



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

Rayner Maurício e Silva Machado

**Desenvolvimento e análise de incerteza de método de zoneamento bioclimático
para edifícios brasileiros**

Florianópolis, SC
2024

Rayner Maurício e Silva Machado

**Desenvolvimento e análise de incerteza de método de zoneamento bioclimático
para edifícios brasileiros**

Tese submetida ao Programa de Pós-Graduação
em Engenharia Civil da Universidade Federal de
Santa Catarina como requisito parcial para a obten-
ção do título de Doutor em Engenharia Civil.

Orientador: Prof. Roberto Lamberts, PhD

Coorientadora: Profa. Ana Paula Melo, Dra.

Florianópolis, SC
2024

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Machado, Rayner Maurício e Silva
Desenvolvimento e análise de incerteza de método de zoneamento bioclimático para edifícios brasileiros / Rayner Maurício e Silva Machado ; orientador, Roberto Lamberts, coorientador, Ana Paula Melo, 2024.
183 p.

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia Civil, Florianópolis, 2024.

Inclui referências.

1. Engenharia Civil. 2. Zoneamento bioclimático. 3. Modelagem computacional. 4. Ilha de calor urbana. 5. Mudanças climáticas. I. Lamberts, Roberto. II. Melo, Ana Paula. III. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Civil. IV. Título.

Rayner Maurício e Silva Machado

**Desenvolvimento e análise de incerteza de método de zoneamento bioclimático
para edifícios brasileiros**

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

Profa. Joyce Correna Carlo, Dra.

Universidade Federal de Viçosa

Prof. Antônio César Silveira Baptista da Silva, Dr.

Universidade Federal de Pelotas

Prof. Deivis Luis Marinoski, Dr.

Universidade Federal de Santa Catarina

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

Coordenação do Programa de
Pós-Graduação

Prof. Roberto Lamberts, PhD
Orientador

Florianópolis, SC, 2024.

"Sábio é aquele que conhece os limites da própria ignorância."
(Sócrates)

RESUMO

Como os ambientes das edificações são sistemas bioclimáticos específicos e complexos, são essencialmente necessários métodos de classificação climática adequados para desenvolver diretrizes e normas para edificações. Para resolver isso, a presente pesquisa introduz um novo método de agrupamento para o zoneamento bioclimático baseado no desempenho higrotérmico e energético de edificações brasileiras. A disponibilidade de dados climáticos confiáveis e precisos é crucial para a implementação de um método de zoneamento eficaz, mas outras incertezas como os microclimas e as condições climáticas futuras também podem influenciar. Assim, o estudo também tem como objetivo investigar como a incerteza em relação aos dados climáticos pode influenciar a classificação climática, explorando o impacto da acurácia do banco de dados climáticos, dos microclimas e do comportamento climático futuro. Este zoneamento bioclimático foi desenvolvido para atualizar uma normativa brasileira e foi validado em vários climas e tipologias de edificações (residenciais e comerciais) no Brasil. Numa análise preliminar, foram desenvolvidos três métodos de classificação utilizando K-means e Árvore de Decisão para classificar os climas de acordo com o desempenho do edifício. Posteriormente, um método final de zoneamento bioclimático foi desenvolvido utilizando uma versão customizada do melhor método projetado para aplicações do mundo real no contexto brasileiro. O desempenho do zoneamento bioclimático desenvolvido foi comparado com três classificações climáticas existentes: Köppen-Geiger, ASHRAE 169-2020 e ABNT-NBR 15220-3 (Norma Brasileira). Os resultados mostraram que o novo método de zoneamento bioclimático superou os existentes para agrupar os indicadores de desempenho da edificação. Além disso, bancos de dados climáticos de alta resolução espacial, como NASA-POWER, CRU e ERA5-Land, foram processados e analisados para serem empregados em locais sem dados medidos adequadamente. Três metamodelos de indicadores climáticos foram desenvolvidos e comparados com estas bases de dados para selecionar as fontes de dados climáticos mais precisas. Por fim, essas bases de dados foram utilizadas para classificar todos os 5.570 municípios brasileiros de acordo com o zoneamento bioclimático final, o que possibilitou o desenvolvimento de um mapa preciso e de alta resolução. O estudo também avalia a incerteza na acurácia dos dados climáticos comparando dados de reanálise (ERA5-Land) e uma rede neural artificial (ANN) com dados de anos meteorológicos típicos (TMYx.2007-2021). Para avaliar o microclima é utilizado o software *Urban Weather Generator* (UWG), que é calibrado com base na temperatura de bulbo seco de uma estação meteorológica urbanizada, utilizando *Particle Swarm Optimization* (PSO) e posteriormente aplicado em Zonas Climáticas Locais (LCZs). A análise das mudanças climáticas considerou dois cenários de emissões (RCP2.6 e RCP8.5), três modelos GCMs (HadGEM2, MPI-ESM e NorESM1) e dois modelos RCMs (RegCM e REMO). Todas as cidades brasileiras (5.570) foram analisadas, mas uma análise profunda foi realizada em 34 delas. Por fim, a avaliação das três fontes de incerteza resultou em diferenças significativas. Essas diferenças impactam na classificação bioclimática das cidades analisadas.

Palavras-chave: Zoneamento bioclimático. Modelagem computacional. Ilha de calor urbana. Mudanças climáticas. Análise de incerteza.

ABSTRACT

Building environments are specific and complex bioclimatic systems. Thus, well-suited climate classification methods for buildings are essentially needed to develop building design guidelines and standards. To address it, the present research introduces a novel fit-for-purpose clustering method for bioclimatic zoning based on the hygrothermal and energy performance of buildings. The availability of reliable and accurate climate data is crucial for implementing an effective zoning method, but other uncertainties like microclimates and future climate conditions can also influence. Thus, the study also aims to investigate how uncertainty regarding climate data can influence climate classification, considering a bioclimatic zoning method for Brazil and exploring the impact of climate database accuracy, microclimates, and future climate behavior on climate classification. This bioclimatic zoning was developed to update the Brazilian standard and has been validated across various climates and building typologies (residential and commercial) in Brazil. In a preliminary analysis, three classification methods were developed using K-means and Decision Tree to classify climates according to building performance. Subsequently, a final bioclimatic zoning method was developed using a tailored version of the best method designed for real-world applications in the Brazilian context. The performance of the bioclimatic zoning achieved was compared with three existing climate classifications: Köppen-Geiger, ASHRAE 169-2020, and ABNT-NBR 15220-3 (Brazilian Standard). The results showed that the new bioclimatic zoning method outperformed the existing ones to cluster the building performance indicators. Moreover, high-resolution spatial climate databases, such as NASA-POWER, CRU, and ERA5-Land, were processed and analyzed to be employed in locations without properly measured data. Three metamodels of climate indicators were developed and compared with these databases to select the most accurate climate data sources. Finally, these databases were employed to classify all 5570 Brazilian municipalities according to the final bioclimatic zoning, which enabled the development of an accurate and high-resolution map. The study evaluates the accuracy of climate data analysis by comparing reanalysis data (ERA5-Land) and an artificial neural network (ANN) to data from typical meteorological years (TMYx.2007-2021). To evaluate the microclimate, the Urban Weather Generator (UWG) software is employed, which is calibrated based on dry-bulb temperature from an urbanized meteorological station, using Particle Swarm Optimization (PSO) and subsequently applied in Local Climate Zones (LCZs). The climate change analysis considered two emission scenarios (RCP2.6 and RCP8.5), three GCMs models (HadGEM2, MPI-ESM, and NorESM1), and two RCMs models (RegCM and REMO). All Brazilian cities (5570) were analyzed, but a deep analysis was conducted in 34 of them. Finally, evaluating the three sources of uncertainty resulted in significant differences. These differences have an impact on the bioclimatic classification of the cities analyzed.

Keywords: Bioclimatic zoning. Computational modeling. Urban heat island. Climate change. Uncertainty analysis.

LISTA DE FIGURAS

Figura 1 – Porcentagem de anos por clima presente em cada base de dados (A) e número de localidades por base de dados (B).	46
Figura 2 – Histograma do número de locais de acordo com o número de horas medidas por dia (A) e histograma do número de locais de acordo com a soma das horas com dados faltantes ao longo do ano no TMYx.2004-2018 e TMYx.2007-2021 (B).	47
Figura 3 – Índice de sensibilidade dos indicadores climáticos frente aos indicadores de desempenho de edificações residenciais e comerciais. . . .	48
Figura 4 – Zoneamento baseado no desempenho da edificação: gráfico de barra da métrica Silhouette de quatro grupos de indicadores de desempenho do edifício (A) e <i>boxplot</i> da carga térmica de resfriamento do edifício de referência do melhor e pior zoneamento (B).	50
Figura 5 – Zoneamento baseado em indicadores climáticos: dispersão da métrica Silhouette e do Calinski-Harabasz, considerando todas as combinações (A) e indicadores climáticos das três melhores combinações de acordo com a métrica Silhouette (B).	51
Figura 6 – Zoneamento baseado na árvore de decisão: Dispersão do Silhouette Score e Calinski-Harabasz Score do melhor zoneamento para cada número de grupos (A) e importância dos indicadores climáticos (B).	52
Figura 7 – Avaliação do desempenho de métodos de zoneamento climático existentes e da proposta final de zoneamento bioclimático segundo a métrica Silhouette e Calinski-Harabasz.	55
Figura 8 – Validação dos resultados do metamodelo de DBTmean (A), RHmean (B), HDD14 (C).	56
Figura 9 – Mapa da proposta final de zoneamento bioclimático brasileiro. . . .	58
Figura 10 – Mapa de valores interpolados da diferença entre os dados espaciais de alta resolução (ERA5-Land e ANN) e os dados do TMY (TMYx.2007-2021): (A) DBTmean e (B) RHmean	66
Figura 11 – Relação entre temperatura média anual de bulbo seco, altitude e latitude.	68
Figura 12 – Histogramas da diferença entre a temperatura média anual máxima e mínima de bulbo seco observada no território de cada município brasileiro: (A) amplitude e (B) desvio-padrão.	69
Figura 13 – Mudanças na classificação climática de três cidades devido à temperatura de bulbo seco observada em diferentes estações meteorológicas.	71

Figura 14 – Histogramas do RMSE da temperatura média anual de bulbo seco do PSO e da Sequência de Sobol.	72
Figura 15 – Comparação dos valores médios horários de dezembro de 2018 considerando a simulação no UWG e as estações meteorológicas rurais e urbanizadas: (A) temperatura de bulbo seco e (B) umidade relativa.	73
Figura 16 – Valores máximos, mínimos e médios de acordo com seis zonas climáticas locais: (A) temperatura de bulbo seco e (B) umidade relativa.	74
Figura 17 – DBTmean em diferentes cenários de emissões: (A) baixas emissão e (B) alta emissão.	75
Figura 18 – RHmean em diferentes cenários de emissões: (A) baixa emissão e (B) alta emissão.	76
Figura 19 – DBTmean e RHmean para Brasília, considerando vários modelos e décadas: (A) cenário de baixa emissão e (B) cenário de alta emissão.	77

LISTA DE QUADROS

Quadro 1 – Comparativo entre programas de simulação energética 29

LISTA DE TABELAS

Tabela 1 – Critérios de classificação do zoneamento bioclimático final para o Brasil.	54
Tabela 2 – Análise da acurácia dos dados do NASA-POWER, ERA5-Land e CRU em comparação com os dados do TMYx.2007-2021.	57
Tabela 3 – Valores mínimos e máximos das entradas do UWG usados na calibração.	62
Tabela 4 – Combinações de parâmetros usados no algoritmo PSO.	63
Tabela 5 – Três cidades com alterações na zona bioclimática devido à incerteza na acurácia dos dados.	67
Tabela 6 – Quatro cidades com alterações na zona bioclimática devido à incerteza na análise climática local.	70

SUMÁRIO

1	INTRODUÇÃO	14
1.1	PROBLEMÁTICAS	15
1.2	HIPÓTESE, PERGUNTAS E INOVAÇÕES	18
1.3	OBJETIVOS	19
1.3.1	Objetivo Geral	19
1.3.2	Objetivos Específicos	19
1.4	ESTRUTURA DA TESE	20
2	REFERENCIAL TEÓRICO	21
2.1	CLIMATOLOGIA	21
2.1.1	Zoneamentos climáticos	21
2.1.2	Mudanças climáticas	23
2.2	CLIMATOLOGIA URBANA	24
2.2.1	Fenômeno físico em meio urbano	25
2.2.2	Área de influência	26
2.2.3	Zoneamentos climáticos locais	27
2.3	MODELAGEM NUMÉRICA	28
2.3.1	Modelagem energética de edificações	28
2.3.2	Modelagem do microclima urbano	30
2.3.2.1	Modelos intensivos computacionalmente	30
2.3.2.2	Modelos de rápida resposta	31
2.3.3	Modelagens de edificações urbanas	32
2.4	DESENVOLVIMENTO DE ZONEAMENTOS CLIMÁTICOS	35
2.4.1	Seleção dos indicadores climáticos	35
2.4.2	Métodos de agrupamento	39
2.4.3	Classificação de locais sem dados climáticos	41
2.4.4	Validação do agrupamento	42
2.5	CONSIDERAÇÕES FINAIS	43
3	ZONEAMENTO BIOCLIMÁTICO BRASILEIRO	46
3.1	ESCOLHA DA BASE CLIMÁTICA PARA A SIMULAÇÃO COMPUTACIONAL	46
3.2	ANÁLISE DE SENSIBILIDADE DOS INDICADORES CLIMÁTICOS E DE DESEMPENHOS	48
3.3	ANÁLISE DE MÉTODOS PARA O ZONEAMENTO BIOCLIMÁTICO	49
3.3.1	Zoneamento usando K-means e indicadores de performance de edifícios	49
3.3.2	Zoneamento usando K-means e indicadores climáticos	51
3.3.3	Zoneamento usando árvore de decisão	52

3.4	ZONEAMENTO BIOCLIMÁTICO FINAL PARA O BRASIL	53
3.4.1	Comparação com outros métodos de classificação climática	54
3.5	INTERPOLAÇÃO DOS DADOS CLIMÁTICOS PARA TODOS OS MUNICÍPIOS	55
3.5.1	Metamodelagem e comparação com outros bancos de dados climáticos	56
3.5.2	Desenvolvimento do mapa do zoneamento bioclimático	57
3.6	CONCLUSÕES	58
4	ANÁLISE DE INCERTEZA	60
4.1	MÉTODO	60
4.1.1	Avaliando a acurácia do banco de dados	60
4.1.1.1	Incerteza relacionada à temperatura e umidade relativa	60
4.1.1.2	O impacto da acurácia do banco de dados na classificação climática	60
4.1.2	Avaliando o microclima	61
4.1.2.1	Incerteza sobre o clima local usando dados climáticos de alta resolução espacial	61
4.1.2.2	O impacto do microclima urbano na classificação climática	62
4.1.3	Avaliando as mudanças climáticas	63
4.1.3.1	Incerteza sobre a modelagem do clima futuro	64
4.1.3.2	Impacto do clima futuro na classificação climática	64
4.2	RESULTADOS E DISCUSSÕES	64
4.2.1	Incógnitas motivadas pela acurácia dos dados meteorológicos	65
4.2.1.1	Incerteza associada à temperatura e umidade relativa	65
4.2.1.2	O impacto da acurácia na classificação bioclimática	66
4.2.2	Impacto do microclima	67
4.2.2.1	Incerteza sobre o clima local usando dados climáticos de alta resolução espacial	68
4.2.2.2	Impacto do microclima urbano na classificação climática	70
4.2.3	Impacto das mudanças climáticas	74
4.2.3.1	Incerteza sobre a modelagem do clima futuro	74
4.2.3.2	Impacto das mudanças climáticas na classificação climática	76
4.3	CONCLUSÕES	78
5	CONSIDERAÇÕES FINAIS	80
5.1	LIMITAÇÕES	82
5.2	TRABALHOS FUTUROS	83
	REFERÊNCIAS	85
	APÊNDICE A – ARTIGO 1 - ZONEAMENTO BIOCLIMÁTICO BRASILEIRO	106
	APÊNDICE B – ARTIGO 2 - ANÁLISE DE INCERTEZA	149

ANEXO A – ZONAS CLIMÁTICAS LOCAIS 181

1 INTRODUÇÃO

As mudanças climáticas têm envolvido cientistas de diversas áreas do conhecimento para reduzir o impacto ambiental causado por agentes que podem alterar negativamente o ciclo natural do sistema climático. Um dos principais aspectos a serem enfrentados e mitigados em todo o mundo é o uso de combustíveis fósseis (IPCC, 2015; IEA, 2017) e o consumo de energia em edifícios (SANTAMOURIS *et al.*, 2015; ALLEGRENI *et al.*, 2012a). Indiretamente, os edifícios em funcionamento promovem uma intensificação das mudanças climáticas, visto que a energia consumida para o condicionamento artificial, especialmente quando oriunda de fontes não renováveis, promove a emissão de agentes que estabelecem o aquecimento do sistema climático, estabelecendo um acréscimo na necessidade de condicionamento artificial. Essa assertiva é endossada pela sensível correspondência da temperatura do ar perante o consumo de energia elétrica (PARDO *et al.*, 2002), fato que tem sido amplamente estudado, de modo que se conclui que essa referida correlação se deve especialmente aos setores residenciais e comerciais (EPE, 2020).

Neste contexto, a idealização de um mundo com perfil de consumo mais sustentável justifica regulamentações com forte apelo ambiental, especialmente quanto aos edifícios, como é o caso das normativas internacionais ISO 52003 (ISO, 2017), ISO 16346 (ISO, 2013), ASHRAE 189.1 (ASHRAE, 2011), ASHRAE 90.1 (ASHRAE, 2004) e ASHRAE 169 (ASHRAE, 2020) e das normativas brasileiras INI-C (INMETRO, 2022), INI-R (INMETRO, 2022), NBR 15220 (ABNT, 2005) e NBR 15575 (ABNT, 2021). Uma forma de alcançar padrões mais eficazes é estabelecer métodos de análise bem fundamentados para tornar os projetos de edifícios mais adequados ao clima. Como estas regulamentações estabelecem a sua aplicabilidade em um contexto territorial limitado, que tem diversidade climática implícita, o zoneamento climático permite generalizar as diretrizes de acordo com os tipos climáticos incluídos na área abrangida. Portanto, a capacidade de agrupar climas semelhantes torna o zoneamento uma ferramenta poderosa para generalizar recomendações e prever resultados (WALSH *et al.*, 2017b).

