrada que influenciam o desempenho da edificação (Cetin; Manuel; Novoselac, 2016).

Percebe-se que, durante as fases de projeto de uma edificação, a simulação de desempenho pode ser empregada para determinar uma medida de resiliência, otimizando as análises comportamento do ambiente construído em relação a diferentes cenários climáticos futuros (Brotas; Lafuente, 2014). Isso permite que projetistas e pesquisadores experimentem variações de projeto e operação e seu impacto no desempenho da edificação. No entanto, grande parte dos dados meteorológicos disponíveis são baseados em monitoramento em áreas que não são representativas da localização da edificação ou são baseados em medições antigas. Por isso, a adoção de dados meteorológicos adequados também possui considerável importância nas discussões, seja para comparações em análises de curto prazo, médio e longo prazo, ou como um ponto de partida para projeções futuras (De Masi *et al.*, 2021).

A bibliografia evidencia que as abordagens determinísticas clássicas, que dependem de um único arquivo climático para determinar o desempenho energético das edificações são

inadequadas, havendo-se a necessidade de empregar um conjunto diversificado de arquivos climáticos para representar possibilidades futuras (Yassaghi; Gurian; Hoque, 2020). Para tanto, os pesquisadores costumam adotar duas abordagens para avaliar o efeito das incertezas do clima: a primeira abordagem consiste em utilizar arquivos climáticos típicos e conjuntos de dados climáticos extremos de inverno e verão; e a segunda abordagem consiste em utilizar conjuntos de dados climáticos reais correspondentes a um período maior (cerca de 30 anos) (Chaturvedi; Rajasekar, 2022; Gaterell; McEvoy, 2005; Goffart; Mara; Wurtz, 2017; Hosseini; Lee; Vakili, 2017).

Adicionalmente, a bibliografia enfatiza que, em geral (seja no contexto das mudanças climáticas ou não), as análises determinísticas de desempenho térmico e energético de edificações oferecem confiança muito limitada. Como os modelos BEM envolvem muitos parâmetros de entrada, a incerteza introduzida por cada parâmetro pode invalidar todo o resultado da simulação. Portanto, a necessidade de quantificação de incerteza e identificação de fatores-chave de desempenho de edificações é bastante evidente (Zhu *et al.*, 2022); e as mudanças climáticas apresentam-se como um fator adicional à essa incerteza.

O uso de simulações de Monte Carlo para análise de incertezas é dominante na bibliografia. A combinação de muitas simulações aleatórias, geralmente por meio do EnergyPlus, consiste em uma técnica que fornece resultados interessantes para a previsão de desempenho de edificações diante das mudanças climáticas. A Estatística Bayesiana, geralmente com abordagem MCMC, também tem sido uma ferramenta que vem sendo bastante explorada em pesquisas recentes. Como descrevem Ma *et al.* (2021), a inferência bayesiana oferece uma abordagem natural para quantificar a incerteza ou estocasticidade na estimativa dos parâmetros do modelo, e pode ajudar a considerar o efeito de variáveis não observadas, incluindo fatores não quantificáveis que influenciam no desempenho do ambiente construído.

Dada as limitações relatadas sobre as análises de desempenho de edificações diante das mudanças climáticas, as pesquisas também sugerem que é necessário considerar as incertezas do clima futuro no desenvolvimento e atualizações normativas que visam estabelecer parâmetros de desempenho e maior eficiência nas construções (Yassaghi; Gurian; Hoque, 2020). Os parâmetros e as normas de desempenho térmico e energético de edificações são essenciais para regular a demanda energética, fornecendo orientações para a arquitetura, materiais e sistemas de resfriamento, conforme as condições climáticas e operacionais. Chaturvedi e Rajasekar (2022) argumentam que, em países em desenvolvimento, como Índia e

Brasil, por exemplo, onde grande parte das edificações ainda será construída, a implementação de orientações normativas é ainda mais importante.

As projeções climáticas oferecem uma visão do clima futuro, com base nas tendências atuais de emissões. No entanto, é importante compreender a natureza incerta dessas projeções e propagar essa incerteza para as simulações de edificações. Poucos estudos reproduzem a incerteza dos dados meteorológicos aplicados em simulações, e menos ainda propõem métodos ou parâmetros que reproduzam a variação e a distribuição de probabilidade da incerteza das variáveis. A maioria dos parâmetros normativos de desempenho energético de edificações atuais, que permitem verificações baseadas em simulação, não considera o efeito das incertezas no modelo. Os estudos da revisão mostram que ignorar os efeitos da incerteza pode resultar em diferenças significativas entre o desempenho predito e o real do ambiente construído (Chaturvedi; Rajasekar, 2022).

Desenvolver análises de incertezas e sensibilidade em estudos que envolve simulações computacionais é um meio de conduzir estimativas mais realistas, para tomadas de decisão mais assertivas. Adicionalmente, considerando-se a vida útil longa das edificações, esses procedimentos permitem que as edificações sejam mais resilientes, incorporando a variância no desempenho decorrente das mudanças climáticas. Essa incorporação de incertezas permite comparações de projeto sob condições esperadas e inesperadas, que caracterizam uma maneira de avaliar a resiliência do ambiente construído. E com a análise de sensibilidade é possível compreender a influência das variáveis do modelo para o desempenho de edificações em diferentes condições (Chaturvedi; Rajasekar, 2022).

2.3.1 O Estado da Arte e as Oportunidades de Pesquisa

A revisão bibliográfica permitiu relacionar algumas oportunidades de pesquisa sobre a importância de considerar as variações do clima, incluindo eventos extremos, ao avaliar as soluções futuras e o desempenho energético de estoques de edificações. Os estudos revelam que os eventos climáticos recentes levam a variações notáveis nas demandas de energia e cargas de pico em diferentes condições climáticas. Por isso, é necessário avaliar o desempenho térmico e energético e a resiliência climática de novas construções. A disponibilidade de dados climáticos de alta resolução auxilia na avaliação das demandas de energia no setor, sendo importante considerar as incertezas climáticas, múltiplos cenários e eventos extremos. Essas

avaliações abrangentes de impacto das mudanças climáticas são essenciais para estabelecer as bases para transições energéticas sustentáveis (Yang; Javanroodi; Nik, 2021).

Tavakoli *et al.* (2022) ponderam que, embora a vulnerabilidade e a resistência de edificações de baixo consumo de energia tenham sido investigadas, mais pesquisas são necessárias em relação à robustez e à capacidade de recuperação de estratégias de resfriamento por ventilação. Também há falta de dados para essas estratégias em edificações de baixo consumo de energia para verificar e apoiar melhorias nas práticas de projeto e regulamentações de construção.

A integração da bibliografia sobre abordagens de quantificação de resiliência e parâmetros de desempenho térmico de edificações demonstra a importância da quantificação de resiliência com um conjunto apropriado de métricas. No entanto, pouco progresso foi feito no desenvolvimento de métricas que capturem a resiliência das construções diante dos eventos climáticos previstos (Homaei; Hamdy, 2021). As métricas devem ajudar na comparação de diferentes projetos do ponto de vista da resiliência de maneira mais informativa e fácil de entender. Homaei e Hamdy (2021) desenvolveram estudo nesse sentido, porém ainda se observa a necessidade de mais avanços na área.

Também se relaciona a busca por ajustes e estratégias que garantam ‘riscos aceitáveis’ de superaquecimento e demandas energéticas ‘aceitáveis’, mesmo diante do esperado aumento de temperatura até o final do século XXI. Convém mencionar que a busca por parâmetros compreendidos pelo termo ‘satisfatório’, ao invés de ‘ótimo’ (no sentido de ‘otimização’), são discutidos como mais adequados, pois na prática, frequentemente há critérios complementares e subjetivos no projeto de edificações (como sua aparência), e é mais razoável regulamentar a exigência de um padrão ou requisito ‘aceitável’ ou ‘mínimo’ do que ‘ótimo’ ou ‘excelente’ (Baker; Challenor; Eames, 2021).

Embora exista uma bibliografia razoável sobre os impactos das mudanças climáticas no desempenho energético de edificações, juntamente com estratégias para mitigar o consumo energético, há uma lacuna no estudo do consumo de energia em edificações sob as mudanças climáticas, especialmente quando se lida com dados climáticos limitados (Yassaghi; Gurian; Hoque, 2020). E, ainda que exista literatura técnica dirigida a esta limitação, a natureza incerta do clima demanda mais estudos que verifiquem os resultados nessas condições estocásticas. Segundo Mohseni *et al.* (2022), a maior parte dos artigos que quantificam as incertezas paramétricas associadas – examinando diferentes possibilidades para o modelo, geradas a partir de distribuições de probabilidade – aplica simulações de Monte Carlo clássicas. Nesse sentido,

os autores sugerem pesquisas futuras relacionadas à incerteza por meio da incorporação de técnicas bayesianas para a representação dos parâmetros incertos associados às distribuições de probabilidade.

Um desafio que persiste é desenvolver um modelo matemático que represente explicitamente o processo de propagação da incerteza em cenários de amplas incertezas e suas interdependências. Nesse sentido, uma maneira para aprimorar a quantificação do risco climático é pesquisar como integrar a análise de propagação de incerteza com modelagem numérica ou inteligência artificial. Essa quantificação e avaliação do risco induzido pelas mudanças climáticas são necessárias para que as cidades adotem ações de adaptação climática (Ye *et al.*, 2021).

Por último, cita-se a relevância de se considerar os efeitos do fenômeno da ilha de calor urbano juntamente com condições extremas em estudos futuros (Berardi; Jafarpur, 2020), e de se representar as expectativas térmicas futuras dos usuários de edificações, integrando a interferência humana (percepção dos usuários) para melhorar as condições do ambiente térmico. Essa é uma direção de pesquisa que vale a pena explorar para fornecer considerações sobre a interação humano-edifício que possam direcionar o projeto arquitetônico, além de impactar positivamente o consumo de energia e o bem-estar dos ocupantes do ambiente construído (Ma *et al.*, 2021).

2.3.2 Limitações da Revisão Bibliográfica Sistemática

Embora a investigação dos 141 trabalhos selecionados tenha contribuído muito para a elaboração do panorama abrangente descrito neste capítulo, situando o cenário sobre as mudanças climáticas e o desempenho térmico e energético de edificações, convém salientar que esta revisão também tem limitações. A busca e a análise focaram apenas nos efeitos das mudanças climáticas, especialmente o aumento da temperatura, e no desempenho térmico e energético de edificações. Também não especificou o tipo de edificação estudada ou o método de pesquisa adotado, e não incorporou nesta seção quaisquer análises específicas e detalhadas em cada uma das pesquisas.

Além disso, como disposto no início deste capítulo, os vieses no processo de revisão podem ter acarretado limitações no âmbito do conteúdo selecionado e explorado. O autor reconhece que existe uma ampla e rica literatura técnica abordando mudanças climáticas e edificações, incluindo livros, artigos, trabalhos de mestrado e doutorado, bem como medidas

orientativas e normativas, que podem não ter sido abarcados na revisão sistemática devido aos critérios de pesquisa adotados, ou podem ter sido ignorados por eventual falha nos critérios e na abordagem exploratória e descritiva do autor.

3 DESENVOLVIMENTO DO MÉTODO

De modo a estudar a variabilidade de desempenho térmico e energético de habitações de interesse social, considerando os efeitos das mudanças climáticas no Brasil, o desenvolvimento do método de avaliação de desempenho consiste na aplicação de análise de incertezas, considerando aspectos relacionados à resiliência, no nível edificação ao longo de sua vida útil.

Para elaborar o método, resultados da base de dados desenvolvida por Nunes (2021) são explorados. Conforme a pesquisa anterior, as informações de desempenho térmico e energético do ambiente construído foram estabelecidas de acordo com definições de simulações computacionais paramétricas com o EnergyPlus, em função de incertezas em variáveis de projeto e alterações no clima, de modo a identificar as variáveis termofísicas mais influentes para diferentes indicadores de desempenho, localidades (climas) e períodos climáticos.


As análises de incertezas desenvolvidas nesta tese abordam o clima de São Paulo, de acordo com três horizontes de tempo com condições climáticas distintas (curto, médio e longo prazo), obtidas com auxílio da ferramenta CCWorldWeatherGen. Este estudo avalia os dois indicadores de maior significância nas análises prévias e no contexto de elevação da temperatura, abrangendo situações sem e com uso de ar-condicionado: graus-hora para resfriamento (GHR) – desempenho sem ar-condicionado – e consumo energético com resfriamento (CR) – desempenho com ar-condicionado.

Na análise de incertezas, auxiliada por linguagem de programação R (R Core Team, 2024), além da quantificação da variabilidade de desempenho para diferentes períodos, estimativas de função de densidade de probabilidade são calculadas por meio de mecanismos de inferência bayesiana, aprimorando os resultados e a assertividade do estudo. E, de modo a propor parâmetros de avaliação de desempenho, são definidos quatro níveis de classificação, que ajudam na identificação de parâmetros de projeto mais adequados para melhores desempenhos, de acordo com o experimento conduzido.

O fluxograma do processo de desenvolvimento do método aplicado na tese é ilustrado na Figura 16. De modo resumido, para atender aos objetivos propostos, empregam-se simulações térmicas e energéticas de curto, médio e longo prazo, por meio do EnergyPlus, e simulações estatísticas, aplicando o método de Monte Carlo via Cadeias de Markov. No decorrer desta seção, são apresentadas as características do objeto de estudo, os climas

analizados, bem como procedimentos seguidos para o experimento e para as simulações computacionais e análises.

Figura 16 – Processo de desenvolvimento do método aplicado na tese



Fonte: o autor

Tendo em vista que a tese abrange e dá continuidade ao trabalho iniciado por Nunes (2021) – resumido no Anexo A – e às publicações associadas (Nunes; Giglio, 2020; 2021; 2022a; 2022b; Nunes *et al.*, 2023), alguns itens relacionados aos procedimentos metodológicos, tais como objeto de estudo, obtenção de dados climáticos futuros, e definições de amostragem e simulações computacionais são comuns às publicações citadas. Ainda que anteriormente descritos, para facilitar o entendimento independente desta pesquisa, todos os procedimentos metodológicos necessários para o desenvolvimento da tese são apresentados a seguir, com as devidas referências às publicações consolidadas.

3.1 CARACTERIZAÇÃO DA BASE DE DADOS

O desenvolvimento da tese tem como referência inicial a base de dados de simulações caracterizadas nesta seção. A seguir, apresentam-se os procedimentos metodológicos adotados para as simulações termoenergéticas (modelo, parâmetros e configurações de processamento/cálculo, ocupação, uso, cargas térmicas internas e sistemas de ventilação), e para a análise de incertezas frente às mudanças climáticas (parâmetros de ‘entrada’ e ‘saída’, e avaliação de desempenho, conforme indicadores estatísticos).

3.1.1 Objeto de Estudo


O desenvolvimento do método se baseia em um modelo unifamiliar de edificação residencial de interesse social. São consideradas variações em parâmetros termofísicos, simulando decisões projetuais diferentes para a habitação, e/ou requisitos de normas e regulamentações técnicas.

O modelo consiste em uma edificação que está situada no câmpus da Universidade Estadual de Londrina, sede do Laboratório de Eficiência Energética e Sustentabilidade em Edificações (E3SLab), do Departamento de Construção Civil. A edificação, adotada como referência de estudo por vários pesquisadores (Bortone *et al.*, 2018; Sanches, 2021; Santos, 2019; Zara, 2019; Zara; Santos; Giglio, 2018), foi construída em 2013, e possui aproximadamente 40 m², sendo dividida em uma sala integrada com cozinha, dois dormitórios e um banheiro. As paredes são construídas em *wood frame*, conforme a diretriz número 005 do Sistema Nacional de Avaliação Técnica (SINAT) (Brasil, 2011b) e o Documento de Avaliação Técnica (DATec) número 020, emitido em 2013 (IFBQ, 2013). O sistema de piso é composto

por um radier em concreto armado de 15 cm de espessura, coberto com cerâmica. O sistema de cobertura é formado, de fora para dentro, por telhas cerâmicas, estrutura em madeira, ático não ventilado, lã de rocha de 10 cm de espessura e forro de PVC. As janelas são formadas por caixilhos de alumínio com duas folhas deslizantes e vidro simples incolor de 3 mm de espessura, sem elementos de sombreamento (Nunes, 2021).

Na Figura 17, apresenta-se o modelo geométrico (planta baixa e corte transversal) adaptado como edificação residencial de referência neste projeto; a orientação solar indicada corresponde ao azimuth zero (a orientação solar teve variações de 90°, sendo que a referência inicial de orientação 0° é quando as janelas dos dois dormitórios estão para o norte). Todas as medidas da figura estão em metros.

Figura 17 – Planta baixa e corte transversal da edificação residencial adotada (medidas em metros)



Fonte: Nunes (2021); adaptada de Tecverde (2013)³


3.1.2 Clima Analisado

Nesta pesquisa, o conceito de mudanças climáticas é traduzido por meio de três horizontes representativos, de acordo a literatura técnica: 2020 (representa o horizonte de curto prazo, com o período de 2011 a 2040), 2050 (representa o horizonte de médio prazo, com o período de 2041 a 2070) e 2080 (representa o horizonte de longo prazo, com o período de 2071 a 2100) (Jentsch; Bahaj; James, 2012; Jentsch *et al.*, 2013). Na Figura 18, situa-se a cidade de

³ Acervo pessoal: projeto arquitetônico cedido pela empresa Tecverde. Outras informações sobre o projeto são descritas por Quiza (2013).

São Paulo, inserida no tipo climático Cwa (clima subtropical, conforme classificação climática mundial de Köppen-Geiger (Alvares *et al.*, 2013; Peel; Finlayson; McMahon, 2007).

Figura 18 – Mapa mundial da classificação climática Köppen-Geiger, e situação de São Paulo



Fonte: o autor; adaptada de Peel, Finlayson e McMahon (2007)

De acordo com a classificação da NBR 15220 (ABNT, 2005)⁴, São Paulo (23° 32' 56" S, 46° 38' 20" O, 745 m) está situada na zona bioclimática 3, que abrange 6,5% do Brasil – principalmente as regiões sul e sudeste, onde se concentra a maior parte da população (IBGE, 2022), justificando sua adoção na pesquisa –, possui um clima ameno, com verões quentes e úmidos, e invernos pouco secos e frios.

No item Anexo A.2, estão descritas as características climáticas de referência, conforme os arquivos TRY (Carlo; Lamberts, 2005; Goulart; Lamberts; Firmino, 1998) de São Paulo, bem como as progressões para os períodos 2020, 2050 e 2080, de acordo com o cenário A2 do IPCC. Os valores e algumas estatísticas descritivas da temperatura de bulbo seco, umidade relativa, radiação solar, e velocidade do vento de São Paulo estão no Anexo C.

Os arquivos climáticos futuros foram obtidos por meio da ferramenta CCWorldWeatherGen (versão 1.9) (University of Southampton, 2023), que permite produzir informações consolidadas, livres, e cientificamente aceitas, embora não considere,

⁴ Em processo de revisão.

especificamente, o último relatório de avaliação do IPCC (2021). Apesar de haver uma recente ferramenta (Future Weather Generator) atualizada para o último relatório do IPCC (Rodrigues; Fernandes; Carvalho, 2023), o uso do CCWorldWeatherGen foi mantido, considerando sua prévia validação e aplicação em etapas de pesquisas anteriores.

O CCWorldWeatherGen foi empregado para a obtenção de dados climáticos futuros dos três intervalos de tempo representativos: 2020 (2011–2040); 2050 (2041–2070); e 2080 (2071–2100), a partir do arquivo climático TRY. O uso do arquivo TRY é justificado pela premissa de progressão da ferramenta, considerando o uso de dados que represente o período de 1961 a 1990 – apesar de o TRY de São Paulo, estar um pouco fora do intervalo, os dados são anteriores ao intervalo definido, evitando superestimar as progressões. Detalhes sobre a metodologia que o CCWorldWeatherGen utiliza para a progressão dos arquivos meteorológicos podem ser consultados em seu manual de referência técnica (Jentsch, 2012).


3.1.3 Simulações de Desempenho Térmico e Energético

As simulações para obtenção do comportamento térmico e energético do ambiente construído, durante o ano todo, foram realizadas por meio do EnergyPlus (versão 9.3.0), programa gratuito e de código aberto, desenvolvido pelo Departamento de Tecnologias de Construção (BTO) do Departamento de Energia dos Estados Unidos (DOE) e gerenciado pelo Laboratório Americano de Energias Renováveis (NREL) (DOE. U.S, 2020). O EnergyPlus é caracterizado como a ferramenta de simulação termoenergética mais utilizada pela indústria da construção civil mundial (Kirimtat *et al.*, 2016), e foi adotado na pesquisa devido à sua ampla validação, capacidade de modelar sistemas e componentes avançados de edificações, e disponibilidade gratuita (De Wilde; Tian, 2012). A seguir descrevem-se os procedimentos e as definições considerados.

3.1.3.1 Modelo

A modelagem do objeto de estudo foi desenvolvida com auxílio do *plug-in Open Studio* (versão 2.9.1) inserido no SketchUp (versão 2017), técnica que proporciona uma interface visual para o EnergyPlus, como se ilustra na Figura 19. Cada ambiente da habitação objeto de estudo foi modelado como uma zona térmica, respeitando-se suas características geométricas e componentes construtivos.

Figura 19 – Modelo da habitação para as simulações computacionais



Fonte: o autor

Considerou-se a modelagem da construção isolada, explorando uma situação crítica de exposição ambiental sem sombreamento. Nesse sentido, Yaqubi *et al.* (2022) relatam que edificações localizadas em locais com baixa densidade de construções no entorno podem ser mais vulneráveis ao calor.

O modelo computacional foi calibrado e validado a partir da resposta térmica da construção real (E3SLab), analisando-se a temperatura horária dos ambientes de permanência prolongada durante um mês (23 de março de 2020 a 23 de abril de 2020), de acordo com Sanches (2021) e Sanches, Moro e Giglio (2021). O modelo final apresentou diferenças máximas de 0,26 °C, 0,25 °C e 0,22 °C para as temperaturas medidas e simuladas da sala/cozinha, dormitório 1 e dormitório 2, respectivamente (Sanches, 2021).

3.1.3.2 Definições de parâmetros e configurações do EnergyPlus

No Quadro 13, apresentam-se as definições de algoritmos, de modelagem, e de operação das simulações no EnergyPlus.

Quadro 13 – Definições de parâmetros e configurações computacionais

Definições	Parâmetros e configurações considerados
<i>Software</i>	EnergyPlus (versão 9.3.0)
Período de simulação	01 de janeiro a 31 de dezembro
Algoritmo de convecção externa	DOE-2
Algoritmo de convecção interna	TARP
Algoritmo de balanço térmico das superfícies	ConductionTransferFunctions
Algoritmo de balanço térmico do ar	ThirdOrderBackwardDifference
Número mínimo de <i>warmup days</i>	6
Número máximo de <i>warmup days</i>	25
Tolerância de convergência de carga	0,04 Watts
Tolerância de convergência de temperatura	0,40 $\Delta^{\circ}\text{C}$
<i>Timesteps</i> por hora	10
Distribuição dos raios solares	FullInteriorandExteriorwithReflections
Expoente de perfil de velocidade do vento no entorno da edificação	0,33
Espessura da camada limite do perfil de velocidade do vento no entorno da edificação	460 metros
Tipo de terreno	City
Tipo de edificação	Low-rise
Transferência de calor com o solo	Objeto <i>Site:GroundDomain:Slab</i> , a partir da correlação de Kusuda e Achenbach
Dados do solo	Solo argiloso [massa específica: 1.700 kg/m ³ ; calor específico: 840 J/kgK; condutividade térmica: 0,52 W/mK; teor de umidade natural: 30%; teor de umidade saturado: 50%]; entorno da edificação com calçamento


Fonte: o autor; elaborado a partir de ABNT (2005) e DOE (2015)

3.1.3.3 Definições de ocupação e uso, cargas internas e sistemas de ventilação

As definições de ocupação e uso, cargas internas e sistemas de ventilação da habitação seguem alguns parâmetros adaptados do método de simulação da proposta da INI-R (CB3E, 2018), NBR 15575 (ABNT, 2024) e de referências técnicas da ASHRAE (ASHRAE, 2017a; ASHRAE, 2017b; ASHRAE, 2023) e do DOE (2015).

Nas simulações, foram consideradas duas pessoas por dormitório, totalizando até quatro ocupantes na sala/cozinha; o padrão de ocupação dos ambientes de permanência prolongada é ilustrado na Figura 20. A taxa de metabolismo dos ocupantes, admitindo 1,8 m² de área de pele, foi 81 W/pessoa nos dormitórios (dormindo ou descansando) e 126 W/pessoa na sala/cozinha (de pé ou relaxado) (ASHRAE, 2017a; ASHRAE, 2017b), a fração radiante dos usuários (parte da taxa de metabolismo – calor sensível – dos ocupantes que se transforma em calor no ambiente) foi 0,6 (ASHRAE, 2017b) e a fração de calor sensível foi calculada pelo EnergyPlus.


Figura 20 – Rotina de ocupação da habitação para as simulações computacionais



Fonte: Nunes (2021); adaptada de CB3E (2018)

O sistema de iluminação artificial foi modelado com densidade de potência instalada de 5 W/m² nos dormitórios e na sala/cozinha, operando conforme acionamento apresentado na Figura 21; foi considerada iluminação do tipo sobreposta no teto, que acarreta fração radiante (radiação de onda longa) de 0,72 e fração visível (radiação de onda curta) de 0,18, como estabelecido pelo DOE (2015).

Figura 21 – Rotina de acionamento da iluminação da habitação para as simulações computacionais (0 significa desligada e 1 significa ligada)



Fonte: Nunes (2021); adaptada de CB3E (2018)

Também foi inserida uma carga interna de equipamentos na sala, com densidade de potência de 120 W constante, operando das 14:00 horas às 21:59 horas (ABNT, 2024); a fração radiante (parte da potência nominal do equipamento que se transforma em calor no ambiente), foi 0,50, segundo apontado pela ASHRAE (ASHRAE, 2017b).

No Quadro 14, apresenta-se um resumo dos parâmetros de fontes de calor para as simulações computacionais.

Quadro 14 – Parâmetros de fontes de calor para as simulações computacionais

Fontes de calor		Ambientes de permanência prolongada	
		Dormitórios	Sala
Pessoas	Ocupação	2 pessoas/dormitório	4 pessoas
	Taxa metabólica	81 W/pessoa	126 W/pessoa
	Fração radiante	0,6	0,6
Iluminação	Densidade de potência instalada	5,0 W/m ²	5,0 W/m ²
	Fração radiante	0,72	0,72
	Fração visível	0,18	0,18
Equipamentos	Densidade de cargas internas	–	120 W
	Fração radiante	–	0,5

Fonte: o autor; adaptado de ASHRAE (2017a; 2017b) e DOE (2015)

Com relação aos sistemas de ventilação, foram considerados dois modelos: o primeiro com ventilação exclusivamente natural, e o segundo com ventilação combinada com acionamento por ar-condicionado (híbrida), ou seja, ora natural, ora artificial, conforme se descreve nos itens 3.1.3.3.1 e 3.1.3.3.2, a seguir. Os dois sistemas de ventilação servem para analisar a resposta do ambiente construído em termos de conforto térmico, quando a habitação é naturalmente ventilada, e de consumo de energia, quando a habitação possui ventilação híbrida.


3.1.3.3.1 Sistema natural de condicionamento (ventilação natural)

O sistema de ventilação natural é operado conforme a temperatura do ar e ocupação dos ambientes, que controlam a abertura das janelas. Na rotina definida, de acordo com a ocupação dos ambientes de permanência prolongada, a ventilação natural é habilitada quando a temperatura do ar interno é igual ou superior a 19 °C (*setpoint*) e superior à temperatura do ar externo; as janelas da edificação estão fechadas quando não há ocupação (das 08:00 h às 14:00 h); das 14:00 h às 22:00 h, quando a sala está ocupada, os dormitórios também podem adotar o uso da ventilação natural; o banheiro está sempre com a janela aberta; as portas de todos os ambientes estão sempre fechadas (ventilação por frestas). O sistema de ventilação natural foi configurado por meio do parâmetro *AirflowNetwork* do EnergyPlus, que calcula o fluxo de ar entre as zonas térmicas e o exterior, a partir das frestas e janelas. Considerou-se o sistema de controle *MultiZoneWithoutDistribution*, coeficiente de pressão do vento calculado pelo programa, número máximo de iterações igual a 500, *ZeroNodePressures* como tipo de inicialização para o cálculo da ventilação, tolerância de convergência relativa igual a 0,0001,

tolerância de convergência absoluta igual a 0,000001 kg/s, e limite de aceleração de convergência igual a -0,5 (DOE. U.S., 2015; Nunes, 2021).


Nas Figuras 22 e 23, ilustram-se os fluxogramas dos algoritmos de controle da ventilação natural considerados para os dormitórios e para a sala/cozinha, respectivamente.