Em um zoneamento, quando um edifício é avaliado em vários climas, o comportamento deve ser semelhante naqueles locais com a mesma classificação climática. Portanto, quando um estudo conclui que um determinado sistema ou mesmo uma estratégia bioclimática pode ser inadequado para um local, é provável que comportamento semelhante seja observado em outras áreas que tenham a mesma classificação climática (WALSH *et al.*, 2017a). Porém, esta afirmação só será válida se o sistema estudado for suscetível ao clima, e o zoneamento climático considerar indicadores climáticos que afetam a resposta do sistema.

Existem vários métodos internacionais de zoneamento climático (ASHRAE 169 e Köppen-Geiger) e nacionais (NBR 15220 e Roriz), cada um com suas características

e abordagens. O método da ASHRAE 169 (ASHRAE, 2020), por exemplo, categoriza os climas em 19 zonas climáticas, considerando precipitação, graus-hora de aquecimento e resfriamento. Já o método de Köppen-Geiger (KOTTEK *et al.*, 2006b) é mais amplo, classificando os climas em três níveis de acordo com a temperatura e precipitação. No Brasil, a NBR 15220 (ABNT, 2005) apresenta o método mais utilizado para zoneamento climático, considerando três variáveis climáticas: temperatura máxima e mínima mensal e umidade relativa. Além disso, existem outras propostas, como o método de Roriz (RORIZ, 2014), que classifica os climas brasileiros exclusivamente pela temperatura do ar. Cada método tem suas vantagens e desvantagens, e a escolha do método mais adequado depende do objetivo e do contexto do estudo.

Problemas podem ser encontrados nos métodos de classificação climática existentes, como foi investigado por Mazzaferro *et al.* (2020). Por exemplo, Köppen-Geiger é impreciso para a análise de eficiência energética de edifícios, embora seja citado em muitos estudos relacionados ao assunto (HARKOUESS *et al.*, 2018). No geral, ASHRAE 169-2020 (ASHRAE, 2020) provou ser preciso para a análise de sistemas de climatização, porém, no Brasil, agrupa os climas em poucas zonas climáticas, o que significa que regiões com características climáticas e ambientais diferentes estão na mesma zona climática. Embora a ASHRAE 169-2020 classifique apenas algumas cidades no Brasil, a normativa estabelece um mapa que permite entender o comportamento climático de cada região brasileira. Ainda assim, a resolução deste mapa é baixa. Além disso, a ASHRAE 169-2020 não separa adequadamente as áreas secas e úmidas no Brasil. Tudo isso justifica o desenvolvimento de um novo zoneamento bioclimático que resolva todas as limitações aqui listadas. O atual zoneamento bioclimático da ABNT-NBR 15220 (ABNT, 2005) também se mostrou pouco preciso e precisa ser atualizado.

1.1 PROBLEMÁTICAS

O zoneamento climático é amplamente utilizado para generalizar soluções arquitetônicas (VERICHEV; CARPIO, Manuel, 2018), para estabelecer o comportamento de módulos fotovoltaicos (DASH *et al.*, 2017), turbinas eólicas (CASTINO *et al.*, 2003), para dimensionar sistemas de ar condicionado e para projetar sistemas de aproveitamento de águas pluviais (PALLA *et al.*, 2012). Assim, a construção de uma classificação climática única para todos os propósitos pode não ser viável, uma vez que a sensibilidade dos indicadores climáticos é diferente de acordo com o sistema considerado. Por exemplo, no zoneamento dedicado a sistemas fotovoltaicos (FVs), a radiação solar é o principal indicador para estabelecer o nível de produção de energia dos FVs (ASCENCIO-VÁSQUEZ *et al.*, 2019). No entanto, as temperaturas externas são mais relevantes para o zoneamento climático quanto ao desempenho térmico dos edifícios (WALSH *et al.*, 2017b). Assim, existe uma forte possibilidade de que um zoneamento climático específico seja preciso para um propósito, mas menos preciso para outras

aplicações.

O zoneamento climático pode ser desenvolvido considerando uma abordagem determinística ou probabilística. A primeira abordagem assume que cada cidade é classificada numa única zona climática (hard clustering). Na segunda abordagem, cada local pode estar em mais de uma zona, seguindo uma probabilidade de ocorrência (soft clustering) (LI, H.; WANG, J., 2024). A abordagem mais tradicional para o desenvolvimento do zoneamento climático é determinística, a qual geralmente aplica um método de agrupamento (por exemplo, K-means) a indicadores climáticos, como temperatura de bulbo seco, precipitação e umidade relativa. Dentro de cada categoria, existe uma grande quantidade de técnicas de agrupamento, bem como de indicadores para serem considerados na clusterização. Assim, é importante entender qual a abordagem mais adequada, pois grande parte dos métodos podem ter desempenhos inadequados.

Dados climáticos confiáveis e representativos são essenciais para o desenvolvimento do zoneamento climático. Para este propósito, os dados são geralmente obtidos de estações meteorológicas. Devido ao número limitado de estações meteorológicas, os dados climáticos podem ser interpolados para classificar o clima de locais sem estações (LI, M. *et al.*, 2022). Outra possibilidade é utilizar dados climáticos de alta resolução espacial, como ERA5, CRU ou POWER. Contudo, a precisão destas bases de dados dificilmente seria superior à das estações meteorológicas calibradas. Assim, classificar o clima de locais sem estações meteorológicas estabelece uma importante fonte de incerteza.

É possível encontrar diversos estudos no Brasil e no mundo que tratam do zoneamento climático para diversos fins. No entanto, existem apenas alguns esforços de investigação relativos ao desenvolvimento de zoneamento climático para avaliar o desempenho térmico e energético dos edifícios (BENEVIDES *et al.*, 2022; LI, M. *et al.*, 2022; OMAROV *et al.*, 2023; WALSH *et al.*, 2023; XIONG *et al.*, 2019; PRAENE *et al.*, 2019). Nesse sentido, a simulação energética de edifícios permite uma validação numérica de zoneamentos novos ou existentes, bem como o seu desenvolvimento por meio de indicadores de performance do edifício. Com ela foi possível estabelecer um método de classificação climática mais adequado para propósitos específicos (WALSH *et al.*, 2017a, 2018). No entanto, a simulação energética de edifícios requer dados meteorológicos representativos e de qualidade, por exemplo, anos meteorológicos típicos (TMYs), informações muitas vezes limitadas pelo número de estações meteorológicas disponíveis em todo o mundo.

Quando o zoneamento climático adiciona dois locais com comportamentos climáticos diferentes em uma zona climática, isso sugere um problema de precisão (OMAROV *et al.*, 2023), resultando em um zoneamento menos confiável. Todavia, é típico de qualquer método de zoneamento climático ter dispersão dentro de cada zona climática. Por exemplo, se fossem simulados edifícios em todas as cidades de uma zona climá-

tica, poderia ser observada uma dispersão no consumo de energia para aquecimento ou arrefecimento. Nesse sentido, o zoneamento climático pode ser entendido como um modelo ou classificação muitas vezes baseado em técnicas de aprendizado de máquina, como árvore de decisão ou K-means (MAZZAFERRO *et al.*, 2020; WALSH *et al.*, 2023). Apesar de possuir alta precisão, espera-se encontrar incertezas nos valores preditos por um modelo (MACHADO *et al.*, 2023; OLINGER *et al.*, 2023). Assim, o zoneamento climático também pode apresentar incerteza quanto aos seus resultados. Porém, quando diversas fontes de incerteza estão associadas, a precisão final do zoneamento tende a se tornar mais incerta.

Outra fonte de incerteza em relação aos dados climáticos é o microclima. Por exemplo, climas urbanos podem ser afetados pelos fenômenos da ilha de calor urbana e da ilha de frescor urbana (RIZWAN *et al.*, 2008; DUAN *et al.*, 2019). As ilhas de calor urbano (UHIs) ocorrem quando a temperatura do ar dentro de um contexto urbano é superior à observada em áreas rurais, ocorrendo principalmente à noite. Este fenômeno leva a um maior consumo de energia para refrigeração e menor consumo para aquecimento (SANTAMOURIS *et al.*, 2015). Para ilhas de frescor urbanas (UCIs), a temperatura do ar dentro do contexto urbano é mais baixa do que nas regiões do perímetro rural, ocorrendo durante o dia (YANG *et al.*, 2016). Como a temperatura é um dos principais indicadores climáticos utilizados nos métodos de zoneamento climático, o clima urbano pode impactar a classificação climática.

O aumento das concentrações de gases do efeito estufa está acelerando as mudanças climáticas, conduzindo a mudanças significativas nos climas futuros. Por exemplo, espera-se que a temperatura do ar aumente consideravelmente em todo o mundo. As implicações destas alterações podem ser relevantes, principalmente quanto ao desempenho térmico do edifício (ISMAIL *et al.*, 2021; CHAKRABORTY *et al.*, 2021). Além disso, é importante considerar que o estabelecimento do zoneamento bioclimático, que depende do desempenho da edificação, pode ser influenciado. A hipótese aqui apresentada destaca a importância de analisar como as condições climáticas futuras poderão afetar o zoneamento bioclimático. Mesmo com avanços notáveis na modelagem climática, diversas incertezas ainda estão associadas à previsão do clima futuro. Sistemas climáticos complexos, variações climáticas e emissões de gases do efeito estufa estão entre os muitos fatores que contribuem para estas incertezas (ZOU *et al.*, 2023; NIK, 2016). Apesar das suas limitações, estes modelos são essenciais para a compreensão dos padrões climáticos globais, permitindo aos cientistas prever cenários climáticos futuros e desenvolver estratégias eficazes para mitigar as mudanças climáticas.

Em síntese, as problemáticas introduzidas aqui se resumem em:

- Um zoneamento climático pode ser mais preciso para um propósito específico ou indicador de performance do edifício do que para outros indicadores e propósitos.

- Dada a grande quantidade de técnicas de agrupamento e entradas para serem consideradas, é importante entender qual a abordagem mais adequada.
- Nem todas as cidades possuem estações meteorológicas válidas ou de qualidade, fazendo com que exista uma grande incerteza ao classificar seus climas.
- Dependendo de onde a edificação está, seu entorno estabelece condições microclimáticas distintas daquelas observadas nas estações meteorológicas.
- O zoneamento é estabelecido com dados do passado, porém será utilizado no futuro, em um cenário onde as mudanças climáticas podem ser significativas.

1.2 HIPÓTESE, PERGUNTAS E INOVAÇÕES

Com base na literatura mais recente, observou-se diversas limitações e problemáticas. De maneira que a principal hipótese deste trabalho é que a incerteza em relação aos dados climáticos pode ser um fator determinante para a acurácia de um zoneamento bioclimático. Assim, o presente estudo é conduzido exatamente baseado nesses pontos, pois existem várias questões em aberto. Para delimitar exatamente o que é apresentado ao longo do trabalho, cada temática avaliada é listada abaixo. Como existem limitações nas várias fases do desenvolvimento de um zoneamento bioclimático, desenvolver um novo método específico para edificações é algo necessário. Além do mais, várias fontes potenciais de incerteza podem afetar a classificação climática e devem ser devidamente investigadas. Com isso, surgiram os seguintes questionamentos que direcionam esse trabalho:

- Vários estudos foram conduzidos para explorar diferentes abordagens para estabelecer um novo método de zoneamento bioclimático. Dentre essas abordagens, qual a mais adequada para o desempenho higrotérmico e energético de edifícios? É esperado que uma apresente o melhor desempenho.
- A avaliação da incerteza relacionada aos dados climáticos é um ponto muitas vezes esquecido nessas análises. Alguns estudos apontaram esta fonte de incerteza, mas sem uma análise abrangente do tema. Porém, qual seria o impacto da incerteza dos dados climáticos em uma classificação climática? É esperado que a acurácia dos dados climáticos interfira na classificação climática.
- Os dados climáticos geralmente são medidos em estações meteorológicas, porém existe um número limitado de pontos de medição ao redor do mundo. Como classificar as localidades sem dados climáticos válidos? É esperado que um método seja capaz de estabelecer dados climáticos confiáveis da maneira mais acurada possível para essas localidades sem estação meteorológica.

- Há um indicativo de que o entorno dentro do contexto urbano ou rural influencia consideravelmente o comportamento climático ali observado. Assim, quantas zonas bioclimáticas podem existir dentro do território municipal ou como os microclimas podem afetar a classificação climática? É esperado que especialmente a ilha de calor urbana e a altitude produzam diferenças na classificação climática.
- Ao longo dos anos tem se observado um aumento na temperatura global. Dependendo do nível de emissão de gases do efeito estufa, é esperado que no futuro as mudanças climáticas se intensifiquem. Baseado nisso, como a classificação climática pode ser impactada pelas mudanças climáticas? É esperado que o aquecimento global interfira na classificação climática.

Dentre as contribuições propostas, destacam-se: o desenvolvimento de um novo método de zoneamento bioclimático, a validação de bases de dados climáticas, a análise de sensibilidade de acordo com indicadores climáticos e indicadores de desempenho de edifícios, a validação do zoneamento em edifícios residenciais e comerciais, a análise de três protocolos de agrupamento, a análise de contingência, a validação de métodos de zoneamento e a análise de incerteza dos dados climáticos. A inovação deste trabalho está em tratar a incerteza em relação a classificação climática de forma abrangente, pois explora a acurácia das bases de dados climáticos, detalhando se existem pontos ao longo dos microclimas urbano e rural de cada território municipal que poderiam ser classificados em outra zona climática, além de explorar a incerteza quanto ao comportamento climático futuro. Além disso, uma grande contribuição foi alcançada em relação à generalização da classificação para todos os climas e municípios do Brasil por meio de uma nova combinação de interpolações baseadas em redes neurais artificiais com um banco de dados climáticos de reanálise.

1.3 OBJETIVOS

Nas seções abaixo estão descritos o objetivo geral e os objetivos específicos.

1.3.1 Objetivo Geral

O objetivo deste trabalho é desenvolver um zoneamento bioclimático brasileiro válido para o desempenho higrotérmico e energético de edificações comerciais e residenciais, o qual é usado para avaliar o impacto da incerteza em relação aos dados climáticos na classificação bioclimática final.

1.3.2 Objetivos Específicos

Dentre os objetivos específicos, destacam-se:

1. Selecionar a base de dados climáticos mais adequada para o processo de zoneamento climático.
2. Selecionar um método de agrupamento para estabelecer um zoneamento bioclimático.
3. Validar o método de zoneamento bioclimático proposto e os zoneamentos climáticos existentes.
4. Estabelecer dados climáticos para cidades que não possuem estações meteorológicas e classificá-las.
5. Analisar o impacto da acurácia da base de dados, do microclima e das mudanças climáticas no zoneamento bioclimático.

1.4 ESTRUTURA DA TESE

O presente estudo detalhado neste documento foi estruturado baseado em dois artigos científicos. Assim, a estrutura básica da tese é composta por introdução, referencial teórico, resumos expandidos dos artigos e conclusões. O primeiro artigo aborda o desenvolvimento de um método de zoneamento bioclimático para o Brasil. O segundo avalia a incerteza em relação aos dados climáticos e a classificação bioclimática do método de zoneamento estabelecido no primeiro artigo. Ambos os artigos podem ser encontrados nos Apêndices A e B. Para facilitar o entendimento do conteúdo desses artigos, foi incluído um resumo expandido nos capítulos 3 e 4.

2 REFERENCIAL TEÓRICO

A estrutura apresentada nesta seção parte do agrupamento de assuntos que são relevantes para a climatologia, para o desenvolvimento de zoneamentos climáticos, para as modelagens microclimáticas urbanas e térmica de edificações. Inicialmente, é apresentada uma breve introdução das questões climatológicas permitindo observar como as características geométricas e físicas do contexto urbano podem promover modificações nas variáveis climáticas locais. Além disso, o agrupamento permite notar as distintas classificações climáticas em termos globais e locais. Em seguida são apresentadas algumas formas de modelagem numérica que servem de método em assuntos correlatos aos que norteiam essa investigação, revisando artigos relacionados ao assunto aqui pesquisado.

2.1 CLIMATOLOGIA

A climatologia é um ramo da ciência que se concentra na análise e compreensão dos padrões e dinâmicas da atmosfera em um local específico, com ênfase particular nos dados coletados durante um período específico. Devido à influência dos diversos componentes do meio ambiente, as condições climáticas são significativamente impactadas, razão pela qual ocupa uma posição central e importante no amplo campo da ciência ambiental (MENDONÇA; DANNI-OLIVEIRA, 2017; AYOADE, 1986).

Os estudos climáticos geralmente abordam aspectos responsáveis por condicionar as características climáticas e os atributos físicos que definem as propriedades atmosféricas. A caracterização do clima geralmente é dada pelos elementos climáticos que são definidos por propriedades atmosféricas mensuráveis, e.g., temperatura do ar, umidade do ar, movimentos das massas de ar, precipitações e nebulosidades. Já os fatores geomorfológicos e espaciais que impactam as condições climáticas de determinado local se dividem em fatores climáticos globais, e.g., radiação solar, latitude, altitude, circulação atmosférica e massas de água e terra; e fatores climáticos locais, e.g., topografia, vegetação, atividades humanas e superfície do solo natural ou construído (ROMERO, 2001).

2.1.1 Zoneamentos climáticos

Para fins energéticos, especialmente direcionado para edificações, há o método de zoneamento climático da ASHRAE 169 (ASHRAE, 2020), de escopo internacional. Ele categoriza os grupos climáticos com base em graus-hora de aquecimento (HDD18), tendo como temperatura base 18°C, e graus-hora de resfriamento, com temperatura base de 10°C (CDD10). Após esta primeira etapa, os climas são separados mediante a umidade da zona, considerando os dados mensais de precipitação e temperatura.

Esta abordagem multinível permite incluir diferentes aspectos no zoneamento climático final. Quanto à umidade, os climas são classificados em marinhos, secos e úmidos. A precipitação ao longo do ano é classificada com base na temperatura média anual e na quantidade máxima de precipitação ao longo do ano (WALSH *et al.*, 2019, 2018). Este método de zoneamento climático estabelece 19 zonas climáticas ao todo, porém o Brasil possui somente cinco que são visualmente identificáveis no mapa da ASHRAE 169, devido à sua resolução. Como para categorizar as localidades é necessário um conjunto de dados com indicadores climáticos usados para identificar o grupo climático, existe uma grande probabilidade de que o número de grupos no território nacional seja superior a cinco dependendo da base utilizada.

O método de zoneamento climático de Köppen-Geiger (KOTTEK *et al.*, 2006b), que possui abrangência internacional, é determinado mediante um processo de agrupamento em diferentes camadas (multinível), onde as zonas climáticas são classificadas em três níveis de classificação. Este método permite agrupar os climas de acordo com seu comportamento sazonal, com base na temperatura do ar e precipitação. A primeira camada de classificação estabelece cinco categorias, divididas de acordo com a temperatura (equatorial, temperado quente, neve e polar) ou precipitação (árido). O segundo nível classifica os climas com base na precipitação (totalmente úmido, verão seco, inverno seco, monção, estepe e deserto) ou temperatura (tundra e geada). O terceiro nível de classificação define a severidade sazonal dos climas com relação à temperatura (árido quente, árido frio, verão quente, verão seco, verão frio e extremamente continental).

Com foco no desempenho térmico de residências unifamiliares de interesse social, a NBR 15220 (ABNT, 2005) é o método de zoneamento climático mais utilizado para propósito energético no contexto nacional. Este método se baseia principalmente em três variáveis climáticas: média de temperaturas máximas mensais, média das temperaturas mínimas mensais e média dos valores mensais de umidade relativa. A NBR 15220 apresenta o zoneamento climático brasileiro de acordo com as estratégias de projeto determinadas pela Carta Bioclimática proposta por Givoni (1992) e ajustada aos princípios de Mahoney (GIVONI, 1992; WALSH *et al.*, 2017b). Do ponto de vista do projeto arquitetônico, a classificação climática apresentada na NBR 15220 permite uma atribuição direta das soluções necessárias para a adaptação térmica de edifícios residenciais, de acordo com os princípios bioclimáticos. As estratégias bioclimáticas incluem o uso de massa térmica, ventilação natural, resfriamento artificial, aquecimento artificial, umidificação e desumidificação do ar.

Nesse contexto, dentre as iniciativas desenvolvidas para melhorar o atual zoneamento bioclimático brasileiro da NBR 15220, o zoneamento proposto por Roriz (RORIZ, 2014) foi desenvolvido para possivelmente substituir esse método. A proposta de Roriz classifica os climas brasileiros exclusivamente pela temperatura do ar, dividindo as

cidades brasileiras pela temperatura média anual do ar em 3 classes primárias: inferior a 21°C, entre 21°C e 25°C e superior a 25°C. Essas 3 classes primárias são divididas em 6 classes secundárias, de acordo com o desvio padrão dos valores médios mensais das temperaturas médias diárias do ar. Os 6 grupos resultantes são divididos em 12 subgrupos, de acordo com a amplitude média anual, que é calculada a partir das amplitudes médias mensais. Esses 12 subgrupos geram um total de 24 zonas climáticas para o Brasil, de acordo com o desvio padrão da amplitude média anual.

A proposta desenvolvida por Walsh *et al.* (2023) considera que o clima pode ser agrupado através de indicadores de desempenho do edifício, ou seja, assumindo o clima de forma indireta. Para isso, os autores agruparam os climas aplicando K-means aos dados de carga térmica, desconforto térmico e risco de mofo de 100 variações de um arquétipo residencial. Inicialmente, os autores separaram o território brasileiro em macrozonas, delimitando as regiões que possuem demanda energética para aquecimento e resfriamento artificiais e outra macrozona onde há apenas necessidade de resfriamento, sendo divididas em dois e oito grupos, respectivamente. O estudo foi desenvolvido e validado para edifícios residenciais e não foi validado para edifícios comerciais.

Mazzaferro *et al.* (2020) desenvolveram propostas de zoneamentos climáticos para o Brasil, as quais consideram a carga térmica total de resfriamento de escritórios e indicadores climáticos como a temperatura de bulbo seco, ponto de orvalho, graus-dia de resfriamento, dentre outros. A melhor das propostas foi desenvolvida considerando o método de aprendizado de máquina supervisionado conhecido como árvore de decisão. Essa proposta possui 8 zonas climáticas no total. Todas as zonas climáticas são separadas conforme a temperatura média anual, mas somente as zonas mais quentes são separadas pelo ponto de orvalho. O estudo foi desenvolvido para edifícios comerciais (escritórios) e não foi validado para residências.

2.1.2 Mudanças climáticas

O aumento contínuo das concentrações de gases do efeito estufa está acelerando as mudanças climáticas, conduzindo a mudanças significativas nos climas futuros. As implicações destas mudanças podem ser significativas, particularmente em relação ao desempenho do edifício (ISMAIL *et al.*, 2021; CHAKRABORTY *et al.*, 2021). Além disso, é importante considerar que o estabelecimento do zoneamento bioclimático, que depende do desempenho da edificação, pode ser influenciado. Dada a incerteza quanto ao comportamento climático futuro, podemos também colocar isto como uma fonte de incerteza para o zoneamento bioclimático. Todavia, nesta fase, é essencial compreender as técnicas utilizadas na determinação destes climas futuros.

Existe uma gama de escala e complexidade entre os modelos climáticos utilizados para prever as condições climáticas futuras. Certos modelos simulam o clima futuro

em um âmbito global, e são chamados de *Global Climate Models*, *General Circulation Models* ou *Global Circulation Models* (GCMs). Estes modelos consideram diferentes cenários de emissões de gases do efeito estufa, representando possíveis caminhos para o futuro desenvolvimento socioeconômico e esforços de mitigação (BAMDAD *et al.*, 2021). Outros modelos têm enfoque regional, simulando o comportamento de regiões geográficas específicas, definidas como *Regional Climate Models* (RCMs). De modo geral, os RCMs usam os GCMs como condição de contorno, estabelecendo uma maior resolução espacial e temporal (ABOLHASSANI *et al.*, 2023). Os cenários de emissões são descritos como *Representative Concentration Pathways* (RCPs), abrangendo desde um aumento substancial de emissões (RCP8.5) até uma diminuição dramática (RCP2.6), resultando numa variedade de potenciais futuros climáticos (ZOU *et al.*, 2023).

O clima em escala global é simulado usando GCMs, que consideram interações complexas entre a atmosfera, os oceanos, a superfície terrestre e as camadas de gelo (NIK, 2016). O comportamento da atmosfera e dos oceanos é descrito através da resolução de equações físicas em uma grade tridimensional. O tamanho de um único elemento pode ser de 100 x 100 até 500 x 500 quilômetros quadrados (BAMDAD *et al.*, 2021; ABOLHASSANI *et al.*, 2023). Assim, para entender como as mudanças climáticas se comportam em uma região específica dentro de um único elemento desta grade, os RCMs podem ser utilizados como método de *downscaling* (ZOU *et al.*, 2023). Os RCMs servem como uma extensão dos GCMs e são utilizados para modelar padrões climáticos a um nível regional mais detalhado. Ao considerar características topográficas e uso do solo, podem fornecer informações mais detalhadas sobre o clima em áreas específicas, considerando os fatores que podem influenciar o clima local. Esses modelos possuem um alto custo de processamento computacional, sendo geralmente simulados em supercomputadores.

Mesmo com os avanços notáveis na modelagem climática, ainda existem várias incertezas associadas à previsão do clima futuro. Sistemas climáticos complexos, variações climáticas e emissões de gases do efeito estufa estão entre os vários fatores que contribuem para estas incertezas (ZOU *et al.*, 2023; NIK, 2016). Apesar das suas limitações, estes modelos são ferramentas essenciais para a compreensão dos padrões climáticos globais, permitindo aos cientistas prever cenários climáticos futuros e desenvolver estratégias eficazes para mitigar as mudanças climáticas. Para progredirmos em direção a um futuro sustentável, atualmente essas incertezas devem ser entendidas como características de modelo.

2.2 CLIMATOLOGIA URBANA

Compreender o comportamento do clima é essencial para a concepção de projetos com diretrizes bioclimáticas. Todavia, o arquivo climático utilizado na simulação

computacional estabelece que o edifício está submetido às mesmas características atmosféricas da estação meteorológica. Assim, esse aspecto define que os fatores geomorfológicos e espaciais (fatores climáticos) que impactam as condições climáticas são idênticos em ambos os casos (ALLEGRINI *et al.*, 2012a; ROMERO, 2001), quando na realidade apresentam características distintas. Os fatores climáticos que compõem o ambiente urbano condicionam a formação de fenômenos que podem inviabilizar determinadas estratégias bioclimáticas, fundamentando a importância de reconhecer o comportamento dos elementos climáticos sobretudo para fornecer condições de contorno realistas à modelagem.

2.2.1 Fenômeno físico em meio urbano

O efeito do contexto urbano sobre os elementos climáticos é amplamente documentado, de maneira que dois principais fenômenos são observados: ilha de calor urbana e ilha de frescor urbana (RIZWAN *et al.*, 2008). A ilha de calor urbana é desenvolvida principalmente em cidades com balanço térmico positivo, podendo causar sério impacto sobre o consumo energético das edificações (SANTAMOURIS *et al.*, 2015). Já a ilha de frescor representa áreas urbanas cuja temperatura do ar é menor que nas regiões rurais perimetrais (YANG *et al.*, 2016).

A ilha de calor é formada durante o dia através da radiação de onda curta (solar) e salientada durante a noite pela radiação de onda longa (superfície terrestre). No período diurno, os raios solares incidem sobre os materiais que compõem a superfície urbana, aquecendo-os, e durante a noite a dificuldade em perder calor contribui para que o clima local apresente maior temperatura (SOUZA, 2010).

A ilha de frescor representa áreas urbanas que em certas condições meteorológicas apresentam ar menos aquecido que nas zonas rurais adjacentes. Sua maior intensidade é principalmente observada durante o período diurno, porém há estudos que mostram que no inverno a ilha de frescor pode apresentar maior intensidade durante a noite. Além disso, geralmente a ilha de frescor está associada a espaços urbanos vegetados, porém também pode ocorrer em centros urbanos adensados (YANG *et al.*, 2016; DUAN *et al.*, 2019).

Durante um período de 24 horas, a ilha de calor e a ilha de frescor podem ocorrer em um mesmo local. Porém, isso depende de fatores como o índice de cobertura vegetal, características térmicas da malha urbana e calor antropogênico liberado nas ruas, os quais estão relacionados com o processo e o nível de urbanização (DUAN *et al.*, 2019). A complexidade das interações térmicas que ocorrem na estrutura urbana pode ser satisfatoriamente representada mediante redes de fluxo que equacionam o balanço energético da superfície em um dado volume de controle. Além disso, essa abordagem permite relacionar simultaneamente o impacto do calor (sensível, latente, armazenado e antropogênico), da radiação (ondas longas e curtas) e da rede de

advecção; no fluxo de energia resultante (MIRZAEI; HAGHIGHAT, 2010; SREBRIC *et al.*, 2015; RIZWAN *et al.*, 2008).

O fluxo de calor sensível é decorrente da modificação da temperatura de um determinado corpo que é submetido a uma adição ou subtração de energia (OKE, 2002), sendo um elemento bastante influente no balanço energético do meio urbano e um dos principais responsáveis pelo desenvolvimento das ilhas de calor (MOREIRA, 2014). O calor latente é denotado quando uma substância muda de estado numa determinada temperatura, afetando o balanço energético do sistema (OKE, 2002). Assim o calor latente tende a aliviar a temperatura urbana, por meio de regiões produtoras de umidade (PEREZ *et al.*, 2001). Em síntese, "a vegetação e os corpos hídricos exercem grande relevância no balanço de energia em áreas urbanas, proporcionando transporte contínuo de umidade para a atmosfera oriunda da evapotranspiração e evaporação, ocasionado pelo fluxo de calor latente"(MOREIRA, 2014, p. 36).

Geralmente o aquecimento urbano é um fenômeno resultante do calor antropogênico, calor armazenado e irradiado pela complexa e densa estrutura urbana; além de estar relacionado com questões pontuais como a velocidade do ar, nebulosidade, cobertura vegetal, padrões construtivos, radiação solar, fluxo de veículos e uso de condicionadores de ar (RIZWAN *et al.*, 2008).

A rede de advecção é predominantemente afetada pelo vento, que em meio urbano apresenta significativa redução na sua velocidade. Esse fato promove um aumento na temperatura do ar, principalmente em áreas urbanas densamente construídas (OKE *et al.*, 2017). O regime dos ventos é fortemente impactado em áreas urbanas devido à presença de obstáculos que alteram suas direções e módulos. Essas modificações, por sua vez, têm impacto direto sobre o padrão de infiltração admitido pelas edificações, podendo influenciar significativamente seus padrões de consumo energético (NIKKHO *et al.*, 2017).

Para entender o comportamento climático em meio urbano, os pesquisadores costumam usar técnicas de modelagem numérica (XU *et al.*, 2022) ou medição (ROMERO RODRÍGUEZ *et al.*, 2023). Como essas técnicas possuem vantagens e desvantagens, tem se observado muito na literatura o uso combinado para a aquisição de dados climáticos (TANOORI *et al.*, 2024; MAO *et al.*, 2018). Do ponto de vista espacial, a modelagem numérica possui vantagens significativas frente a medição, porém a validação desses dados de modelagem somente é possível através de medições.

2.2.2 Área de influência

Devido à grande variabilidade dos elementos urbanos em termos horizontais e verticais, observa-se grandes diferenças em medições de pontos estacionários que se encontram próximos. Nesse contexto, a precisão de muitos estudos da *Urban Heat Island* (UHI) foi recentemente questionada devido à ausência ou definição incompleta

do contexto de medição, onde a dupla diferenciação entre urbano-rural era tradicionalmente aceita (PEIRÓ *et al.*, 2019). Isso levanta a necessidade de conhecer inclusive como é a área onde se encontra a estação meteorológica urbana, para saber o quanto se difere de outros contextos.

Um ponto de medição em áreas urbanas está condicionado aos fatores urbanísticos que o rodeiam. Esse conceito está alinhado com o termo círculo de influência¹. O tamanho dessa área pode influenciar de caso para caso, porém para medições de temperatura os autores usualmente consideram algo entre 200 e 500 metros, dependendo das características da área adjacente e da estabilidade das condições atmosféricas. Além do mais, as temperaturas podem flutuar através de curtas distâncias dentro desse círculo de influência, definindo a necessidade de trabalhar espacialmente com temperaturas médias (YANG *et al.*, 2018; LEHNERT *et al.*, 2015; HOUET; PIGEON, 2011). Conforme foi comentado anteriormente, as condições atmosféricas devem ser estáveis para não prejudicar as medições realizadas. Para isso, valores baixos de nebulosidade e velocidade do vento são essenciais para determinar os critérios de estabilidade atmosférica (WANG, Z. *et al.*, 2016; STEWART *et al.*, 2014; LECONTE *et al.*, 2015).

2.2.3 Zoneamentos climáticos locais

Stewart e Oke (2012) desenvolveram um método de classificação denominado *Local Climate Zone* (LCZ) que se propõe a ser versátil para representar as mais diversas configurações urbanas e rurais. O sistema de classificação LCZ foi estruturado de modo a auxiliar os pesquisadores a identificar parâmetros construtivos que, ao serem contextualizados com o método proposto, promovem uma padronização prévia do comportamento climático do ambiente em questão, facilitando assim os estudos acerca das ilhas de calor (STEWART; OKE, 2012). O sistema promove uma excelente descrição da configuração das superfícies urbanas e rurais, facilitando o processo de classificação e de atribuição dos metadados de maneira que possa melhorar a consistência e precisão dos relatórios de caracterização do clima local, resultando em 17 categorias que ao serem combinadas fornecem subclasses que apresentam características derivadas do conjunto padrão (Anexo A).

Anteriormente à LCZ, para facilitar a troca de conhecimento interdisciplinar e auxiliar na aquisição de metadados para estudos climáticos, existiam outras formas de classificação urbana, como a *Urban Zones of Energy partitioning* (UZE), *Urban Terrain Zones* (UTZ), a *Davenport roughness classification* e *Urban Climate Zone* (UCZ). Contudo, limitações como a relevância climática das classes, representação urbano-rural, nomenclatura, origem e escopo impedem que sejam aplicadas universalmente. Por conta disso, a LCZ surgiu como um melhoramento do UCZ, que era a classificação

¹ *Circle of Influence* ou *Source Area* é o entorno capaz de condicionar o comportamento climático do ponto central analisado, por meio de aspectos morfológicos, materiais, antropogênicos, etc.

mais universal entre os sistemas acima, porém focada somente em cenários urbanos modernos e bem desenvolvidos (ZHENG *et al.*, 2018; SHI *et al.*, 2019).

Em Hong Kong foi desenvolvido o sistema *Urban Climatic Map* (UCMap) que apresenta informações climáticas em uma plataforma, que podem auxiliar na tomada de decisões para planejadores e formuladores de políticas públicas. O UCMap classifica a superfície do solo de acordo com as cargas térmicas e potenciais dinâmicos da morfologia urbana. Oito classes de clima foram identificadas em Hong Kong. O sistema fornece um conjunto abrangente de recomendações de planejamento nas escalas da cidade e distrito (ZHENG *et al.*, 2018; SHI *et al.*, 2019).

O tema comum desses diferentes esquemas é que todos eles são estabelecidos de acordo com as informações dos indicadores urbanos. Esses indicadores urbanos incluem, entre outros, o padrão de uso e cobertura do solo, topografia, geometria da superfície e informações espaciais climáticas. Com base nessas informações, os sistemas de classificação acima mencionados podem representar os efeitos do ambiente urbano sobre as condições climáticas locais (SHI *et al.*, 2019).