Figura 22 – Fluxograma do algoritmo de controle do sistema de ventilação natural para os dormitórios



Fonte: Nunes (2021)

Figura 23 – Fluxograma do algoritmo de controle do sistema de ventilação natural para a sala/cozinha



Fonte: Nunes (2021)

3.1.3.3.2 Sistema híbrido de condicionamento (ventilação natural combinada com uso de ar-condicionado)


As configurações do sistema foram feitas com o sistema de gerenciamento de energia (*Energy Management System – EMS*) do programa EnergyPlus, recurso que possibilita controles avançados nas simulações. O sistema de condicionamento de ar é operado conforme a temperatura dos ambientes e as condições limites de aceitabilidade de uso da ventilação

natural. O condicionamento artificial só funciona quando os ambientes estão ocupados (conforme Figura 20); e quando o sistema de condicionamento de ar é acionado, permanece ligado até o último horário de funcionamento do ambiente (até às 22:00 h para a sala, e até às 08:00 h para os dormitórios). A partir da temperatura interna de 26 °C (*setback*), o sistema de resfriamento é acionado, e a partir da temperatura interna de 16 °C (*setback*), o sistema de aquecimento é acionado; a temperatura do termostato de resfriamento é de 23 °C e a temperatura do termostato de aquecimento é de 18 °C (Nunes, 2021).

O sistema de ventilação natural foi configurado pelo parâmetro *AirflowNetwork* do EnergyPlus, seguindo as definições de cálculo apresentadas no Item 3.1.3.3.1; e para a modelagem e dimensionamento do sistema de ar condicionado foi utilizado o parâmetro *Packaged Terminal Heat Pump* (PTHP) do EnergyPlus instalado nos ambientes de permanência prolongada, considerando taxa de fluxo de ar de 0,0075 m³/s/pessoa, ventilador com 70% eficiência e motor com 90% de eficiência, coeficiente de performance (COP) de 3,50 W/W para resfriamento e para aquecimento, e dimensionamento da potência do sistema com coeficiente de 1,2, a partir dos dados anuais dos arquivos climáticos.


Nas Figuras 24 e 25, ilustram-se os fluxogramas dos algoritmos de controle da integração do sistema híbrido que foram considerado para os dormitórios e para a sala/cozinha, respectivamente.

Figura 24 – Fluxograma do algoritmo de controle da integração do sistema de condicionamento artificial e da ventilação natural para os dormitórios



Fonte: Nunes (2021)

Figura 25 – Fluxograma do algoritmo de controle da integração do sistema de condicionamento artificial e da ventilação natural para a sala/cozinha



Fonte: Nunes (2021)

3.1.4 Parâmetros do Experimento

A amostra do experimento, para a propagação da incerteza, foi desenvolvida por meio do método de Morris (1991) e Campolongo, Cariboni e Saltelli (2007). Essa abordagem permite uma amostragem global de seleção aleatória, com intuito de otimizar o custo computacional (Branger *et al.*, 2015; Saltelli *et al.*, 2008). O procedimento de amostragem seleciona um número de pontos das distribuições de probabilidade dos parâmetros de entrada, de modo que eles representem uniformemente as regiões do espaço das entradas (Wate *et al.*, 2019).

A amostragem de Morris é dada pela Equação (5).

$$n = r \times (k + 1) \quad \text{Equação (5)}$$

Em que:

n é o tamanho total da amostra do experimento;

r é o número de trajetórias de aleatorização do experimento;

k é número de variáveis analisadas no experimento.

Os dados de entrada são apresentados como um número discreto de valores (divididos em p níveis) para cada uma das variáveis investigadas, conforme o número de trajetórias de aleatorização. Segundo Campolongo e Saltelli (1997), Campolongo, Tarantola e Saltelli (1999) e Saltelli, Tarantola e Campolongo (2000), experimentos mostraram que a escolha de $r = 10$ para $p = 4$ produziram bons resultados, e segundo Khare e Muñoz-Carpena (2014) e Chitale *et al.* (2017), 10 a 20 trajetórias são suficientes, sendo que o número de trajetórias deve ser múltiplo do número de níveis (por exemplo: $r = 8$ ou 12 , para $p = 4$) para melhores resultados, com amostras perfeitamente uniformes. Dessa maneira, consideraram-se: número de níveis igual a 4, número de trajetórias igual a 12 e número de variáveis analisadas igual a 13 (descritas na sequência do capítulo, no Item 3.1.4.1), gerando-se, portanto, um tamanho de amostra igual a 168 para a localidade (São Paulo) e para cada um dos arquivos de períodos climáticos (TRY, 2020, 2050 e 2080). Considerando, ainda, a aplicação de dois sistemas de ventilação da edificação, tem-se que um total de 1.344 simulações foram estudadas nesta pesquisa.

Para gerar a amostra, com auxílio de linguagem de programação R, foi utilizado o algoritmo ‘*morris.create*’, desenvolvido por Silva (2016), usando a função ‘*morris*’ do pacote ‘*sensitivity*’ de Iooss *et al.* (2020).

3.1.4.1 Variáveis independentes (parâmetros de ‘entrada’)

As variáveis independentes correspondem aos parâmetros termofísicos relacionados a decisões de projetos de edificações, representando incertezas nas entradas do modelo. As variáveis independentes são 13 parâmetros termofísicos relacionados à envoltória do ambiente construído, e que são associados ao conforto ambiental dos usuários e ao desempenho termoenergético das edificações, com base em Almeida (2014), Mechri, Capozzi e Corrado (2010), Silva e Ghisi (2013), Silva, Almeida e Ghisi (2016), Silva (2016) e Zara (2019). Os limites amostrais, categorizados em quatro níveis de variação (p), descrevem parâmetros representativos de possíveis escolhas de projeto em uma habitação real. No Quadro 15, estão listadas todas as variáveis de entrada, as simbologias para as análises, os valores limites amostrais e as variações; LI significa limite inferior e LS significa limite superior.

Quadro 15 – Variáveis independentes para a criação da amostra

Parâmetros termofísicos	Símbolo	LI	LS	Variação (p)
Absortância solar da cobertura [-]	acob	{0,2 0,8}		0,20
Absortância solar das paredes [-]	apar	{0,2 0,8}		0,20
Capacidade térmica da cobertura [kJ/m²K]	CTcob	{11 568}		185,67
Capacidade térmica das paredes [kJ/m²K]	CTpar	{40 445}		135,00
Capacidade térmica do piso [kJ/m²K]	CTpis	{13,40 505}		163,87
Emissividade da face interna da cobertura [-]	ecob	{0,05 0,9}		0,28
Fator de ventilação das janelas [-]	Fvent	{0,2 0,9}		0,23
Fator solar dos vidros das janelas [-]	FSvid	{0,36 0,87}		0,17
Orientação solar [°]	OS	{0 270}		90
Transmitância solar e visível das janelas (sombreamento) [-]	tvnez	{0,2 0,9}		0,23
Transmitância térmica da cobertura [W/m²K]	Ucob	{0,53 2,30}		1,36
Transmitância térmica das paredes externas [W/m²K]	Upar	{0,27 4,40}		1,38
Transmitância térmica do piso [W/m²K]	Upis	{0,72 4,67}		1,32


Fonte: Nunes (2021); elaborado a partir de Almeida (2014), Mechri, Capozzi e Corrado (2010), Silva e Ghisi (2013), Silva, Almeida e Ghisi (2016), Silva (2016) e Zara (2019)

3.1.4.2 Variáveis dependentes (parâmetros de ‘saída’)

As variáveis dependentes definem a resposta do modelo, representando o desempenho térmico e energético da edificação. Elas foram obtidas por Nunes (2021), por meio de indicadores de graus-hora para resfriamento (GHR) e consumo energético com resfriamento (CR), de acordo com o método desenvolvido por Silva (2016). Dessa maneira, os ambientes de permanência prolongada (dormitórios e sala/cozinha) tiveram seu desempenho anual avaliado em termos de índices de conforto térmico e de consumo de energia.

Neste trabalho, o conforto térmico adaptativo condiciona os parâmetros para os cálculos dos graus-hora para resfriamento (GHR), sendo que nesta etapa considera-se ventilação exclusivamente natural, conforme sistema descrito no Item 3.1.3.3.1. Computa-se, assim, a quantidade de horas ocupadas (conforme Figura 20) em desconforto térmico, para 80% de aceitabilidade, admitindo-se a proposta de fixação do limite inferior em 19,5 °C quando a temperatura média mensal do ar externo excede 16,5 °C, segundo a revisão da NBR 16401 (ABNT, 2008) e De Vecchi *et al.* (2014), conforme apresenta-se na Figura 26.

Figura 26 – Limites de conforto térmico adaptativo



Fonte: o autor; elaborada a partir de ASHRAE (2017a) e De Vecchi (2014)

A partir das definições dos limites de conforto térmico para cada localidade e período climático, o indicador de GHR define o desempenho da habitação naturalmente ventilada. Por meio das Equações (6) e (7) mostram-se os procedimentos para os cálculos do GHR (Silva, 2016).

$$GHR_{app,j} = \sum_{i=1}^n (T_{opi,appj} - T_{LS,mês}), \text{ se } T_{opi,appj} > T_{LS,mês} \quad \text{Equação (6)}$$

$$GHR = \frac{\sum GHR_{app,j} \times A_{app,j}}{\sum A_{app,j}} \quad \text{Equação (7)}$$

Em que:

- i é cada uma das horas ocupadas no ano, sob condição de ventilação natural;
- j é cada um dos três ambientes de permanência prolongada;
- n é o total de horas ocupadas no ano, sob condição de ventilação natural;
- $T_{LI, mês}$ é a temperatura limite inferior mensal de conforto térmico [°C];
- $T_{LS, mês}$ é a temperatura limite superior mensal de conforto térmico [°C];
- $T_{opi,appj}$ é a temperatura operativa horária em cada ambiente de permanência prolongada [°C];

$GHR_{app,j}$ é o indicador de graus-hora para resfriamento de cada ambiente de permanência prolongada [°Ch];

GHR é o indicador de graus-hora para resfriamento (ponderado) da edificação [°Ch];

$A_{app,j}$ é a área de cada ambiente de permanência prolongada [m²].

Por sua vez, o indicador de consumo de energia para resfriamento (CR) da edificação, se refere à energia consumida com resfriamento durante o ano todo (conforme Item 3.1.3.3), nos ambientes de permanência prolongada, de acordo com as Equações (8) e (9) (Silva, 2016). Nesta etapa, consideram-se as simulações com o sistema de ventilação híbrida, descrito no Item 3.1.3.3.2.

$$CR_{app,j} = \sum_{i=1}^n cr_{i,appj}, \text{ se } T_{i,appj} \geq 26 \text{ }^{\circ}\text{C} \quad \text{Equação (8)}$$

$$CR = \sum CR_{app,j} \quad \text{Equação (9)}$$

Em que:

i é cada uma das horas ocupadas no ano, sob condicionamento artificial;

j é cada um dos três ambientes de permanência prolongada;

n é o total de horas ocupadas no ano, sob condicionamento artificial;

$T_{i,appj}$ é a temperatura horária em cada ambiente de permanência prolongada [$^{\circ}\text{C}$];

$cr_{i,appj}$ é o consumo horário para resfriamento de cada ambiente de permanência prolongada [kWh];

$CR_{app,j}$ é o indicador de consumo anual para resfriamento de cada ambiente de permanência prolongada [kWh/ano];

CR é o indicador de consumo anual total para resfriamento da edificação [kWh/ano].

3.2 ANÁLISE DE INCERTEZAS DE DESEMPENHO TÉRMICO E ENERGÉTICO

Nesta etapa, a análise incertezas é aplicada para analisar a dispersão nos resultados do modelo (desempenho térmico e energético da edificação) devido às incertezas nas variáveis de entrada (incertezas climáticas e de projeto). Ela permite caracterizar a dispersão de valores que podem ser atribuídos (estar inclusos em uma faixa de probabilidades) em conjunto ao resultado mensurado. Além disso, as funções de distribuição de probabilidade possibilitam compreender a faixa de variação térmica e energética da edificação, assim como os indicadores de incertezas permitem quantificar parâmetros úteis para avaliar a resiliência de edificações, como indicado na bibliografia.

O método de análise de incertezas combina a técnica de Monte Carlo com simulações de desempenho de edificações, no sentido de definir uma expectativa de resultados de desempenho térmico e energético do ambiente construído, com base na amostragem aleatória das entradas do modelo habitacional. Por meio das simulações dos modelos com as combinações aleatórias das variáveis independentes, são obtidas as variáveis dependentes, e a incerteza pode ser analisada por meio da sua distribuição de probabilidade.

Todo o método de análise de incertezas desenvolvido foi conduzido por meio da combinação da linguagem de programação R, do EnergyPlus, e de planilhas eletrônicas do Excel. Esta combinação de ferramentas computacionais oferece benefícios como a geração rápida de modelos, pela combinação da plataforma de linguagem R e do EnergyPlus, da interface fácil de entender e operar os modelos BEM, da sistematização de análises, e da redução de erros humanos e tempo de execução das análises (Silva, 2016; Zhu *et al.*, 2022).

3.2.1 Quantificação das Incertezas

Nesta pesquisa, a quantificação das incertezas de desempenho térmico e energético em cenários de mudanças climáticas é apresentada tanto como valores numéricos, quanto como elementos gráficos. Os indicadores numéricos são as medidas estatísticas descritivas, incluindo a média, o desvio padrão, a amplitude, o desvio padrão relativo e os quartis, e os elementos gráficos incluem os diagramas de caixa e as funções de densidade de probabilidade.

Os gráficos de caixa são usados para mostrar a média, mediana, amplitude e os quartis; as funções de densidade de probabilidade adequada permitem representar informações valiosas como níveis de confiança e probabilidade de desempenho (Zhu *et al.*, 2022).

3.2.2 Inferência Bayesiana

O procedimento de inferência bayesiana possui o diferencial de simular e otimizar probabilidades para uma determinada condição, mesmo que ela não tenha sido observada no conjunto (base de dados) inicial, por exemplo, além de incluir um intervalo de credibilidade junto às probabilidades calculadas. Dessa maneira, pode-se aproveitar os dados disponíveis, aprimorando a confiabilidade do modelo e alcançando resultados e análises mais realistas e que contribuem para o projeto de edificações. Tendo em vista que o tamanho da amostra (168 modelos) é relativamente reduzido para os padrões de múltiplas simulações térmica e

energéticas em pesquisas da área, esta etapa é importante para ampliação das análises. Ademais, convém dispor que a estatística bayesiana é adequada para analisar tamanhos de amostra pequenos, sem a identificação de um tamanho mínimo (Joseph; Bélisle, 2019; Hox; van de Schoot; Matthijsse, 2012; Tattoni; LaBarbera, 2022). Na prática, tem-se que o tamanho da amostra em si não é o mais relevante para a inferência, mas sim a convergência dos dados. Ela que indicará se a inferência obtida foi adequada ao conjunto de dados disponíveis ou não.

Nesta etapa do método desenvolvido, estimativas de função de densidade de probabilidade são calculadas por meio de mecanismos inovadores de inferência bayesiana, aplicando a técnica de amostragem por fatias (*slice sampling*), desenvolvido por Wand (2020), Wand e Yu (2021) e Wand e Yu (2022), de acordo com 1000 simulações para o conjunto de dados; para tanto, utilizou-se o pacote ‘densEstBayes’ de Wand (2023). Wand e Yu (2022) explicam que uma característica fundamental da abordagem desenvolvida é a conversão do problema de estimativa de densidade em um problema de regressão não paramétrica de Poisson. A classe de estimativas de densidade *a posteriori*⁵ usa *splines*⁶ de suavização, aproveitando as vantagens do mecanismo de inferência bayesiana.

Os dados são definidos como uma variável aleatória x , condicional ao conjunto (s_1, s_2, s_3, s_4) , sabendo que $s_1 \in \mathbb{R}$ e $s_2 > 0$, são variáveis aleatórias e s_3 e s_4 são vetores aleatórios de mesma dimensão; assim, tem-se o conjunto denotado por $x|s_1, s_2, s_3, s_4 \sim \mathcal{H}(s_1, s_2, s_3, s_4)$. A partir da estimativa de uma regressão não paramétrica de Poisson, e por meio do uso de modelos mistos de suavização *splines*, tem-se que a função de densidade de probabilidade de x , é dada pela Equação (10).

$$p(x|s_1, s_2, s_3, s_4) \propto e^{\left\{ \frac{s_1 x - x^2}{2s_2} - \mathbf{1}^T e^{(xs_3 + s_4)} \right\}}, -\infty < x < \infty \quad \text{Equação (10)}$$

Wand e Yu (2022) explicam que, na Equação (10), $\mathbf{1}$ denota um vetor das unidades com o mesmo número de linhas que s_3 e s_4 , e, assim, o termo $e^{(xs_3 + s_4)}$ é avaliado elemento a elemento. Posteriormente, ocorre a amostragem escalar de Gibbs, de maneira que se obtém o desenho das distribuições das funções de densidade de probabilidade para cada uma das variáveis, aplicando-se a abordagem de amostragem por fatias de Neal (2003).

⁵ Do latim, partindo do que é posterior (que parte do efeito para a causa).

⁶ Originariamente, *spline* é uma fita flexível usada para desenhar curvas que passam por pontos (nós) determinados. Em estatística, pode ser entendida como uma função segmentada por polinômios, ou conjunto de funções conectadas por meio de nós, utilizados para ajustar uma curva a um conjunto de dados, por partes (Paulino *et al.*, 2011).

A abordagem proposta é composta por estatística bayesiana, onde todas as estimativas são acompanhadas por uma medida de variabilidade correspondente – nominalmente, intervalos de credibilidade pontuais, de 95%, correspondentes, que permitem a variabilidade na seleção de parâmetros de suavização. Assim, define-se uma faixa em torno da estimativa de densidade calculada, fornecendo uma visualização da variabilidade de probabilidade.

Intervalos de credibilidade pontuais são um subproduto simples de saídas de mecanismos de inferência bayesianos; eles medem a variabilidade das estimativas pontuais das funções de densidade de probabilidade estimadas. Assim, nas funções de densidade de probabilidades estimadas, se está interessado nos pontos que estão exatamente na linha (curva) desta função; chamando esta linha de um parâmetro escalar θ , em que se observa-se uma amostra de elementos $x_1, x_2, \dots, x_n$, e sendo $h(\theta|x_1, x_2, \dots, x_n)$ uma distribuição *a posteriori*, tem-se que $[\theta'(x_1, x_2, \dots, x_n), \theta''(x_1, x_2, \dots, x_n)]$ é um intervalo de credibilidade a $100(1 - \alpha)\%$ para θ , representado pela Equação (11). Portanto, o intervalo de credibilidade é aquele em que há $100(1 - \alpha)\%$ de chances de uma nova estimativa pontual estar contida; no método aplicado, α equivale a 0,05, acarretando uma probabilidade de 95% para o intervalo de credibilidade.

$$\int_{\theta'}^{\theta''} h(\theta|x_1, x_2, \dots, x_n) d\theta = 1 - \alpha, 0 < \alpha < 1 \quad \text{Equação (11)}$$

3.3 CLASSIFICAÇÃO DE DESEMPENHO E INFLUÊNCIA DAS PRINCIPAIS VARIÁVEIS TERMOFÍSICAS


Nesta etapa, analisam-se o comportamento da habitação nos períodos climáticos de curto prazo (2020), médio prazo (2050) e longo prazo (2080), e determinam-se análises para os seguintes panoramas: apenas curto prazo, com os resultados para 2020; e para curto, médio e longo prazo, com os resultados para 2020 a 2080.

A classificação de desempenho térmico e energético consiste no cálculo e análise dos quartis obtidos na quantificação das incertezas. A ideia é aplicar a análise da dispersão dos dados (saídas do modelo), alinhados com as separatrizes com os valores que dividem a distribuição em quatro partes iguais (quartis), determinando quatro níveis de desempenho para a amostra: insatisfatório, mínimo, intermediário e superior, de modo a estabelecer parâmetros de desempenho nos diferentes panoramas ou, ainda, de modo que arquitetos(as) e

engenheiros(as) consigam replicar o procedimento, relativamente simplificado, de acordo com a condição particular da edificação estudada.

Como ilustra-se na Figura 27, analisando-se os indicadores de desempenho (os graus-hora ou consumo de energia) das amostras do experimento, o primeiro quartil (Q1) delimita 25% dos dados com menores valores – definindo o intervalo de desempenho superior; o segundo quartil (Q2) delimita 50% dos dados com menores valores – definindo o intervalo de desempenho intermediário; e o terceiro quartil (Q3) delimita 75% dos dados com menores valores – definindo o intervalo de desempenho mínimo; os valores acima do terceiro quartil definem o intervalo de desempenho classificado com insatisfatório.

Figura 27 – Intervalos genéricos de classificação de desempenho, de acordo com os quartis definidos



Fonte: o autor

A partir dos intervalos de classificação definidos, e conhecendo as propriedades termofísicas mais influentes na resposta do modelo, é possível sobrepor os dados e observar a variabilidade nas variáveis de saída (desempenho) em relação às incertezas nas variáveis de entrada (propriedades termofísicas da envoltória). Dessa maneira, o(a) projetista pode tomar decisões mais assertivas para o desempenho térmico e energético do ambiente construído, no contexto das mudanças climáticas, definindo, por exemplo, quais propriedades devem ser consideradas para a construção da edificação.

As propriedades investigadas nesta etapa foram as que se destacaram na análise preliminar relatada no item Anexo A.3 (ver Quadro 22): absorvância solar da cobertura, absorvância solar das paredes externas e transmitância térmica das paredes externas, capacidade térmica das paredes externas e fator de ventilação das janelas, para o indicador GHR; e absorvância solar da cobertura, absorvância solar das paredes externas e transmitância térmica das paredes externas, para o indicador CR.

4 RESULTADOS E ANÁLISES


Neste capítulo, descrevem-se o comportamento dos indicadores de desempenho dos modelos da amostra e apresentam-se os resultados da aplicação do método desenvolvido, considerando os graus-hora e o consumo para resfriamento em um estudo no clima de São Paulo. Para cada indicador de desempenho (sem e com uso de ar-condicionado), apresentam-se as estatísticas descritivas, a classificação de desempenho proposta e a relação entre as variáveis termofísicas mais importantes e o panorama de desempenho.

4.1 ESTUDO NO CLIMA DE SÃO PAULO

4.1.1 Graus-hora para Resfriamento (Sistema de Ventilação Natural)

Na Figura 28, ilustra-se a correlação entre os graus-hora para resfriamento, conforme as simulações para os diferentes períodos climáticos de São Paulo. Os resultados para o horizonte de curto prazo (2020) e médio prazo (2050) possuem uma correlação maior com as saídas dos modelos no período TRY, representadas pelo R^2 0,9345 e 0,9188, respectivamente. No cenário de longo prazo (2080), o R^2 0,8737 denota o impacto maior na relação entre o desempenho do passado e do futuro. Desse modo, as relações nos diferentes períodos simulados indicam que quanto mais distante o cenário climático comparado, menor é a linearidade (maior dispersão dos dados decorrente das mudanças no clima).

Figura 28 – Relação entre o graus-hora para resfriamento da habitação, em São Paulo, de acordo com as simulações para o período TRY e para as progressões dos períodos climáticos 2020, 2050 e 2080



Fonte: o autor

Essa condição no longo prazo, que sugere maior preocupação com os impactos no desempenho devido à maior elevação da temperatura no futuro mais distante, é observada na bibliografia investigada, em diferentes climas do Brasil (Alves; Duarte; Gonçalves, 2016; Guarda *et al.*, 2020; 2023; Invidiata; Ghisi, 2016; Triana; Lamberts; Sassi, 2018). Especificamente no clima de São Paulo, Nobre *et al.* (2011) estudaram a vulnerabilidade da região metropolitana, alertando que os riscos serão maiores devido às temperaturas mais altas, sinalizando que as tendências de temperatura causarão mais dias quentes menos dias frios, mais noites quentes e menos noites frias (Marengo *et al.*; Nobre *et al.*, 2011). Nas projeções descritas por Nobre *et al.* (2011), estima-se que a temperatura média anual, prevista em um cenário de altas emissões globais no final deste século, aumente de 2 °C a 4 °C. Por sua vez, as projeções climáticas que deram origem aos resultados apresentados na Figura 28, apontam elevação média na temperatura anual de 0,91 °C no curto prazo (período 2020), 2,24 °C no médio prazo (período 2050) e 4,23 °C no longo prazo (período 2080), o que explica as diferenças na correlação de desempenho.

As análises específicas para o indicador de graus-hora para resfriamento da habitação, no clima de São Paulo, relacionando alguns estudos correlatos são detalhadas nos subitens a seguir.

4.1.1.1 Estatística descritiva dos efeitos das incertezas


No Quadro 16, descrevem-se valores de parâmetros estatísticos de incertezas e, nas Figuras 29 e 30, ilustram-se os diagramas de caixa e as funções de densidade de probabilidade do consumo de energia para resfriamento da habitação, de acordo com as simulações considerando os diferentes períodos climáticos em São Paulo.

Quadro 16 – Parâmetros estatísticos de incerteza no graus-hora para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080

Parâmetros estatísticos	TRY (1954)	2020	2050	2080
Mínima [°Ch]	3,94	32,44	92,33	320,47
Média [°Ch]	273,37	646,30	994,15	1733,81
Mediana [°Ch]	183,12	452,50	780,76	1458,14
Máxima [°Ch]	1274,94	2719,63	3506,45	4908,83
Amplitude [°Ch]	1271,00	2687,19	3414,12	4588,36
Desvio padrão [°Ch]	250,61	526,81	678,95	928,04
Desvio padrão relativo [%]	91,67	81,51	68,29	53,53


Fonte: o autor

Figura 29 – Diagramas de caixa para o graus-hora para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080



Fonte: o autor

Figura 30 – Funções de densidade de probabilidade de graus-hora para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080



Fonte: o autor

A partir dos resultados obtidos, observa-se um aumento na média de graus-hora de resfriamento em torno de 136%, 246% e 534% para os períodos de curto, médio e longo prazo, representados pelos arquivos climáticos 2020, 2050 e 2080, respectivamente, quando comparados com o período climático de referência. A notável variação de desempenho é um indício fundamental da relevância de se considerar essas incertezas de desempenho na concepção do ambiente construído, como indicado nas pesquisas anteriores mencionadas.


A variabilidade dos dados em relação à média é bastante expressiva, como indicado pelos elevados valores de desvio padrão relativo (RSD); quanto maior o RSD, maior a variabilidade das informações em relação à média, o que indica um grupo de dados mais heterogêneo. Quando se analisa esse parâmetro nas simulações com o arquivo TRY, tem-se um valor 91,67%, e quando se analisa nas simulações com os arquivos para os períodos 2020, 2050 e 2080, observa-se uma redução para 81,51%, 68,29% e 53,53%, respectivamente. Isso ocorre porque o aumento das temperaturas promove o aumento dos períodos de desconforto térmico por calor nas edificações analisadas, principalmente nos casos com menores indicadores, gerando um menor desvio padrão relativo. Em outras palavras, pode-se dizer que aqueles modelos que possuem GHR baixo em cenários mais amenos, passam a apresentar GHR elevados, fazendo com que o indicador GHR da amostra fique mais homogêneo nesse sentido. Os dados meteorológicos de 1954 representam características de um clima mais oscilante (variação entre temperaturas muito baixas no inverno e altas temperaturas no verão – ver Figuras 62 a 64 e Item Anexo C); por exemplo, durante o período TRY, a média das

temperaturas mínimas é 16,23 °C e a média das temperaturas máximas 24,89 °C, enquanto os mesmos parâmetros no período 2080 são 19,69 °C e 28,51 °C. Em outras palavras, a constância e condição marcante de um clima mais quente faz com que o desvio padrão relativo seja menor (o que não significa, necessariamente, que isso seja bom, já que o consumo com resfriamento aumenta sob temperaturas mais elevadas no futuro).

Em comparação com os resultados de Triana, Lamberts e Sassi (2018), que analisaram estratégias de desempenho de uma habitação de interesse social em São Paulo nos períodos TRY, 2020 e 2050, nota-se similaridade em alguns indicadores GHR calculados pelos autores, embora o método aplicado tenha sido diferente – os autores analisaram o desempenho sob ventilação natural tendo como referência a temperatura operativa de 26 °C para o cálculo. A amostra dos autores foi obtida a partir da combinação de estratégias construtivas envolvendo cores da envoltória, isolamento térmico, sombreamento nas janelas e fator de ventilação das janelas. Nas combinações, alcançaram-se valores próximos de 50 a 2400 °Ch, no período TRY, e 750 a 7500 °Ch, no período 2050, notando-se que os limites mínimos e máximos diferem mais. Tendo em vista que a temperatura limite para resfriamento foi 26 °C, além de outras definições metodológicas, ocorre que as diferenças nos limites obtidos podem ser maiores, sobretudo nas progressões.