2.3 MODELAGEM NUMÉRICA

No processo de modelagem numérica (de edificações ou clima urbano) o estabelecimento da escala de modelagem adequada é um procedimento que deve ocorrer ainda na fase inicial da investigação, contudo o método adequado depende muito dos objetivos do estudo. Os modelos caracterizam-se especialmente pela sua abrangência; no caso dos modelos de edificações, existe um enfoque no desempenho térmico. Por outro lado, modelos de microescala e mesoescala são considerados em investigações relacionadas ao clima urbano; porém o primeiro apresenta um nível de detalhamento maior para uma área menos abrangente que o segundo.

2.3.1 Modelagem energética de edificações

A modelagem na escala do edifício objetiva determinar a performance energética das edificações considerando dados de entrada como ganhos internos, propriedades térmicas e ópticas dos materiais, além de assumir simplificações para o entorno da edificação. Assim, a integração com modelos de escalas mais abrangentes é essencial quando os efeitos do clima urbano sobre o desempenho energético de edificações estão sendo investigados (MIRZAEI, 2015).

Østergård *et al.* (2016) realizaram uma revisão das principais ferramentas computacionais que podem ser utilizadas na modelagem energética de edificações. Os programas elencados (Quadro 1) não apresentam a capacidade de realizar análises paramétricas abrangentes que variem simultaneamente geometria, materiais e sistemas. Portanto, para realizar um grande volume de simulações energéticas é necessário

implementar rotinas computacionais usando alguma linguagem de programação que automatize os processos, possibilitando análises em larga escala.

Quadro 1 – Comparativo entre programas de simulação energética

Table 2

Comparison of software in terms of fulfilling the requirements of the proposed software framework. Checkmarks indicate fulfilment of the requirement. Checkmarks in parenthesis indicate that software include the specific feature without satisfying the requirement. See explanations of headers A–F in the text [120–130,132–135].

Software	A. Users		B. Design stage		C. Interoperability		D. Core complexity		E. Objectives		F. Parametric sim.		Ref.								
	Architects	Engineers	Conceptual	Preliminary	Detailed	Management			Energy	Thermal	Daylight	Air Quality	LCA	LCC	Cloud	I/O Configurable	UA	SA	OAT	Optimisation	
BPS (own engine)	Be10 (ISO 13790 monthly) ²	(A)	E	✓	✓	✓	Standalone	Low	✓	(✓)					✓					[120]	
	BSim		E	✓	✓	✓	Standalone	High	✓	✓	✓	✓							(✓)	[121]	
	DOE2		E	✓	✓	✓	Standalone	Medium	✓							✓					[110]
	EnergyPlus (E+)		E	✓	✓	✓	Standalone	High	✓	✓	✓	✓				✓					[28]
	EPC (ISO 13790 hourly)	(A)	E	✓	✓	✓	Standalone	Medium	✓							✓					[122]
	ESP-r		E	✓	✓	✓	Standalone	High	✓	✓	✓	✓				✓					[123]
	IDA-ICE		E	✓	✓	✓	File exchange	High	✓	✓	✓	✓					✓				[124]
	iBuild		E	✓	✓	✓	Standalone	Medium	✓	✓	✓	✓						✓			[125]
	IESVE	(A)	E	✓	✓	✓	File exchange	High	✓	✓	✓	✓	✓	✓							[83]
	Radiance	(A)	E	✓	✓	✓	Standalone	High			✓						✓				[87]
BPS (external engine)	VELUX Daylight Visualizer	A	E	✓	✓	✓	File exchange	High													[126]
	A+E3D	A	✓	✓	✓	✓	Integrated	Be10	✓	(✓)	(✓)										[127]
	DaySim	(A)	E	✓	✓	✓	Run-time	Radiance			✓					✓					[86]
	DesignBuilder	(A)	E	✓	✓	✓	File exchange	E+, Radiance, jE+	✓	✓	✓	✓	✓	✓	✓					✓	[128]
	eQuest		E	✓	✓	✓	Standalone	DOE2	✓												[129]
	N++		E	✓	✓	✓	Separated	E+, jE+, GenOpt	✓	✓	✓	✓			✓					✓	[130]
	OpenStudio		E	✓	✓	✓	File exchange	E+, Radiance	✓	✓	✓	✓			✓	✓					[84]
	Riuska		E	✓	✓	✓	File exchange	DOE 2, own engine	✓	✓	✓	✓				✓	✓				[131]
	Sefaira	A	✓	✓	✓	✓	Run-time	E+, Radiance	✓	✓	✓	✓			✓	(✓)	(✓)	✓			[82]
	DIVA for Rhino	A (E)	✓	✓	✓	✓	Run-time	Radiance			✓										[132]
Plug-in	Green Building Studio	A (E)	✓	✓	✓	✓	File exchange	DOE2	✓							✓					[78]
	HoneyBee (GH)	A	E	✓	✓	✓	File exchange	OpenStudio, E+, Radiance	✓	✓	✓	✓	✓	✓		✓					[100]
	jEPlus (+ JESS)		E	✓	✓	✓	Run-time	E+, DesignBuilder, N++	✓	✓	✓	✓	✓	✓		(✓)	(✓)	✓			[133]
	Parametric Analysis Tool		E	✓	✓	✓	File exchange	OpenStudio	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	[134]
	Solon	(A)	E	✓	✓	✓	File exchange	Green Building Studio	✓							✓	(✓)	✓			[135]
Glue ¹	Dynamo	A	E	✓	✓	✓	-	-													[98]
	Grasshopper (GH)	A	E	✓	✓	✓	-	-													[97]

¹ Glue refers to software that enables linking between BPS and geometrical modeling through graphical programming (also referred to as algorithmic modeling)

² Be10 is mandatory to use for code compliance in Denmark

Fonte: Adaptado de Østergård *et al.* (2016).

Dentre os programas destaca-se o TRNSYS, que é um programa computacional comercial, amplamente utilizado pela comunidade científica para modelar e simular o comportamento de sistemas transientes, como sistemas solares, elétricos, HVAC² e na análise energética de edificações, permitindo que o usuário incorpore modelos matemáticos personalizados mediante seu sistema modular (SUDHAKAR *et al.*, 2019; SHRIVASTAVA *et al.*, 2017). Já o EnergyPlus é uma ferramenta equivalente ao TRNSYS, porém gratuita, permitindo a simulação de sistemas de climatização, radiantes, fotovoltaicos, solares, integrando-os com a performance energética da edificação (DOE, 2018). Ambos os programas fazem uso de arquivos climáticos que definem as condições atmosféricas, iluminação, radiação, nebulosidade e precipitação em termos anuais para uma dada localidade.

O CitySim é outro mecanismo computacional que tem sido utilizado pelos cientistas, especialmente por permitir a modelagem simultânea de milhares de edificações e ser capaz de captar as complexas interações da energia radiante (MARTINS, 2014),

² Heating, Ventilating and Air Conditioning

porém os recursos que caracterizam a edificação ainda não possuem o nível de detalhamento observado em ferramentas mais consolidadas. Nesse sentido, a complexidade do mecanismo computacional (algoritmo) é essencial quando o detalhamento está no escopo da modelagem, sobretudo para reproduzir os fenômenos de forma efetiva. Nesse contexto, programas computacionais de código aberto que apresentam essa capacidade como EnergyPlus e ESP-r, ganham relevância em estudos do comportamento térmico e energético de edificações, bem como seus sistemas.

2.3.2 Modelagem do microclima urbano

À medida que a estrutura urbana aumenta a sua complexidade e abrangência, simulações numéricas oferecem a possibilidade de avaliar a distribuição de temperatura em toda a cidade. Contudo, os resultados do modelo podem estar sujeitos a incertezas, por exemplo, devido aos métodos numéricos empregados e à representação simplificada de processos físicos. O realismo dos resultados do modelo numérico, portanto, precisa ser cuidadosamente avaliado. Além disso, os parâmetros do modelo que descrevem a morfologia urbana precisam ser inicializados corretamente para uma modelagem mais próxima da realidade. No entanto, os modelos numéricos apresentam algumas vantagens sobre os dados medidos, pois preservam a consistência física entre os parâmetros meteorológicos e permitem a simulação de cenários (KWOK *et al.*, 2019).

2.3.2.1 Modelos intensivos computacionalmente

A fluidodinâmica computacional (CFD), diferentemente dos modelos de balanço energético, permite a simulação simultânea dos campos de velocidade e temperatura. Sua aplicação permite obter informações mais precisas sobre a distribuição da ilha de calor urbana do que seria obtido através do modelo de dossel urbano (UCM), porém sua grande limitação é referente ao restrito tamanho de domínio frente a capacidade de processamento e armazenamento computacional (MIRZAEI, 2015; SREBRIC *et al.*, 2015; MIRZAEI; HAGHIGHAT, 2010), além do intervalo de tempo simulado. Comumente o CFD é baseado em volumes finitos, sendo necessário um maior refinamento da malha onde o fluxo é mais turbulento.

Extrapolar o CFD para uma mesoescala aumentará, consideravelmente, o número de células, podendo inviabilizar a modelagem. Em vista disso, há uma eminent necessidade em intensificar as simplificações geométricas para que essa abordagem seja factível, o que por sua vez promove a descaracterização dos elementos que compõem a microescala, impossibilitando qualquer análise microclimática anual mediante uma abordagem em mesoescala. Aqui são apresentados alguns modelos intensivos computacionalmente como é o caso do ENVI-met, SOLENE-microclimat, UrbClim e MUKLIMO_3.

Os programas ENVI-met (MOONEN *et al.*, 2012) e SOLENE-microclimat (AZAM *et al.*, 2018) são algumas ferramentas que implementam fluidodinâmica computacional e apresentam boa aceitação na comunidade acadêmica, especialmente a primeira. Tipicamente o ENVI-met divide o domínio da modelagem em um número discreto de pontos que formam uma malha de células hexahedral, calculando para cada célula, parâmetros como: velocidade do vento, direção do vento, temperatura, umidade relativa, radiação e concentração de poluentes (BRUSE, 2004; VANKERKOM *et al.*, 2012).

O modelo UrbClim é baseado no *Land Surface Interaction Calculation* (LAICa), que foi expandido nos últimos anos para contabilizar superfícies urbanas. Este esquema calcula os fluxos de calor na superfície, dividindo em malhas que são compostas por frações de vegetação, solo e superfície urbana. Cada célula possui seu próprio balanço energético e comportamento térmico correspondente. A superfície urbana é apresentada como uma área impermeável e rugosa, caracterizada por vários parâmetros relacionados ao uso da terra (albedo, emissividade, comprimento de rugosidade, resistência estomática e total da planta, coeficiente de distribuição radicular e vedação do solo). O esquema de transferência da atmosfera de movimentação do solo é acoplado a um módulo atmosférico em 3D, que inclui a camada limite atmosférica e se estende a uma altura de três quilômetros (VERDONCK *et al.*, 2018).

MUKLIMO_3 é um modelo de microescala não hidrostática projetado para simular campos de fluxo atmosférico na presença de edifícios. A versão termodinâmica do modelo inclui equações para a temperatura e umidade do ar. A parametrização de edifícios usa a abordagem de meios porosos; radiação de ondas curtas e longas; transferência de calor e umidade no solo; e um modelo de vegetação. O modelo considera os efeitos de atrito das superfícies dos edifícios e a geração de turbulências decorrentes da separação do fluxo de ar. O modelo considera os efeitos da cobertura de nuvens na radiação. Contudo, ele não inclui processos físicos que ocorrem nas nuvens, precipitação, escoamento horizontal ou calor antropogênico (GELETIČ *et al.*, 2019).

2.3.2.2 Modelos de rápida resposta

O modelo de dossel urbano (UCM) é derivado da equação de balanço energético da superfície aplicado em volume de controle que contém duas edificações adjacentes, cujo fluxo de ar é tratado de forma desacoplada do campo de temperatura (MIRZAEI, 2015; MIRZAEI; HAGHIGHAT, 2010). Embora seja notável a alta resolução do modelo numa microescala, extrapolá-lo para uma mesoescala elevaria exponencialmente o número de incertezas relativas aos parâmetros de entrada, aumentando eventuais imprecisões relativas à modelagem. Todavia, esse método de modelagem é muito apropriado para investigações paramétricas em microescala, e seu uso acoplado à modelagem termo energética de edificações é algo a ser considerado.

Urban Weather Generator (UWG) (BUENO *et al.*, 2015) e *Weather Research and Forecast with Urban Canopy Model* (WRF-UCM) (WANG, Z.-H. *et al.*, 2016) são algumas ferramentas que apresentam a capacidade de implementar um modelo de dossel urbano (UCM) numa estrutura relativamente amigável, sendo utilizados em estudos relacionados ao clima urbano. O algoritmo implementado no UWG executa quatro modelos (estação rural, difusão vertical, camada limite urbana e camada de dossel urbano) que retornam valores horários de temperatura, umidade do ar e velocidade do vento do ambiente urbano com base em dados meteorológicos rurais, considerando a radiação, precipitação, velocidade do ar e umidade medida na estação meteorológica, bem como fluxos de calor oriundos de edificações, estradas e outras fontes antrópicas presentes no contexto urbano (BUENO *et al.*, 2015).

O modelo WRF fornece diversos esquemas de parametrização de processos físicos e dinâmicos estabelecidos pela comunidade científica, o que o torna adequado para uma ampla gama de aplicações. A técnica *grid nesting* permite que o WRF seja capaz de executar simulações em várias escalas em uma resolução cada vez mais precisa sem adicionar muitos recursos computacionais (MU *et al.*, 2019). Um balanço energético superficial separado por ruas, telhados e paredes dos edifícios, é resolvido para estimar o fluxo de calor sensível trocado entre os edifícios e a atmosfera. O sombreamento e o aprisionamento da radiação no cânion é considerado nesse balanço. As larguras das ruas e prédios, a razão de aspecto do cânion e a distribuição das alturas dos prédios são representadas de maneira simplificada para que os cálculos de radiação no cânion sejam viáveis, computacionalmente, no modelo de mesoescala. Além disso, o modelo requer ainda informações sobre o albedo da superfície e outras propriedades térmicas dos materiais, e a modelagem energética da edificação leva em consideração a transferência de calor e radiação entre áreas internas e externas, geração de calor interno por ocupantes, máquinas, ventilação, aquecimento ou resfriamento via condicionamento artificial (MUGHAL *et al.*, 2019).

2.3.3 Modelagens de edificações urbanas

Essa seção apresenta estudos que relacionam o clima urbano e o desempenho energético de edificações, direcionando o foco para seus objetivos, métodos e resultados. Além do mais, é possível observar como os pesquisadores têm contornado as limitações que impedem a implementação de uma escala integrada.

Allegrini *et al.* (2012b) desenvolveram um estudo em Basel (Suíça) visando quantificar a influência do microclima urbano sobre a demanda energética usando uma abordagem que inclui múltiplas reflexões da energia radiante, redução das perdas de calor convectivo e a ilha de calor urbana. O cânion urbano foi modelado pelo TRNSYS mediante um átrio contendo a edificação. A ilha de calor urbana foi considerada mediante a aproximação de sua intensidade com base em medições. Os

resultados mostraram um aumento de 13,6 MJ/m²/ano na demanda de resfriamento anual e uma diminuição de 9,76 MJ/m²/ano na demanda de aquecimento anual.

Nikkho *et al.* (2017) propuseram uma metodologia responsável por modelar os efeitos dos obstáculos locais sobre o vento incidente à edificação, estabelecendo multiplicadores de velocidade para oito direções principais com base em CFD. Os multiplicadores foram responsáveis pelo ajuste do arquivo climático que foi utilizado na modelagem energética realizada pelo EnergyPlus, ajustando também os coeficientes da classe *ZoneInfiltration:DesignFlowRate*. Apesar do estudo de caso aplicado numa edificação da Universidade de Maryland mostrar somente 5% de mudança quanto ao uso de energia por metro quadrado (EUI), os padrões de consumo confirmaram uma significativa mudança nas demandas de aquecimento e resfriamento.

Samuelson *et al.* (2016) com o objetivo de avaliar o impacto do sombreamento proveniente do contexto urbano sobre o consumo energético em climas frios e quentes, realizaram uma modelagem paramétrica mediante *Grasshopper* e EnergyPlus. Os resultados mostraram que a consideração do sombreamento promove um aumento no consumo energético em regiões de clima frio e uma redução em climas quentes, sendo notável o aumento da demanda de aquecimento e a diminuição no resfriamento.

Zhi-Hua Wang *et al.* (2016) investigaram o potencial de atenuação do consumo energético de edificações localizadas em Phoenix (EUA) mediante a introdução de gramados e árvores na área contexto. A modelagem do clima urbano foi desenvolvida baseada em métodos implementados no WRF-UCM que calculam os fatores de forma e as redes de radiação. Os resultados indicam que o efeito do gramado na economia energética é dado de forma indireta, através do resfriamento resultante da evapotranspiração e mediante a radiação térmica refletida do solo para as paredes. Já as árvores agem de forma direta, através do sombreamento que reduz diretamente a temperatura superficial dos elementos construtivos, assim seu impacto sobre a demanda de resfriamento acaba sendo mais significativo.

Evins *et al.* (2014) implementam melhorias no EnergyPlus com relação à radiação de onda longa entre superfícies externas, visto que a temperatura dos elementos de sombreamento são consideradas como tendo a mesma temperatura do solo. A nova abordagem é comparada com a implementação existente no EnergyPlus, considerando o clima de Genebra (Suíça). Os resultados mostraram um aumento na temperatura superficial em até 6°C, com variação média de 2°C, causando um aumento na carga anual de resfriamento de 4,3 kWh/m²/ano (18,8%) e uma redução na carga de aquecimento de 1,4 kWh/m²/ano (18,1%).

Allegrini *et al.* (2016) comentam que um dos fenômenos mais influentes no contexto urbano são as trocas radiantes, sendo essencial considerar o detalhamento do entorno para simular a demanda de energia do edifício de forma mais precisa. Neste estudo, para o clima de Zürich (Suíça) a demanda de resfriamento de edifícios isolados

é comparada com edifícios modelados em cânions urbanos, utilizando os modelos de radiação implementados no CitySim. Os resultados mostraram uma forte influência do entorno sobre a demanda energética da edificação, especialmente no que tange às superfícies da área contexto com baixa refletância e alta absorção, possuindo alta temperatura superficial.

Vallati *et al.* (2017) estudaram os efeitos das trocas radiativas entre edificações em Roma (Itália) através do programa TRNSYS, caracterizando seu comportamento em diferentes orientações e geometrias. Os resultados mostraram que as trocas radiativas modificam o microclima local assim influenciando a demanda anual de resfriamento com um acréscimo de até 16,3 kWh/m² (167%) e um decréscimo de 30,1 kWh/m² (38%) na demanda de aquecimento. Isso se deve às múltiplas reflexões que promovem o aprisionamento da radiação de maneira que mais radiação é absorvida pela fachada.

Palme *et al.* (2017) comentam que a simulação do desempenho do edifício não incluem adequadamente o efeito da ilha de calor urbana, o que pode implicar em um grande impacto no consumo energético computado. Assim, é proposta uma metodologia para incorporar tal efeito na modelagem. Os procedimentos metodológicos de forma resumida utilizam UWG para a modelagem climática e TRNSYS para a modelagem do edifício, sendo aplicado em Guayaquil (Equador), Lima (Peru), Antofagasta e Valparaíso (Chile). Os resultados indicam que quando o efeito da ilha de calor é incorporado, um aumento na demanda de energia entre 17% (13 kWh/m²) e 200% (1,9 kWh/m²) pode ser esperado.

Street (2013) estudou o efeito da modificação da temperatura e umidade relativa em Cambridge (EUA) através do UWG e *Crawley Model*, simulando o uso energético para o aquecimento e resfriamento de edificação unifamiliar e escritório. A aplicação do UWG reduz o erro na simulação energética um edifício urbano unifamiliar com um arquivo climático rural de 21% (19,53 kWh/m²) para 13% (12,09 kWh/m²). Com o algoritmo de Crawley o erro é reduzido para -8% (8 kWh/m²) ou +11% (10 kWh/m²), dependendo da intensidade da ilha de calor urbana considerada.

Miller *et al.* (2015) acoplaram CitySim e EnergyPlus implementando um melhor detalhamento para a radiação de onda longa, visto que o CitySim apresenta capacidades mais avançadas para trocas radiativas e o EnergyPlus é mais avançado para a simulação da demanda energética da edificação. Os dados de radiação obtidos no CitySim são utilizados para sobrepor as simplificações assumidas no EnergyPlus, que praticamente negligencia as superfícies adjacentes. Os resultados mostraram que o acoplamento promoveu diferenças de até 6,6% (2240 kWh) na demanda de resfriamento e 27,47% (1457 kWh) na demanda de aquecimento em Zürich (Suíça).

2.4 DESENVOLVIMENTO DE ZONEAMENTOS CLIMÁTICOS

O desenvolvimento de zoneamento climático é geralmente realizado através de métodos estatísticos que permitem uma profunda análise multivariada, desempenham papel principal na transformação de características climáticas em classificações congruentes com os climas inclusos no processo. Portanto, essas classes possuem exemplares cujas características individuais se assemelham dentro do grupo climático e se diferem dos demais grupos (FENG; TIAN, J., 2018). Por mais que isso seja o suficiente para o desenvolvimento de um sistema de classificação climática, existe uma série de procedimentos que são determinantes para a sua acurácia.

Primeiro, é importante entender qual o propósito do zoneamento climático, visto que no mundo existem inúmeros métodos, dos quais grande parte possui um propósito de uso específico. Segundo, é necessário entender como realizar a seleção dos indicadores climáticos que caracterizam cada local individualmente, visto que através dessas características individuais as categorias serão construídas. Terceiro, é importante saber mais sobre os métodos de agrupamento, uma vez que existem vantagens e desvantagens inerentes a cada um. Quarto, é importante entender o que pode ser realizado para a classificação de locais que encontram-se distantes dos pontos amostrais com dados meteorológicos. Quinto, é essencial compreender como pode ser realizada a validação do zoneamento climático, visto que existe uma grande gama de protocolos possíveis para o seu desenvolvimento e nem todos geram resultados aceitáveis.

2.4.1 Seleção dos indicadores climáticos

Mesmo que o processo de seleção dos indicadores climáticos que não seja suficiente para conferir uma boa acurácia ao zoneamento, pode ser o principal responsável pela sua baixa qualidade. Isso fica evidente quando se observa que uma variável climática como a radiação pode ser mais adequada para zoneamentos climáticos destinados a sistemas fotovoltaicos (ASCENCIO-VÁSQUEZ *et al.*, 2019), temperatura de bulbo úmido para sistemas de climatização de ambientes (BORGSTEIN; LAMBERTS, 2014) e precipitação para o aproveitamento de água da chuva (SEMAAN *et al.*, 2020). É importante definir o que será caracterizado no que se refere à temporalidade, quer seja variações nas variáveis climáticas ao longo dos meses do ano, tendência central ou mesmo as mudanças climáticas no período que está sendo analisado. Isso mostra a importância de compreender o que se quer caracterizar a partir da base de dados climáticos inicial (PRAENE *et al.*, 2019; DI GIUSEPPE *et al.*, 2013).

Potencialmente, os indicadores podem ser derivados de variáveis climáticas como a temperatura do ar, umidade relativa, radiação solar, precipitação, velocidade do vento, direção do vento, pressão atmosférica, nebulosidade, entalpia, temperatura de bulbo úmido e ponto de orvalho (PRAENE *et al.*, 2019; BORGSTEIN; LAMBERTS,

2014; MAZZAFERRO *et al.*, 2020; WALSH *et al.*, 2017c). Porém, é observado a utilização de variáveis espaciais e ambientais como latitude, longitude, altitude e vegetação (PRAENE *et al.*, 2019; KOTTEK *et al.*, 2006a; WALSH *et al.*, 2017c). Além do mais, índices de conforto como o de Terjung, a temperatura equivalente fisiológica (PET) e voto médio predito (PMV), configuram em outro grupo de variáveis que também podem ser utilizadas (PRAENE *et al.*, 2019).

Para compreender exatamente como pode ser realizado o processo de seleção das variáveis, vamos mergulhar nos procedimentos que são usados no aprendizado de máquina. De modo geral essa seleção pode ser realizada através de critérios subjetivos ou empíricos, métodos de análise de sensibilidade ou protocolos equivalentes (TIAN, W., 2013), e mediante algoritmos de otimização que realizam o processo de maneira cíclica a fim de identificar a melhor forma de caracterização.

A análise de sensibilidade permite entender quais variáveis de entrada mais impactam a resposta do modelo a partir de uma dada incerteza em sua entrada (SALTELLI *et al.*, 2004). Essa é uma ferramenta valiosa principalmente em análises energéticas de edificações (TIAN, W., 2013), já que explicita os parâmetros que, ao serem mal detalhados, podem promover inconsistências no resultado obtido na simulação do edifício. A análise de sensibilidade pode ser realizada por métodos locais ou globais, contudo dentro dessas categorias existem métodos que podem apresentar instabilidades quando submetidos a modelos complexos, não monotônicos e não lineares (NGUYEN; REITER, 2015; TIAN, W., 2013).

Os métodos mais robustos são os baseados em variância, como FAST e Sobol, porém eles necessitam de amostras especiais e isso impede seu uso quando as variáveis de entrada são dados climáticos. Vale ressaltar que a ANOVA mesmo sendo baseada em variância, não necessita de amostras especiais, sendo uma alternativa viável (NGUYEN; REITER, 2015). Todavia, métodos baseados em regressão (SRC) ou correlação (PCC) também ganham relevância nesse contexto, os quais permitem a determinação de índices de sensibilidade estáveis com custo de processamento computacional moderado. Além do mais, esses métodos possuem sinergia com o ambiente construído, sendo adequado na determinação da sensibilidade frente ao desempenho energético de edificações (MAO *et al.*, 2017). Essa sinergia também é observada quando esses métodos são aplicados em habitações naturalmente ventiladas, mostrando-se eficientes no estabelecimento dos índices de sensibilidade, com nível de confiança de 95% (GARCIA, 2020). Isso permite considerar que uma análise de sensibilidade também possibilitaria selecionar objetivamente os indicadores climáticos mais sensíveis, considerando edificações condicionadas artificialmente ou ventiladas naturalmente, os quais podem ser utilizados no desenvolvimento do zoneamento climático subsequente.

A maioria dos algoritmos de otimização tem seu comportamento inspirado na

natureza, especialmente com relação aos sistemas biológicos e físicos. Essa inspiração contribuiu para o desenvolvimento de ferramentas que hoje em dia são capazes de minimizar efetivamente uma série de problemas. Ao buscar inspiração na natureza, muitos algoritmos de otimização têm se tornado mais robustos e eficientes frente a busca por um mínimo global, especialmente quando a análise da população inteira seria algo inviável (YANG, 2010; GOMES *et al.*, 2018).

Por essas razões, o algoritmo genético tem sido amplamente usado pela comunidade acadêmica, especialmente devido a sua capacidade em explorar o espaço amostral sem que fique estagnado em um mínimo local. Além disso, a abordagem clássica dos algoritmos de otimização consideram somente um único indicador de saída. Portanto, quando o problema de otimização estabelece dois indicadores de saída, os pesquisadores geralmente aplicam os algoritmos usando uma fórmula alternativa que possa representar ambos indicadores (BRE *et al.*, 2016, 2020). Por exemplo, no caso do zoneamento é possível estabelecer uma função que considere a complexidade, desempenho do método e indicadores climáticos.

O uso de valores médios anuais é algo a ser realizado de maneira cuidadosa, visto que climas com médias semelhantes podem apresentar amplitudes diferentes (COLLINS, 1954). Essa questão é principalmente relevante em zoneamentos globais, onde a caracterização climática necessita ser corretamente estabelecida. Uma saída para essa questão é representar o clima por médias mensais ou mesmo incluir a amplitude (NETZEL; STEPINSKI, 2016; YAO, 1997). Todavia, a lógica da média não funciona para variáveis como radiação solar e precipitação, que desempenha um melhor papel de caracterização quando é realizado seu somatório dentro do período analisado. Isso não impede que a temperatura do ar tenha uma abordagem semelhante, visto que muitos zoneamentos utilizam a soma anual acima ou abaixo de uma temperatura base, conhecido graus-hora ou graus-dia (BORGSTEIN; LAMBERTS, 2014; WALSH *et al.*, 2017a). Além do mais, é importante ressaltar que o excesso de indicadores para caracterizar o clima pode promover ruído no processo de agrupamento.

Técnicas estatísticas mais complexas também são usadas no estabelecimento desses indicadores climáticos. No contexto do zoneamento climático, a redução de dimensão através da análise de componentes principais (PCA) é sem dúvida uma das utilizadas (DEGAETANO; SHULMAN, 1990; TERCEK *et al.*, 2012; KALKSTEIN *et al.*, 1987). Essa técnica permite que variáveis quantitativas sejam utilizadas para explorar e visualizar uma matriz composta por dados individuais. O principal objetivo do PCA é maximizar a variação total dos pontos projetados, ou seja, definir o subespaço que melhor representa a diversidade dos indivíduos (PRAENE *et al.*, 2019). Todavia, a redução de dimensão dificulta a inclusão de novos climas no zoneamento, visto que para uma correta inserção é necessário processar a base por completo. Esse mesmo problema é observado em métodos de redução de dimensão mais robustos

como o TNSE e UMAP. Isso não impede o uso dessas técnicas para o zoneamento, porém a inclusão de novos climas deve ser realizada mediante técnicas descriptivas das categorias climáticas resultantes do agrupamento.

O grande avanço nas técnicas de redução de dimensão é a possibilidade resumir informações relevantes em um número de dimensões que seja suficiente para não causar problemas de instabilidades na aplicação dos métodos de agrupamento. Por exemplo, é possível reduzir a dimensão de valores mensais de grandes períodos de tempo, considerando um grande número de variáveis climáticas, em poucos indicadores (DEGAETANO; SHULMAN, 1990; KALKSTEIN *et al.*, 1987). Portanto, com a perda de pouca informação é possível caracterizar os aspectos mais detalhados dos dados climáticos. Quanto maior o número de dimensões consideradas, maior é a capacidade da técnica caracterizar o comportamento da base climática (TERCEK *et al.*, 2012), porém até 3 dimensões são desejáveis para posterior análise exploratória mediante gráficos.

A redução de dimensão também pode ser realizada através de abordagem funcional, que permite resumir séries temporais em funções através de poucos coeficientes que a caracterizam. Todavia, a escolha da função base é fator determinante para que o desempenho da combinação linear seja satisfatório. As duas bases mais comumente escolhidas são Fourier e B-splines. A primeira é adotada principalmente quando se supõe que os dados tenham um componente periódico importante; o segundo é particularmente adequado quando nenhuma periodicidade é prevista nos dados ou é afetada por alguma forma de perturbação. Os coeficientes da expansão podem ser determinados pelo critério de mínimos quadrados (DI GIUSEPPE *et al.*, 2013).

Quando a sazonalidade ou tendências ao longo dos anos é algo a ser levado em consideração no processo de agrupamento, a abordagem funcional ganha relevância, visto que os coeficientes determinam uma identificação clara dos mecanismos de variabilidade (DI GIUSEPPE *et al.*, 2013). Há uma grande vantagem no uso de funções frente a métodos de redução mais convencionais, visto a possibilidade de reduzir a dimensão dos dados através de um único exemplar. Isso alivia o custo computacional decorrente do processamento da base inteira, o que geralmente é necessário nos demais métodos. Todavia, o detalhamento dos dados climáticos numa microescala temporal não garante que o agrupamento potencialmente possua um bom desempenho, visto que ele pode estar representando características que não impactam o indicador de saída dos sistemas que estão sendo analisados através da aplicação do zoneamento final. Isso mostra a importância de um estudo abrangente antes do estabelecimento do indicador climático a ser considerado no agrupamento.

Quando os dados climáticos possuem diferentes unidades ou ordens de grandeza, é essencial realizar o processo de normalização (ZHANG, 2005; NETZEL; STEPINSKI, 2016). Isso deve ocorrer na fase anterior à aplicação ao método de agrupa-

mento, visto que a dissimilaridade calculada por eles é influenciada fortemente pelas distâncias absolutas dos indicadores de um caso em relação a outro (YAO, 1997). Existe uma série de formas de normalização, porém as mais comumente utilizadas são o método de máximo e mínimo (ZHANG, 2005) e z-score (KOZJEK *et al.*, 2017). O primeiro padroniza os dados de 0 a 1, de maneira que 0 é atribuído para o exemplar climático que possui o valor mais baixo para um determinado indicador climático e 1 para o caso com maior valor. O segundo identifica a distância do valor original com a média e pondera isso pelo desvio padrão, definindo um valor adimensional que assume valores negativos ou positivos.

2.4.2 Métodos de agrupamento

O processo de agrupamento é comumente aplicado com o objetivo de agrupar climas com indicadores semelhantes, considerando as variáveis climáticas simultaneamente (DEGAETANO; SHULMAN, 1990). Esses indicadores são previamente normalizados de maneira que a aplicação do método de agrupamento produza resultados estáveis. Essa boa prática deve vir acompanhada de uma incessante busca por protocolos de agrupamento. Conforme os dados climáticos disponíveis, o protocolo mais adequado pode mudar e por conta disso é importante realizar uma busca pela melhor configuração. Cada método possui uma série de parâmetros que impactam o desempenho das classes climáticas obtidas no final do processo. Esses métodos são divididos em particionamento, hierárquico, heurísticos and *supervised machine learning* (aprendizado de máquina supervisionado).

Os métodos de particionamento mais recorrentes no contexto do zoneamento climático são K-Means e K-Medoids, os quais reúnem o conjunto de dados próximo de centroides (DI GIUSEPPE *et al.*, 2013; KOZJEK *et al.*, 2017; XIONG *et al.*, 2019). Em contraste com o algoritmo K-Means, o algoritmo K-Medoids escolhe pontos como centros (medoids ou exemplos), facilitando a identificação das características do grupo. É mais robusto ao ruído e aos outliers em comparação aos K-Means, porque minimiza uma soma de diferenças pareadas em vez de uma soma de distâncias euclidianas quadradas (DI GIUSEPPE *et al.*, 2013). Para classificar um determinado conjunto de dados usando o procedimento K-Means, certas etapas devem ser seguidas. Primeiro, os K centroides devem ser selecionados aleatoriamente como os centroides iniciais do grupo. Segundo, cada ponto deve ser alocado para um determinado grupo e associado ao centroide mais próximo; essa etapa continua até que o critério de convergência seja atendido (ZHANG, 2005).

Os métodos hierárquicos podem ser realizados por abordagens divisivas ou aglomerativas (XIONG *et al.*, 2019; KALKSTEIN *et al.*, 1987). No primeiro caso, os indivíduos que compõem todos os casos da amostra são divididos em dois grupos, os quais são posteriormente separados até que cada grupo seja composto por um

único indivíduo. No segundo caso, cada indivíduo é reunido com outro indivíduo mais semelhante, posteriormente esse grupo é combinado com o grupo mais semelhante até que todos os indivíduos estejam ligados a um mesmo grupo principal (HAN, 2011). Os métodos hierárquicos de agrupamento são um dos métodos mais diretos, porém exige muitos recursos computacionais, visto que exige o cálculo da distância ou matriz de similaridade entre todos os pares de objetos (KOZJEK *et al.*, 2017). A abordagem aglomerativa têm a vantagem de não exigir pré-especificação do número de grupos e serem mais reproduzíveis do que métodos que fazem o uso de procedimentos randômicos e de convergência.