Para estimativas e análises dos dados mais apuradas, nas Figuras 31 a 34, apresentam-se as inferências bayesianas para o indicador GHR em cada período climático representativo. O processo envolve a substituição dos dados originais por combinações de intervalos numéricos em uma grade fina e igualmente espaçada, de modo a ampliar a cobertura e precisão das informações, por meio de 1000 simulações de estimativas de densidade de probabilidade, a partir do conjunto de dados. As funções de densidade de probabilidade são acompanhadas pelo intervalo de credibilidade (região sombreada) e, junto a elas, apresenta-se o diagnóstico de queima da cadeia de Markov particionada, correspondente às fatias verticais (seis intervalos) da estimativa de densidade, aos gráficos de rastreamento, à dispersão ou defasagem dos valores da cadeia em relação a seus valores anteriores e à autocorrelação da amostra, ou correlograma, que refere-se ao grau de correlação das mesmas variáveis entre dois intervalos de tempo sucessivos.

Figura 31 – Inferência bayesiana para o graus-hora para resfriamento, para o arquivo TRY (1954)
 (a) funções de densidade de probabilidade de graus-hora para resfriamento (comparação entre abordagem bayesiana e frequentista)




(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Figura 32 – Inferência bayesiana de graus-hora para resfriamento, para o período 2020
(a) funções de densidade de probabilidade de graus-hora para resfriamento (comparação entre abordagem bayesiana e frequentista)




(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Figura 33 – Inferência bayesiana de graus-hora para resfriamento, para o período 2050
 (a) funções de densidade de probabilidade de graus-hora para resfriamento (comparação entre abordagem bayesiana e frequentista)




(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Figura 34 – Inferência bayesiana de graus-hora para resfriamento, para o período 2080
 (a) funções de densidade de probabilidade de graus-hora para resfriamento (comparação entre abordagem bayesiana e frequentista)



(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

De modo geral, observa-se que a amostra e as simulações de inferência bayesiana acarretam bons resultados, dado o caráter estacionário do logaritmo da função de densidade estimada por amostragem por fatias em sua extensão. Os gráficos de rastreamento são importantes para avaliar a mistura da cadeia; o ideal é um padrão no qual as cadeias se misturam e não apresentem uma tendência específica (no mesmo estado por muito tempo), sem uma grande variação de valores no eixo vertical ou muitas etapas consecutivas em uma direção (inclinação constante ao longo das iterações, no eixo horizontal) – demonstrando que elas convergiram para um certo valor do parâmetro e se mantiveram nessa região durante a

amostragem. A dispersão dos valores da cadeia indica boa exploração da parte posterior e as autocorrelações também permitem verificar a convergência, pela sua rápida redução.


As simulações demonstram que os valores do indicador graus-horas de resfriamento com maiores probabilidades de ocorrência nos períodos TRY (1954), 2020, 2050 e 2080 correspondem, respectivamente, a aproximadamente 60 °Ch, 230 °Ch, 450 °Ch e 1000 °Ch. Esse aumento de GHR significa maior desconforto térmico para os usuários.

Relacionando o aumento no indicador GHR com o aumento do desconforto por calor, pode-se abordar a pesquisa de Alves, Duarte e Gonçalves (2016). Os autores investigaram o desempenho de edificações reais e por meio de simulações computacionais e analisaram o conforto térmico adaptativo em cenários climáticos futuros, avaliando mudanças climáticas em São Paulo. Os cenários simulados compreenderam os períodos denominados como presente (1975-2005), futuro próximo (2015-2044), futuro intermediário (2045-2074) o futuro distante (2076-2096). Os resultados comprovaram a evolução e o aumento de desconforto por calor nas condições de progressões climáticas, associadas às ondas de calor.

4.1.1.2 Classificação de desempenho


Para o horizonte de curto prazo, definem-se quatro níveis representativos de desempenho térmico, conforme o GHR, como ilustram-se nas Figuras 35 e 36. E para os horizontes de curto, médio e longo prazo, definem-se outros quatro níveis representativos de desempenho térmico, como ilustram-se nas Figuras 37 e 38.

Figura 35 – Inferência bayesiana e níveis de desempenho definidos para o grau-hora para resfriamento, considerando os experimentos para curto prazo (2020), em São Paulo




Fonte: o autor

Figura 36 – Níveis de desempenho definidos para o graus-hora para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto prazo (2020), em São Paulo




Fonte: o autor

Figura 37 – Inferência bayesiana e níveis de desempenho definidos para o graus-hora para resfriamento, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo



Fonte: o autor

Figura 38 – Níveis de desempenho definidos para o consumo de energia para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo



Fonte: o autor


Para o horizonte de curto prazo (Figura 36), os casos com GHR entre 32,44 °Ch e 227,68 °Ch são classificados no nível de desempenho superior; entre 227,69 °Ch e 452,50 °Ch como nível intermediário; entre 452,51 °Ch e 939,10 °Ch como nível mínimo; e entre 939,11 °Ch e 2719,63 °Ch como nível insatisfatório. Por sua vez, para os horizontes de curto, médio e longo prazo (Figura 38), os níveis representativos de desempenho térmico apresentam como limites os valores de 32,44 °Ch e 448,89 °Ch para o nível superior; 448,90 °Ch e 921,50 °Ch para o nível intermediário; 921,51 °Ch e 1532,94 °Ch para o nível mínimo; e 1532,95 °Ch e 4908,03 °Ch para o nível insatisfatório.

Observa-se que para o segundo horizonte (curto, médio e longo prazo), os valores limites apresentam um aumento de quase duas vezes quando comparados com o horizonte de curto prazo, indicando um aumento na quantidade de horas em desconforto térmico nos edifícios analisados devido às alterações no clima. Como o modelo de classificação considera a distribuição dos dados das simulações, essa adaptação dos níveis de desempenho era esperada, possibilitando que a classificação de desempenho seja ajustada ao longo do ciclo de vida do ambiente construído.

4.1.1.3 Influência de variáveis termofísicas na classificação de desempenho


Considerando os experimentos para curto (2020) prazo, segundo o indicador de graus-hora para resfriamento e de acordo com as variáveis termofísicas mais influentes, a variação de desempenho térmico é ilustrada na Figura 39. De modo análogo, para os experimentos para curto (2020), médio (2050) e longo (2080) prazo, a variação é ilustrada na Figura 40.

Figura 39 – Análise de desempenho para os graus-hora para resfriamento, de acordo com as cinco variáveis termofísicas mais influentes, considerando os experimentos para curto (2020) prazo



Fonte: o autor

Figura 40 – Análise de desempenho para os graus-hora para resfriamento, de acordo com as cinco variáveis termofísicas mais influentes, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo



Fonte: o autor

No curto prazo (Figura 39), observa-se que o desempenho superior da habitação é alcançado por meio de absorvência solar da cobertura igual a 0,4, absorvência solar das paredes externas igual a 0,2, transmitância térmica das paredes externas igual a 1,65 W/m²K, capacidade térmica das paredes externas igual a 445 kJ/m²K e fator de ventilação das janelas igual a 0,9. Percebe-se, ainda, que as cores mais escuras consideradas na envoltória (absorvência solar 0,6 e 0,8), transmitância térmica das paredes externas de 3,02 e 4,4 W/m²K, capacidade térmica

baixa ($40 \text{ kJ/m}^2\text{K}$) e fator de ventilação das janelas baixo (0,2) estão associados a condições de desempenho mínimo ou insatisfatório (piores casos) para a habitação naturalmente ventilada.


Para os modelos com menores GHR, obtiveram-se valores próximos de 32°Ch para o curto prazo (2020), 100°Ch para o médio prazo (2050) e 342°Ch para o longo prazo (2080), representando um aumento de quase 200% e 900% no médio e longo prazo, respectivamente. Da mesma forma, os modelos com maiores GHR apresentaram valores em torno de 2700°Ch para o curto prazo, 3500°Ch para o médio prazo, e 4900°Ch para o longo prazo, ou seja, um aumento de quase 30% e 80% no médio e longo prazo, respectivamente. Apesar desse impacto das alterações climáticas no GHR, todos os casos mantiveram a classificação de nível de desempenho, sendo nível superior nos menores GHR e nível insatisfatório nos maiores. Nesse sentido, verifica-se a relevância da escolha das propriedades das envoltórias para um bom desempenho térmico e energético nos cenários atuais e futuros.

Nas classificações de desempenho convém analisar, particularmente, o fato de que a absorptância solar da cobertura igual a 0,4 resultou em níveis de desempenhos melhores do que a absorptância solar da cobertura igual a 0,2, assim como a absorptância solar da cobertura igual a 0,8 resultou em níveis de desempenhos melhores do que a absorptância solar da cobertura igual a 0,6. Essas aparentes distorções inesperadas podem ser justificadas pela limitação da cobertura do campo amostral (número de modelos), além do fato de a resposta global do modelo ser associada à mais parâmetros (combinação de configurações da amostra).

O padrão de comportamento das variáveis se mantém para as análises para o médio e longo prazo (Figura 40). No entanto, quando se comparam as mesmas características construtivas, nota-se uma maior dificuldade em se alcançar níveis de desempenhos superiores nos cenários futuros, mesmo com a adaptação dos limites de classificação.

Para um entendimento mais aprofundado acerca das alterações de desempenho, que se associam à resiliência do ambiente construído, na Figura 63 apresenta-se a correlação entre as variáveis termofísicas mais influentes nos graus-hora para resfriamento e o desvio padrão relativo de desempenho das amostras simuladas, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo. Convém revisar que, como notado na bibliografia, o RSD configura uma medida de resiliência do ambiente construído; quanto menor o valor, menor os desvios de desempenho por causa da alteração no clima.

Figura 41 – Correlação entre as variáveis termofísicas mais influentes nos graus-hora para resfriamento e o desvio padrão relativo de desempenho das amostras simuladas, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo



Fonte: o autor

Observa-se que os modelos com melhores desempenho, ou seja, com valores mais baixos de absorptância solar na envoltória e transmitância térmica das paredes, maior capacidade térmica das paredes externas e maior fator de ventilação, apresentam valores de RSD maiores. Isso demonstra que esses modelos são mais sensíveis à desvios de desempenho decorrentes das alterações climáticas. Enquanto os modelos com tendência de ocasionar níveis de desempenho inferiores apresentam menor RSD, o que indica menor variabilidade no nível de desempenho (as repostas dos modelos já são ruins nos cenários atuais; consequentemente, têm menos margem para piorar).


Em termos quantitativos, essa diferença nos valores de RSD chega a cerca de 15 pontos percentuais (pp) para a absorptância solar da cobertura e das paredes externas, com redução de 85% para 70%; e 10 pp para a transmitância térmica das paredes. Para a capacidade térmica das paredes externas e o fator de ventilação das janelas, no entanto, observou-se uma diferença acima de 30 pp e 20 pp, respectivamente.

De qualquer forma, as habitações, em geral, devem passar por impactos relevantes no indicador graus-hora de resfriamento no contexto climático futuro, afetando o seu desempenho. Desse modo, a escolha das definições construtivas é determinante para que se tenha edificações mais eficientes tanto nas condições meteorológicas atuais quanto futuras. A manutenção de um padrão no comportamento das variáveis pode auxiliar projetistas e pesquisadores no desafio de se construir edificações mais resilientes.

4.1.2 Consumo de Energia para Resfriamento (Sistema de Ventilação Natural Combinada com Uso de Ar-Condicionado)

Na Figura 42, ilustra-se a correlação entre o consumo para resfriamento da habitação, em São Paulo, de acordo com as simulações para o período TRY e para as progressões dos períodos climáticos 2020, 2050 e 2080.

Figura 42 – Relação entre o consumo para resfriamento da habitação, em São Paulo, de acordo com as simulações para o período TRY e para as progressões dos períodos climáticos 2020, 2050 e 2080



Fonte: o autor

Assim como observado no item 4.1.1 para o indicador GHR, os resultados para o horizonte de curto prazo (2020) e médio prazo (2050) possuem uma correlação maior com as saídas dos modelos no período TRY, com R^2 0,966 e 0,9278, respectivamente. No longo prazo (2080), o R^2 é 0,8626, indicando que quanto mais distante o cenário climático comparado, menor é a linearidade. Ademais, nota-se que a não linearidade entre as simulações para os

períodos TRY e 2080 demonstram um maior distanciamento dos padrões de consumo para refrigerar do que se tem atualmente.

As análises para o indicador de consumo de energia para resfriamento da habitação, no clima de São Paulo, são detalhadas nos subitens a seguir, relacionando alguns estudos correlatos.

4.1.2.1 Estatística descritiva dos efeitos das incertezas


No Quadro 17, descrevem-se valores de parâmetros estatísticos de incertezas e, nas Figuras 43 e 44, ilustram-se os diagramas de caixa e as funções de densidade de probabilidade do consumo de energia para resfriamento da habitação, de acordo com as simulações considerando os diferentes períodos climáticos em São Paulo.

Quadro 17 – Parâmetros estatísticos de incerteza no consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080

Parâmetros estatísticos	TRY (1954)	2020	2050	2080
Mínima [kWh/ano]	316,59	686,08	1366,22	2753,24
Média [kWh/ano]	1283,74	2410,66	3403,06	5043,16
Mediana [kWh/ano]	1149,01	2239,86	3248,46	4934,97
Máxima [kWh/ano]	2946,73	4836,36	6158,13	8339,62
Amplitude [kWh/ano]	2630,14	4150,28	4791,91	5586,38
Desvio padrão [kWh/ano]	647,31	1059,00	1196,48	1382,60
Desvio padrão relativo [%]	50,43	43,93	35,16	27,42


Fonte: o autor

Figura 43 – Diagramas de caixa para o consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080



Fonte: o autor

Figura 44 – Funções de densidade de probabilidade de consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY e as progressões para 2020, 2050 e 2080



Fonte: o autor


Por meio dos resultados de desempenho simulados, de acordo com o experimento, observa-se, respectivamente, um aumento na média de consumo para resfriamento das amostras de quase 90%, 165% e 300% no consumo, quando se comparam as simulações considerando o período climático de referência e as progressões para os períodos curto, médio e longo prazo, representado pelos arquivos climáticos 2020, 2050 e 2080.

Além disso, em termos de variabilidade de desempenho, conforme o conjunto de dados, é interessante observar a dispersão dos resultados nos diferentes períodos climáticos, conforme as mínimas, máximas, amplitude e funções de densidade de probabilidade, por exemplo. Nota-se que, com as progressões de clima, há uma dispersão maior nos valores, com a predominância de maiores consumos para resfriamento. Quando se analisa o desvio padrão relativo do consumo de energia para resfriamento nas simulações com o arquivo TRY, tem-se um valor 50,43%, e quando se analisa o desvio padrão relativo do consumo de energia para resfriamento nas simulações com os arquivos para os períodos 2020, 2050 e 2080, observa-se uma redução para 43,93%, 35,16% e 27,42%, respectivamente.

Nas Figuras 45 a 48, apresentam-se as inferências bayesianas para o consumo em cada período climático representativo. As funções de densidade de probabilidade são acompanhadas pelo intervalo de credibilidade (região sombreada) e, junto a elas, apresenta-se o diagnóstico de queima da cadeia de Markov particionada, correspondente às fatias verticais (seis intervalos) da estimativa de densidade, aos gráficos de rastreamento, à dispersão ou defasagem dos valores da cadeia em relação a seus valores anteriores e à autocorrelação da amostra.

Figura 45 – Inferência bayesiana para o consumo de energia para resfriamento, de acordo com as simulações para o clima de São Paulo, considerando o arquivo climático TRY (1954)

(a) funções de densidade de probabilidade de consumo de energia para resfriamento (comparação entre abordagem bayesiana e frequentista)




(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Figura 46 – Inferência bayesiana de consumo de energia para resfriamento, para o período 2020
 (a) funções de densidade de probabilidade de consumo de energia para resfriamento (comparação entre abordagem bayesiana e frequentista)




(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Figura 47 – Inferência bayesiana de consumo de energia para resfriamento, para o período 2050
(a) funções de densidade de probabilidade de consumo de energia para resfriamento (comparação entre abordagem bayesiana e frequentista)




(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Figura 48 – Inferência bayesiana de consumo de energia para resfriamento, para o período 2080
 (a) funções de densidade de probabilidade de consumo de energia para resfriamento (comparação entre abordagem bayesiana e frequentista)



(b) diagnóstico de queima da cadeia de Markov particionada

Intervalos das cadeias particionadas	Gráficos de rastreamento	Dispersão dos valores das cadeias	Autocorrelação da amostra
1/6 do intervalo			
2/6 do intervalo			
3/6 do intervalo			
4/6 do intervalo			
5/6 do intervalo			

Fonte: o autor

Em resumo, as funções de densidade de probabilidade e os diagnósticos de inferência bayesiana indicam bons resultados de dispersão dos valores da cadeia, com rápida convergência dos dados.

As simulações demonstram que os valores de consumo de energia para resfriamento com maiores probabilidades de ocorrência nos períodos TRY (1954), 2020, 2050 e 2080 correspondem, respectivamente, a aproximadamente 700 kWh/ano, 1500 kWh/ano, 2500 kWh/ano e 3750 kWh/ano. Tomando o período 2020 como atual, o consumo de 1500 kWh/ano é relativamente coerente com os dados do último levantamento de consumo médio da classe residencial do estado de São Paulo – 2256 kWh/ano, em 2022 (Brasil, 2023b); convém ponderar


que, no levantamento da EPE, analisa-se o consumo de todas as unidades residenciais juntas, independentemente do padrão da moradia ou da classe social da população.

Fazendo uma análise de consumo por metro quadrado, nota-se que o consumo aproximado no período TRY, de 18,82 kWh/m²ano, aumenta para 40,32 kWh/m²ano no período 2020, 67,20 kWh/m²ano no período 2050 e 100,81 kWh/m²ano no período 2080. Comparando esses índices de consumos com maiores probabilidades de ocorrência no âmbito da amostra simulada com os resultados para uma habitação de interesse social típica estudada por Triana, Lamberts e Sassi (2018), percebe-se uma similaridade maior no consumo para a simulação no período TRY. Os autores observaram possível aumento de 140% no consumo para resfriamento até 2050, sendo que o aumento previsto para o período 2050 foi de 45,92 kWh/m²ano e o simulado no período TRY foi de 19,12 kWh/m²ano.

4.1.2.2 Classificação de desempenho

De acordo com o consumo simulado para o horizonte de curto prazo, definem-se quatro níveis representativos de desempenho, como ilustram-se nas Figuras 49 e 50, e para os horizontes de curto, médio e longo prazo, definem-se outros quatro níveis representativos de desempenho, como ilustram-se nas Figuras 51 e 52.

Figura 49 – Inferência bayesiana e níveis de desempenho definidos para o consumo de energia para resfriamento, considerando os experimentos para curto prazo (2020), em São Paulo




Fonte: o autor

Figura 50 – Níveis de desempenho definidos para o consumo de energia para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto prazo (2020), em São Paulo




Fonte: o autor

Figura 51 – Inferência bayesiana e níveis de desempenho definidos para o consumo de energia para resfriamento, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo



Fonte: o autor

Figura 52 – Níveis de desempenho definidos para o consumo de energia para resfriamento, de acordo com a estatística descritiva e inferência bayesiana dos dados, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo, em São Paulo



Fonte: o autor


Os limites dos níveis representativos de desempenho térmico para o horizonte de curto prazo (Figura 50) são 686,08 kWh/ano e 1545,88 kWh/ano para o nível superior; 1548,89 kWh/ano e 2239,86 kWh/ano para o nível intermediário; 2239,87 kWh/ano e 3051,01 kWh/ano para o nível mínimo; e 3051,02 kWh/ano e 4836,36 kWh/ano para o nível insatisfatório. Da Figura 52, para os horizontes de curto, médio e longo prazo, os limites de classificação são 686,08 kWh/ano e 2356,74 kWh/ano para o nível superior; 2356,75 kWh/ano e 3439,14 kWh/ano para o nível intermediário; 3436,15 kWh/ano e 4577,87 kWh/ano para o nível mínimo; e 4577,88 kWh/ano e 8339,62 kWh/ano para o nível insatisfatório.

Assim como no indicador graus-hora de resfriamento, para o consumo de energia para refrigeração obteve-se um aumento nos valores limites dos níveis de desempenho nos horizontes de curto, médio e longo prazo, caracterizando um aumento da temperatura. Neste caso, esse aumento foi menos expressivo, apresentando-se com cerca de 50% maior que os obtidos para o horizonte de curto prazo.

4.1.2.3 Influência de variáveis termofísicas na classificação de desempenho


Na Figura 53, ilustra-se a variação de desempenho para o consumo de energia para resfriamento, de acordo com as três variáveis termofísicas mais influentes, em São Paulo, considerando os experimentos para curto (2020) prazo, e, de modo análogo, na Figura 54, ilustra-se essa análise considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo.

Figura 53 – Análise de desempenho para o consumo de energia para resfriamento, de acordo com as três variáveis termofísicas mais influentes, em São Paulo, considerando os experimentos para curto (2020) prazo



Fonte: o autor

Figura 54 – Análise de desempenho para o consumo de energia para resfriamento, de acordo com as três variáveis termofísicas mais influentes, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo



Na análise de curto prazo (Figura 53), observa-se que o desempenho superior da habitação é alcançado por meio de absorptância solar da cobertura igual a 0,4, absorptância solar das paredes externas igual a 0,2 e transmitância térmica das paredes externas igual a 1,65 W/m²K. Percebe-se, ainda, que as cores mais escuras consideradas na envoltória (absorptância solar 0,6 e 0,8) e transmitância térmica das paredes externas de 3,02 e 4,4 W/m²K estão mais associadas a condições de desempenho mínimo ou insatisfatório (piores casos) de consumo de energia.

Quando se estende essas análises para o médio e longo prazo o padrão de comportamento das variáveis se mantém: melhor desempenho com absorptância solar 0,2 e 0,4 e transmitância térmica das paredes 0,27 e 1,65 W/m²K. No médio prazo, com essas características construtivas, observa-se que ainda é possível alcançar níveis de desempenho superiores, no âmbito da amostra. Porém, pelos critérios adotados, no longo prazo, os modelos com melhores níveis de desempenho ficam no intervalo intermediário – ainda que possuam cores claras na envoltória e baixa transmitância térmica nas paredes – em virtude da maior severidade de alteração climática no período de 2071 a 2100.


De forma mais específica, quando analisados o consumo de energia para resfriamento até o longo prazo (Figura 54), para os melhores casos, notam-se valores de cerca 700 kWh/ano para o curto prazo (2020), 1400 kWh/ano para o médio prazo (2050) e 2800 kWh/ano para o longo prazo (2080), representando um aumento de 100% e 300% no médio e longo prazo, respectivamente. Esse aumento foi responsável pela passagem da classificação de nível superior para o curto e médio prazo para o nível intermediário no longo prazo. De forma análoga,

analisando os piores casos, tem-se um aumento do consumo de energia de aproximadamente 4900 kWh/ano no período de curto prazo (2020), 6200 kWh/ano no médio prazo (2050) e 8300 kWh/ano, o que corresponde a um aumento em torno de 27% no médio prazo e 70% no longo prazo. Nesses casos, nos três períodos analisados, a edificação foi classificada como nível insatisfatório.

Assim como observado para o indicador de desempenho GHR, nota-se que a absorptância solar da cobertura igual a 0,4 resultou em níveis de desempenhos melhores do que a absorptância solar da cobertura igual a 0,2, assim como a absorptância solar da cobertura igual a 0,8 resultou em níveis de desempenhos melhores do que a absorptância solar da cobertura igual a 0,6. Quanto menor a absorptância solar (cor clara), menor a absorção de calor pela cobertura e/ou paredes externas, o que, a princípio favorece o desempenho térmico e energético do ambiente construído; embora seja necessário levar em conta que há um conjunto de combinações obtidas pela amostragem definida.

Para um entendimento mais aprofundado acerca das alterações de desempenho, que se associam à resiliência do ambiente construído, na Figura 55, ilustra-se a correlação entre as variáveis termofísicas mais influentes no consumo de energia para resfriamento e o desvio padrão relativo de desempenho das amostras simuladas, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo. Convém revisar que, como notado na bibliografia, o RSD configura uma medida de resiliência do ambiente construído; quanto menor o valor, menor os desvios de desempenho por causa da alteração no clima.

Figura 55 – Correlação entre as variáveis termofísicas mais influentes no consumo de energia para resfriamento e o desvio padrão relativo de desempenho das amostras simuladas, em São Paulo, considerando os experimentos para curto (2020), médio (2050) e longo (2080) prazo



Fonte: o autor

Os modelos com menor absorptância solar na envoltória (com melhores desempenhos), apresentam RSD ligeiramente maiores (em torno de 10 pp), indicando que estão mais sujeitos a desvios de desempenho em virtude das mudanças climáticas, como notado para o consumo para resfriamento. Essa condição é parecida, embora menos expressiva, quando se analisa a correlação do RSD e da transmitância térmica das paredes externas, principalmente para os modelos com $1,65 \text{ W/m}^2\text{K}$.

Portanto, ocorre que habitações com bom desempenho (baixo consumo para resfriamento) no contexto climático atual têm uma tendência a sofrerem maiores perturbações em seu comportamento nos diferentes cenários futuros, porque são mais sensíveis à impactos que acarretam redução de desempenho. Por outro lado, há uma tendência de as propriedades que causam níveis de desempenho inferiores ocasionem um RSD menor, ou seja, os modelos com alta absorptância solar na envoltória e alta transmitância térmica nas paredes externas já apresentam respostas ruins nos cenários climáticos atuais, e, portanto, tem menos margem para piorar.

De todo modo, independentemente das definições construtivas, as habitações sofrerão impactos importantes em seu desempenho, sobretudo as que são tidas como ‘mais eficientes’ ou com ‘desempenho satisfatório’ em abordagens de simulações com as condições meteorológicas do passado.

4.1.3 Considerações Gerais sobre o Desempenho Térmico e Energético de Habitações para o Futuro

Os resultados descritos para o graus-hora e consumo de energia para resfriamento de habitações de interesse social em São Paulo direcionam algumas análises e considerações importantes no que concerne a habitações para o futuro, complementando algumas observações recentemente estabelecidas na bibliografia correlata.

Por meio do expressivo aumento no indicador de graus-hora para resfriamento nos períodos de progressão, constata-se que análise conjunta do desempenho do ambiente construído naturalmente ventilado e artificialmente condicionado é necessária. Tendo em vista que os graus-hora para resfriamento foram quantificados segundo o conforto térmico adaptativo, seu aumento (superior a 500% até o final do século) aponta a demanda de uso de aparelhos de ar-condicionado – já em expansão de uso no setor habitacional (Abrahão; Souza, 2021; PROCEL/Eletronbras, 2019) –, assim como sugere a bibliografia recente (Bracht *et al.*,

2024; Guarda, 2023; Hamdy *et al.*, 2017). Guarda (2023) relata que os aparelhos de ar-condicionado caracterizam uma solução importante para a habitabilidade, em termos de conforto térmico, do ambiente construído sob condições ambientais futuras.

Enfatizando a relação de variáveis termofísicas com o desempenho de habitações naturalmente ventiladas no clima de São Paulo, de modo similar à avaliação de Triana, Lamberts e Sassi (2018), o uso de cores claras na envoltória, isolamento e massa térmica das paredes externas, e ventilação natural são estratégias passivas necessárias para melhores níveis de desempenho em diferentes períodos da vida útil da construção, apesar de não serem suficientes para assegurar isso. Nesse sentido, os elevados valores de RSD indicam que a manutenção do bom desempenho – associado a resiliência – do ambiente naturalmente ventilado em diferentes períodos climáticos é mais difícil do que quando o ambiente é condicionado também por ar-condicionado (RSD menores do que os observados para a situação de ventilação natural).

Para o desempenho pelo CR, além do uso e cores claras, é pertinente comentar sobre os valores de transmitância térmica das paredes externas. Reduzir o valor da transmitância térmica possibilita reduzir o consumo de energia, impactando significativamente o fluxo de calor na envoltória (Rodrigues *et al.*, 2024). Nesse sentido, assim como este estudo, Rodrigues, Parente e Fernandes (2024) também mostraram que baixa transmitância térmica é favorável à robustez às mudanças climáticas, porque o consumo energético futuro é menor em edificações com maior isolamento térmico. Contudo, também se destaca que o isolamento excessivo (transmitância térmica muito baixa), é prejudicial para o desempenho, já que afeta a dissipação de calor interno em cenários de maiores temperaturas no futuro. De acordo com Rodrigues, Parente e Fernandes (2024), que investigaram transmitâncias térmicas ideais (intervalo de 0,05 a 1,25 W/m²K) em cenários de mudanças climáticas no Brasil, o isolamento excessivo não é muito vantajoso no clima de São Paulo, visto que valores muito baixos acarretam maior demanda de energia. Assim, a transmitância térmica 1,65 W/m²K analisada nesta pesquisa (relativamente próxima do limite superior 1,25 W/m²K avaliado por Rodrigues, Parente e Fernandes (2024)) se mostra mais adequada.