Os métodos heurísticos partem da Lógica Fuzzy (MCBRATNEY; MOORE, 1985), bem como algoritmos de otimização como *Particle Swarm Optimization* (PSO) (LEE; KUNG, 2011) e *Simulated Annealing Algorithm* (SA) (JACOBET, 2010). Os algoritmos de otimização podem ser muito úteis quando há dificuldades em estabelecer o agrupamento através de métodos convencionais, onde pontos dispersos ou mesmo a interface entre zonas climáticas podem causar problemas no agrupamento. Em um primeiro momento é difícil pensar em conjuntos ou classes de uma maneira difusa ou contínua, porém através da Lógica Fuzzy isso é possível (MCBRATNEY; MOORE, 1985). Além disso, tratar o processo de agrupamento como um problema de otimização, tem sido algo muito promissor, mostrando melhor desempenho do que o algoritmo tradicional (LEE; KUNG, 2011). Esses algoritmos de otimização evitam soluções ótimas locais, de maneira que o conjunto de categorias tende a ser a solução ótima global.

Os métodos baseados em aprendizado de máquina supervisionado são composto principalmente por redes neurais artificiais (ANN) (JACOBET, 2010; MALMGREN; WINTER, 1999) e árvore de regressão multivariada (MRT) (CANNON, 2012; BELDA *et al.*, 2015). Talvez o exemplo mais importante para a aprendizado de máquina sejam os mapas auto-organizados (SOM). Eles criam um conjunto organizado espacialmente de padrões generalizados de variabilidade, permitem representar ao mesmo tempo, diferentes aspectos da variabilidade e incluem padrões intermediários que refletem transições suaves entre os estados distintos da classificação (JACOBET, 2010). Essa técnica categoriza vetores de entrada, reconhecendo regularidades e correlações entre eles, sendo ideal quando o número de classes do agrupamento não é conhecido *a priori* (MALMGREN; WINTER, 1999). O MRT é um método automatizado que acelera o desenvolvimento e os testes; é hierárquico, o que permite definir uma série de classes aninhadas; e é baseado em regras, o que permite que as classes climáticas sejam definidas sem ambiguidade e sejam facilmente interpretadas; sendo uma ferramenta muito útil no desenvolvimento de zoneamentos climáticos (CANNON, 2012).

2.4.3 Classificação de locais sem dados climáticos

Em face do número limitado de estações meteorológicas para medição de dados climáticos, bem como sua distribuição espacial, há vários locais ao redor do mundo cujo comportamento climático é desconhecido por falta de dados medidos. Porém, o uso de dados de latitude, altitude e longitude pode ser suficiente para calcular uma boa aproximação no processo de zoneamento climático, interpolando e extrapolando esses valores para áreas onde não há disponibilidade de dados climáticos (CARPIO, M. et al., 2015).

Foi identificado uma ampla gama de métodos de interpolação, tais como polígonos de Voronoi, *Local Natural Neighbor*, interpolação polinomial, *spline*, interpolação polinomial global, distância inversa ponderada (IDW), função de base radial e Kriging (Krigagem) (LEE; OH, 2018; PIRI et al., 2017). Esses métodos são de suma importância na análise espacial, especialmente no processo de geoprocessamento das classificações climáticas. Portanto, via interpolação é possível o desenvolvimento de modelos contínuos mediante distribuições espaciais e temporais (PIRI et al., 2017).

O método Kriging é amplamente usado para a interpolação espacial, que na sua forma mais simples prediz um valor para uma dada localidade sem dados mediante a dependência espacial dos valores observados. Isso significa que as observações mais próximas são mais prováveis de ter valores similares do que as observações mais distantes (KARKI et al., 2016).

Para analisar a temperatura do ar, métodos de interpolação estatística são comumente usados para preparar mapas de temperatura usando medições baseadas em pontos. Todavia, o espaçamento das estações meteorológicas pode ser um fator limitante, especialmente em locais que possuem características espaciais e topográficas complexas (KARKI et al., 2016; LEE et al., 2019). Isso estabelece a necessidade da utilização de métodos mais robustos como a Krigagem (Kriging) universal baseada em regressão de processo gaussiano e técnicas baseadas em regressão como aprendizado de máquina (LEE et al., 2019; RAHIMI et al., 2019). O uso desses métodos permite a consideração de parâmetros que condicionam o comportamento climático do local, porém por um método mais simples seriam desconsiderados. Por exemplo, variáveis como altitude, distância da costa, porcentagem de área contendo corpos d'água hídrico, cobertura do solo e vegetação (LEE et al., 2019; RIZWAN et al., 2008). Todavia, ainda que o método seja robusto e estejam sendo consideradas diversas variáveis que impactam no comportamento climático do local, é necessário que os valores interpolados sejam obrigatoriamente validados (KARKI et al., 2016).

Mesmo que o processo de validação seja realizado, definindo que a interpolação foi robusta o suficiente para representar o comportamento climático de todo o domínio, eventualmente, inconsistências podem ocorrer. Sem dúvida o principal problema relacionado a isso é que os métodos comumente definem as características

climáticas baseadas na amostra, isso tende a promover uma suavização dos valores preditos (DEGAETANO, 1996). Portanto, uma possibilidade é o uso de técnicas de regressão como o *machine learning* para aumentar o número de locais na amostra e posteriormente o uso de métodos de interpolação como o Kriging (RAHIMI *et al.*, 2019).

2.4.4 Validação do agrupamento

Esse é um dos procedimentos mais importantes no protocolo de agrupamento. Através dele é possível verificar se as categorias apresentam desempenho adequado. Esse desempenho pode ser verificado por meio de características inerentes às categorias ou mediante a adequabilidade do zoneamento climático para um dado propósito de aplicação. O primeiro estabelece métricas estatísticas que definem o quanto as categorias possuem indivíduos semelhantes e diferentes dos observados nas demais. A segunda parte da mesma premissa de semelhança entre indivíduos da mesma classe e diferença com as demais, porém a análise é realizada por meio da resposta, por exemplo, do consumo energético de edifícios comerciais nas zonas climáticas do zoneamento analisado.

O número de grupos é um parâmetro que está presente na maioria dos métodos de agrupamento e controla o desempenho inerente às categorias. Quanto maior for o número de grupos, maior será a semelhança entre climas da mesma classe e diferença com as demais (KOZJEK *et al.*, 2017). O problema é que um número excessivo de grupos torna a aplicação do método de zoneamento pouco prática. Porém um número pequeno de grupos pode definir zonas climáticas que apresentam grande variabilidade climática. Como não existem métodos satisfatórios para determinar o número ideal de grupos, a escolha de quantos grupos usar é geralmente uma decisão arbitrária (DEGAETANO; SHULMAN, 1990).

Há métricas e técnicas estatísticas que auxiliam nessa tomada de decisão, como o coeficiente de determinação, critério de Calinski-Harabasz, *elbow method*, critério de informação bayesiana (KOZJEK *et al.*, 2017), ANOVA (LEE *et al.*, 2019), *silhouette method* (PRAENE *et al.*, 2019), *cubic clustering criteria*, pseudo F e pseudo t^2 (DEGAETANO; SHULMAN, 1990). É importante ressaltar que o uso combinado de mais de um desses indicadores pode ser útil ou mesmo confundir a decisão do número de grupos, visto que o comportamento observado em um pode indicar algo que não é observado explicitamente na outra métrica (DEGAETANO; SHULMAN, 1990).

Definindo um número de grupos que apresente coerência através do desempenho inerente às categorias, o desempenho do zoneamento frente ao propósito de aplicação, potencialmente, pode ser adequado. Caso isso não ocorra, é muito provável que a seleção dos indicadores climáticos tenha sido realizada de maneira equivocada, ou seja, a forma de caracterização não é a mais adequada para o propósito de aplica-

ção do zoneamento. Portanto, o pesquisador deve voltar ao processo de seleção do indicador para estabelecer uma melhor forma de caracterização.

2.5 CONSIDERAÇÕES FINAIS

O zoneamento climático é um processo complexo que inclui vários métodos e áreas do conhecimento. Tudo se inicia pelo propósito ao qual o zoneamento climático está sendo desenvolvido. Esse propósito tende a direcionar procedimentos para escolhas específicas. Além do que, a determinação dos indicadores climáticos, responsáveis por descrever o comportamento climático, configura na etapa mais importante. Para que o zoneamento tenha um bom desempenho para um dado propósito, é necessário que o mesmo seja desenvolvido considerando indicadores climáticos que sejam sensíveis ao comportamento térmico do edifício, bem como dos seus sistemas.

Para que os indicadores climáticos calculados caracterizem realmente o comportamento climático do local, é necessário que os mesmos sejam provenientes de banco de dados bem consolidados. Para isso é importante investigar a qualidade dos bancos utilizados no processo de zoneamento climático. Além do mais, foi identificado que o número limitado de pontos com dados de boa qualidade define uma problemática ligada à classificação climática de localidades sem estação meteorológica. Para contornar isso, muitos pesquisadores interpolam os dados seguindo meramente parâmetros espaciais. Por outro lado, a literatura mostra que o uso de métodos de aprendizado de máquina supervisionado pode ser uma abordagem para melhorar a robustez e confiabilidade do zoneamento para os climas sem dados climáticos.

Mesmo que métodos de particionamento (K-means) sejam frequentemente utilizados no processo de zoneamento, foi observado que existe uma ampla gama de outras possibilidades. Além do que, métodos de árvore de regressão se mostram muito eficientes no processo de zoneamento, pois automatizam muitos procedimentos e podem ser facilmente validados mediante o desempenho dos modelos gerados. Porém, estabelecer um novo método de zoneamento climático somente é algo necessário caso os existentes sejam incapazes de representar o comportamento do sistema considerado de maneira satisfatória. Portanto, inclusive os métodos de zoneamento existentes necessitam ser previamente validados para cada propósito ao qual será aplicado. Para validá-los ou mesmo para o desenvolvimento de novos métodos, o uso de dados de desempenho térmico de edifícios se mostrou algo essencial a ser incluído no processo de zoneamento.

Um zoneamento climático pode ser desenvolvido baseado em abordagens probabilísticas e determinísticas. Todavia, de qualquer forma existe uma incerteza associada a classificação climática, mesmo que o zoneamento seja desenvolvido e validado da melhor forma possível. Quando uma abordagem probabilística é considerada, a ideia de que um clima pode estar na transição entre duas zonas climáticas é apre-

sentada explicitamente. Porém, para o desenvolvimento de uma normativa, uma abordagem determinística é o mais indicado, onde cada município brasileiro possui uma classificação bem definida. Além da incerteza estar relacionada com a robustez do método de zoneamento, existem outras incertezas que também podem impactar fortemente a classificação climática final, tais como: acurácia da base de dados climáticos, microclima onde a edificação está localizada e o clima futuro.

Quanto à acurácia, dependendo da base de dados escolhida pode haver uma diferença significativa em relação ao comportamento dos dados climáticos. Isso pode influenciar os resultados da classificação climática quer seja feita via dados climáticos ou baseada em dados de simulação computacional de edifícios. Isso indica que ao desenvolver um zoneamento climático deve-se evitar a combinação de mais de uma base de dados climáticos, especialmente quando a fonte de dados e os métodos para gerar as bases são muito distintos. Ao combinar duas bases muito distintas, o zoneamento climático pode ter dificuldade em agrupar os climas de maneira adequada, pois a diferença entre as bases promoveria um ruído com relação a real diferença entre os climas.

Quanto ao microclima e clima futuro, o avanço tecnológico e científico tem permitido que diferentes técnicas de suporte sejam aplicadas de maneira satisfatória. Nesse âmbito, a modelagem numérica ganha relevância frente a problemática apresentada neste estudo. Para representar o efeito do contexto urbano sobre o comportamento térmico e energético de edificações, os pesquisadores comumente realizam modelagens na escala do edifício e escala urbana. Isso ocorre por meio de cosimulação ou mediante um processamento prévio dos dados do contexto urbano. Para o clima futuro, usa-se base de dados gerados por fluidodinâmica computacional a nível regional e global, que são ajustados para uma escala mais refinada baseado em dados climáticos medidos no local.

A literatura mostra que a investigação do microclima urbano previamente à simulação energética da edificação é uma notável necessidade, visto que há parâmetros que podem impactar os elementos climáticos locais. O comportamento da edificação frente ao clima urbano não ocorre de forma unilateral, visto que os zoneamentos climáticos e locais definem condicionantes que afetam a carga térmica admitida pela edificação. Assim, escolher a abordagem adequada é algo essencial para considerar a influência desses parâmetros sobre o consumo energético das edificações. Todavia, para incluir o clima urbano em um zoneamento climático de uma normativa seria necessário levantar quais zonas climáticas locais existem em todos municípios brasileiros, inviabilizando o estudo. Por esse motivo, optou-se por avaliar a incerteza em relação ao clima urbano posteriormente ao desenvolvimento do zoneamento climático.

Mesmo que métodos intensivos computacionalmente sejam mais precisos do que modelos de resposta rápida, seu custo de processamento é considerado muito

elevado, inviabilizando um estudo em larga escala. Além do mais, foi observado que o modelo de resposta rápida conhecido como UWG estabelece resultados confiáveis ainda que seu algoritmo simplifique a maneira como o contexto urbano é caracterizado. Isso pode ser um problema caso seja necessário representar algo que venha a extrapolar o nível de detalhamento do modelo, porém isso é algo que não foi observado claramente nos estudos revisados. Nesse sentido, é válido ressaltar que métodos de modelagem simplificados podem não captar com precisão a resposta de determinado objeto de estudo; ao passo que metodologias muito elaboradas estão suscetíveis a uma série de incertezas que podem estabelecer resultados inconsistentes, especialmente, quando variáveis incertas possuem alta sensibilidade.

Finalmente, foi possível identificar que até o presente momento faltam estudos que analisam o zoneamento climático em um plano mais próximo do comportamento real, considerando diferentes microclimas e mudanças climáticas. Além do mais, classificar da maneira mais acurada possível as cidades sem estações meteorológicas também é algo essencial para desenvolver um zoneamento climático robusto para todos os municípios brasileiros.

3 ZONEAMENTO BIOCLIMÁTICO BRASILEIRO

Esse capítulo é um resumo expandido do artigo presente no Apêndice A intitulado "*Bioclimatic zoning for building performance using tailored clustering method and high-resolution climate data*". Esse artigo foi publicado na revista *Energy and Buildings* com o DOI "<https://doi.org/10.1016/j.enbuild.2024.114157>".

3.1 ESCOLHA DA BASE CLIMÁTICA PARA A SIMULAÇÃO COMPUTACIONAL

Uma análise exploratória foi realizada em quatro bancos de dados de arquivos climáticos (o INMET e três versões do TMYx) para definir o mais adequado para o protocolo de agrupamento. Aqui, a confiabilidade dos dados climáticos é analisada de acordo com a representatividade histórica, número de localidades, quantidade de dados faltantes e valores discrepantes. É importante que cada localidade represente adequadamente a série histórica e esteja bem distribuída espacialmente. Para entender como os bancos de dados se comportam nesses dois aspectos, a Figura 1a mostra o número de anos presentes em cada arquivo climático, e a Figura 1b estabelece o número de localidades.

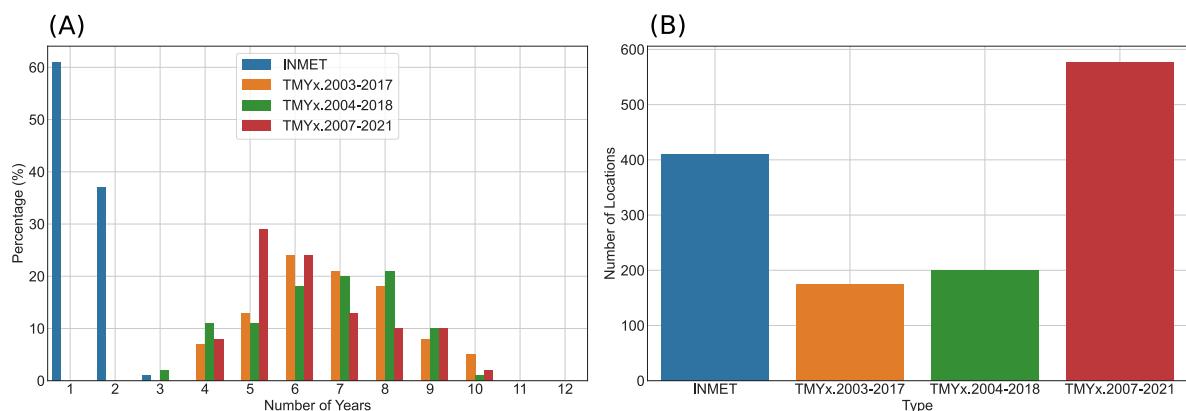


Figura 1 – Porcentagem de anos por clima presente em cada base de dados (A) e número de localidades por base de dados (B).

Os histogramas mostram que o INMET possui mais de 60% de localidades com apenas um ano, sendo praticamente um ano real. Na base de dados do INMET, o máximo foi de três anos diferentes entre 12 possíveis. Para as demais bases de dados, tais valores apresentam maior variabilidade, com medianas entre 5 e 8 anos. A documentação descreve que os arquivos do INMET contêm dados de 2001 a 2010. No entanto, há indícios de que o INMET foi derivado de dados medidos com limitações substanciais de disponibilidade. Esta suposição é confirmada uma vez que o número de estações meteorológicas aumentou, principalmente entre 2006 e 2008, de 154

locais para 417. Por esse motivo, apenas as duas últimas versões dos TMYs serão analisadas na Figura 2.