De modo complementar, cumpre salientar que as estratégias construtivas devem mudar com a evolução (aquecimento) do clima, sugerindo que os projetistas devem estudar estratégias diferentes, avaliando como o clima se altera em cada região (Rodrigues; Parente; Fernandes, 2024). Assim, para as definições construtivas, importa considerar as mudanças de classificações climáticas, por exemplo, como vem sendo proposto em etapas de pesquisas focadas nesse

campo (Beck *et al.*, 2018; Rodrigues; Parente; Fernandes, 2024; Silva *et al.*, 2024). As atualizações em orientações normativas de desempenho de edificações podem ser baseadas nos resultados apresentados e em novas classificações climáticas, direcionando requisitos para parâmetros termofísicos que auxiliem profissionais em tomadas de decisão sobre estratégias construtivas para o futuro. Por último, convém ponderar que essas estratégias devem ser associadas, baseadas em combinações de medidas que resultem em construções mais preparadas para os desafios climáticos previstos.

5 CONCLUSÕES

Diante da relevância e oportunidade de pesquisas referentes ao desempenho térmico e energético de edificações residenciais brasileiras, abrangendo os efeitos e riscos das mudanças climáticas, as contribuições deste trabalho abarcaram o desenvolvimento de um método de análise e, particularmente, a avaliação de parâmetros de desempenho de habitações de interesse social considerando incertezas no clima de São Paulo. Nesse sentido, o método desenvolvido e os resultados analisados podem orientar um procedimento simplificado para que profissionais da área possam analisar soluções de desempenho térmico e energético para edificações preparadas para o futuro de curto e de longo prazo.

A aplicação do método demonstrou que:

- a) Ignorar os efeitos das alterações no clima causam diferenças entre o desempenho avaliado atualmente e o desempenho previsto em situações de mudanças climáticas. Para o desempenho do ambiente naturalmente ventilado, em relação ao período TRY, a elevação nos graus-hora para resfriamento fica em torno de 136%, 246% e 534% no curto (2020), médio (2050) e longo prazo (2080). E para o desempenho da habitação com o uso de ar-condicionado, o aumento do consumo é de cerca de 90%, 165% e 300% no curto (2020), médio (2050) e longo prazo (2080);
- b) No clima de São Paulo, há uma correlação maior ($R^2 > 0,9$) entre o desempenho térmico e energético de habitações entre os cenários climáticos mais próximos (curto ou médio prazo);
- c) A inclusão da incerteza de desempenho pode proporcionar estimativas de desempenho mais adequadas e a consideração das variáveis mais influentes pode facilitar e promover decisões mais adequadas ao ambiente construído. Portanto, em estudos de desempenho térmico e energético, para resultados mais assertivos, as análises por meio de simulação não devem ser determinísticas, mas sim probabilísticas;
- d) Uma vez que as habitações, usualmente, são construídas para durar, pelo menos, 50 anos, e reconhecendo o comprovado impacto das mudanças climáticas no desempenho térmico e energético do ambiente construído, as análises de medidas relacionadas à resiliência, como o RSD calculado, podem ajudar nas definições de estratégias construtivas;
- e) A análise da influência de variáveis termofísicas na classificação de desempenho nos diferentes cenários climáticos de São Paulo mostraram que, para a habitação

condicionada naturalmente (analisada por meio do indicador GHR), melhores resultados são alcançados com absorvância solar da envoltória igual a 0,2 e 0,4, transmitância térmica igual a 1,65 W/m²K, capacidade térmica igual a 445 kJ/m²K e fator de ventilação das janelas externas igual a 0,9; e, para a habitação condicionada artificialmente (analisada por meio do indicador CR), melhores resultados são alcançados com absorvância solar da envoltória igual a 0,2 e 0,4 e transmitância térmica igual a 0,27 e 1,65 W/m²K;

- f) As definições construtivas são determinantes para que a habitação seja mais eficiente em diferentes períodos e a manutenção de um padrão no comportamento das variáveis pode auxiliar projetistas e pesquisadores no desafio de se construir edifícios mais resilientes. É necessário observar que as habitações com definições construtivas mais eficientes são, também, as mais suscetíveis a impactos (variações de desempenho) decorrentes de alterações no clima, de acordo com os maiores valores de RSD.

Essas contribuições da pesquisa são oportunas à atual demanda de conhecimento sobre dificuldades de se considerar alterações no clima. Quanto maior o conhecimento sobre o tema, maior a possibilidade de resiliência às mudanças. Por fim, é evidente que esta pesquisa não soluciona as questões ambientais abarcadas pelo tema discutido, mas pode ajudar na preparação de moradias para o futuro.

5.1 LIMITAÇÕES DO TRABALHO

As seguintes limitações do trabalho devem ser observadas:

- a) A revisão sistemática foi desenvolvida no final de 2022. Portanto, algumas pesquisas mais recentes que, eventualmente, possam ter contribuído com definições e atualizações para procedimentos mais assertivos ou mais simplificados na área de estudo não foram consideradas para a execução das etapas finais desta tese;
- b) As análises consideraram apenas o cenário SRES-A2 do IPCC. Nesse sentido, as progressões climáticas possuem incertezas intrínsecas, que sugerem também a consideração de mais cenários de emissões de poluentes e estimativas futuras. Além do mais, uma vez que as progressões de arquivos climáticos são baseadas em dados anteriores, possíveis inconsistências nas variáveis podem prejudicar as progressões;
- c) O estudo foi desenvolvido para um modelo de habitação unifamiliar isolada (sem entorno) situada no clima de São Paulo. Assim, as análises são válidas para a tipologia

residencial específica, segundo as definições de clima, arquitetura, uso, ocupação e operação;

- d) Apenas algumas variáveis termofísicas de projeto de edificações foram consideradas. Logo, outras condições e estratégias projetuais poderiam ser incluídas em outras análises, de acordo com a finalidade delas. Além disso, há que se considerar que o projeto de uma habitação envolve outras variáveis, relacionadas a aspectos estéticos, econômicos e sociais, por exemplo, não considerados na investigação;
- e) O tamanho da amostra foi relativamente pequeno, visando explorar e complementar dados e análises prévias. Dispor de informações em quantidade e qualidade satisfatória é uma das etapas mais desafiadoras na área de estudo. Embora seja de interesse do pesquisador obter o maior volume de dados possível, limitações operacionais, econômicas e de tempo e esforço computacional interferem na obtenção e análise de muitos modelos. Assim, mesmo que a inferência bayesiana tenha sido aplicada muito oportunamente e com êxito, no sentido de otimizar as estimativas de probabilidade, a análise da influência de variáveis na classificação de desempenho proposta pode ter sido impactada por causa do campo amostral explorado na amostragem reduzida;
- f) O método de análise desenvolvido não foi validado, por meio de medições e/ou verificações comparativas de classificações análogas às propostas nesta tese (baseadas em dados climáticos históricos), para se averiguar eventuais similaridades/equivalências nos níveis de classificação.

5.2 SUGESTÕES PARA TRABALHOS

As seguintes ideias de trabalhos são sugeridas:

- a) Analisar as incertezas de desempenho quando considerados outros cenários de projeções climáticas e/ou outros arquivos climáticos com conjuntos de dados meteorológicos típicos e extremos, desenvolvidos recentemente para estudar a resiliência de edifícios às mudanças climáticas e ondas de calor – incluindo dados para São Paulo (Machard *et al.*, 2024);
- b) Considerar outros indicadores de desempenho, como o percentual de horas de ocupação da unidade habitacional dentro da faixa de temperatura operativa, carga térmica de refrigeração, carga térmica total da unidade habitacional, entre outros, observando eventuais diferenças associadas ao método de análise;

- c) Estudar o desempenho de outros tipos de habitações ou, ainda, outros tipos de edificações (comerciais e de serviços, por exemplo), buscando entender se e como as diferenças de ocupação e uso afetariam os resultados e as análises.

REFERÊNCIAS

- ABNT. **NBR 15220: Desempenho Térmico de Edificações**. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2005.
- ABNT. **NBR 16401: Instalações de ar-condicionado**. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2008.
- ABNT. **NBR 15575: Edificações habitacionais - Desempenho**. Rio de Janeiro: Associação Brasileira de Normas Técnicas, 2024.
- ABRAHÃO, K. C. D. F. J.; SOUZA, R. G. V. Estimativa da evolução do uso final de energia elétrica no setor residencial do Brasil por região geográfica. **Ambiente Construído**, v. 21, n. 2, p. 383-408, 2021. <https://doi.org/10.1590/s1678-86212021000200532>.
- ADELARD, L. *et al.* A detailed weather data generator for building simulations. **Energy and Buildings**, v. 31, n. 1, p. 75–88, 2000. [doi.org/10.1016/S0378-7788\(99\)00009-2](https://doi.org/10.1016/S0378-7788(99)00009-2).
- AHMED, T.; MUTTAQI, K. M.; AGALGAONKAR, A. P. Climate change impacts on electricity demand in the State of New South Wales, Australia. **Applied Energy**, v. 98, p. 376-383, 2012. <https://doi.org/10.1016/j.apenergy.2012.03.059>.
- ALESSANDRINI, J.-M.; RIBÉRON, J.; DA SILVA, D. Will naturally ventilated dwellings remain safe during heatwaves? **Energy and Buildings**, v. 183, p. 408-417, 2019. <https://doi.org/10.1016/j.enbuild.2018.10.033>.
- ALFRAIDI, Y.; BOUSSABAIN, A. Design Resilient Building Strategies in Face of Climate Change. **Design Resilient Building Strategies in Face of Climate Change**, v. 9, n. 1, p. 23–28, 2015. <https://doi.org/10.5281/zenodo.1338054>.
- ALMEIDA, L. S. S. **Influência de parâmetros físicos e geométricos no desempenho termoenergético de habitações unifamiliares**. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal de Santa Catarina, Florianópolis, 2014.
- ALVARES, C. A. *et al.* Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013. doi.org/10.1127/0941-2948/2013/0507.
- ALVES, C. A.; DUARTE, D. H. S.; GONÇALVES, F. L. T. Residential buildings thermal performance and comfort for the elderly under climate changes context in the city of São Paulo, Brazil. **Energy and Buildings**, v. 114, p. 62–71, 2016. doi.org/10.1016/j.enbuild.2015.06.044.
- ANDERSEN, R.; NEGENDAHL, K. Lifespan prediction of existing building typologies. **Journal of Building Engineering**, v. 65, 105696, 2023. doi.org/10.1016/j.job.2022.105696.
- ANGELOCCI, L. R.; SENTELHAS, P. C. **Variabilidade, anomalia e mudança climática**. Notas de aula, Departamento de Ciências Exatas, Universidade de São Paulo, São Paulo, 2007.
- ASHRAE. **Fundamentals**. Atlanta, GA: American Society of Heating, Refrigerating and Air-conditioning Engineers, 2005.

ASHRAE. **Standard 55 - Thermal Environmental Conditions for Human Occupancy**. Atlanta, GA: American Society of Heating, Refrigerating and Air-conditioning Engineers, 2017a.

ASHRAE. **Fundamentals (SI Edition)**. Atlanta, GA: American Society of Heating, Refrigerating and Air-conditioning Engineers, 2017b.

ASHRAE. **Standard 55-2023: Thermal Environmental Conditions for Human Occupancy**. Atlanta: American Society of Heating, Refrigerating and Air-conditioning Engineers, 2023.

ASKIE, L.; OFFRINGA, M. Systematic reviews and meta-analysis. **Seminars in Fetal and Neonatal Medicine**, v. 20, p. 403-409, 2015. <https://doi.org/10.1016/j.siny.2015.10.002>.

ATTIA, S. *et al.* Resilient cooling of buildings to protect against heat waves and power outages: Key concepts and definition. **Energy and Buildings**, v. 239, 110869, 2021. <https://doi.org/10.1016/j.enbuild.2021.110869>.

BAKER, E.; CHALLENGOR, P.; EAMES, M. Future Proofing a Building Design using History Matching Inspired Level-set Techniques. **Journal of the Royal Statistical Society Series C: Applied Statistics**, v. 70, n. 2, p. 335-350, 2021. <https://doi.org/10.1111/rssc.12461>.

BECK, H. *et al.* Present and future Köppen-Geiger climate classification maps at 1-km resolution. **Scientific Data**, v. 5, 180214, 2018. <https://doi.org/10.1038/sdata.2018.214>.

BELCHER, S. E.; HACKER, J. N.; POWELL, D. S. Constructing design weather data for future climates. **Building Services Engineering Research and Technology**, v. 26, n. 1, p. 49-61, 2005. doi.org/10.1191/0143624405bt112.

BENGTSSON, J.; HARGREAVES, R.; PAGE, I. C. **Assessment of the Need to Adapt Buildings in New Zealand to the Impacts of Climate Change**. Porirua, New Zealand: BRANZ, 2007. p. 63-70.

BERARDI, U.; JAFARPUR,. Assessing the impact of climate change on building heating and cooling energy demand in Canada. **Renewable and Sustainable Energy Reviews**, v. 121, 109681, 2020. doi.org/10.1016/j.rser.2019.109681.

BERRANG-FORD, L. *et al.* A systematic global stocktake of evidence on human adaptation to climate change. **Nature Climate Change**, v. 11, p. 989-1000, 2021. doi.org/10.1038/s41558-021-01170-y.

BHIMJI, W. **Guidance on the use of strategic futures analysis for policy development in government**. Londres: Foresight Horizon Scanning Centre, 2009.

BOOTH, A. T.; CHOUDHARY, R.; SPIEGELHALTER, J. Handling uncertainty in housing stock models. **Building and Environment**, v. 48, p. 35-47, 2012. doi.org/10.1016/j.buildenv.2011.08.016.

BORREGO, C. E. A. Modelling uncertainty estimation procedures for air quality assessment. Proceedings of the 3rd International Symposium on Air Quality Management at Urban, Regional and Global Scales (AQM). **Anais...** Istanbul, Turkey: [s.n.], 2005. p. 26-30.

BORTONE, H. *et al.* Thermo-Energetic Performance of Wood Frame Panels in Brazilian Low-Income Housing. ZEMCH 2018 International Conference. **Anais...** Melbourne: [s.n.], 2018. p. 161-178.

BOSHER, L. *et al.* Realising a resilient and sustainable built environment: towards a strategic agenda for the United Kingdom. **Disasters**, v. 31, n. 3, p. 236-255, 2007. <https://doi.org/10.1111/j.1467-7717.2007.01007.x>.

BRACHT, M. K. *et al.* Multiple regional climate model projections to assess building thermal performance in Brazil: Understanding the uncertainty. **Journal of Building Engineering**, v. 88, 109248, 2024. <https://doi.org/10.1016/j.jobbe.2024.109248>.

BRANGER, F. *et al.* Global sensitivity analysis of an energy-economy model of the residential building sector. **Environmental Modelling & Software**, v. 70, p. 45–54, 2015. <https://doi.org/10.1016/j.envsoft.2015.03.021>.

BRASIL. **Diretriz para Avaliação Técnica de Produtos – Diretriz SINAT N° 005 Sistemas construtivos estruturados em peças de madeira maciça serrada, com fechamentos em chapas delgadas (Sistemas leves tipo “Light Wood Framing”)**. Brasília: Ministério das Cidades. Programa Brasileiro da Qualidade e Produtividade do Habitat – PBQP-H, 2011b.

BRASIL. **Balanço Energético Nacional 2023: ano base 2022**. Rio de Janeiro: Empresa de Pesquisa Energética, 2023a. 275.

BRASIL. **Anuário estatístico de energia elétrica 2023 - ano base 2022**. Rio de Janeiro: Ministério de Minas e Energia, Empresa de Pesquisa Energética, 2023b.

BRASIL. **BEN 2024: relatório síntese**. Rio de Janeiro: Empresa de Pesquisa Energética, 2024. 71.

BREESCH, H.; JANSSENS, A. Performance evaluation of passive cooling in office buildings based on uncertainty and sensitivity analysis. **Solar Energy**, v. 84, n. 8, p. 1453–1467, 2010. <https://doi.org/10.1016/j.solener.2010.05.008>.

BROHUS, H. *et al.* Quantification of uncertainty in predicting building energy consumption: A stochastic approach. **Energy and Buildings**, v. 55, p. 127-140, 2012. doi.org/10.1016/j.enbuild.2012.07.013.

BROTAS, L.; LAFUENTE, J. The impact of the Urban Heat Island in the energy consumption and overheating of domestic buildings in London. Proceedings of 8th Windsor Conference: Counting the Cost of Comfort in a Changing World. **Anais...** [S.l.]: [s.n.], 2014. p. 805-815.

BUENO, B. *et al.* The urban weather generator. **Journal of Building Performance Simulation**, v. 6, n. 4, p. 269-281, 2013. <https://doi.org/10.1080/19401493.2012.718797>.

BURKE, D. T.; HYND, P.; PRIYADARSHINI, A. Quantifying farm-to-fork greenhouse gas emissions for five dietary patterns. **Resources, Environment and Sustainability**, v. 12, 100108, 2023. doi.org/10.1016/j.resenv.2023.100108.

BURMAN, E.; KIMPIAN, J.; MUMOVIC, D. **Reconciling resilience and sustainability in overheating and energy performance assessments of non-domestic buildings**. London: Centre for Urban Sustainability and Resilience, University College London, 2014.

CAMPANIÇO, H. *et al.* Impact of climate change on building cooling potential of direct ventilation and evaporative cooling: A high resolution view for the Iberian Peninsula. **Energy and Buildings**, v. 192, p. 31-44, 2019. <https://doi.org/10.1016/j.enbuild.2019.03.017>.

CAMPOLONGO, F.; CARIBONI, J.; SALTELLI, A. An effective screening design for sensitivity analysis of large models. **Environmental Modelling & Software**, v. 22, n. 10, 1509-1518, 2007. doi.org/10.1016/j.envsoft.2006.10.004.

CAMPOLONGO, F.; SALTELLI, A. Sensitivity analysis of an environmental model; an application of different analysis methods. **Reliability Engineering & System Safety**, v. 57, n. 1, p. 49-69, 1997. [https://doi.org/10.1016/S0951-8320\(97\)00021-5](https://doi.org/10.1016/S0951-8320(97)00021-5).

CAMPOLONGO, F.; TARANTOLA, S.; SALTELLI, A. Tackling quantitatively large dimensionality problems. **Computer Physics Communications**, v. 117, n. 1-2, p. 75-85, 1999. [https://doi.org/10.1016/S0010-4655\(98\)00165-9](https://doi.org/10.1016/S0010-4655(98)00165-9).

CANEPA, M. *et al.* Ecolopes, beyond greening. A multi-species approach for urban design. **AGATHÓN – International Journal of Architecture, Art and Design**, v. 11, p. 238-245, 2022. doi.org/10.19229/2464-9309/11212022.

CARLO, J. C.; LAMBERTS, R. **Processamento de Arquivos Climáticos para Simulação do Desempenho Energético de Edificações**. Laboratório de Eficiência Energética em Edificações, Universidade Federal de Santa Catarina, Florianópolis, 2005. Disponível em: https://labeee.ufsc.br/sites/default/files/arquivos_climaticos/RT200504.pdf. Acesso em: 29 dez. 2022.

CASAGRANDE, B. G.; ALVAREZ, C. E. Preparação de arquivos climáticos futuros para avaliação dos impactos das mudanças climáticas no desempenho termoenergético de edificações. **Ambiente Construído**, v. 13, n. 4, p. 173-187, 2013. doi.org/10.1590/S1678-86212013000400012.

CASTALDO, V. L.; PISELLO, A. L. Uses of dynamic simulation to predict thermal-energy performance of buildings and districts: a review. **WIREs Energy and Environment**, v. 7, n. 1, e269, 2018. <https://doi.org/10.1002/wene.269>.

CB3E. **Proposta de Instrução Normativa Inmetro para a Classe de Eficiência Energética de Edificações Residenciais**. Florianópolis: Centro Brasileiro de Eficiência Energética em Edificações, 2018.

CETIN, K. S.; MANUEL, ; NOVOSELAC,. Thermal comfort evaluation for mechanically conditioned buildings using response surfaces in an uncertainty analysis framework. **Science and Technology for the Built Environment**, v. 22, n. 2, p. 140-152, 2016. doi.org/10.1080/23744731.2015.1100022.

CHAROENKIT, S.; KUMAR, S. Building low-carbon and disaster-resilient communities: Integrating climate mitigation and adaptation into the assessment of self-help housing design.

Mitigation and Adaptation Strategies for Global Change, v. 22, p. 695–728, 2017.
<https://doi.org/10.1007/s11027-015-9694-4>.

CHATURVEDI, S.; RAJASEKAR, E. Application of a probabilistic LHS-PAWN approach to assess building cooling energy demand uncertainties. **Building Simulation**, v. 15, p. 373–387, 2022. <https://doi.org/10.1007/s12273-021-0815-6>.

CHATURVEDI, S.; RAJASEKAR, E.; NATARAJAN, S. Multi-objective building design optimization under operational uncertainties using the NSGA II algorithm. **Buildings**, v. 10, n. 5, 88, 2020. <https://doi.org/10.3390/buildings10050088>.

CHITALE, J. *et al.* An effective parameter screening strategy for high dimensional models. Proceedings of the ASME 2017 International Mechanical Engineering Congress and Exposition. **Anais...** Tampa: The American Society of Mechanical Engineers, 2017.

CRAWLEY, D. B. Estimating the impacts of climate change and urbanization on building performance. **Journal of Building Performance Simulation**, v. 1, n. 2, p. 91–115, 2008.
<https://doi.org/10.1080/19401490802182079>.

CRAWLEY, D. B.; LAWRIE, L. K. Rethinking the TMY: is the ‘typical’ meteorological year best for building performance simulation? 14th Conference of International Building Performance Simulation Association. **Anais...** Hyderabad, India: [s.n.], 2015. p. 2655–2662.

DAN, D. *et al.* Passive house design—An efficient solution for residential buildings in Romania. **Energy for Sustainable Development**, v. 32, p. 99–109, 2016.
<https://doi.org/10.1016/j.esd.2016.03.007>.

DAVIS, L. W.; GERTLER, P. J. Contribution of air conditioning adoption to future energy use under global warming. **Proceedings of the National Academy of Sciences**, v. 112, n. 19, p. 5962–5967, 2015. <https://doi.org/10.1073/pnas.1423558112>.

DE CIAN, E. *et al.* Households’ adaptation in a warming climate. Air conditioning and thermal insulation choices. **Environmental Science & Policy**, v. 100, p. 136–157, 2019.
<https://doi.org/10.1016/j.envsci.2019.06.015>.

DE MASI, R. F. *et al.* Impact of weather data and climate change projections in the refurbishment design of residential buildings in cooling dominated climate. **Applied Energy**, v. 303, 117584, 2021. <https://doi.org/10.1016/j.apenergy.2021.117584>.

DE VECCHI, R. *et al.* Application of the adaptive model proposed by ASHRAE 55 in the Brazilian climate context: raising some issues. 8th Windsor Conference. **Anais...** Londres: [s.n.], 2014.

DE WILDE, P.; TIAN, W. Identification of key factors for uncertainty in the prediction of the thermal performance of an office building under climate change. **Building Simulation**, v. 2, p. 157–174, 2009. doi.org/10.1007/s12273-009-9116-1.

DE WILDE, P.; TIAN, W. Towards probabilistic performance metrics for climate change impact studies. **Energy and Buildings**, v. 43, p. 3013–3018, 2011.
doi.org/10.1016/j.enbuild.2011.07.014.

DE WILDE, P.; TIAN, W. Management of thermal performance risks in buildings subject to climate change. **Building and Environment**, v. 55, p. 167-177, 2012. doi.org/10.1016/j.buildenv.2012.01.018.

DE WIT, S.; AUGENBROE, G. Analysis of uncertainty in building design evaluations and its implications. **Energy and Buildings**, v. 34, n. 9, p. 951-958, 2002. doi.org/10.1016/S0378-7788(02)00070-1.

DEETMAN, S. *et al.* Modelling global material stocks and flows for residential and service sector buildings towards 2050. **Journal of Cleaner Production**, v. 245, 118658, 2020. doi.org/10.1016/j.jclepro.2019.118658.

DEVUYST, D.; HENS, L.; DE LANNOY, W. **Sustainability assessment and management of urban environments**. Nova York: Columbia University Press, 2001.

DICKINSON, R.; BRANNON, B. Generating future weather files for resilience. 36th International Conference on Passive and Low Energy Architecture. **Anais...** Los Angeles: PLEA, 2016.

DOE. U.S. EnergyPlus. **EnergyPlus 9.3**, 2020. Disponível em: <https://energyplus.net/downloads>. Acesso em: 14 abr. 2024.

DOE. U.S. **Input Output Reference**. 2015. [S.l.]: U.S. Department of Energy, 2015.

DOE. U.S. **EnergyPlus Engineering Reference**. [S.l.]: U.S. Department of Energy, 2021.

DOE. U.S. Weather data. **Department of Energy**, 2023. Disponível em: <https://energyplus.net/weather>. Acesso em: 05 novembro 2023.

DU, Y.-M. *et al.* Maximum entropy approach to reliability. **Physical Review E**, v. 101, 012106, 2020. <https://doi.org/10.1103/PhysRevE.101.012106>.

EBRAHIMPOUR, A.; MAEREFAT, M. A method for generation of typical meteorological year. **Energy Conversion and Management**, v. 51, n. 3, p. 410-417, 2010. <https://doi.org/10.1016/j.enconman.2009.10.002>.

EM-IAG-USP. Dados meteorológicos medidos de 01/01/2011 a 30/06/2023: temperatura de bulbo seco; umidade relativa do ar; radiação solar global; velocidade do vento. **Estação Meteorológica do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo**, 2023. ISSN http://www.estacao.iag.usp.br/sol_dados.php. Acesso em: 03 dez. 2023.

ERBA, S.; CAUSONE, F.; ARMANI, R. The effect of weather datasets on building energy simulation outputs. **Energy Procedia**, v. 134, p. 545-554, 2017. <https://doi.org/10.1016/j.egypro.2017.09.561>.

EURACHEM/CITAC. **Guide, Quantifying Uncertainty in Analytical Measurement**. 2. ed. [S.l.]: [S.n.], 2000.

FAN, X.; THOMPSON, B.; WANG, L. Effects of sample size, estimation methods, and model specification on structural equation modeling fit indexes. **Structural Equation**

Modeling: A Multidisciplinary Journal, v. 6, n. 1, p. 56-83, 1999.
<https://doi.org/10.1080/10705519909540119>.

FARAH, S. *et al.* Integrating climate change into meteorological weather data for building energy simulation. **Energy and Buildings**, v. 183, p. 749–760, 2019.
<https://doi.org/10.1016/j.enbuild.2018.11.045>.

FATICHI, S.; IVANOV, V. Y.; CAPORALI, E. **AWE-GEN: Advanced WEather GENerator**. [S.l.]: Technical Reference, version 1.0, 2011a. 80.

FATICHI, S.; IVANOV, V. Y.; CAPORALI, E. Simulation of future climate scenarios with a weather generator. **Advances in Water Resources**, v. 34, p. 448-467, 2011b.
[doi:10.1016/j.advwatres.2010.12.013](https://doi.org/10.1016/j.advwatres.2010.12.013).

FIOCCHI, L. C.; HOQUE, S. T.; WEIL, B. S. Matching building energy simulation results against measured data with weather file compensation factors. **ASHRAE Transactions**, v. 120, n. 2, p. 397-405, 2014.

FJP. **Déficit habitacional no Brasil – 2016-2019**. Belo Horizonte: Fundação João Pinheiro, 2021a.

FJP. **Inadequação de domicílios no Brasil – 2016-2019**. Belo Horizonte: Fundação João Pinheiro, 2021b.

FLORES-LARSEN, S.; FILIPPÍN, C. Energy efficiency, thermal resilience, and health during extreme heat events in low-income housing in Argentina. **Energy and Buildings**, v. 231, 110576, 2021. <https://doi.org/10.1016/j.enbuild.2020.110576>.

FONSECA, J. A.; NEVAT, I.; PETERS, G. W. Quantifying the uncertain effects of climate change on building energy consumption across the United States. **Applied Energy**, v. 277, 115556, 2020. doi.org/10.1016/j.apenergy.2020.115556.

FRANCO, V. R. O uso da inferência Bayesiana em análises psicométricas. **Avaliação Psicológica**, v. 21, n. 2, p. 127-250, 2022. <http://dx.doi.org/10.15689/ap.2022.2102.ed>.

FUJIMOTO, R. *et al.* Ambient heat exposure after the rainy season is associated with an increased risk of Stroke. **European Heart Journal**, v. 44, n. Supplement_1, ehac779.087, 2023. doi.org/10.1093/eurheartj/ehac779.087.

FÜRBRINGER, J.-M.; ROULET, C. A. Confidence of simulation results: put a sensitivity analysis module in your MODEL: The IEA-ECBCS Annex 23 experience of model evaluation. **Energy and Buildings**, v. 30, n. 1, p. 61-71, 1999. [doi.org/10.1016/S0378-7788\(98\)00046-2](https://doi.org/10.1016/S0378-7788(98)00046-2).