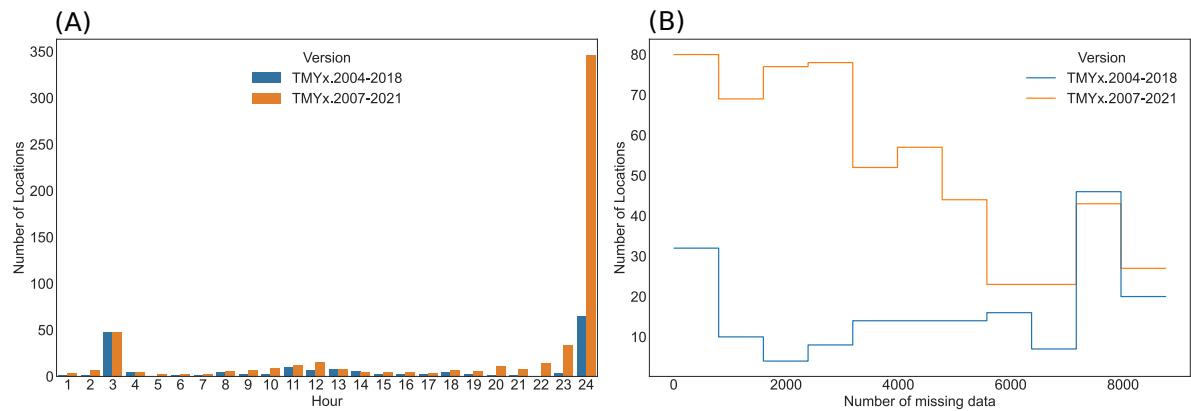


Figura 2 – Histograma do número de locais de acordo com o número de horas medidas por dia (A) e histograma do número de locais de acordo com a soma das horas com dados faltantes ao longo do ano no TMYx.2004-2018 e TMYx.2007-2021 (B).

Para compilar um arquivo climático, é necessário seguir alguns procedimentos para preencher dados faltantes e analisar a combinação de meses que definem um ano meteorológico típico com comportamento próximo ao apresentado pela série histórica. Para verificar os dados faltantes de cada versão do TMY, cada mês típico foi comparado com os respectivos dados da série histórica disponível na plataforma ISD-Lite. De acordo com a Figura 2a, é possível observar que o TMYx.2007-2021 possui diversas estações meteorológicas com 24 horas de medições. Contudo, os resultados também mostram que em ambas as versões do TMY, alguns locais não realizam medições em todas as horas do dia. Quando estas medições não são realizadas 24 horas por dia, é necessário preencher os dados faltantes, o que introduz incerteza na confiabilidade dos dados processados. Dados faltantes também podem ocorrer devido a problemas de medições, como falta de energia, quebra de equipamento, manutenção, etc. A Figura 2b apresenta dados faltantes ao longo do ano, mostrando que a versão mais recente do TMY tem mais dados medidos do que o TMYx.2004-2018. Uma possibilidade para melhorar a confiabilidade do banco de dados é remover locais com dados faltantes maiores que um limite específico. Como vários locais apresentam muitos dados faltantes e problemas com valores maiores ou menores do que o esperado, apenas 298 arquivos climáticos (TMYx.2007-2021) foram selecionados para serem usados no protocolo de agrupamento.

3.2 ANÁLISE DE SENSIBILIDADE DOS INDICADORES CLIMÁTICOS E DE DESEMPENHO

Para compreender como se comportam os indicadores de desempenho higrotérmico e energético dos edifícios frente aos indicadores climáticos, é realizada uma análise de sensibilidade através do coeficiente de determinação, que é apresentado na Figura 3. Os resultados mostram que as tipologias residenciais e comerciais de referência são mais sensíveis à temperatura de bulbo seco (DBTmean), especialmente para PHsFT e CgTr. A correlação da CgTa com a temperatura de bulbo seco foi um pouco menor, mas dentro do que se entende como correlacionada. Além disso, o graus-dia de aquecimento usando 14 °C como temperatura base (HDD14) está fortemente relacionado com indicadores de desempenho relacionados ao desconforto para o frio. A umidade relativa (RHmean) foi o indicador mais sensível para PHRs70 e PHRi30, e esses indicadores de desempenho também mostraram alguma correlação com a radiação horizontal global diária (GHRmean), ponto de orvalho (DPTmean) e amplitude térmica (DBTamp). Esta análise esclarece que o uso da temperatura de bulbo seco e da umidade relativa externa para descrever o desempenho dos edifícios é totalmente viável. A umidade relativa externa foi mais impactante para os indicadores de umidade relativa interna, apesar de seu valor de correlação ser inferior ao observado em outros indicadores de desempenho. Para a velocidade do vento (WSmean), a sensibilidade foi quase insignificante em todos os indicadores de desempenho higrotérmico e energético; porém, entende-se que é muito importante para casos específicos, como remoção de calor ou umidade interna.

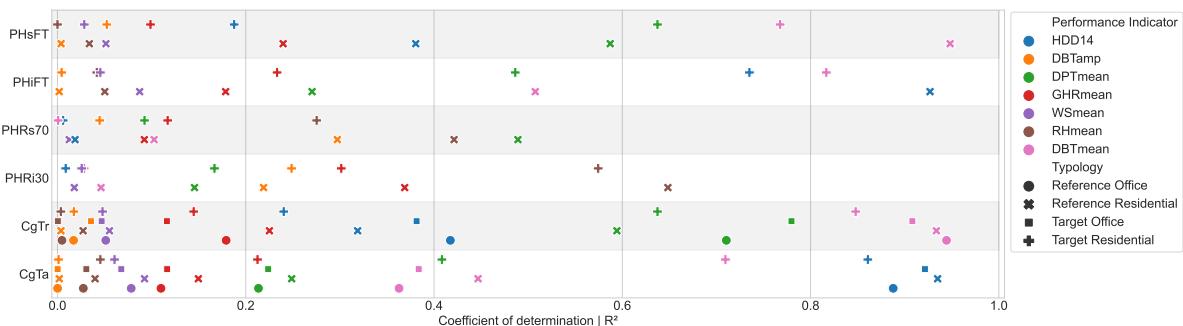


Figura 3 – Índice de sensibilidade dos indicadores climáticos frente aos indicadores de desempenho de edificações residenciais e comerciais.

Esta análise de sensibilidade mostra que essas tipologias podem responder de forma ligeiramente diferente aos climas, mas as tendências gerais permanecem as mesmas. Isto sugere que apenas uma tipologia pode ser suficiente se o detalhamento climático estiver restrito aos indicadores mais sensíveis. Um ponto positivo da utilização de tipologias de referência para zoneamento bioclimático é que elas são frequentemente observadas nas edificações brasileiras e são sempre modeladas para

avaliar o nível de desempenho térmico ou energético das edificações como ocorre na ABNT-NBR 15575 e INI-C, respectivamente. Além disso, o edifício residencial unifamiliar escolhido está mais exposto ao clima do que um edifício comercial. Por conta disso, o zoneamento bioclimático foi desenvolvido considerando a tipologia de referência de um edifício residencial unifamiliar e posteriormente validado com outras tipologias. Além disso, as tipologias de referência apresentam forte correlação com a temperatura de bulbo seco, principalmente quando se considera a carga de resfriamento, que é predominante no contexto brasileiro.

3.3 ANÁLISE DE MÉTODOS PARA O ZONEAMENTO BIOCLIMÁTICO

Os três métodos avaliados aqui são baseados no desempenho de edificações, indicadores climáticos e árvores de decisão. Os primeiros dois métodos utilizam K-means aplicados em indicadores de desempenho de edificações ou climáticos, enquanto a árvore de decisão considera indicadores climáticos e de desempenho do edifício simultaneamente. O número de grupos climáticos variou de 6 a 12. No método baseado no clima, foram consideradas 127 combinações de indicadores climáticos para ser realizada uma análise abrangente. Para os métodos baseados em desempenho e árvore de decisão, os indicadores de desempenho do edifício foram os mesmos apresentados na análise de sensibilidade, considerando a tipologia de referência de uma edificação residencial unifamiliar.

O desenvolvimento e avaliação dos métodos de zoneamento propostos foram realizados utilizando o módulo Scikit-Learn da linguagem de programação Python. Cada proposta foi avaliada usando a métrica Silhouette e a Calinski-Harabasz, também disponíveis no módulo Scikit-Learn. Essas métricas permitem compreender a capacidade do método de zoneamento em produzir grupos distintos entre si com base nos indicadores de desempenho. O Silhouette é 1 quando cada zona climática está perfeitamente agrupada e -1 quando o zoneamento climático é muito ruim. Para o Calinski-Harabasz, o pior agrupamento é zero, não havendo valor máximo pré-estabelecido.

3.3.1 Zoneamento usando K-means e indicadores de performance de edifícios

Para explorar os melhores resultados do método de zoneamento baseado em desempenho, foram consideradas 6 a 12 zonas para separar os climas. O método de agrupamento K-means, disponível no módulo Scikit-Learn, é utilizado para agrupar os indicadores de desempenho dos edifícios. Todos os indicadores de desempenho foram normalizados, considerando valores de 0 a 1. A Figura 4 apresenta o conjunto de indicadores de desempenho calculados conforme a ABNT-NBR 15575, que são chamados de *Key Performance Indicators* (KPIs): PHiFT, PHsFT, CgTa e CgTr. Indicadores de desempenho de edifícios relacionados à umidade também são considerados

nesta análise (PHRi30 e PHRs70).

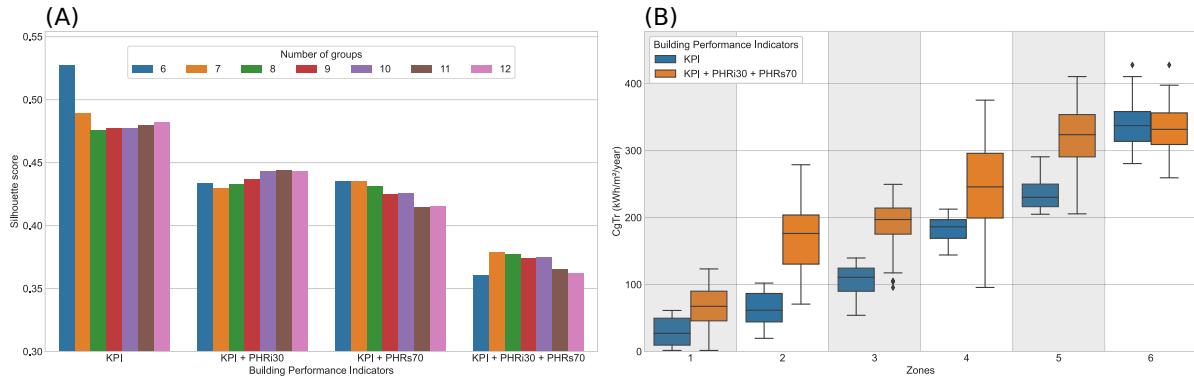


Figura 4 – Zoneamento baseado no desempenho da edificação: gráfico de barra da métrica Silhouette de quatro grupos de indicadores de desempenho do edifício (A) e boxplot da carga térmica de resfriamento do edifício de referência do melhor e pior zoneamento (B).

Os resultados mostram que o zoneamento baseado em indicadores de desempenho relativos ao comportamento térmico (KPIs) estabelece um agrupamento bem definido; veja a Figura 4a. Quando são adicionados indicadores de desempenho não correlacionados à temperatura, o desempenho do zoneamento baseado no desempenho é mais ruidoso nas transições entre zonas climáticas. É importante ressaltar que a proposta com maior e menor pontuação no Silhouette foi estabelecida com seis grupos. Porém, a melhor precisão é observada quando o zoneamento considera apenas os KPIs. A menor precisão foi observada quando incluiu KPIs e indicadores de desempenho relacionados à umidade relativa interna (PHRs70 e PHRi30). Embora se observe um pior desempenho quando se incluem indicadores relativos à umidade relativa, o detalhamento da umidade relativa é essencial no zoneamento bioclimático, que é o objetivo desta tese. Com a inclusão da umidade existe uma clara divisão do bioma amazônico e do semiárido nordestino.

A Figura 4b apresenta a dispersão da carga térmica de resfriamento de cada zona climática dos agrupamentos com valores de Silhouette mais altos e baixos. Os grupos do zoneamento que consideram apenas os KPIs estão mais bem definidos. Quando são somados dois indicadores relacionados à umidade relativa, observa-se uma maior dispersão da carga térmica, resultando em maior ruído nas transições de zonas. É importante ressaltar que ruídos também ocorrem nos demais indicadores de desempenho. Porém, a carga térmica de resfriamento foi apresentada na Figura 4b pois as estratégias relacionadas ao resfriamento são predominantes no Brasil e a necessidade de aquecimento é zero ou próxima de zero em grande parte do território.

3.3.2 Zoneamento usando K-means e indicadores climáticos

Os indicadores climáticos usados na análise de sensibilidade foram normalizados com valores entre 0 e 1 e agrupados através do método de agrupamento K-means. O método de zoneamento baseado no clima considerou propostas que usam de 6 a 12 zonas para separar os climas. Todas as combinações dos sete indicadores climáticos foram analisadas para realizar uma análise abrangente. Portanto, foram analisadas 127 combinações de indicadores climáticos. Isto inclui casos em que apenas um indicador foi considerado e casos em que dois ou mais indicadores foram considerados no zoneamento. Seguindo cada procedimento detalhado aqui, obtemos as métricas Silhouette e Calinski-Harabasz para todas as variantes que seguem o método baseado no clima, conforme mostrado na Figura 5.

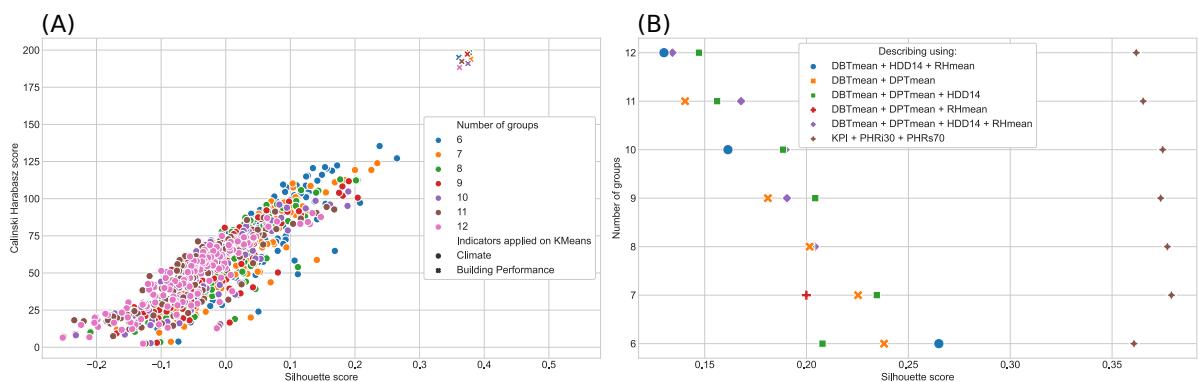


Figura 5 – Zoneamento baseado em indicadores climáticos: dispersão da métrica Silhouette e do Calinski-Harabasz, considerando todas as combinações (A) e indicadores climáticos das três melhores combinações de acordo com a métrica Silhouette (B).

Em relação às métricas Silhouette e Calinski-Harabasz, na Figura 5a, é possível observar que para o método baseado no clima, os melhores resultados são aqueles com poucos grupos climáticos. Para este indicador, quanto maior o valor associado, melhor será o zoneamento climático. Os resultados mostram que o mesmo número de grupos pode estabelecer zoneamentos climáticos adequados ou propostas de baixa qualidade. Portanto, a acurácia da proposta depende dos indicadores climáticos utilizados no processo de agrupamento.

A Figura 5b mostra três combinações com os valores de Silhouette mais altos para cada número de grupos climáticos. Os resultados mostram que as melhores combinações são justamente aquelas compostas pelos mesmos indicadores apresentados como os mais sensíveis na análise de sensibilidade. Para ser mais explícito, as melhores combinações de indicadores climáticos consideraram principalmente a temperatura de bulbo seco (DBTmean), temperatura do ponto de orvalho (DPTmean), umidade relativa (RHmean) e graus-dia de aquecimento usando 14 °C como temperatura base (HDD14). Portanto, os resultados aqui apresentados corroboram a ideia de que uma

análise de sensibilidade é uma ferramenta muito útil para selecionar os indicadores climáticos que serão utilizados no processo de agrupamento.

3.3.3 Zoneamento usando árvore de decisão

Ao contrário dos dois métodos de zoneamento anteriores, o método da árvore de decisão pode definir um zoneamento baseado no clima, mas que também considera o desempenho do edifício. Para isso, foi utilizado o mesmo processo de normalização dos indicadores seguido no método baseado no desempenho do edifício. Para dados climáticos, todos os sete indicadores climáticos foram utilizados sem normalização. Para executar eficazmente o processo de agrupamento, o método da árvore de decisão utiliza no treinamento os indicadores climáticos como entradas e os indicadores normalizados de desempenho do edifício como saídas. Para ser mais claro, as saídas são os KPIs (PHiFT, PHsFT, CgTa e CgTr), PHRi30 e PHRs70. Foi aplicado o método árvore de decisão, considerando 6 a 12 grupos climáticos (folhas). Seguindo cada procedimento detalhado aqui, calculamos os resultados das métricas Silhouette e Calinski-Harabasz para as variantes que seguem o método de Árvores de Decisão; veja a Figura 6a.

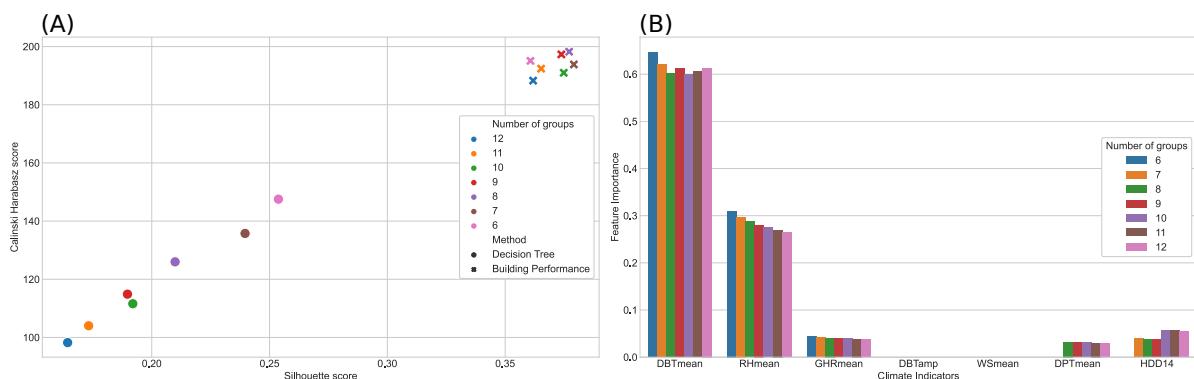


Figura 6 – Zoneamento baseado na árvore de decisão: Dispersão do Silhouette Score e Calinski-Harabasz Score do melhor zoneamento para cada número de grupos (A) e importância dos indicadores climáticos (B).