GAO, C. *et al.* Model averaging and probability of detection estimation under hierarchical uncertainties for Lamb wave detection. **Mechanical Systems and Signal Processing**, v. 165, 108302, 2022. <https://doi.org/10.1016/j.ymssp.2021.108302>.

GARCIA, G. D.; LIMA JR, R. M. Introdução à estatística bayesiana aplicada à linguística. **Revista da Abralin**, v. 20, n. 2, p. 1-24, 2021. <https://doi.org/10.25189/rabralin.v20i2.1914>.

- GATERELL, M. R.; MCEVOY, M. E. The impact of climate change uncertainties on the performance of energy efficiency measures applied to dwellings. **Energy and Buildings**, v. 37, p. 982–995, 2005. <https://doi.org/10.1016/j.enbuild.2004.12.015>.
- GEORGIADOU, M. C.; HACKING, T.; GUTHRIE, P. A conceptual framework for future-proofing the energy performance of buildings. **Energy Policy**, v. 47, p. 145-155, 2012. doi.org/10.1016/j.enpol.2012.04.039.
- GEORGIADOU, M. C.; HACKING, T.; GUTHRIE, P. Future-proofed energy design for dwellings: Case studies from England and application to the Code for Sustainable Homes. **Building Services Engineering Research and Technology**, v. 34, n. 1, p. 1-22, 2013. <https://doi.org/10.1177/0143624412463016>.
- GEROS, V. *et al.* Experimental evaluation of night ventilation phenomena. **Energy and Buildings**, v. 29, n. 2, p. 141-154, 1999. [https://doi.org/10.1016/S0378-7788\(98\)00056-5](https://doi.org/10.1016/S0378-7788(98)00056-5).
- GOFFART, J.; MARA, T.; WURTZ, E. Generation of stochastic weather data for uncertainty and sensitivity analysis of a low-energy building. **Journal of Building Physics**, v. 45, n. 1, p. 41–57, 2017. <https://doi.org/10.1177/1744259116668598>.
- GOULART, S.; LAMBERTS, R.; FIRMINO, S. **Dados climáticos para projeto e avaliação energética de edificações para 14 cidades brasileiras**. Núcleo de Pesquisa em Construção/UFSC, Florianópolis, 1998.
- GUAN, L. Preparation of future weather data to study the impact of climate change on buildings. **Building and Environment**, v. 44, n. 4, p. 793-800, 2009. <https://doi.org/10.1016/j.buildenv.2008.05.021>.
- GUARDA, E. L. A. *et al.* The influence of climate change on renewable energy systems designed to achieve zero energy buildings in the present: A case study in the Brazilian Savannah. **Sustainable Cities and Society**, v. 52, 101843, 2020. doi.org/10.1016/j.scs.2019.101843.
- GUARDA, E. L. A. **Análise das condições internas de edificações residenciais em projeções climáticas futuras: avaliando a vulnerabilidade dos ocupantes e a eficácia de estratégias passivas de projeto**. Tese (Doutorado em Arquitetura e Urbanismo, Florianópolis, 2023).
- GUPTA, R.; GREGG, M. Using UK climate change projections to adapt existing English homes for a warming climate. **Building and Environment**, v. 55, p. 20-42, 2012. doi.org/10.1016/j.buildenv.2012.01.014.
- HACKING, T. Improved energy performance in the built environment: unpicked ‘low-hanging fruit’? Proceedings of the Conference on Building physics and the Sustainable City. **Anais...** Cambridge: University of Cambridge, 2009.
- HALLEGATTE, S. Strategies to adapt to an uncertain climate change. **Global Environmental Change**, v. 19, n. 2, p. 240-247, 2009. <https://doi.org/10.1016/j.gloenvcha.2008.12.003>.

HAMDY, M. *et al.* The impact of climate change on the overheating risk in dwellings—A Dutch case study. **Building and Environment**, v. 122, p. 307-323, 2017. <https://doi.org/10.1016/j.buildenv.2017.06.031>.

HE, J. *et al.* Bayesian inference under small sample sizes using general noninformative priors. **Mathematics**, v. 9, n. 21, 2810, 2021. <https://doi.org/10.3390/math9212810>.

HE, J.; CHEN, J.; GUAN, X. Lifetime distribution selection for complete and censored multi-level testing data and its influence on probability of failure estimates. **Structural and Multidisciplinary Optimization**, v. 62, p. 1-17, 2020. <https://doi.org/10.1007/s00158-019-02465-7>.

HELTON, J. C. **Conceptual and computational basis for the quantification of margins and uncertainty**. Springfield: Sandia National Laboratories, 2009. 339.

HEO, Y.; CHOUDHARY, R.; AUGENBROE, G. A. Calibration of building energy models for retrofit analysis under uncertainty. **Energy and Buildings**, v. 47, p. 550-560, 2012. <https://doi.org/10.1016/j.enbuild.2011.12.029>.

HOMAEI, S.; HAMDY, M. Thermal resilient buildings: How to be quantified? A novel benchmarking framework and labelling metric. **Building and Environment**, v. 201, 108022, 2021. <https://doi.org/10.1016/j.buildenv.2021.108022>.

HONG, T.; CHANG, W.-K.; LIN, H.-W. A fresh look at weather impact on peak electricity demand and energy use of buildings using 30-year actual weather data. **Applied Energy**, v. 111, p. 333–350, 2013. <https://doi.org/10.1016/j.apenergy.2013.05.019>.

HOSSEINI, M.; JAVANROODI, K.; NIK, V. M. High-resolution impact assessment of climate change on building energy performance considering extreme weather events and microclimate – Investigating variations in indoor thermal comfort and degree-days. **Sustainable Cities and Society**, v. 78, 103634, 2022. <https://doi.org/10.1016/j.scs.2021.103634>.

HOSSEINI, M.; LEE, B.; VAKILINIA, S. Energy performance of cool roofs under the impact of actual weather data. **Energy and Buildings**, v. 145, p. 284–292, 2017. <https://doi.org/10.1016/j.enbuild.2017.04.006>.

HOX, J. J. C. M. H.; VAN DE SCHOOT, R.; MATTHIJSSE, S. How few countries will do? Comparative survey analysis from a Bayesian perspective. **Survey Research Methods**, v. 6, p. 87-93, 2012. <https://doi.org/10.18148/srm/2012.v6i2.5033>.

HU, M.; QIU, Y. A comparison of building energy codes and policies in the USA, Germany, and China: Progress toward the net-zero building goal in three countries. **Clean Technologies and Environmental Policy**, v. 21, p. 291-305, 2019. <https://doi.org/10.1007/s10098-018-1636-x>.

HUND, E.; MASSART, D. L.; SMEYERS-VERBEKE, J. Operational definitions of uncertainty. **TrAC Trends in Analytical Chemistry**, v. 20, n. 8, p. 394-406, 2001. [https://doi.org/10.1016/S0165-9936\(01\)00089-9](https://doi.org/10.1016/S0165-9936(01)00089-9).

IBGE. **Censo demográfico 2022: população e domicílios**. [S.l.]: Instituto Brasileiro de Geografia e Estatística, 2022.

IBGE. **Censo Demográfico 2022: Características dos domicílios**. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística -, 2024. 53.

IEA. **The future of cooling. Opportunities for Energy-Efficient Air Conditioning**. [S.l.]: International Energy Agency, 2018.

IEA. **World Energy Outlook 2023**. [S.l.]: International Energy Agency, 2023.

IEA-EBC. **IEA EBC Annex 80 on Resilient Cooling for Residential and Small Non-Residential Buildings**. [S.l.]: International Energy Agency; Energy in Buildings and Communities, 2019. p. 1-14.

IFBQ. **Documento de Avaliação Técnica. DATec n.20. Sistema construtivo leve em madeira**. [S.l.]: Instituto Falcão Bauer da Qualidade, 2013.

INVIDIATA, A.; GHISI, E. Impact of climate change on heating and cooling energy demand in houses in Brazil. **Energy and Buildings**, v. 130, p. 20-32, 2016. doi.org/10.1016/j.enbuild.2016.07.067.

IOANNOU, A.; ITARD, L. C. M. Energy performance and comfort in residential buildings: Sensitivity for building parameters and occupancy. **Energy and Buildings**, v. 92, p. 216-233, 2015. <https://doi.org/10.1016/j.enbuild.2015.01.055>.

IOOSS, B. *et al.* R Package ‘sensitivity’. **Global Sensitivity Analysis of Model Outputs. Version 1.20.0. CRAN**, 2020. Disponível em: <https://cran.r-project.org/package=sensitivity>. Acesso em: 02 jun. 2020.

IPCC. **Climate Change 2001: Synthesis Report**. Cambridge: Intergovernmental Panel on Climate Change, 2001.

IPCC. **Climate Change 2007: Synthesis Report. Contribution of Working Groups I, II and III to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change**. Geneva: Intergovernmental Panel on Climate Change, 2007.

IPCC. **Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation: Special Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press: Intergovernmental Panel on Climate Change, 2012.

IPCC. **Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge, United Kingdom and New York, NY, USA: Intergovernmental Panel on Climate Change, 2013. 1535.

IPCC. **Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**. Geneva: Intergovernmental Panel on Climate Change, 2014.

IPCC. **Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge, United Kingdom and New York, NY, USA: Intergovernmental Panel on Climate Change, 2021. 2391.

ISO. **Guide to the Expression of Uncertainty in Measurement**. Geneva: International Organization for Standardization, 1995.

IVANOV, V. Y.; BRAS, R. L.; CURTIS, D. C. A weather generator for hydrological, ecological, and agricultural applications. **Water Resources Research**, v. 43, n. 10, p. 1-21, 2007. <https://doi.org/10.1029/2006WR005364>.

JANUTA, A. Explainer: The U.N. climate report's five futures - decoded. **Reuters**, 2021. Disponível em: <https://www.reuters.com/business/environment/un-climate-reports-five-futures-decoded-2021-08-09/>. Acesso em: 29 janeiro 2024.

JAVAD, K.; NAVID, G. Thermal comfort investigation of stratified indoor environment in displacement ventilation: Climate-adaptive building with smart windows. **Sustainable Cities and Society**, v. 46, 101354, 2019. <https://doi.org/10.1016/j.scs.2018.11.029>.

JAVANROODI, K.; MAHDAVINEJAD, M.; NIK, V. M. Impacts of urban morphology on reducing cooling load and increasing ventilation potential in hot-arid climate. **Applied Energy**, v. 231, p. 714-746, 2018. <https://doi.org/10.1016/j.apenergy.2018.09.116>.

JENTSCH, M. F. *et al.* Transforming existing weather data for worldwide locations to enable energy and building performance simulation under future climates. **Renewable Energy**, v. 55, p. 514-524, 2013. <https://doi.org/10.1016/j.renene.2012.12.049>.

JENTSCH, M. F. **Climate Change Weather File Generators: Technical reference manual for the CCWeatherGen and CCWorldWeatherGen tools. Version 1.2**. Southampton: University of Southampton, 2012.

JENTSCH, M. F.; BAHAI, A. S.; JAMES, P. A. B. **Manual CCWorldWeatherGen. Climate change world weather file generator. Version 1.7**. Southampton: University of Southampton, 2012.

JEWELL, J. *et al.* **The future climate for development scenarios for low-income countries in a climate-changing world**. Londres: Forum for the Future, 2010. 90.

JOSEPH, L.; BÉLISLE, P. Bayesian consensus-based sample size criteria for binomial proportions. **Statistics in Medicine**, v. 38, p. 4566-4573, 2019. <https://doi.org/10.1002/sim.8316>.

KAVGIC, M. *et al.* A review of bottom-up building stock models for energy consumption in the residential sector. **Building and Environment**, v. 45, n. 7, p. 1683-1697, 2010. <https://doi.org/10.1016/j.buildenv.2010.01.021>.

KERSHAW, T.; EAMES, M.; COLEY, D. Assessing the risk of climate change for buildings: A comparison between multi-year and probabilistic reference year simulations. **Building and Environment**, v. 46, n. 6, p. 1303-1308, 2011. doi.org/10.1016/j.buildenv.2010.12.018.

KHARE, Y.; MUÑOZ-CARPENA, R. **Global Sensitivity Analysis: Elementary Effects Method of Morris using Sampling for Uniformity (SU) MatLab code manual**. Department of Agricultural & Biological Engineering - University of Florida, Gainesville, 2014.

KIM, Y.-J.; AHN, K.-U.; PARK, C.-S. Decision making of HVAC system using Bayesian Markov chain Monte Carlo method. **Energy and Buildings**, v. 72, p. 112-121, 2014. <https://doi.org/10.1016/j.enbuild.2013.12.039>.

KIRIMTAT, A. *et al.* Review of simulation modeling for shading devices in buildings. **Renewable Sustainable Energy Reviews**, v. 53, p. 23-49, 2016. <https://doi.org/10.1016/j.rser.2015.08.020>.

KITCHENHAM, B. *et al.* Systematic literature reviews in software engineering—A systematic literature review. **Information and Software Technology**, v. 51, n. 1, p. 7-15, 2009. <https://doi.org/10.1016/j.infsof.2008.09.009>.

KRUSCHKE, J. **Doing Bayesian data analysis: A tutorial with R, JAGS, and Stan**. 2. ed. [S.l.]: Academic Press, 2014.

LACASSE, M.; GAUR, A.; MOORE, T. Durability and Climate Change—Implications for Service Life Prediction and the Maintainability of Buildings. **Buildings**, v. 3, 53, 2020. <https://doi.org/10.3390/buildings10030053>.

LANGVIN, J.; WEN, J.; GURIAN, P. L. Modeling thermal comfort holistically: Bayesian estimation of thermal sensation, acceptability, and preference distributions for office building occupants. **Building and Environment**, v. 69, p. 206-226, 2013. <https://doi.org/10.1016/j.buildenv.2013.07.017>.

LAOUADI, A. *et al.* **Climate resilience buildings: guideline for management of overheating risk in residential buildings**. [S.l.]: National Research Council Canada, 2022. 147 p. (CRBCPI-Y4-10).

LAUZET, N. *et al.* Construction d'un fichier microclimatique urbain utilisable en STD [Construction of reusable urban microclimate weather files for BPS]. IBPSA Conference. **Anais...** Bordeaux, France: IBPSA, 2018. p. 1-8.

LEE, B. D. *et al.* A Framework for Generating Stochastic Meteorological Years for Risk-Conscious Design of Buildings. Proceedings of SimBuild Conference 2012: 5th conference of IBPSA USA. **Anais...** Madison: IBPSA, 2012. p. 345-352.

LIM, H.; ZHAI, Z. Influences of energy data on Bayesian calibration of building energy model. **Applied Energy**, v. 231, p. 686-698, 2018. <https://doi.org/10.1016/j.apenergy.2018.09.156>.

LOMAS, K. J.; JI, Y. Resilience of naturally ventilated buildings to climate change: Advanced natural ventilation and hospital wards. **Energy and Buildings**, v. 41, p. 629-653, 2009. <https://doi.org/10.1016/j.enbuild.2009.01.001>.

LOMAS, K. J.; PORRITT, S. M. Overheating in buildings: lessons from research. **Building Research & Information**, v. 45, n. 1-2, p. 1-18, 2017. <https://doi.org/10.1080/09613218.2017.1256136>.

LOMAS, K. J.; PORRITT, S. M. Overheating in buildings: lessons from research. **Building Research & Information**, v. 45, n. 1-2, p. 1-18, 2017. <https://doi.org/10.1080/09613218.2017.1256136>.

MA, N. *et al.* Adaptive behavior and different thermal experiences of real people: A Bayesian neural network approach to thermal preference prediction and classification. **Building and Environment**, v. 198, 107875, 2021. <https://doi.org/10.1016/j.buildenv.2021.107875>.

MACHARD, A. *et al.* Typical and extreme weather datasets for studying the resilience of buildings to climate change and heatwaves. **Scientific Data**, v. 11, 531, 2024. <https://doi.org/10.1038/s41597-024-03319-8>.

MAKANTASI, A.-M.; MAVROGIANNI, A. Adaptation of London's social housing to climate change through retrofit: A holistic evaluation approach. **Advances in Building Energy Research**, v. 10, p. 99–124, 2016. <https://doi.org/10.1080/17512549.2015.1040071>.

MALLER, C. J.; STRENGERS, Y. Housing, heat stress and health in a changing climate: Promoting the adaptive capacity of vulnerable households, a suggested way forward. **Health Promotion International**, v. 26, n. 4, p. 492-498, 2011. <https://doi.org/10.1093/heapro/dar003>.

MALMQVIST, T. *et al.* Life cycle assessment in buildings: The ENSLIC simplified method and guidelines. **Energy**, v. 36, n. 4, p. 1900-1907, 2011. <https://doi.org/10.1016/j.energy.2010.03.026>.

MALONEY, R. WeatherShift™ future weather data now available for online purchase. **Arup**, 2016. Disponível em: <https://www.arup.com/news-and-events/weathershift-future-weather-data-now-available-for-online-purchase>. Acesso em: 04 Novembro 2023.

MARENGO, J. A. *et al.* Future change of temperature and precipitation extremes. **International Journal of Climatology**, v. 29, n. 15, p. 2241-2255. <https://doi.org/10.1002/joc.1863>.

MATA, É. *et al.* Economic feasibility of building retrofitting mitigation potentials: Climate change uncertainties for Swedish cities. **Applied Energy**, v. 242, p. 1022-1035, 2019. <https://doi.org/10.1016/j.apenergy.2019.03.042>.

MCGRAYNE, S. B. **The theory that would not die**. [S.l.]: Yale University Press, 2011.

MCKINSEY & COMPANY. **Pathways to a Low-Carbon Economy**. [S.l.]:, 2009. 192.

MCMICHAEL, A. J.; WOODRUFF, R. E.; HALES, S. Climate change and human health: present and future risks. **The Lancet**, v. 367, n. 9513, p. 859-869, 2006. [https://doi.org/10.1016/S0140-6736\(06\)68079-3](https://doi.org/10.1016/S0140-6736(06)68079-3).

MCNEISH, D. On using Bayesian methods to address small sample problems. **Structural Equation Modeling: A Multidisciplinary Journal**, v. 23, n. 5, p. 750-773, 2016. <https://doi.org/10.1080/10705511.2016.1186549>.

MECHRI, H. E.; CAPOZZOLI, A.; CORRADO, V. Use of the ANOVA approach for sensitive building energy design. **Applied Energy**, v. 87, n. 10, p. 3073–3083, 2010. <https://doi.org/10.1016/j.apenergy.2010.04.001>.

MELCHERS, R. E.; BECK, A. T. **Structural reliability analysis and prediction**. [S.l.]: John Wiley & Sons Ltd., 2018.

MENBERG, K.; HEO, Y.; CHOUDHARY, R. Sensitivity analysis methods for building energy models: Comparing computational costs and extractable information. **Energy and Buildings**, v. 133, p. 433-445, 2016. <https://doi.org/10.1016/j.enbuild.2016.10.005>.

MIRASGEDIS, S. *et al.* Modeling framework for estimating impacts of climate change on electricity demand at regional level: case of Greece. **Energy Conversion and Management**, v. 48, p. 1737-1750, 2007. <https://doi.org/10.1016/j.enconman.2006.10.022>.

MOAZAMI, A. *et al.* Impacts of future weather data typology on building energy performance – Investigating long-term patterns of climate change and extreme weather conditions. **Applied Energy**, v. 238, p. 696-720, 2019. <https://doi.org/10.1016/j.apenergy.2019.01.085>.

MOAZAMI, A. *et al.* Impacts of future weather data typology on building energy performance—Investigating long-term patterns of climate change and extreme weather conditions. **Applied Energy**, v. 238, p. 696-720, 2019. <https://doi.org/10.1016/j.apenergy.2019.01.085>.

MOAZAMI, A. *et al.* Towards climate robust buildings: An innovative method for designing buildings with robust energy performance under climate change. **Energy and Buildings**, v. 202, 109378, 2019. doi.org/10.1016/j.enbuild.2019.109378.

MOAZAMI, A.; CARLUCCI, S.; GEVING, S. Critical analysis of software tools aimed at generating future weather files with a view to their use in building performance simulation. **Energy Procedia**, v. 132, p. 640-645, 2017. <https://doi.org/10.1016/j.egypro.2017.09.701>.

MOAZAMI, A.; CARLUCCI, S.; GEVING, S. Robust and resilient buildings: A framework for defining the protection against climate uncertainty. **IOP Conference Series: Materials Science and Engineering**, v. 609, n. 7, 072068, 2019. [10.1088/1757-899X/609/7/072068](https://doi.org/10.1088/1757-899X/609/7/072068).

MOHSENI, S. *et al.* Demand response-integrated investment and operational planning of renewable and sustainable energy systems considering forecast uncertainties: A systematic review. **Renewable and Sustainable Energy Reviews**, v. 158, 112095, 2022. <https://doi.org/10.1016/j.rser.2022.112095>.

MORA, C. *et al.* Global risk of deadly heat. **Nature Climate Change**, v. 7, p. 501-506, 2017. <https://doi.org/10.1038/nclimate3322>.

MORA, C. *et al.* Broad threat to humanity from cumulative climate hazards intensified by greenhouse gas emissions. **Nature Climate Change**, v. 8, p. 1062-1071, 2018. <https://doi.org/10.1038/s41558-018-0315-6>.

MORALES, J. C. C.; CAUSIL, C. J. B. **Introducción a la Estadística Bayesiana**. 1. ed. Medellín: Instituto Tecnológico Metropolitano, 2018. ISBN 978-958-5414-24-2.

MORGAN, M. G.; HENRION, M. **A Guide to Dealing with Uncertainty in Quantitative Risk and Policy Analysis**. New York: Cambridge Univ. Press., 1990.

MORRIS, M. D. Factorial Sampling Plans for Preliminary Computational Experiments. **Technometrics**, v. 33, n. 2, p. 161–173, 1991.

MURPHY, J. *et al.* **UK Climate Projections Science Report: Climate Change**. [S.l.], 2009.

NAKICENOVIC, N.; SWART, R. **Special Report on Emissions Scenarios (SRES) – A Special Report of Working Group III of the Intergovernmental Panel on Climate Change**. New York: Intergovernmental Panel on Climate Change, 2000. 600. (ISBN 0521800811).

NAROWSKI, P.; JANICKI, M.; HEIM, D. Comparison of Untypical Meteorological Years (UMY) and their influence on building energy performance simulations. 13th Conference of International Building Performance Simulation Association. **Anais...** Chambéry, France: IBPSA, 2013. p. 1414-1421.

NASA. NASA Analysis Confirms 2023 as Warmest Year on Record. **National Aeronautics and Space Administration**, 28 jan. 2024a. Disponível em: <https://www.nasa.gov/news-release/nasa-analysis-confirms-2023-as-warmest-year-on-record/>. Acesso em: 6 abr. 2024.

NASA. National Aeronautics and Space Administration. **Global Temperature**, 2024b. Disponível em: <https://climate.nasa.gov/vital-signs/global-temperature>. Acesso em: 06 abr. 2024.

NASA. National Aeronautics and Space Administration. **Global Temperature Anomalies from 1880 to 2023**, 2024c. Disponível em: <https://svs.gsfc.nasa.gov/5207>. Acesso em: 06 abr. 2024.

NCEI-NOAA. Anomalies vs. Temperature. **National Centers for Environmental Information; National Oceanic and Atmospheric Administration.**, 2024. Disponível em: <https://www.ncei.noaa.gov/access/monitoring/dyk/anomalies-vs-temperature>. Acesso em: 06 abr. 2024.

NEAL, R. M. Slice sampling. **The Annals of Statistics**, v. 31, n. 3, p. 705-767, 2003. <https://doi.org/10.1214/aos/1056562461>.

NELSON, C. R.; KIM, M. J. Predictable stock returns: The role of small sample bias. **The Journal of Finance**, v. 48, n. 2, p. 641-661, 1993. <https://doi.org/10.2307/2328916>.

NELSON, K. *et al.* An integrated and dynamic framework for assessing sustainable resilience in complex adaptive systems. **Sustainable and Resilient Infrastructure**, v. 5, n. 5, p. 1–19, 2019. <https://doi.org/10.1080/23789689.2019.1578165>.

NICOL, J. F. *et al.* Suggestion for new approach to overheating diagnostics. **Building Research & Information**, v. 37, n. 4, p. 348–357, 2009. <https://doi.org/10.1080/09613210902904981>.

NIK, V. M. *et al.* Effective and robust energy retrofitting measures for future climatic conditions—Reduced heating demand of Swedish households. **Energy and Buildings**, v. 121, p. 176-187, 2016. doi.org/10.1016/j.enbuild.2016.03.044.

NIK, V. M. Making energy simulation easier for future climate – Synthesizing typical and extreme weather data sets out of regional climate models (RCMs). **Applied Energy**, v. 177, p. 204-226, 2016. doi.org/10.1016/j.apenergy.2016.05.107.

- NIK, V. M.; KALAGASIDIS, A. S. Impact study of the climate change on the energy performance of the building stock in Stockholm considering four climate uncertainties. **Building and Environment**, v. 60, p. 291-304, 2013. doi.org/10.1016/j.buildenv.2012.11.005.
- NIK, V. M.; MATA, E.; KALAGASIDIS, A. S. A statistical method for assessing retrofitting measures of buildings and ranking their robustness against climate change. **Energy and Buildings**, v. 88, p. 262-275, 2015. doi.org/10.1016/j.enbuild.2014.11.015.
- NIK, V. M.; MOAZAMI, A. Using collective intelligence to enhance demand flexibility and climate resilience in urban areas. **Applied Energy**, v. 281, 116106, 2021. https://doi.org/10.1016/j.apenergy.2020.116106.
- NIK, V. M.; PERERA, A. T. D.; CHEN, D. Towards climate resilient urban energy systems: a review. **National Science Review**, v. 8, n. 3, nwaa134, 2021. https://doi.org/10.1093/nsr/nwaa134.
- NOAA. National Oceanic and Atmospheric Administration. **Global Time Series**, 2024a. Disponível em: https://www.ncei.noaa.gov/access/monitoring/climate-at-a-glance/global/time-series/globe/land_ocean/12/12/1880-2023. Acesso em: 06 abr. 2024.
- NOBRE, C. A. *et al.* Vulnerability of Brazilian Megacities to Climate Change: The São Paulo Metropolitan Region (RMSP). In: MOTTA, Ronaldo S. D., *et al.* **Climate Change in Brazil: economic, social and regulatory aspects**. Brasília: Institute for Applied Economic Research, 2011. Cap. 11, p. 197-219.
- NUNES, G. H. *et al.* Eficácia da ferramenta de progressão de arquivos climáticos CCWorldWeatherGen: análise para São Paulo-SP. Encontro Nacional de Conforto no Ambiente Construído. **Anais...** São Paulo: ANTAC, 2023. https://doi.org/10.46421/encac.v17i1.3819.
- NUNES, G. H. *et al.* Effectiveness of the CCWorldWeatherGen weather file generation tool. **Ambiente Construído**, v. 24, e138234, 2024.
- NUNES, G. H. **Influência das mudanças climáticas na sensibilidade global de parâmetros termofísicos de habitações brasileiras**. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2021.
- NUNES, G. H.; GIGLIO, G. F. Influência das mudanças climáticas no desempenho térmico de uma habitação com diferentes sistemas construtivos: análise do clima de São Paulo. **Revista Principia - Divulgação Científica e Tecnológica do IFPB**, p. 46-61, 2020. dx.doi.org/10.18265/1517-03062015v1n48p46-61.
- NUNES, G. H.; GIGLIO, T. G. F. Análise de sensibilidade de parâmetros termofísicos de habitações brasileiras sob a influência das mudanças climáticas. Encontro Nacional de Conforto no Ambiente Construído. **Anais...** Palmas: ANTAC, 2021.
- NUNES, G. H.; GIGLIO, T. G. F. Análise de sensibilidade de variáveis termofísicas de habitações brasileiras sob a influência das mudanças climáticas. **Ambiente Construído**, v. 22, n. 4, p. 91-120, 2022a. https://doi.org/10.1590/s1678-86212022000400630.

NUNES, G.; GIGLIO, T. Effects of climate change in the thermal and energy performance of low-income housing in Brazil—assessing design variable sensitivity over the 21st century. **Renewable and Sustainable Energy Reviews**, v. 168, 112885, 2022b. <https://doi.org/10.1016/j.rser.2022.112885>.

OBRECHT, T. P.; PREMROV, M.; LESKOVAR, V. Ž. Influence of the orientation on the optimal glazing size for passive houses in different European climates (for non-cardinal directions). **Solar Energy**, v. 189, p 15-25, 2019. <https://doi.org/10.1016/j.solener.2019.07.037>.

OLONSCHECK, M.; HOLSTEN, A.; KROPP, J. P. Heating and cooling energy demand and related emissions of the German residential building stock under climate change. **Energy Policy**, v. 39, n. 9, p. 4795-4806, 2011. doi.org/10.1016/j.enpol.2011.06.041.

ONU. **Transformando Nosso Mundo: A Agenda 2030 para o Desenvolvimento Sustentável**. Brasília: Nações Unidas Brasil, 2015. 49.

PANG, Z. *et al.* The role of sensitivity analysis in the building performance analysis: A critical review. **Energy and Buildings**, v. 209, 109659, 2020. <https://doi.org/10.1016/j.enbuild.2019.109659>.

PASTOR, A. V. *et al.* How uncertainties are tackled in multi-disciplinary science? A review of integrated assessments under global change. **Catena**, v. 186, 104305, 2020. doi.org/10.1016/j.catena.2019.104305.

PAULINO, C. D. *et al.* **Glossário Inglês-Português**. Lisboa: Sociedade Portuguesa de Estatística e Associação Brasileira de Estatística, 2011.

PAZ, S.; SEMENZA, J. C. El Nino and climate change—contributing factors in the dispersal of Zika virus in the Americas? **The Lancet**, v. 387, n. 10020, p. 745, 2016. [https://doi.org/10.1016/S0140-6736\(16\)00256-7](https://doi.org/10.1016/S0140-6736(16)00256-7).

PEEL, M. C.; FINLAYSON, B. L.; MCMAHON, T. A. Updated world map of the Koppen-Geiger climate classification. **Hydrology and Earth System Sciences**, v. 11, n. 5, p. 1633–1644, 2007. <https://doi.org/10.5194/hess-11-1633-2007>.

PERERA, A. T. D. *et al.* Quantifying the impacts of climate change and extreme climate events on energy systems. **Nature Energy**, v. 5, p. 150–159, 2020. <https://doi.org/10.1038/s41560-020-0558-0>.

PRATAVIERA, E. *et al.* Evaluation of the impact of input uncertainty on urban building energy simulations using uncertainty and sensitivity analysis. **Applied Energy**, v. 311, 118691, 2022. <https://doi.org/10.1016/j.apenergy.2022.118691>.

PROCEL/ELETOBRAS. **Guia técnico PROCEL edifica: planejamento e controle ambiental - urbano e a eficiência energética**. Rio de Janeiro: Programa Nacional de Conservação de Energia Elétrica, 2013. 222p.

PROCEL/ELETOBRAS. **Pesquisa de Posse e Hábitos de Uso de Equipamentos Elétricos na Classe Residencial 2019**. [S.l.]: Programa Nacional de Conservação de Energia e Eficiência Energética, 2019.

QUIZA, E. G. MCMV de madeira. **Mercado Imobiliário**, 2013. Disponível em: <https://incorporacaoimobiliaria.com/2013/09/04/mcmv-de-madeira/>. Acesso em: 12 abr. 2024.

R CORE TEAM. **R: A language and environment for statistical**. Vienna, Austria: R Foundation for Statistical Computing, 2024.

RAMON, D. *et al.* Future weather data for dynamic building energy simulations: overview of available data and presentation of newly derived data for Belgium. In: MOTOASCA, E.; AGARWAL, A.; BREESCH, H. **Energy Sustainability in Built and Urban Environments. Energy, Environment, and Sustainability**. Singapore: Springer, 2019. p. 111-138.

RAMON, D. *et al.* Dynamic modelling of operational energy use in a building LCA: A case study of a Belgian office building. **Energy and Buildings**, v. 278, n. 1, 112634, 2023. doi.org/10.1016/j.enbuild.2022.112634.

RAÑESES, M. K. *et al.* Housing for now and the future: A systematic review of climate-adaptive measures. **Sustainability**, v. 13, n. 12, 2021. <https://doi.org/10.3390/su13126744>.

RAUDYS, S. J.; JAIN, A. K. Small sample size effects in statistical pattern recognition: Recommendations for practitioners. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 13, n. 3, p. 252-264, 1991. <https://doi.org/10.1109/34.75512>.

REIS, M. M. **Inferência Estatística**. Notas de aula - Universidade Federal de Santa Catarina, Florianópolis, 2023.

REMUND, J. *et al.* **Meteonorm Software. Version 8**. Bern, Switzerland: Meteotest AG, 2020. 2.

REMUND, J.; SALVISBERG, E.; KUNZ, S. On the generation of hourly shortwave radiation data on tilted surfaces. **Solar Energy**, v. 62, n. 5, p. 331-344, 1998. [https://doi.org/10.1016/S0038-092X\(98\)00020-6](https://doi.org/10.1016/S0038-092X(98)00020-6).

REN, Z.; CHEN, Z.; WANG, X. Climate change adaptation pathways for Australian residential buildings. **Building and Environment**, v. 46, n. 11, p. 2398-2412, 2021. <https://doi.org/10.1016/j.buildenv.2011.05.022>.

RESEARCH HIGHLIGHTS. Deadly heat is on the rise. **Nature**, v. 546, p. 578, 2017. <https://doi.org/10.1038/d41586-017-00767-8>.

RITCHIE, H.; ROSADO, P.; ROSER, M. CO₂ and Greenhouse Gas Emissions. **Our World in Data**, 2023. Disponível em: <https://ourworldindata.org/co2-and-greenhouse-gas-emissions>. Acesso em: 06 abr. 2024.

ROBINSON, D.; HALDI, F. Model to predict overheating risk based on an electrical capacitor analogy. **Energy and Buildings**, v. 40, n. 7, p. 1240-1245, 2008. <https://doi.org/10.1016/j.enbuild.2007.11.003>.

RODRIGUES, E. *et al.* Diminishing benefits of thermal mass in Iranian climate: Present and future scenarios. **Building and Environment**, 111635, 2024. <https://doi.org/10.1016/j.buildenv.2024.111635>.

RODRIGUES, E.; FERNANDES, M. S.; CARVALHO, D. Future weather generator for building performance research: An open-source morphing tool and an application. **Building and Environment**, v. 233, 110104, 2023. <https://doi.org/10.1016/j.buildenv.2023.110104>.

RODRIGUES, E.; PARENTE, J.; FERNANDES, M. S. Building for tomorrow: Analyzing ideal thermal transmittances in the face of climate change in Brazil. **Applied Energy**, v. 355, 122360, 2024. <https://doi.org/10.1016/j.apenergy.2023.122360>.

RODRIGUES, E.; PARENTE, J.; FERNANDES, M. S. Building for tomorrow: Analyzing ideal thermal transmittances in the face of climate change in Brazil. **Applied Energy**, v. 355, 122360, 2024. <https://doi.org/10.1016/j.apenergy.2023.122360>.

RODRIGUES, M. L. **Avaliação de técnicas passivas para conforto térmico visando à racionalização do uso de sistemas de ar condicionado em casas populares**. Dissertação (Mestrado em Engenharia Mecânica) - Universidade Estadual Paulista, Guaratinguetá, 2021.

RODRÍGUEZ, G. C. *et al.* Uncertainties and sensitivity analysis in building energy simulation using macroparameters. **Energy and Buildings**, v. 67, p. 79-87, 2013. <https://doi.org/10.1016/j.enbuild.2013.08.009>.

ROGELJ, J. *et al.* Paris Agreement climate proposals need a boost to keep warming well below 2 °C. **Nature**, v. 534, p. 631-639, 2016. <https://doi.org/10.1038/nature18307>.

ROSHAN, ; OJI, ; ATTIA,. Projecting the impact of climate change on design recommendations for residential buildings in Iran. **Building and Environment**, v. 155, p. 283-297, 2019. doi.org/10.1016/j.buildenv.2019.03.053.

ROYALL, R. M. The effect of sample size on the meaning of significance tests. **The American Statistician**, v. 40, n. 4, p. 313-315, 1986.

RYSANEK, A. M.; CHOUDHARY, R. Optimum building energy retrofits under technical and economic uncertainty. **Energy and Buildings**, v. 57, p. 324-337, 2013. doi.org/10.1016/j.enbuild.2012.10.027.

RYSANEK, A.; NUTTALL, R.; MCCARTY, J. Forecasting the impact of climate change on thermal comfort using a weighted ensemble of supervised learning models. **Building and Environment**, v. 190, 107522, 2021. <https://doi.org/10.1016/j.buildenv.2020.107522>.

SALTELLI, A. *et al.* **Global Sensitivity Analysis: The Primer**. [S.l.]: John Wiley and Sons Ltd., 2008.

SALTELLI, A.; TARANTOLA, S.; CAMPOLONGO, F. Sensitivity analysis as an ingredient of modelling. **Statistical Science**, v. 15, n. 4, p. 377-395, 2000. <https://doi.org/10.1214/ss/1009213004>.

SANCHES, G. V. **Análise de métodos de transferência de calor através do solo em simulações computacionais de edificações**. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2021.

SANCHES, G. V.; MORO, G. N.; GIGLIO, T. G. F. Calibração de um modelo computacional de HIS localizada na cidade de Londrina-PR. ENCONTRO NACIONAL DE CONFORTO NO AMBIENTE CONSTRUÍDO. **Anais...** Palmas: ANTAC, 2021. p. 1322–1331.

SÁNCHEZ-GARCÍA, D. *et al.* Towards the quantification of energy demand and consumption through the adaptive comfort approach in mixed mode office buildings considering climate change. **Energy and Buildings**, v. 187, p. 173-185, 2019. <https://doi.org/10.1016/j.enbuild.2019.02.002>.

SANTOS, V. C. **Desempenho energético de sistemas domésticos de aquecimento solar de água em uso: uma abordagem das interfaces com o usuário e o ambiente construído**. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2019.

SCHAEFFER, R. *et al.* Energy sector vulnerability to climate change: A review. **Energy**, v. 38, p. 1-12, 2012. <https://doi.org/10.1016/j.energy.2011.11.056>.

SCHWALM, C. R.; SPENCER, G.; DUFFY, P. B. RCP8.5 tracks cumulative CO2 emissions. **Proceedings of the National Academy of Sciences (PNAS)**, v. 117, n. 33, p. 19656-19657, 2020. <https://doi.org/10.1073/pnas.2007117117>.

SCOTT, M. J.; WRENCH, L. E.; HADLEY, D. L. Effects of climate change on commercial building energy demand. **Energy Sources**, v. 16, n. 3, p. 317-332, 1994. <https://doi.org/10.1080/00908319408909081>.

SETHI, M.; SHARMA, R.; MOHAPATRA, S.. M. S. How to tackle complexity in urban climate resilience? Negotiating climate science, adaptation and multi-level governance in India. **Plos One**, v. 16, n. 7, e0253904, 2021. <https://doi.org/10.1371/journal.pone.0253904>.

SHAMSEER, L. *et al.* Preferred reporting items for systematic review and meta-analysis protocols (PRISMA-P) 2015: elaboration and explanation. **BMJ**, v. 349, g7647, 2015. <https://doi.org/10.1136/bmj.g7647>.

SHARMA, A. *et al.* Life cycle assessment of buildings: A review. **Renewable and Sustainable Energy Reviews**, v. 15, n. 1, p. 871-875, 2011. <https://doi.org/10.1016/j.rser.2010.09.008>.

SHEN, P. *et al.* Rapid multi-objective optimization with multi-year future weather condition and decision-making support for building retrofit. **Energy**, v. 172, p. 891-912, 2019. <https://doi.org/10.1016/j.energy.2019.01.164>.

SHEN, P.; BRAHAM, W.; YI, Y. The feasibility and importance of considering climate change impacts in building retrofit analysis. **Applied Energy**, v. 233, p. 254-270, 2019. <https://doi.org/10.1016/j.apenergy.2018.10.041>.

SILVA, A. S.; ALMEIDA, L. S. S.; GHISI, E. Decision-making process for improving thermal and energy performance of residential buildings: A case study of constructive systems in Brazil. **Energy and Buildings**, v. 128, p. 270-286, 2016. <https://doi.org/10.1016/j.enbuild.2016.06.084>.

SILVA, A. S.; GHISI, E. Análise de sensibilidade global dos parâmetros termofísicos de uma edificação residencial de acordo com o método de simulação do RTQ-R. **Ambiente Construído**, v. 13, n. 4, p. 135-148, 2013. <https://doi.org/10.1590/S1678-86212013000400010>.

SILVA, M. A. *et al.* Towards Climate, Bioclimatism, and Building Performance—A Characterization of the Brazilian Territory from 2008 to 2022. **Buildings**, v. 14, n. 8, 2568, 2024. <https://doi.org/10.3390/buildings14082568>.

SILVA, S. **Desenvolvimento de um método para avaliação do desempenho térmico e energético de edificações aplicando análise de incertezas e sensibilidade**. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Santa Catarina, Florianópolis, 2016.

SIMLAB 2.2. **Reference Manual**. [S.l.]: European Commission - IPSC, 2008. 160.

SMITH, R. C. **Uncertainty Quantification: Theory, Implementation, and Applications**. New York: SIAM, 2013. 400 p.

SONG, J.; WANG, Z.-H. Evaluating the impact of built environment characteristics on urban boundary layer dynamics using an advanced stochastic approach. **Atmospheric Chemistry and Physics**, v. 16, p. 6285–6301, 2016. doi.org/10.5194/acp-16-6285-2016.

STEWART, M. G. Risk and economic viability of housing climate adaptation strategies for wind hazards in southeast Australia. **Mitigation and Adaptation Strategies for Global Change**, v. 20, p. 601-622, 2015. <https://doi.org/10.1007/s11027-013-9510-y>.

SUN, K.; SPECIAN, M.; HONG, T. Nexus of thermal resilience and energy efficiency in buildings: A case study of a nursing home. **Building and Environment**, v. 177, 106842, 2020. <https://doi.org/10.1016/j.buildenv.2020.106842>.

SUN, Y. *et al.* Exploring HVAC system sizing under uncertainty. **Energy and Buildings**, v. 81, p. 243-252, 2014. <https://doi.org/10.1016/j.enbuild.2014.06.026>.

SUN, Y. Sensitivity analysis of macro-parameters in the system design of net zero energy building. **Energy and Buildings**, v. 86, p. 464-477, 2015. <https://doi.org/10.1016/j.enbuild.2014.10.031>.

SWILER, L. P.; PAEZ, T. L.; MAYES, R. L. Epistemic Uncertainty Quantification Tutorial. Proceedings of the 27th International Modal Analysis Conference. **Anais...** Orlando, USA: Society for Experimental Mechanics Inc., 2009.

TAGUCHI, G.; CHOWDHURY, S.; TAGUCHI, S. **Robust engineering: learn how to boost quality while reducing costs & time to market**. New York: McGraw-Hill, 1999.

TATTONI, D. J.; LABARBERA, K. Capture height biases for birds in mist-nets vary by taxon, season, and foraging guild in northern California. **Journal of Field Ornithology**, v. 93, n. 1, 2022. <https://doi.org/10.5751/JFO-00021-930101>.

TAVAKOLI, E. *et al.* Evaluating the indoor thermal resilience of ventilative cooling in non-residential low energy buildings: A review. **Building and Environment**, v. 222, 109376, 2022. <https://doi.org/10.1016/j.buildenv.2022.109376>.

TECVERDE. **Projeto arquitetônico de edificação em wood frame**. [S.l.], 2013.

THEVENARD, D. Influence of long-term trends and period of record selection on the calculation of climatic design conditions and degree days. **ASHRAE Transactions**, v. 116, n. 1, p. 447-460, 2010.

TIAN, W. *et al.* Spatial Variation of Urban Building Energy Analysis. IBPSA Building Simulation Conference. **Anais...** Hyderabad, India: [s.n.], 2015. December 7-9.

TIAN, W. *et al.* A review of uncertainty analysis in building energy assessment. **Renewable and Sustainable Energy Reviews**, v. 93, p. 285-301, 2018. doi.org/10.1016/j.rser.2018.05.029.

TIAN, W. A review of sensitivity analysis methods in building energy analysis. **Renewable and Sustainable Energy Reviews**, v. 20, p. 411-419, 2013. https://doi.org/10.1016/j.rser.2012.12.014.

TIAN, W.; CHOUDHARY, R. A probabilistic energy model for non-domestic building sectors applied to analysis of school buildings in greater London. **Energy and Buildings**, v. 54, p. 1-11, 2012. https://doi.org/10.1016/j.enbuild.2012.06.031.

TIAN, W.; DE WILDE, P. Uncertainty and sensitivity analysis of building performance using probabilistic climate projections: A UK case study. **Automation in Construction**, v. 20, n. 8, p. 1096-1109, 2011. doi.org/10.1016/j.autcon.2011.04.011.

TOOTKABONI, M. P. *et al.* A comparative analysis of different future weather data for building energy performance simulation. **Climate**, v. 9, n. 2, 37, 2021. https://doi.org/10.3390/cli9020037.

TRIANA, M. A.; LAMBERTS, R.; SASSI, P. Desempenho de habitações de interesse social frente às mudanças climáticas. Encontro Nacional de Tecnologia do Ambiente Construído. **Anais...** São Paulo: ANTAC, 2016.

TRIANA, M. A.; LAMBERTS, R.; SASSI, P. Should we consider climate change for Brazilian social housing? Assessment of energy efficiency adaptation measures. **Energy and Buildings**, v. 158, p. 1379-1392, 2018. doi.org/10.1016/j.enbuild.2017.11.003.

TROUP, L.; FANNON, D. Morphing climate data to simulate building energy consumption. Building Performance Modeling Conference. **Anais...** Salt Lake City, USA: ASHRAE; IBPSA-USA, 2016. p. 1-8.

TSOKA, S. *et al.* Evaluation of stochastically generated weather datasets for building energy simulation. **Energy Procedia**, v. 122, p. 853-858, 2017. https://doi.org/10.1016/j.egypro.2017.07.449.

UNIVERSITY OF SOUTHAMPTON. Climate Change World Weather File Generator for World-Wide Weather Data – CCWorldWeatherGen. **Energy and Climate Change Division**, 2023. Disponível em: <http://www.energy.soton.ac.uk/ccworldweathergen>. Acesso em: 05 novembro 2023.

URBAN MICROCLIMATE. Urban Weather Generator 4.1: urban heat island effect modeling software. **Urban Microclimate**, 2016. Disponível em: <https://urbanmicroclimate.scripts.mit.edu/uwg.php#:~:text=Urban%20Weather%20Generator%20%5BUWG%5D%20estimates,from%20a%20rural%20weather%20station>. Acesso em: 04 Novembro 2023.

VAN DE SCHOOT, R.; DEPAOLI, S.; KING, R. Bayesian statistics and modelling. **Nature Reviews Methods Primers**, v. 1, n. 1, p. 1-26, 2021. doi.org/10.1038/s43586-020-00001-2.

VAN DE SCHOOT, R.; MIOČEVIĆ, M. **Small sample size solutions**: A guide for applied researchers and practitioners. London: Routledge, 2020. 284 p.

VAN ECK, N. J.; WALTMAN, L. **Manual for VOSviewer version 1.6.18**. [S.l.]: Universiteit Leiden, 2022.

VAN HOOFF, T. *et al.* On the predicted effectiveness of climate adaptation measures for residential buildings. **Building and Environment**, v. 82, p. 300-316, 2014. doi.org/10.1016/j.buildenv.2014.08.027.

VAN PAASSEN, A. H.-C.; LUO, Q. X. Weather data generator to study climate change on buildings, v. 23, n. 4, 2002. <https://doi.org/10.1191/0143624402bt048oa>.

VAN STADEN, M.; MUSCO, F. **Local Governments and Climate Change**. 1. ed. [S.l.]: Springer, 2010. 434 p.

WAND, M. P. **densEstBayes: Density estimation via Bayesian inference algorithms**. [S.l.]: University of Technology Sydney, 2020.

WAND, M. P. R Package ‘densEstBayes’. **Density Estimation via Bayesian Inference Engines Version 1.0-2.2**, 2023. Disponível em: <https://cran.r-project.org/package=densEstBayes>. Acesso em: 13 jan. 2024.

WAND, M. P.; YU, J. C. F. Density estimation via Bayesian inference engines. **arXiv**, 2021. Disponível em: <https://arxiv.org/abs/2009.06182>. Acesso em: 25 maio 2023. <https://doi.org/10.48550/arXiv.2009.06182>.

WAND, M. P.; YU, J. C. F. Density estimation via Bayesian inference engines. **ASTA Advances in Statistical Analysis**, v. 106, p. 199–216, 2022. <https://doi.org/10.1007/s10182-021-00422-8>.

WANG, J.; MAE, M.; TANIGUCHI, K. Uncertainty modeling method of weather elements based on deep learning for robust solar energy generation of building. **Energy and Buildings**, v. 266, 112115, 2022. <https://doi.org/10.1016/j.enbuild.2022.112115>.

WANG, L.; MATHEW, P.; PANG, X. Uncertainties in energy consumption introduced by building operations and weather for a medium-size office building. **Energy and Buildings**, v. 53, p. 152-158, 2021. doi.org/10.1016/j.enbuild.2012.06.017.

WANG, Z.; HONG, T. Learning occupants’ indoor comfort temperature through a Bayesian inference approach for office buildings in United States. **Renewable and Sustainable Energy Reviews**, v. 119, 109593, 2020. <https://doi.org/10.1016/j.rser.2019.109593>.

WASSERMAN, L. **All of statistics**: a concise course in statistical inference. [S.l.]: Springer, 2004.

WATE, P. *et al.* Uncertainty assessment of building performance simulation: An insight into suitability of methods and their applications. In: EICKER, Ursula **Urban Energy Systems for Low-Carbon Cities**. [S.l.]: Academic Press, 2019. p. 257-287.

WCED. **Our Common Future**. Oslo: World Commission on Environment and Development, The Brundtland Commission, 1987. 300.

- WEFORUM. **The Global Risks Report 2016**. Geneva, Switzerland: World Economic Forum, 2016. 97. (080116).
- WEST, J. J.; SMITH, S. J.; SILVA, R. A. Co-benefits of mitigating global greenhouse gas. **Nature Climate Change**, v. 3, p. 885-889, 2013. <https://doi.org/10.1038/nclimate2009>.
- WILLIAMS, D. *et al.* Climate change influence on building life cycle greenhouse gas emissions: Case study of a UK mixed-use development. **Energy and Buildings**, p. 112-126, 2012. doi.org/10.1016/j.enbuild.2012.01.016.
- WINKLER, R. L. Probabilistic prediction: Some experimental results. **Journal of the American Statistical Association**, v. 66, n. 336, p. 675-685, 1971. <https://doi.org/10.2307/2284212>.
- WONG, L. T.; MUI, K. W.; CHEUNG, C. T. Bayesian thermal comfort model. **Building and Environment**, v. 82, p. 171-179, 2014. <https://doi.org/10.1016/j.buildenv.2014.08.018>.
- YANG, Y.; JAVANROODI, K.; NIK, V. M. Climate change and energy performance of European residential building stocks – A comprehensive impact assessment using climate big data from the coordinated regional climate downscaling experiment. **Applied Energy**, v. 298, 117246, 2021. <https://doi.org/10.1016/j.apenergy.2021.117246>.
- YAQUBI, O. *et al.* Creation and application of future typical weather files in the evaluation of indoor overheating in free-floating buildings. **Building and Environment**, v. 216, 109059, 2022. <https://doi.org/10.1016/j.buildenv.2022.109059>.
- YASSAGHI, ; HOQUE, S. An overview of climate change and building energy: performance, responses and uncertainties. **Buildings**, v. 9, n. 7, 166, 2019. doi.org/10.3390/buildings9070166.
- YASSAGHI, H.; GURIAN, P. L.; HOQUE, S. Propagating downscaled future weather file uncertainties into building energy use. **Applied Energy**, v. 278, 115655, 2020. doi.org/10.1016/j.apenergy.2020.115655.
- YE, B. *et al.* Research on quantitative assessment of climate change risk at an urban scale: Review of recent progress and outlook of future direction. **Renewable and Sustainable Energy Reviews**, v. 135, 110415, 2021. <https://doi.org/10.1016/j.rser.2020.110415>.
- YI, H.; BRAHAM, W. W. Uncertainty characterization of building energy analysis (BEmA). **Building and Environment**, v. 92, p. 538-558, 2015. <http://dx.doi.org/10.1016/j.buildenv.2015.05.007>.
- ZARA, R. B. **Influência dos parâmetros termofísicos no desempenho térmico de edificações residenciais em sistemas construtivos leves**. Dissertação (Mestrado em Engenharia Civil) – Universidade Estadual de Londrina, Londrina, 2019.
- ZARA, R.; SANTOS, V.; GIGLIO, T. Análise do nível de eficiência energética de uma habitação em wood frame pelos métodos prescritivo e simulação do RTQ-R. Anais do XVII Encontro Nacional de Tecnologia do Ambiente Construído. **Anais...** Foz do Iguaçu: ANTAC, 2018. p. 457-466.

ZHANG, C. *et al.* Resilient cooling strategies – A critical review and qualitative assessment. **Energy and Buildings**, v. 251, 111312, 2021. doi.org/10.1016/j.enbuild.2021.111312.

ZHOU, D. *et al.* Probabilistic information fusion with point, moment and interval data in reliability assessment. **Reliability Engineering & System Safety**, v. 213, 107790, 2021. <https://doi.org/10.1016/j.ress.2021.107790>.

ZHOU, Y. *et al.* Modeling the effect of climate change on U.S. state-level buildings energy demands in an integrated assessment framework. **Applied Energy**, v. 113, p. 1077-1078, 2014. <https://doi.org/10.1016/j.apenergy.2013.08.034>.


ZHU, L. *et al.* Uncertainty and sensitivity analysis of cooling and heating loads for building energy planning. **Journal of Building Engineering**, v. 45, 103440, 2022. <https://doi.org/10.1016/j.jobe.2021.103440>.

APÊNDICE A – CONCEITOS BÁSICOS

A.1 MUDANÇAS CLIMÁTICAS

Na Figura 56, ilustra-se a alteração da temperatura média global da Terra em 2023, em comparação com uma média de referência de 1951 a 1980, de acordo com uma análise do Estúdio de Visualização Científica e Instituto Goddard de Estudos Espaciais da NASA (2024c).


Figura 56 – Anomalia de temperatura na Terra no ano de 2023, em relação a 1951–1980



Fonte: NASA (2024c)

A principal evidência da influência do comportamento humano nas mudanças climáticas é observada por meio da correlação entre as emissões de gases de efeito estufa e os aumentos da temperatura média superficial do planeta, como mostra-se na Figura 57, elaborada com informações de emissões de CO₂ mundial e anomalias⁷ de temperatura superficial do planeta (em referência ao período 1951 a 1980). Por meio da Figura 57, pode-se perceber que a variação na temperatura está diretamente associada às emissões, visto que os valores para a variação positiva da anomalia da temperatura acompanham o crescimento da poluição atmosférica.

⁷ O termo anomalia de temperatura significa um desvio extremo em relação a um valor de referência ou média de um determinado período (série climatológica). Esta informação é uma ferramenta de diagnóstico climático em escala global e fornece uma visão geral das temperaturas globais (Angelocci; Sentelhas, 2007; NCEI-NOAA, 2024).

Figura 57 – Emissões de CO₂ e anomalia de temperatura global anual: 1880 a 2022

Fonte: o autor; elaborada com dados de NASA (2024b) e Ritchie, Rosado e Roser (2023)

A.2 ANÁLISE DE INCERTEZAS

A análise de incertezas determina o potencial de dispersão nos resultados (previsões/estimativas) do modelo devido às incertezas sobre as variáveis de entrada (SimLab 2.2, 2008). Segundo Borrego *et al.* (2005) e Morgan e Henrion (1990), a análise de incertezas consiste no cálculo da incerteza total gerada na saída (resultado) pela incerteza quantificada nas entradas (definições/configurações) do modelo, pelos atributos da importância relativa das incertezas de entrada em termos de suas contribuições. Adicionalmente, a incerteza pode ser definida como um parâmetro associado ao resultado de uma medição, que caracteriza a dispersão dos valores que poderiam ser razoavelmente atribuídos ao resultado mensurado (EURACHEM/CITAC, 2000; Hund; Massart; Smeyers-Verbeke, 2001; ISO, 1995).

As fontes de incerteza podem ser classificadas em três (ou dois) tipos: incertezas aleatórias, incertezas epistêmicas e erros – em algumas bibliografias, inclui-se os erros como uma incerteza epistêmica, categorizando, assim, as incertezas em apenas dois grupos: aleatórias e epistêmicas. De acordo com Moazami *et al.* (2019), tem-se a seguinte classificação:

Incerteza aleatória: ocorre devido à natureza inerentemente aleatória ou estocástica de uma variável, ou do sistema (geralmente desconhecido) subjacente; exemplo: a influência do comportamento dos ocupantes e/ou das condições climáticas no desempenho das edificações.

Incerteza epistêmica ou epistemológica: é definida como uma possível imprecisão que se deve à falta de conhecimento; exemplo: as simplificações e aproximações numéricas de processos físicos considerados em modelos numéricos de ferramentas de simulação.

Erro: é definido como a discrepância entre um valor calculado, observado ou medido e o valor ou condição verdadeiro, especificado ou teoricamente correto; exemplos de fontes de erros são as discrepâncias entre a edificação construída e a simulada, devido a falhas humanas durante a construção ou uso de materiais de construção de qualidade inferior à projetada.

A.3 INFERÊNCIA ESTATÍSTICA

Inferência estatística consiste na elaboração de conclusões a partir de conjuntos de dados, geralmente com o intuito de obter informações sobre características específicas de um amplo conjunto de elementos. Seu objetivo é fazer previsões sobre esses grupos com base em informações de elementos disponíveis (obtidos) e avaliar o grau de incerteza associado a essas previsões. Em outras palavras, na inferência utilizam-se observações de dados/resultados para determinar o parâmetro de interesse, permitindo observações e afirmações probabilísticas sobre determinado modelo, com dados de uma amostra aleatória (probabilística). O processo é dado pela seleção de um modelo estatístico que descreva os dados de interesse, para, a partir desses dados, deduzir afirmações (Reis, 2023).

Segundo Wasserman (2004), a inferência estatística pode ser conduzida por meio de duas abordagens diferentes: frequentista e bayesiana, que diferem nos conceitos referentes à natureza estatística, modelos, parâmetros e intervalos de confiança. As duas abordagens possuem como fundamento testar modelos estatísticos, que incorporam pressupostos relacionados à incerteza sobre o processo que gerou os dados observados (Franco, 2022; Kruschke, 2014). Segundo Franco (Franco, 2022), os modelos possuem três componentes principais: as variáveis as quais se pretende descrever, prever ou explicar; os parâmetros que determinam os aspectos das relações entre as variáveis; e as relações funcionais entre variáveis e entre variáveis e parâmetros.

A.4 ESTATÍSTICA FREQUENTISTA

A Estatística Frequentista, também denominada Estatística Clássica, analisa as probabilidades relacionadas às frequências das observações, com base na ocorrência de eventos do experimento. Nesses termos, a probabilidade não é atualizada conforme a aquisição de novos dados.

Essa abordagem estabelece a noção de probabilidade com base na frequência de ocorrência de um dado evento a longo prazo. Portanto, a escola frequentista analisa probabilidades somente a partir de eventos que podem ser repetidos, e as conclusões obtidas por meio dessa inferência se resume à probabilidade dos dados. É o caso de estudos que determinam valores p , com uso de teste de qui-quadrado, o teste t , correlações, e análises de variância (Garcia; Lima Jr, 2021)

A.5 ESTATÍSTICA BAYESIANA

A Estatística Bayesiana aplicada a análise de dados é baseada no teorema de Bayes, que define probabilidades como uma combinação de expectativa *a priori*⁸ e dados coletados. Assim, a inferência bayesiana consiste em combinar informações subjetivas com informações provenientes de dados conhecidos/observados. Tendo em vista que a abordagem bayesiana não requer eventos repetidos para gerar uma dada probabilidade, é possível definir probabilidades para uma determinada condição, mesmo que ela não tenha sido observada previamente (Garcia; Lima Jr, 2021; McGrayne, 2011).

O princípio de amostragem é essencial para tornar a análise de dados possível. Uma técnica bastante utilizada em análise bayesiana são os Métodos de Monte Carlo via Cadeias de Markov (*Markov Chain Monte Carlo* – MCMC); métodos estocásticos que consistem em cadeias onde a probabilidade de um evento n depende apenas da probabilidade do evento $n - 1$ (Franco, 2022).

O resultado da análise bayesiana adiciona um intervalo de credibilidade ao resultado, algo desejável ao se inferir parâmetros desconhecidos com base em uma amostra. Nesse sentido, a Estatística Bayesiana é bastante útil em situações em que coletar informações da amostra é muito difícil (Morales; Causil, 2018). Garcia e Lima Jr (2021) listam os seguintes motivos que justificam a migração de uma análise frequentista para uma análise bayesiana:

- O teorema de Bayes fornece probabilidades sobre hipóteses, e não sobre dados; e a probabilidade de um efeito é quase sempre mais relevante do que a probabilidade de um dado. Conceitualmente, Bayes possibilita um resultado mais relevante;
- Uma análise bayesiana oferece um panorama mais completo sobre os efeitos de interesse, uma vez que considera uma distribuição a posteriori de efeitos plausíveis. Ou seja, ao invés de apenas um valor p para um dado efeito, tem-se uma distribuição inteira.

⁸ Do latim, partindo daquilo que vem antes.

Essa distribuição é mais facilmente definida e interpretada por meio de intervalos de credibilidade.

Os modelos bayesianos oferecem alto poder de personalização, de acordo com o modelo aplicável e nível de conhecimento na área. Nesse sentido, modelos bayesianos são mais robustos em termos de convergência, algo que pode ser um problema em modelos tradicionais frequentistas. Adicionalmente, modelos bayesianos têm a vantagem de lidar bem com dados ausentes ou com dados desbalanceados, quando há quantidade diferente de dados.

ANEXO A – INFLUÊNCIA DAS MUDANÇAS CLIMÁTICAS NA SENSIBILIDADE GLOBAL DE VARIÁVEIS TERMOFÍSICAS DE HABITAÇÕES DE INTERESSE SOCIAL EM SÃO PAULO

Nos itens deste anexo, resumem-se as principais contribuições da pesquisa de Nunes (2021), destacando os resultados obtidos para o clima de São Paulo, de modo a situar o(a) leitor(a) acerca do ponto de partida de desenvolvimento desta tese, que abrange algumas publicações do autor. Em pesquisas anteriores, determinaram-se a influência das mudanças climáticas na sensibilidade global de parâmetros termofísicos de habitações, identificando as variáveis mais importantes para o desempenho térmico e energético, por meio de simulações computacionais para o clima do passado e para projeções de climas atual e futuros.

A.1 EFICÁCIA DA FERRAMENTA DE PROGRESSÃO DE ARQUIVOS CLIMÁTICOS CCWORLDWEATHERGEN


Uma validação da ferramenta CCWorldWeatherGen foi realizada, comparando-se dados de temperatura do ar (bulbo seco), umidade relativa do ar, radiação solar global e velocidade do vento, obtidos para 2020 (representa 2011 a 2040) por meio da progressão do arquivo TRY de São Paulo, com observações reais, de 01 de janeiro de 2011 a 30 de junho de 2023, registradas pela Estação Meteorológica do Instituto de Astronomia, Geofísica e Ciências Atmosféricas da Universidade de São Paulo (EM-IAG-USP, 2023). A pesquisa foi descrita inicialmente por Nunes (2021) e, recentemente, foi revisada, atualizada e ampliada por Nunes *et al.* (2024).

Nas Figuras 58 a 61 ilustram-se os dados de temperatura do ar (bulbo seco), umidade do ar, radiação solar e velocidade do vento para São Paulo, em médias mensais, médias diárias, médias horárias e médias mensais horárias para o ano todo. As diferentes linhas plotadas nos gráficos representam dados do arquivo TRY, do arquivo com as progressões do CCWorldWeatherGen para o período de 2020 (2011 a 2040) e da EM-IAG-USP (EM-IAG-USP, 2023).

Nos Quadros 18 a 21 listam-se os erros calculados para cada mês e para o ano inteiro, de acordo com os indicadores Erro de Viés Médio (*Mean Bias Error* – MBE), Erro Absoluto Médio (*Mean Absolute Error* – MAE), Raiz Quadrada do Erro-Médio (*Root Mean Squared Error* – RMSE), Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error* – MAPE)

e Raiz Quadrada Relativa do Erro-Médio (*Relative Root Mean Square Error* – RRMSE). Para os valores de MBE, o número indica a quantidade e o sinal mostra o lado do desvio: o sinal negativo indica superestimativa nos valores dos arquivos climáticos em relação aos valores observados (dados da estação meteorológica); um sinal positivo indica subestimativa. Para MAE, RMSE, MAPE e RRMSE, valores maiores e tons mais escuros indicam erros maiores.

Figura 58 – Temperatura do ar (bulbo seco) de São Paulo




Fonte: o autor; adaptada de Nunes *et al.* (2024)

Quadro 18 – Indicadores de erros mensais e anual da temperatura de bulbo seco dos arquivos climáticos, em relação às observações da EM-IAG-USP

Indicador	EPW	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Ano
MBE (°C)	TRY	+0,26	+0,67	+0,79	+1,69	+0,98	+0,03	+0,23	-0,32	+0,49	+1,99	+1,14	+2,05	+0,83
	2020	-0,53	-0,02	+0,06	+0,90	-0,17	-1,17	-0,75	-1,44	-0,63	+1,08	+0,26	+1,47	-0,08
MAE (°C)	TRY	2,20	2,07	2,02	2,89	2,35	2,19	2,57	3,18	3,11	3,58	2,26	3,35	2,65
	2020	2,17	1,95	1,98	2,61	2,29	2,48	2,71	3,48	3,01	3,10	1,98	3,12	2,58
RMSE (°C)	TRY	2,83	2,76	2,64	3,51	3,02	2,79	3,26	4,01	4,07	4,40	3,00	4,05	3,42
	2020	2,88	2,69	2,54	3,22	2,90	3,06	3,40	4,31	4,06	3,94	2,73	3,80	3,35
MAPE (%)	TRY	9,53	8,77	8,96	14,27	13,01	12,85	15,48	18,72	16,41	17,53	10,99	15,07	13,50
	2020	9,41	8,32	8,75	12,93	12,80	14,92	16,64	20,71	16,06	15,15	9,62	14,05	13,32
RRMSE (%)	TRY	12,46	12,11	12,03	17,37	17,06	16,61	20,03	23,72	21,87	22,10	14,97	18,37	17,40
	2020	12,66	11,80	11,58	15,94	16,37	18,21	20,89	25,51	21,78	19,78	13,63	17,24	17,04

Fonte: o autor; adaptado de Nunes *et al.* (2024)

Figura 59 – Umidade relativa do ar de São Paulo



Fonte: o autor; adaptada de Nunes *et al.* (2024)


Quadro 19 – Indicadores de erros mensais e anual da umidade relativa do ar dos arquivos climáticos, em relação às observações da EM-IAG-USP

Indicador	EPW	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Ano
MBE (pp)	TRY	+0,64	-4,23	-3,92	-3,42	-7,26	-3,21	-3,18	+4,81	-3,10	-5,16	-1,47	+0,47	-2,40
	2020	+1,64	-3,23	-2,92	-2,42	-6,26	-2,18	-1,18	+6,81	-3,07	-6,08	-1,47	+1,45	-1,56
MAE (pp)	TRY	9,33	9,13	8,33	8,70	9,65	9,82	12,63	15,16	14,51	12,96	8,23	10,84	10,79
	2020	9,23	8,75	7,87	8,29	8,96	9,49	12,04	15,36	14,51	13,34	8,24	10,80	10,59
RMSE (pp)	TRY	12,83	12,27	11,34	11,72	12,43	12,85	15,79	19,38	18,02	16,53	11,54	14,33	14,35
	2020	12,92	11,96	11,03	11,47	11,87	12,66	15,51	19,97	18,02	16,79	11,54	14,40	14,32
MAPE (%)	TRY	12,29	12,67	11,10	11,71	13,28	13,09	17,88	21,04	20,20	17,72	11,05	14,43	14,73
	2020	12,16	12,15	10,52	11,20	12,40	12,68	17,09	21,28	20,20	18,22	11,05	14,36	14,47
RRMSE (%)	TRY	15,89	15,32	13,82	14,47	15,35	15,74	20,49	25,30	23,37	20,68	14,40	17,98	17,99
	2020	16,00	14,94	13,44	14,16	14,67	15,50	20,13	26,06	23,37	21,00	14,40	18,07	17,95

Fonte: o autor; adaptado de Nunes *et al.* (2024)

Nota: Uma vez que a umidade relativa é expressa em porcentagem (%), pontos percentuais (pp) foram usados para diferenciar a escala medida pelo MBE, MAE e RMSE e a quantidade percentual de erro dada pelo MAPE e RRMSE.

Figura 60 – Radiação solar global de São Paulo⁹



Fonte: o autor; adaptada de Nunes *et al.* (2024)


Quadro 20 – Indicadores de erros mensais e anual da radiação solar global dos arquivos climáticos, em relação às observações da EM-IAG-USP

Indicador	EPW	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez	Ano
MBE (W/m²)	TRY	-32,53	-11,71	-8,23	+1,54	+17,42	+12,57	+30,45	+8,15	+9,34	-26,00	-31,28	-37,85	-5,67
	2020	-37,91	-17,12	-19,78	-23,73	-9,50	-25,46	-6,73	-26,12	0,46	-24,67	-27,99	-42,91	-21,85
MAE (W/m²)	TRY	55,40	39,45	31,47	24,16	19,95	19,43	32,21	32,88	45,37	65,92	57,10	58,38	40,19
	2020	59,14	41,87	38,78	36,72	22,65	37,95	42,97	54,45	54,61	70,26	56,02	61,84	48,18
RMSE (W/m²)	TRY	62,14	48,79	39,27	29,95	24,18	23,12	39,57	40,54	52,18	79,08	65,29	80,03	52,26
	2020	66,71	53,78	48,84	46,60	29,09	45,47	48,96	61,93	60,55	83,94	64,16	84,75	60,00
MAPE (%)	TRY	24,89	17,90	15,67	13,64	12,89	14,73	21,33	19,70	23,96	33,55	25,99	25,34	20,84
	2020	26,54	19,10	19,27	20,43	15,58	29,45	28,75	33,28	28,81	35,73	25,52	26,79	25,82
RRMSE (%)	TRY	27,66	22,00	19,50	16,84	16,32	17,46	26,27	23,79	27,03	38,77	29,07	34,19	27,49
	2020	29,69	24,26	24,25	26,20	19,63	34,34	32,51	36,34	31,37	41,16	28,56	36,21	31,57

Fonte: o autor; adaptado de Nunes *et al.* (2024)

⁹ Uma vez que a EM-IAG-USP fornece a radiação solar global em médias diárias, não foi possível elaborar os gráficos com valores em média horária e média mensal horária.

Figura 61 – Velocidade do vento de São Paulo



Fonte: o autor; adaptada de Nunes *et al.* (2024)

Quadro 21 – Indicadores de erros mensais e anual da velocidade do vento dos arquivos climáticos, em relação às observações da EM-IAG-USP

Indicador	EPW	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Oout	Nov	Dez	Ano
MBE (m/s)	TRY	-2,16	-2,31	-2,11	-2,54	-2,73	-1,89	-2,42	-2,34	-2,67	-2,98	-2,79	-2,86	-2,48
	2020	-2,23	-2,38	-2,11	-2,67	-2,77	-1,95	-2,53	-2,51	-2,67	-2,93	-2,79	-2,89	-2,54
MAE (m/s)	TRY	2,40	2,51	2,32	2,63	2,82	2,13	2,52	2,61	2,85	3,10	2,93	2,98	2,65
	2020	2,46	2,58	2,33	2,76	2,86	2,19	2,63	2,77	2,85	3,05	2,93	3,01	2,70
RMSE (m/s)	TRY	3,13	3,26	2,90	3,22	3,38	2,71	3,14	3,42	3,47	3,72	3,49	3,59	3,30
	2020	3,20	3,34	2,91	3,36	3,44	2,78	3,25	3,62	3,47	3,66	3,49	3,63	3,36
MAPE (%)	TRY	175,90	206,99	179,27	206,72	232,51	197,32	221,92	194,04	186,37	200,10	191,48	198,38	199,23
	2020	180,62	212,36	179,63	216,45	235,61	202,69	230,75	205,55	186,35	196,99	191,48	200,15	203,19
RRMSE (%)	TRY	208,80	223,05	199,48	229,14	242,27	213,57	232,78	223,86	212,52	223,07	208,05	222,61	220,45
	2020	213,89	228,43	200,13	239,52	246,19	219,09	241,23	236,98	212,47	219,30	208,05	225,42	224,44

Fonte: o autor; adaptado de Nunes *et al.* (2024)

Nunes *et al.* (2024) concluíram que a temperatura de bulbo seco e a umidade relativa tiveram boa precisão com os dados medidos, mas a radiação solar e a velocidade do vento não. Apesar dos erros, considerando as condições da pesquisa, conclui-se que é possível gerar progressões de arquivos climáticos confiáveis para análise do desempenho de edificações sob

as perspectivas de mudanças climáticas; no entanto, o processo é limitado à consistência do arquivo climático de referência.

O fato de o clima ser um evento de difícil previsibilidade, somado às limitações do arquivo TRY para São Paulo e condições de medição da EM-IAG-USP (por exemplo, localização e precisão de equipamentos), explicam os erros maiores na radiação solar global e velocidade do vento geradas pelo CCWorldWeatherGen. Por outro lado, a ferramenta gerou progressões de temperatura e umidade relativa que mostraram boa fidelidade com observações reais para o período de 2011 a 2023, em comparação com os dados do TRY (Nunes *et al.*, 2024).


Dessa maneira, considerando todo o apanhado das análises, a ferramenta foi parcialmente validada. A praticidade para gerar arquivos climáticos futuros completos e de forma livre é ressaltada no estudo, observando-se que as progressões são adequadas para simulações de edificações, visto que não foram observadas inconsistências ou dados excessivamente imponderados no arquivo gerado a partir do arquivo de referência.

A.2 PROGRESSÕES CLIMÁTICAS DE SÃO PAULO

Nesta seção, são apresentadas as progressões das variáveis climáticas temperatura do ar (bulbo seco), umidade relativa do ar, radiação solar e velocidade do vento, considerando os períodos 2020, 2050 e 2080. As progressões foram obtidas por meio do CCWorldWeatherGen, a partir do arquivo climático TRY de São Paulo (1954), desenvolvido por Goulart, Lamberts e Firmino (1998) e revisado por Carlo e Lamberts (2005), e disponibilizado pelo Departamento de Energia dos Estados Unidos, na página do EnergyPlus (DOE. U.S., 2023).


As médias mensais horárias, bem como outros parâmetros estatísticos, das variáveis climáticas são ilustradas a seguir, nas Figuras 62 a 64.

Figura 62 – Variáveis climáticas de São Paulo, em médias mensais horárias, de acordo com o arquivo climático TRY e as progressões para 2020, 2050 e 2080




Fonte: Nunes (2021); elaborada a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Figura 63 – Diagramas de caixa para variáveis climáticas de São Paulo, de acordo com o arquivo climático TRY e as progressões para 2020, 2050 e 2080



Fonte: Nunes (2021); elaborada a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Figura 64 – Histogramas de frequência para variáveis climáticas de São Paulo, de acordo com o arquivo climático TRY e progressões para 2020, 2020, 2050 e 2080



Fonte: Nunes (2021); elaborada a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Segundo Nunes (2021), as progressões climáticas conduzem conclusões importantes e preocupantes sobre as alterações no clima ao qual edificações brasileiras estarão sujeitas nos próximos anos. Em relação aos dados meteorológicos do ano climático de referência de São Paulo, estima-se que, no período atual, 2020 (2011–2040), a temperatura do ar, em média anual, é superior em 0,91 °C, e, até 2100, será superior em 4,23 °C.

Nota-se, portanto, a relevância de se considerar os efeitos das alterações no clima e de se dispor de dados meteorológicos adequados à vida útil do ambiente construído, para a realização de simulações. Os resultados evidenciam, ainda, que os arquivos climáticos TRY não são mais suficientes para análises de desempenho de edificações. Embora a ciência climática envolva diversas incertezas, as condições do clima mudam, e, assim sendo, o uso de informações meteorológicas do passado somente, não é razoável para estudos de desempenho de edificações (Nunes, 2021).

A.3 SENSIBILIDADE DE VARIÁVEIS TERMOFÍSICAS EM CENÁRIOS DE MUDANÇAS CLIMÁTICAS

Por último, no Quadro 22 apresentam-se, entre 13 variáveis analisadas, as três variáveis mais influentes (primeira, segunda e terceira, em ordem de apresentação) na resposta do modelo, conforme os períodos climáticos de cada local e conforme os cinco indicadores de desempenho considerados por Nunes (2021): graus-hora para aquecimento (GHA) e resfriamento (GHR), consumo energético com aquecimento (CA) e resfriamento (CR), e desempenho equivalente combinando condicionamento natural e artificial para aquecimento e resfriamento (I_{eq}).

Quadro 22 – Variáveis termofísicas mais influentes no desempenho térmico e energético de habitações, de acordo com cada período climático, em São Paulo

Indicadores de desempenho	Variáveis termofísicas mais influentes, conforme cada período climático			
	TRY (1954)	2020	2050	2080
GHA	Transmitância térmica das paredes Capacidade térmica das paredes Capacidade térmica da cobertura	Capacidade térmica da cobertura Capacidade térmica das paredes Transmitância térmica das paredes	Capacidade térmica da cobertura Capacidade térmica do piso Capacidade térmica das paredes	Capacidade térmica do piso Capacidade térmica da cobertura Absortância solar das paredes
GHR	Capacidade térmica das paredes Transmitância térmica das paredes Absortância solar da cobertura		Transmitância térmica das paredes Capacidade térmica das paredes Absortância solar das paredes	Transmitância térmica das paredes Capacidade térmica das paredes Fator de ventilação
CA	Capacidade térmica da cobertura Capacidade térmica das paredes Transmitância térmica das paredes	Capacidade térmica do piso Capacidade térmica da cobertura Capacidade térmica das paredes	Capacidade térmica do piso Capacidade térmica da cobertura Sombreamento das janelas	não há demanda para aquecimento
CR	Absortância solar da cobertura Transmitância térmica das paredes Absortância solar das paredes	Absortância solar das paredes Transmitância térmica das paredes Absortância solar da cobertura		Transmitância térmica das paredes Absortância solar das paredes Absortância solar da cobertura
Ieq	Transmitância térmica das paredes Capacidade térmica das paredes Absortância solar da cobertura	Transmitância térmica das paredes Absortância solar das paredes Absortância solar da cobertura		

Fonte: o autor; elaborado com dados de Nunes (2021)

Percebe-se que os parâmetros que mais se destacaram nas análises de sensibilidade foram a absortância solar da envoltória, o fator de ventilação, e a transmitância e capacidade térmica das paredes. Por meio dos índices de sensibilidade, nota-se a relevância da ventilação natural como estratégia de aumento de desempenho térmico, diante de temperaturas mais elevadas no futuro. Além disso, a baixa absortância solar e transmitância térmica também podem ser características fundamentais a serem consideradas em definições de projeto de habitações, embora o objetivo e método da pesquisa não tenham visado especificar quais estratégias resultam em melhor desempenho de habitações em períodos futuros (Nunes, 2021).

Embora tenham sido apresentados indicadores para situações de aquecimento (GHA e CA), notou-se que eles foram menos relevantes por causa do contexto de elevação da temperatura (fazendo com que a demanda para aquecimento seja reduzida no futuro).

ANEXO B – AMOSTRA SIMULADA

No Quadro 23, apresentam-se as propriedades termofísicas de cada um dos modelos da amostragem considerada.

Quadro 23 – Propriedades termofísicas de cada modelo da amostra (continua)

Mod	acob	apar	CTcob	CTpar	CTpis	ecob	Fvent	FSvid	OS	tvenez	Ucob	Upar	Upis
1	0,40	0,60	382,33	310,00	177,27	0,33	0,43	0,36	270,00	0,20	1,12	0,27	2,04
2	0,40	0,60	382,33	310,00	177,27	0,33	0,43	0,53	270,00	0,20	1,12	0,27	2,04
3	0,40	0,80	382,33	310,00	177,27	0,33	0,43	0,53	270,00	0,20	1,12	0,27	2,04
4	0,40	0,80	382,33	175,00	177,27	0,33	0,43	0,53	270,00	0,20	1,12	0,27	2,04
5	0,40	0,80	382,33	175,00	177,27	0,33	0,43	0,53	270,00	0,43	1,12	0,27	2,04
6	0,40	0,80	382,33	175,00	177,27	0,33	0,43	0,53	270,00	0,43	1,12	1,65	2,04
7	0,40	0,80	568,00	175,00	177,27	0,33	0,43	0,53	270,00	0,43	1,12	1,65	2,04
8	0,40	0,80	568,00	175,00	177,27	0,62	0,43	0,53	270,00	0,43	1,12	1,65	2,04
9	0,40	0,80	568,00	175,00	177,27	0,62	0,43	0,53	270,00	0,43	1,12	1,65	0,72
10	0,60	0,80	568,00	175,00	177,27	0,62	0,43	0,53	270,00	0,43	1,12	1,65	0,72
11	0,60	0,80	568,00	175,00	13,40	0,62	0,43	0,53	270,00	0,43	1,12	1,65	0,72
12	0,60	0,80	568,00	175,00	13,40	0,62	0,67	0,53	270,00	0,43	1,12	1,65	0,72
13	0,60	0,80	568,00	175,00	13,40	0,62	0,67	0,53	180,00	0,43	1,12	1,65	0,72
14	0,60	0,80	568,00	175,00	13,40	0,62	0,67	0,53	180,00	0,43	0,53	1,65	0,72
15	0,80	0,40	382,33	310,00	177,27	0,05	0,67	0,87	90,00	0,43	1,71	0,27	2,04
16	0,80	0,40	382,33	310,00	177,27	0,05	0,67	0,87	90,00	0,43	2,30	0,27	2,04
17	0,80	0,40	382,33	310,00	177,27	0,05	0,43	0,87	90,00	0,43	2,30	0,27	2,04
18	0,60	0,40	382,33	310,00	177,27	0,05	0,43	0,87	90,00	0,43	2,30	0,27	2,04
19	0,60	0,40	382,33	310,00	177,27	0,33	0,43	0,87	90,00	0,43	2,30	0,27	2,04
20	0,60	0,20	382,33	310,00	177,27	0,33	0,43	0,87	90,00	0,43	2,30	0,27	2,04
21	0,60	0,20	382,33	175,00	177,27	0,33	0,43	0,87	90,00	0,43	2,30	0,27	2,04
22	0,60	0,20	382,33	175,00	177,27	0,33	0,43	0,87	90,00	0,67	2,30	0,27	2,04
23	0,60	0,20	382,33	175,00	341,13	0,33	0,43	0,87	90,00	0,67	2,30	0,27	2,04
24	0,60	0,20	382,33	175,00	341,13	0,33	0,43	0,87	180,00	0,67	2,30	0,27	2,04
25	0,60	0,20	382,33	175,00	341,13	0,33	0,43	0,87	180,00	0,67	2,30	1,65	2,04
26	0,60	0,20	196,67	175,00	341,13	0,33	0,43	0,87	180,00	0,67	2,30	1,65	2,04
27	0,60	0,20	196,67	175,00	341,13	0,33	0,43	0,87	180,00	0,67	2,30	1,65	3,35
28	0,60	0,20	196,67	175,00	341,13	0,33	0,43	0,70	180,00	0,67	2,30	1,65	3,35
29	0,40	0,40	382,33	175,00	177,27	0,05	0,67	0,53	180,00	0,67	0,53	3,02	3,35
30	0,40	0,40	382,33	175,00	177,27	0,05	0,67	0,53	180,00	0,67	0,53	3,02	2,04
31	0,40	0,40	382,33	175,00	341,13	0,05	0,67	0,53	180,00	0,67	0,53	3,02	2,04
32	0,40	0,40	382,33	175,00	341,13	0,05	0,67	0,36	180,00	0,67	0,53	3,02	2,04
33	0,40	0,40	382,33	175,00	341,13	0,33	0,67	0,36	180,00	0,67	0,53	3,02	2,04
34	0,40	0,40	382,33	175,00	341,13	0,33	0,67	0,36	90,00	0,67	0,53	3,02	2,04
35	0,40	0,40	568,00	175,00	341,13	0,33	0,67	0,36	90,00	0,67	0,53	3,02	2,04
36	0,40	0,60	568,00	175,00	341,13	0,33	0,67	0,36	90,00	0,67	0,53	3,02	2,04
37	0,40	0,60	568,00	175,00	341,13	0,33	0,67	0,36	90,00	0,43	0,53	3,02	2,04
38	0,40	0,60	568,00	175,00	341,13	0,33	0,67	0,36	90,00	0,43	1,12	3,02	2,04

Quadro 23 – Propriedades termofísicas de cada modelo da amostra (continua)

Mod	acob	apar	CTcob	CTpar	CTpis	ecob	Fvent	FSvid	OS	tvnez	Ucob	Upar	Upis
39	0,40	0,60	568,00	175,00	341,13	0,33	0,90	0,36	90,00	0,43	1,12	3,02	2,04
40	0,20	0,60	568,00	175,00	341,13	0,33	0,90	0,36	90,00	0,43	1,12	3,02	2,04
41	0,20	0,60	568,00	310,00	341,13	0,33	0,90	0,36	90,00	0,43	1,12	3,02	2,04
42	0,20	0,60	568,00	310,00	341,13	0,33	0,90	0,36	90,00	0,43	1,12	1,65	2,04
43	0,20	0,40	196,67	175,00	505,00	0,62	0,90	0,70	90,00	0,43	1,71	3,02	0,72
44	0,20	0,40	196,67	175,00	505,00	0,62	0,90	0,53	90,00	0,43	1,71	3,02	0,72
45	0,20	0,40	196,67	175,00	505,00	0,62	0,90	0,53	90,00	0,43	1,12	3,02	0,72
46	0,40	0,40	196,67	175,00	505,00	0,62	0,90	0,53	90,00	0,43	1,12	3,02	0,72
47	0,40	0,40	196,67	310,00	505,00	0,62	0,90	0,53	90,00	0,43	1,12	3,02	0,72
48	0,40	0,40	196,67	310,00	505,00	0,62	0,90	0,53	90,00	0,43	1,12	1,65	0,72
49	0,40	0,20	196,67	310,00	505,00	0,62	0,90	0,53	90,00	0,43	1,12	1,65	0,72
50	0,40	0,20	196,67	310,00	505,00	0,62	0,90	0,53	90,00	0,43	1,12	1,65	2,04
51	0,40	0,20	196,67	310,00	505,00	0,62	0,67	0,53	90,00	0,43	1,12	1,65	2,04
52	0,40	0,20	11,00	310,00	505,00	0,62	0,67	0,53	90,00	0,43	1,12	1,65	2,04
53	0,40	0,20	11,00	310,00	341,13	0,62	0,67	0,53	90,00	0,43	1,12	1,65	2,04
54	0,40	0,20	11,00	310,00	341,13	0,62	0,67	0,53	180,00	0,43	1,12	1,65	2,04
55	0,40	0,20	11,00	310,00	341,13	0,33	0,67	0,53	180,00	0,43	1,12	1,65	2,04
56	0,40	0,20	11,00	310,00	341,13	0,33	0,67	0,53	180,00	0,20	1,12	1,65	2,04
57	0,80	0,40	196,67	175,00	341,13	0,33	0,20	0,70	90,00	0,43	1,71	3,02	3,35
58	0,80	0,40	196,67	175,00	341,13	0,33	0,20	0,53	90,00	0,43	1,71	3,02	3,35
59	0,80	0,40	196,67	175,00	341,13	0,33	0,20	0,53	0,00	0,43	1,71	3,02	3,35
60	0,80	0,40	196,67	175,00	341,13	0,33	0,20	0,53	0,00	0,43	2,30	3,02	3,35
61	0,80	0,40	196,67	175,00	341,13	0,33	0,43	0,53	0,00	0,43	2,30	3,02	3,35
62	0,80	0,40	196,67	175,00	341,13	0,33	0,43	0,53	0,00	0,43	2,30	4,40	3,35
63	0,80	0,40	196,67	175,00	341,13	0,33	0,43	0,53	0,00	0,43	2,30	4,40	2,04
64	0,80	0,40	196,67	175,00	341,13	0,05	0,43	0,53	0,00	0,43	2,30	4,40	2,04
65	0,80	0,40	196,67	40,00	341,13	0,05	0,43	0,53	0,00	0,43	2,30	4,40	2,04
66	0,80	0,40	11,00	40,00	341,13	0,05	0,43	0,53	0,00	0,43	2,30	4,40	2,04
67	0,60	0,40	11,00	40,00	341,13	0,05	0,43	0,53	0,00	0,43	2,30	4,40	2,04
68	0,60	0,40	11,00	40,00	177,27	0,05	0,43	0,53	0,00	0,43	2,30	4,40	2,04
69	0,60	0,20	11,00	40,00	177,27	0,05	0,43	0,53	0,00	0,43	2,30	4,40	2,04
70	0,60	0,20	11,00	40,00	177,27	0,05	0,43	0,53	0,00	0,20	2,30	4,40	2,04
71	0,40	0,40	382,33	445,00	341,13	0,62	0,90	0,53	270,00	0,20	2,30	0,27	2,04
72	0,40	0,60	382,33	445,00	341,13	0,62	0,90	0,53	270,00	0,20	2,30	0,27	2,04
73	0,60	0,60	382,33	445,00	341,13	0,62	0,90	0,53	270,00	0,20	2,30	0,27	2,04
74	0,60	0,60	382,33	445,00	341,13	0,62	0,90	0,53	270,00	0,20	2,30	1,65	2,04
75	0,60	0,60	382,33	445,00	177,27	0,62	0,90	0,53	270,00	0,20	2,30	1,65	2,04
76	0,60	0,60	382,33	445,00	177,27	0,62	0,90	0,36	270,00	0,20	2,30	1,65	2,04
77	0,60	0,60	382,33	445,00	177,27	0,62	0,90	0,36	270,00	0,43	2,30	1,65	2,04
78	0,60	0,60	382,33	310,00	177,27	0,62	0,90	0,36	270,00	0,43	2,30	1,65	2,04
79	0,60	0,60	196,67	310,00	177,27	0,62	0,90	0,36	270,00	0,43	2,30	1,65	2,04
80	0,60	0,60	196,67	310,00	177,27	0,33	0,90	0,36	270,00	0,43	2,30	1,65	2,04
81	0,60	0,60	196,67	310,00	177,27	0,33	0,90	0,36	270,00	0,43	1,71	1,65	2,04
82	0,60	0,60	196,67	310,00	177,27	0,33	0,90	0,36	270,00	0,43	1,71	1,65	0,72

Quadro 23 – Propriedades termofísicas de cada modelo da amostra (continua)

Mod	acob	apar	CTcob	CTpar	CTpis	ecob	Fvent	FSvid	OS	tvenez	Ucob	Upar	Upis
83	0,60	0,60	196,67	310,00	177,27	0,33	0,90	0,36	180,00	0,43	1,71	1,65	0,72
84	0,60	0,60	196,67	310,00	177,27	0,33	0,67	0,36	180,00	0,43	1,71	1,65	0,72
85	0,40	0,40	196,67	310,00	177,27	0,90	0,43	0,53	90,00	0,43	1,12	0,27	4,67
86	0,40	0,20	196,67	310,00	177,27	0,90	0,43	0,53	90,00	0,43	1,12	0,27	4,67
87	0,40	0,20	196,67	310,00	341,13	0,90	0,43	0,53	90,00	0,43	1,12	0,27	4,67
88	0,40	0,20	11,00	310,00	341,13	0,90	0,43	0,53	90,00	0,43	1,12	0,27	4,67
89	0,40	0,20	11,00	310,00	341,13	0,62	0,43	0,53	90,00	0,43	1,12	0,27	4,67
90	0,60	0,20	11,00	310,00	341,13	0,62	0,43	0,53	90,00	0,43	1,12	0,27	4,67
91	0,60	0,20	11,00	310,00	341,13	0,62	0,43	0,53	90,00	0,43	1,12	1,65	4,67
92	0,60	0,20	11,00	310,00	341,13	0,62	0,43	0,53	0,00	0,43	1,12	1,65	4,67
93	0,60	0,20	11,00	310,00	341,13	0,62	0,43	0,53	0,00	0,43	1,12	1,65	3,35
94	0,60	0,20	11,00	310,00	341,13	0,62	0,43	0,53	0,00	0,43	1,71	1,65	3,35
95	0,60	0,20	11,00	310,00	341,13	0,62	0,20	0,53	0,00	0,43	1,71	1,65	3,35
96	0,60	0,20	11,00	310,00	341,13	0,62	0,20	0,53	0,00	0,20	1,71	1,65	3,35
97	0,60	0,20	11,00	445,00	341,13	0,62	0,20	0,53	0,00	0,20	1,71	1,65	3,35
98	0,60	0,20	11,00	445,00	341,13	0,62	0,20	0,36	0,00	0,20	1,71	1,65	3,35
99	0,40	0,60	382,33	175,00	505,00	0,62	0,43	0,53	180,00	0,43	1,12	0,27	2,04
100	0,20	0,60	382,33	175,00	505,00	0,62	0,43	0,53	180,00	0,43	1,12	0,27	2,04
101	0,20	0,60	568,00	175,00	505,00	0,62	0,43	0,53	180,00	0,43	1,12	0,27	2,04
102	0,20	0,60	568,00	175,00	505,00	0,62	0,43	0,53	180,00	0,67	1,12	0,27	2,04
103	0,20	0,60	568,00	175,00	505,00	0,62	0,43	0,53	180,00	0,67	1,71	0,27	2,04
104	0,20	0,80	568,00	175,00	505,00	0,62	0,43	0,53	180,00	0,67	1,71	0,27	2,04
105	0,20	0,80	568,00	175,00	505,00	0,62	0,43	0,53	180,00	0,67	1,71	1,65	2,04
106	0,20	0,80	568,00	175,00	505,00	0,62	0,43	0,36	180,00	0,67	1,71	1,65	2,04
107	0,20	0,80	568,00	175,00	505,00	0,62	0,43	0,36	270,00	0,67	1,71	1,65	2,04
108	0,20	0,80	568,00	310,00	505,00	0,62	0,43	0,36	270,00	0,67	1,71	1,65	2,04
109	0,20	0,80	568,00	310,00	505,00	0,90	0,43	0,36	270,00	0,67	1,71	1,65	2,04
110	0,20	0,80	568,00	310,00	505,00	0,90	0,20	0,36	270,00	0,67	1,71	1,65	2,04
111	0,20	0,80	568,00	310,00	505,00	0,90	0,20	0,36	270,00	0,67	1,71	1,65	3,35
112	0,20	0,80	568,00	310,00	341,13	0,90	0,20	0,36	270,00	0,67	1,71	1,65	3,35
113	0,60	0,60	382,33	310,00	13,40	0,33	0,43	0,53	90,00	0,90	1,71	4,40	2,04
114	0,60	0,80	382,33	310,00	13,40	0,33	0,43	0,53	90,00	0,90	1,71	4,40	2,04
115	0,60	0,80	382,33	310,00	13,40	0,33	0,43	0,53	180,00	0,90	1,71	4,40	2,04
116	0,60	0,80	382,33	310,00	177,27	0,33	0,43	0,53	180,00	0,90	1,71	4,40	2,04
117	0,60	0,80	382,33	310,00	177,27	0,33	0,43	0,53	180,00	0,90	1,71	3,02	2,04
118	0,60	0,80	196,67	310,00	177,27	0,33	0,43	0,53	180,00	0,90	1,71	3,02	2,04
119	0,60	0,80	196,67	310,00	177,27	0,05	0,43	0,53	180,00	0,90	1,71	3,02	2,04
120	0,60	0,80	196,67	175,00	177,27	0,05	0,43	0,53	180,00	0,90	1,71	3,02	2,04
121	0,60	0,80	196,67	175,00	177,27	0,05	0,43	0,70	180,00	0,90	1,71	3,02	2,04
122	0,60	0,80	196,67	175,00	177,27	0,05	0,67	0,70	180,00	0,90	1,71	3,02	2,04
123	0,40	0,80	196,67	175,00	177,27	0,05	0,67	0,70	180,00	0,90	1,71	3,02	2,04
124	0,40	0,80	196,67	175,00	177,27	0,05	0,67	0,70	180,00	0,90	1,71	3,02	3,35
125	0,40	0,80	196,67	175,00	177,27	0,05	0,67	0,70	180,00	0,67	1,71	3,02	3,35
126	0,40	0,80	196,67	175,00	177,27	0,05	0,67	0,70	180,00	0,67	1,12	3,02	3,35

Quadro 23 – Propriedades termofísicas de cada modelo da amostra (conclusão)

Mod	acob	apar	CTcob	CTpar	CTpis	ecob	Fvent	FSvid	OS	tvnez	Ucob	Upar	Upis
127	0,60	0,20	11,00	310,00	177,27	0,33	0,90	0,70	270,00	0,67	1,12	3,02	2,04
128	0,60	0,20	11,00	310,00	177,27	0,33	0,90	0,70	270,00	0,67	1,12	4,40	2,04
129	0,60	0,20	11,00	310,00	177,27	0,33	0,90	0,70	180,00	0,67	1,12	4,40	2,04
130	0,60	0,20	11,00	445,00	177,27	0,33	0,90	0,70	180,00	0,67	1,12	4,40	2,04
131	0,60	0,20	11,00	445,00	177,27	0,33	0,90	0,70	180,00	0,67	0,53	4,40	2,04
132	0,60	0,20	11,00	445,00	177,27	0,33	0,90	0,87	180,00	0,67	0,53	4,40	2,04
133	0,60	0,20	11,00	445,00	177,27	0,33	0,90	0,87	180,00	0,67	0,53	4,40	3,35
134	0,60	0,20	11,00	445,00	177,27	0,05	0,90	0,87	180,00	0,67	0,53	4,40	3,35
135	0,60	0,40	11,00	445,00	177,27	0,05	0,90	0,87	180,00	0,67	0,53	4,40	3,35
136	0,80	0,40	11,00	445,00	177,27	0,05	0,90	0,87	180,00	0,67	0,53	4,40	3,35
137	0,80	0,40	11,00	445,00	341,13	0,05	0,90	0,87	180,00	0,67	0,53	4,40	3,35
138	0,80	0,40	11,00	445,00	341,13	0,05	0,90	0,87	180,00	0,43	0,53	4,40	3,35
139	0,80	0,40	196,67	445,00	341,13	0,05	0,90	0,87	180,00	0,43	0,53	4,40	3,35
140	0,80	0,40	196,67	445,00	341,13	0,05	0,67	0,87	180,00	0,43	0,53	4,40	3,35
141	0,40	0,60	196,67	40,00	13,40	0,90	0,43	0,70	0,00	0,67	1,71	1,65	2,04
142	0,20	0,60	196,67	40,00	13,40	0,90	0,43	0,70	0,00	0,67	1,71	1,65	2,04
143	0,20	0,60	196,67	40,00	13,40	0,90	0,43	0,70	90,00	0,67	1,71	1,65	2,04
144	0,20	0,60	196,67	40,00	13,40	0,90	0,43	0,87	90,00	0,67	1,71	1,65	2,04
145	0,20	0,80	196,67	40,00	13,40	0,90	0,43	0,87	90,00	0,67	1,71	1,65	2,04
146	0,20	0,80	196,67	40,00	13,40	0,90	0,43	0,87	90,00	0,67	1,71	3,02	2,04
147	0,20	0,80	196,67	40,00	177,27	0,90	0,43	0,87	90,00	0,67	1,71	3,02	2,04
148	0,20	0,80	196,67	40,00	177,27	0,90	0,43	0,87	90,00	0,67	1,71	3,02	3,35
149	0,20	0,80	196,67	40,00	177,27	0,90	0,43	0,87	90,00	0,90	1,71	3,02	3,35
150	0,20	0,80	196,67	175,00	177,27	0,90	0,43	0,87	90,00	0,90	1,71	3,02	3,35
151	0,20	0,80	196,67	175,00	177,27	0,90	0,67	0,87	90,00	0,90	1,71	3,02	3,35
152	0,20	0,80	196,67	175,00	177,27	0,62	0,67	0,87	90,00	0,90	1,71	3,02	3,35
153	0,20	0,80	196,67	175,00	177,27	0,62	0,67	0,87	90,00	0,90	2,30	3,02	3,35
154	0,20	0,80	11,00	175,00	177,27	0,62	0,67	0,87	90,00	0,90	2,30	3,02	3,35
155	0,60	0,80	11,00	175,00	341,13	0,33	0,20	0,70	180,00	0,90	0,53	4,40	4,67
156	0,60	0,80	11,00	310,00	341,13	0,33	0,20	0,70	180,00	0,90	0,53	4,40	4,67
157	0,60	0,80	11,00	310,00	341,13	0,33	0,20	0,70	180,00	0,90	0,53	3,02	4,67
158	0,60	0,80	11,00	310,00	341,13	0,33	0,20	0,70	180,00	0,90	1,12	3,02	4,67
159	0,60	0,80	11,00	310,00	341,13	0,33	0,20	0,70	270,00	0,90	1,12	3,02	4,67
160	0,60	0,80	196,67	310,00	341,13	0,33	0,20	0,70	270,00	0,90	1,12	3,02	4,67
161	0,60	0,80	196,67	310,00	341,13	0,33	0,43	0,70	270,00	0,90	1,12	3,02	4,67
162	0,60	0,80	196,67	310,00	341,13	0,33	0,43	0,70	270,00	0,90	1,12	3,02	3,35
163	0,60	0,80	196,67	310,00	177,27	0,33	0,43	0,70	270,00	0,90	1,12	3,02	3,35
164	0,60	0,80	196,67	310,00	177,27	0,05	0,43	0,70	270,00	0,90	1,12	3,02	3,35
165	0,60	0,80	196,67	310,00	177,27	0,05	0,43	0,70	270,00	0,67	1,12	3,02	3,35
166	0,80	0,80	196,67	310,00	177,27	0,05	0,43	0,70	270,00	0,67	1,12	3,02	3,35
167	0,80	0,80	196,67	310,00	177,27	0,05	0,43	0,53	270,00	0,67	1,12	3,02	3,35
168	0,80	0,60	196,67	310,00	177,27	0,05	0,43	0,53	270,00	0,67	1,12	3,02	3,35


Fonte: Nunes (2021)

ANEXO C – PROGRESSÕES CLIMÁTICAS

Nos itens deste anexo, detalham-se dados de temperatura de bulbo seco, umidade relativa do ar, radiação solar global (desconsiderando-se os horários noturnos) e velocidade do vento de São Paulo, em médias mensais, médias diárias, médias mensais horárias, e valores horários para o ano todo, conforme os períodos climáticos estudados.


Nas Figuras 65 a 68, e nos Quadros 24 a 27, apresentam-se informações referentes às progressões climáticas.

Figura 65 – Temperatura de bulbo seco de São Paulo, conforme os períodos climáticos




Fonte: Nunes (2021); elaborada a partir de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Figura 66 – Umidade relativa do ar de São Paulo, conforme os períodos climáticos




Fonte: Nunes (2021); elaborada a partir de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Figura 67 – Radiação solar global de São Paulo, conforme os períodos climáticos



Fonte: Nunes (2021); elaborada a partir de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Figura 68 – Velocidade do vento de São Paulo, conforme os períodos climáticos



Fonte: Nunes (2021); elaborada a partir de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Quadro 24 – Estatísticas para a temperatura de bulbo seco [°C] de São Paulo, conforme os períodos climáticos

Mês		Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
TRY (1954)	Média	22,47	22,13	21,18	18,51	16,74	16,76	16,05	17,23	18,13	17,91	18,88	20,00
	Média das mínimas	18,74	18,98	18,06	15,42	13,95	13,36	12,23	12,35	14,45	14,64	15,31	16,23
	Média das máximas	28,48	26,92	26,60	23,20	21,05	21,72	21,91	23,66	24,39	23,10	24,68	24,89
	Mínima	15,64	16,72	15,27	11,73	9,56	8,92	9,20	7,82	9,76	10,17	12,64	12,40
	Máxima	32,03	32,58	30,82	28,62	26,67	24,71	26,88	27,58	31,78	30,89	32,47	31,13
2020	Média	23,27	22,82	21,91	19,31	17,89	17,95	17,03	18,35	19,26	18,82	19,75	20,58
	Média das mínimas	19,52	19,62	18,76	16,19	15,05	14,49	13,11	13,38	15,62	15,69	16,27	16,79
	Média das máximas	29,28	27,62	27,39	24,03	22,27	23,00	23,05	24,88	25,43	23,79	25,43	25,49
	Mínima	16,34	17,32	15,97	12,43	10,56	9,92	10,00	8,76	10,86	11,41	13,64	12,90
	Máxima	32,83	33,28	31,62	29,52	27,97	26,01	28,18	28,88	32,68	31,29	33,07	31,73
2050	Média	24,33	23,85	23,01	20,45	19,35	19,29	18,49	19,90	21,02	20,29	21,06	21,79
	Média das mínimas	20,47	20,68	19,94	17,33	16,46	15,78	14,39	14,73	17,10	16,95	17,51	17,96
	Média das máximas	30,52	28,66	28,41	25,19	23,82	24,43	24,76	26,71	27,66	25,58	26,79	26,76
	Mínima	17,24	18,37	17,17	13,63	11,91	11,22	11,10	9,92	12,06	12,37	14,84	14,10
	Máxima	34,17	34,38	32,62	30,62	29,67	27,51	30,08	30,88	35,53	33,49	34,51	33,13
2080	Média	25,99	25,53	24,72	22,23	21,47	21,75	20,81	22,24	23,03	22,35	23,11	23,53
	Média das mínimas	22,09	22,25	21,56	19,13	18,60	18,25	16,93	17,15	19,12	18,89	19,46	19,69
	Média das máximas	32,29	30,52	30,25	26,95	25,91	26,87	26,77	28,93	29,65	27,83	29,03	28,51
	Mínima	18,84	19,92	18,72	15,43	14,06	13,67	13,90	12,42	14,26	14,17	16,74	15,80
	Máxima	36,03	36,38	34,52	32,42	31,67	29,97	31,78	33,08	37,48	36,09	36,97	34,83

Fonte: Nunes (2021); elaborado a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Quadro 25 – Estatísticas para a umidade relativa do ar [%] de São Paulo, conforme os períodos climáticos

Mês		Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
TRY (1954)	Média	80,07	84,29	85,97	84,44	88,22	84,87	80,23	71,81	80,21	85,13	81,63	79,22
	Média das mínimas	52,69	63,46	61,91	60,98	67,61	61,97	52,39	44,03	53,27	61,88	55,61	56,77
	Média das máximas	96,29	96,85	97,58	97,36	98,36	98,53	96,55	93,00	96,11	98,00	95,94	94,67
	Mínima	33,55	38,10	39,00	40,80	49,00	35,45	34,25	21,00	26,10	32,35	25,15	31,45
	Máxima	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00	100,00
2020	Média	79,07	83,29	84,97	83,44	87,22	83,85	78,23	69,82	80,18	86,04	81,64	78,23
	Média das mínimas	51,69	62,46	60,91	59,98	66,61	60,94	50,39	42,03	53,23	62,88	55,61	55,77
	Média das máximas	95,29	95,85	96,58	96,36	97,36	97,53	94,55	91,06	96,07	98,55	95,98	93,70
	Mínima	32,55	37,10	38,00	39,80	48,00	34,45	32,25	19,00	26,10	33,35	25,15	30,45
	Máxima	99,00	99,00	99,00	99,00	99,00	99,00	98,00	98,00	100,00	100,00	100,00	99,00
2050	Média	78,07	82,29	83,97	82,44	86,22	81,90	76,26	67,81	76,24	84,10	80,63	77,24
	Média das mínimas	50,69	61,46	59,91	58,98	65,61	59,00	48,42	40,03	49,30	60,85	54,61	54,80
	Média das máximas	94,29	94,85	95,58	95,36	96,36	95,57	92,55	89,10	92,17	96,97	94,94	92,70
	Mínima	31,55	36,10	37,00	38,80	47,00	32,45	30,25	17,00	22,10	31,35	24,15	29,45
	Máxima	98,00	98,00	98,00	98,00	98,00	97,00	96,00	96,00	98,00	99,00	99,00	98,00
2080	Média	76,07	80,29	81,97	80,44	83,25	79,87	75,20	64,85	74,23	82,10	79,61	76,22
	Média das mínimas	48,69	59,46	57,91	56,98	62,64	56,97	47,36	37,06	47,30	58,85	53,61	53,77
	Média das máximas	92,29	92,85	93,58	93,36	93,38	93,53	91,52	86,19	90,14	94,97	93,94	91,67
	Mínima	29,55	34,10	35,00	36,80	44,00	30,45	29,25	14,00	20,10	29,35	23,15	28,45
	Máxima	96,00	96,00	96,00	96,00	95,00	95,00	95,00	94,00	95,00	97,00	98,00	97,00

Fonte: Nunes (2021); elaborado a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Quadro 26 – Estatísticas para a radiação solar global [W/m²] de São Paulo, conforme os períodos climáticos

Mês		Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
TRY (1954)	Média	440,92	410,65	388,86	352,66	261,57	239,64	240,36	324,55	359,39	405,42	438,72	466,12
	Média das mínimas	11,87	12,86	12,43	21,79	11,35	4,36	3,39	11,69	26,36	5,47	13,62	23,34
	Média das máximas	822,77	737,84	715,45	615,03	473,89	467,03	468,05	614,57	629,34	778,87	834,57	843,93
	Mínima	4,22	0,73	2,05	15,18	5,10	2,06	1,96	3,73	1,44	1,59	5,02	16,08
	Máxima	1070,04	1006,90	961,90	863,90	621,01	575,13	618,85	773,87	867,83	1125,07	1000,91	1244,47
2020	Média	450,14	420,16	410,29	403,20	315,39	315,72	314,71	393,08	376,75	403,07	433,09	474,78
	Média das mínimas	14,34	12,61	10,40	28,08	13,80	5,66	4,22	15,47	34,18	5,07	12,38	30,04
	Média das máximas	829,91	753,22	758,78	704,23	570,05	615,26	603,43	722,00	653,65	758,40	812,57	839,17
	Mínima	5,82	1,72	0,99	15,89	8,09	3,50	2,35	5,27	2,07	0,76	4,83	16,22
	Máxima	1072,82	1056,80	1011,66	1000,32	798,93	782,15	802,49	880,61	883,04	1091,48	967,67	1185,08
2050	Média	461,37	426,23	407,79	409,25	322,22	323,24	320,13	395,85	386,80	417,30	434,40	479,21
	Média das mínimas	14,44	12,63	10,40	28,21	13,75	5,65	4,21	15,47	34,68	5,07	12,40	30,00
	Média das máximas	850,92	764,20	754,15	715,44	582,65	630,79	614,66	726,82	671,56	787,15	814,91	847,54
	Mínima	5,93	1,72	1,05	16,05	7,98	3,51	2,43	5,27	2,12	0,66	4,80	16,13
	Máxima	1100,34	1067,05	1004,49	1016,21	816,99	802,28	814,93	891,30	907,53	1133,77	969,63	1182,83
2080	Média	465,80	434,92	424,08	411,46	335,96	331,50	322,07	401,03	390,58	421,07	441,96	478,52
	Média das mínimas	14,48	12,62	10,32	28,30	13,59	5,63	4,21	15,53	35,05	5,07	12,34	29,95
	Média das máximas	859,13	780,26	784,84	719,52	608,69	647,24	618,85	735,91	679,38	795,14	829,24	846,23
	Mínima	5,94	1,72	0,83	16,22	7,48	3,61	2,43	5,39	2,12	0,62	4,82	16,15
	Máxima	1111,15	1094,71	1046,54	1020,10	854,27	805,36	822,89	903,50	918,35	1144,14	987,17	1182,93

Fonte: Nunes (2021); elaborado a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

Quadro 27 – Estatísticas para a velocidade do vento [m/s] de São Paulo, conforme os períodos climáticos

Mês		Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro
TRY (1954)	Média	3,66	3,77	3,56	3,94	4,12	3,16	3,77	3,87	4,30	4,65	4,47	4,47
	Média das mínimas	0,56	1,09	0,65	1,33	1,30	0,79	1,23	1,09	1,45	1,57	1,56	1,28
	Média das máximas	8,10	7,66	7,33	7,28	7,43	6,47	7,15	7,53	7,91	8,34	8,14	8,44
	Mínima	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	Máxima	14,55	15,75	9,55	10,00	11,45	10,90	11,80	13,00	10,45	12,00	10,00	12,10
2020	Média	3,72	3,84	3,57	4,08	4,16	3,22	3,88	4,04	4,30	4,60	4,47	4,50
	Média das mínimas	0,57	1,10	0,66	1,37	1,30	0,80	1,27	1,13	1,45	1,57	1,56	1,28
	Média das máximas	8,22	7,79	7,35	7,52	7,52	6,58	7,34	7,86	7,91	8,24	8,14	8,53
	Mínima	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	Máxima	14,81	16,01	9,65	10,30	11,55	11,10	12,15	13,60	10,45	11,90	10,00	12,20
2050	Média	3,79	3,85	3,67	4,12	4,26	3,29	3,91	4,02	4,42	4,65	4,44	4,50
	Média das mínimas	0,59	1,10	0,67	1,38	1,34	0,82	1,28	1,13	1,50	1,57	1,56	1,28
	Média das máximas	8,40	7,85	7,53	7,62	7,65	6,72	7,42	7,82	8,11	8,31	8,04	8,53
	Mínima	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	Máxima	15,05	16,11	9,85	10,50	11,80	11,35	12,25	13,50	10,75	11,90	9,90	12,20
2080	Média	3,74	3,99	3,81	4,34	4,44	3,45	4,14	4,21	4,47	4,65	4,38	4,55
	Média das mínimas	0,57	1,15	0,70	1,46	1,41	0,87	1,36	1,19	1,50	1,57	1,54	1,29
	Média das máximas	8,29	8,11	7,86	8,00	7,99	7,03	7,86	8,16	8,23	8,34	7,97	8,58
	Mínima	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00
	Máxima	14,91	16,66	10,31	11,00	12,35	11,89	12,94	14,10	10,85	12,00	9,85	12,30

Fonte: Nunes (2021); elaborado a partir de dados de Carlo e Lamberts (2005) e Goulart, Lamberts e Firmino (1998)