Os resultados do Silhouette e do Calinski-Harabasz (Figura 6a) mostram que as variantes com poucas zonas climáticas apresentaram resultados mais acurados, da mesma forma como ocorreu no método baseado no clima. Um ponto a ser enfatizado é que uma proposta com poucas zonas produz um zoneamento com grande dispersão dentro de cada grupo climático. Quando uma zona climática específica apresenta grande dispersão, há um agrupamento de climas muito diferentes numa mesma zona climática. Por outro lado, quando o número de zonas climáticas é grande, a dispersão tende a ser menor.

A análise de importância realizada pelo método de Árvores de Decisão (Figura 6b) revelou que a temperatura de bulbo seco (DBTmean) continua a ser o indicador

mais importante, seguida da umidade relativa (RHmean) e da temperatura de ponto de orvalho (DPTmean). Além disso, os graus-dia de aquecimento com base em 14°C (HDD14) foi considerado menos importante do que RHmean, embora tenha apresentado uma correlação extremamente alta com os indicadores de desempenho de PHiFT e CgTa, com valores próximos a 1. Isso ocorre porque todos os indicadores de desempenho utilizados como saída foram considerados simultaneamente, onde uma grande parte das localidades apresenta demanda de resfriamento.

3.4 ZONEAMENTO BIOCLIMÁTICO FINAL PARA O BRASIL

Essa seção trata do desenvolvimento e validação de uma proposta de zoneamento bioclimático, o qual para propósitos práticos foi estabelecido atendendo aos seguintes requisitos: (1) O zoneamento bioclimático não deve ter um número excessivo de zonas; (2) a dispersão em cada zona climática deve ser semelhante; (3) separar as zonas mais frias; (4) diferenciar zonas secas e úmidas; (5) o método de zoneamento deve ser de fácil compreensão; e (6) deve estar alinhado com normativas nacionais existentes.

O agrupamento dos climas foi realizado mediante o método de aprendizado de máquina supervisionado conhecido como árvore de decisão. Esse método permite considerar indicadores climáticos e desempenho do edifício simultaneamente no desenvolvimento do zoneamento bioclimático. É um método de fácil compreensão e muito adequado para uso prático. O método usa indicadores climáticos como entradas do modelo e indicadores de desempenho do edifício como saídas do modelo.

Optamos por utilizar apenas a temperatura de bulbo seco (DBTmean) e a umidade relativa (RHmean) por serem as variáveis mais sensíveis observadas nas análises de sensibilidade. Como saída do modelo usou-se a carga térmica de aquecimento (CgTa) e resfriamento (CgTr), percentual de horas ocupadas acima do limite máximo (PHsFT) e abaixo do mínimo (PHiFT) referente à temperatura operativa, percentual de horas ocupadas onde a umidade relativa interna está acima de 70% (PHRs70) e abaixo de 30% (PHRi30). Antes de realizar o treinamento da árvore de decisão, foi realizada a normalização das saídas do modelo com valores entre 0 a 1.

Como esse método de zoneamento é principalmente direcionado para o desempenho térmico de edifícios, para evitar um número excessivo de zonas, decidiu-se que o número de zonas térmicas não deveria ser superior a oito. Esse é exatamente o número de zonas do zoneamento bioclimático da NBR 15220-3 publicado em 2005. Assim, as divisões de acordo com o nível de umidade da zona não entram neste valor. Para estabelecer um valor mínimo de zonas, foi definido que a dispersão do indicador de performance descrito na NBR 15575 como o percentual de horas ocupadas onde a temperatura operativa interna é superior ao limite máximo (PHsFT) deveria ser próxima de 20–25%. Foi verificado que o treinamento de árvores de decisão com 10

Tabela 1 – Critérios de classificação do zoneamento bioclimático final para o Brasil.

Zones	Description	Criteria 1	Criteria 2
1R	Very cold zone with severe winter	DBTmean <18.8 °C	Note 1
1M	Very cold zone with moderate winter		Criteria 2 of 1R must be false
2R	Cold zone with severe winter	$18.8^{\circ}\text{C} \leq \text{DBTmean} < 20.9^{\circ}\text{C}$	Note 2
2M	Cold zone with moderate winter		Criteria 2 of 2R must be false
3A	Mixed and humid zone	$20.9^{\circ}\text{C} \leq \text{DBTmean} < 22.9^{\circ}\text{C}$	RHmean >73.2%
3B	Mixed and dry zone		RHmean \leq 73.2%
4A	Slightly hot and humid zone	$22.9^{\circ}\text{C} \leq \text{DBTmean} < 25^{\circ}\text{C}$	RHmean >70.3%
4B	Slightly hot and dry zone		RHmean \leq 70.3%
5A	Hot and humid zone	$25^{\circ}\text{C} \leq \text{DBTmean} < 27^{\circ}\text{C}$	RHmean >68.7%
5B	Hot and dry zone		RHmean \leq 68.7%
6A	Very hot and humid zone	$27^{\circ}\text{C} \leq \text{DBTmean}$	RHmean >66.8%
6B	Very hot and dry zone		RHmean \leq 66.8%

Note 1: (-30° < Latitude <-27.7° and DBTmean <17 °C) or (Latitude \leq -30° and DBTmean <18.5 °C)

Note 2: Latitude \leq -24.2° and Longitude \leq -50.3°

zonas climáticas produziu uma dispersão próxima do que era anteriormente desejável.

Os critérios obtidos pelo método da árvore de decisão são apresentados na Tabela 1. Para classificar cada local, primeiro é necessário separar os climas de acordo com a temperatura média anual de bulbo seco (DBTmean), em números que variam de 1 a 6. Esse agrupamento preliminar já separa muito bem os climas de acordo com o desempenho térmico do edifício. Além da separação de acordo com o desempenho térmico, foi necessária a separação das zonas 3 a 6 de acordo com a umidade relativa média anual (RHmean), atribuindo a letra "A" quando a RHmean estiver acima do limite de umidade relativa e "B" quando estiver abaixo. Com esse critério foi possível separar as regiões litorânea e amazônica, mais úmidas, do centro do território brasileiro, mais seco.

3.4.1 Comparação com outros métodos de classificação climática

Para que um novo zoneamento bioclimático seja justificável, ele deve ser melhor que os demais zoneamentos climáticos existentes, que aqui são representados pela NBR 15220, Köppen-Geiger e ASHRAE 169. Para avaliar o desempenho desses métodos, foram calculadas duas métricas de avaliação de cluster (Silhouette e Calinski-Harabasz), considerando os indicadores de desempenho de quatro diferentes tipologias de edifícios. Estas tipologias representam edifícios comerciais e residenciais com alto (*target building*) e baixo desempenho térmico (*reference building*), o que permite verificar o desempenho dos métodos de zoneamento em diferentes tipologias. Para facilitar a visualização dos dois resultados apresentados na Figura 7, essas métricas de desempenho de zoneamento são normalizadas com valores entre 0 e 1, onde o melhor desempenho ocorre quando os métodos estão mais próximos de 1.

Os resultados mostram que a proposta final do zoneamento bioclimático, representada pela cor azul, apresenta o melhor desempenho para os edifícios de escritórios e edifícios residenciais. Embora o Silhouette mostre que o atual método de zoneamento da NBR 15220 apresenta melhor desempenho de acordo com a tipologia de

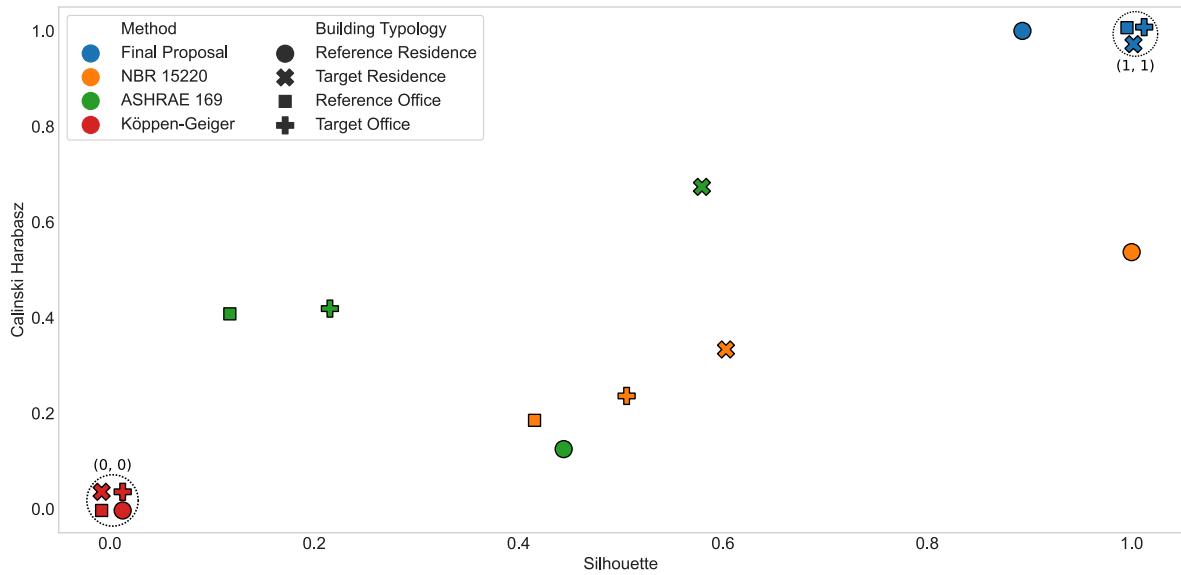


Figura 7 – Avaliação do desempenho de métodos de zoneamento climático existentes e da proposta final de zoneamento bioclimático segundo a métrica Silhouette e Calinski-Harabasz.

referência de edificação residencial, para Calinski-Harabasz o melhor resultado é o da proposta final. Assim, isso indica que o comportamento dos indicadores de desempenho é melhor compreendido pelo método proposto. Através dessa análise, constatamos que o Köppen-Geiger apresentou os piores resultados de desempenho em todas as tipologias de edifícios.

3.5 INTERPOLAÇÃO DOS DADOS CLIMÁTICOS PARA TODOS OS MUNICÍPIOS

Como foram selecionados apenas 298 arquivos climáticos de boa qualidade para executar a simulação do desempenho das edificações e desenvolver os critérios de zoneamento bioclimático, é necessário utilizar algum mecanismo para classificar os demais municípios brasileiros que não possuem arquivos climáticos de boa qualidade. É possível observar uma série de métodos que poderiam ajudar na classificação dos 5.570 municípios brasileiros. Existem métodos de interpolação que estão presentes em sistemas de geoprocessamento, como *Inverse Distance Weighted* (IDW), *Triangulated Irregular Network* (TIN) e Krigagem. Porém, é possível observar na literatura métodos que permitem um maior nível de detalhe e precisão, como mapas auto-organizados (SOM) e redes neurais artificiais (RNA ou ANN).

Como os métodos de zoneamento climático geralmente consideram indicadores climáticos para classificar cada local, uma possibilidade é utilizar bancos de dados climáticos como NASA-POWER, CRU ou ERA5. Porém, para verificar a qualidade dessas bases de dados e selecionar uma, elas deverão passar por um processo de validação considerando o contexto brasileiro. Para competir com a precisão observada

em cada uma dessas bases de dados, metamodelos foram treinados por meio de redes neurais artificiais para prever indicadores climáticos para cada município brasileiro. Apenas a temperatura média anual de bulbo seco (DBTmean), umidade relativa (RHmean) e graus-dia de aquecimento usando 14 °C como temperatura base (HDD14) foram treinados, uma vez que são os principais indicadores climáticos observados na análise de sensibilidade.

3.5.1 Metamodelagem e comparação com outros bancos de dados climáticos

Esta seção apresenta o método utilizado para desenvolver e validar três metamodelos climáticos. As saídas dos metamodelos são DBTmean, RHmean e HDD14. As entradas para a DBTmean são latitude, longitude, altitude e as interpolações da DBTmean, RHmean e GHRmean. Essas entradas interpoladas são os valores que seriam atribuídos a um determinado local via interpolação se seu arquivo climático não existisse no banco de dados. Essas interpolações foram realizadas utilizando o método *Inverse Distance Weighted* (IDW), considerando pesos de 2, 3, 4 e 5. No metamodelo de umidade relativa, a temperatura média anual de bulbo seco previamente prevista pelo metamodelo substituiu a temperatura interpolada. Para o HDD14 foram utilizadas as mesmas entradas do metamodelo RHmean, bem como os valores interpolados do HDD14 considerando os mesmos pesos mencionados anteriormente. Para evitar *overfitting*, está sendo utilizada uma arquitetura enxuta com 30 neurônios, e o treinamento é realizado considerando o método de validação cruzada conhecido como *K-Fold* com 10 partes.

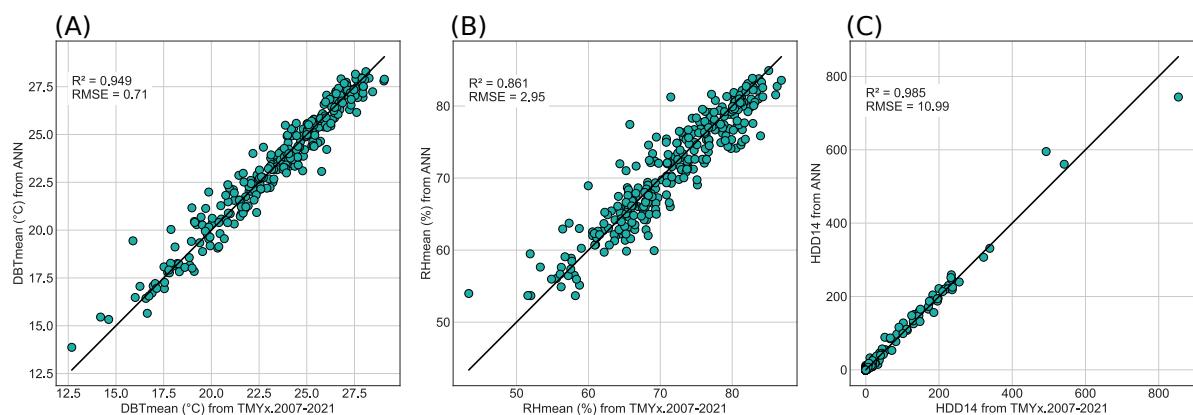


Figura 8 – Validação dos resultados do metamodelo de DBTmean (A), RHmean (B), HDD14 (C).

Os resultados mostram que o metamodelo de temperatura de bulbo seco possui alta acurácia ao ser comparado com os valores médios do TMYx.2007-2021. Seu coeficiente de determinação (R^2) foi de 0,949, com a raiz do erro quadrático médio (RMSE) de 0,71 °C. O metamodelo de umidade relativa tem uma acurácia um pouco menor, com R^2 de 0,861 e RMSE de 2,95%. O metamodelo de HDD14 apresentou os

melhores resultados, com R^2 de 0,985 e RMSE de 10,99. Esses valores são suficientemente satisfatórios para serem utilizados na classificação dos municípios brasileiros utilizando o zoneamento bioclimático proposto neste estudo. Contudo, para verificar se estes resultados são adequados, na sequência há uma análise da acurácia de outras bases de dados climáticos. Como as bases de dados avaliadas não possuem dados HDD14, apenas os metamodelos DBTmean e RHmean serão comparados com outras bases de dados climáticos existentes (Tabela 2).

Tabela 2 – Análise da acurácia dos dados do NASA-POWER, ERA5-Land e CRU em comparação com os dados do TMYx.2007-2021.

Variable	Source	R^2	RMSE	MAE	MAX.ERROR
DBTmean (°C)	ANN	0.949	0.71	0.52	3.55
	ERA5-Land	0.960	0.63	0.47	2.46
	NASA-POWER	0.876	1.11	0.84	4.45
	CRU	0.851	1.22	0.93	4.92
RHmean (%)	ANN	0.861	2.95	2.20	11.68
	ERA5-Land	0.695	4.36	3.30	16.08
	NASA-POWER	0.643	4.70	3.67	18.73

Observando esses resultados (Tabela 2), é possível perceber que o ERA5-Land possui valores muito semelhantes ao metamodelo de temperatura de bulbo seco. Isso indica que, para a classificação final dos municípios brasileiros, a temperatura considerada pode ser proveniente do metamodelo ou mesmo do ERA5-Land, com pouca diferença na acurácia dos dados. Com esses resultados, o ERA5-Land superou ligeiramente o metamodelo treinado com 298 arquivos climáticos, mas quando o treinamento do metamodelo ocorreu com todos os 577 arquivos climáticos, os resultados médios do metamodelo de DBTmean foram melhores do que o ERA5-Land. Isso mostra que quanto maior o número de arquivos climáticos utilizados no treinamento, melhor será o desempenho do metamodelo desenvolvido.

3.5.2 Desenvolvimento do mapa do zoneamento bioclimático

Para classificar os 5.570 municípios brasileiros, utilizou-se o ERA5-Land para temperatura média anual de bulbo seco (DBTmean) e o metamodelo para umidade relativa média anual (RHmean). Posteriormente, cada território municipal foi identificado pela cor correspondente à sua zona bioclimática utilizando o software QGIS. Para os municípios que possuem um ou mais TMYs válidos contidos em seu território, foi utilizada a classificação estabelecida por esses arquivos. Quando os TMYs de um município possuem classificações diferentes, estabeleceu-se que a classificação climática final que irá constar no mapa será exatamente aquela que aparece com maior frequência nos TMYs daquele município. Se as duas frequências mais altas forem iguais, a classificação climática adotada será a mesma obtida usando o ERA5-Land para DBTmean e o metamodelo para RHmean. Desta forma, foi possível verificar que: (1) as zonas mais frias se encontram mais a sul e em regiões de elevada altitude;

(2) as zonas mais quentes ficam mais ao norte; e (3) as áreas mais úmidas estão predominantemente na região amazônica ou próximas à costa brasileira.

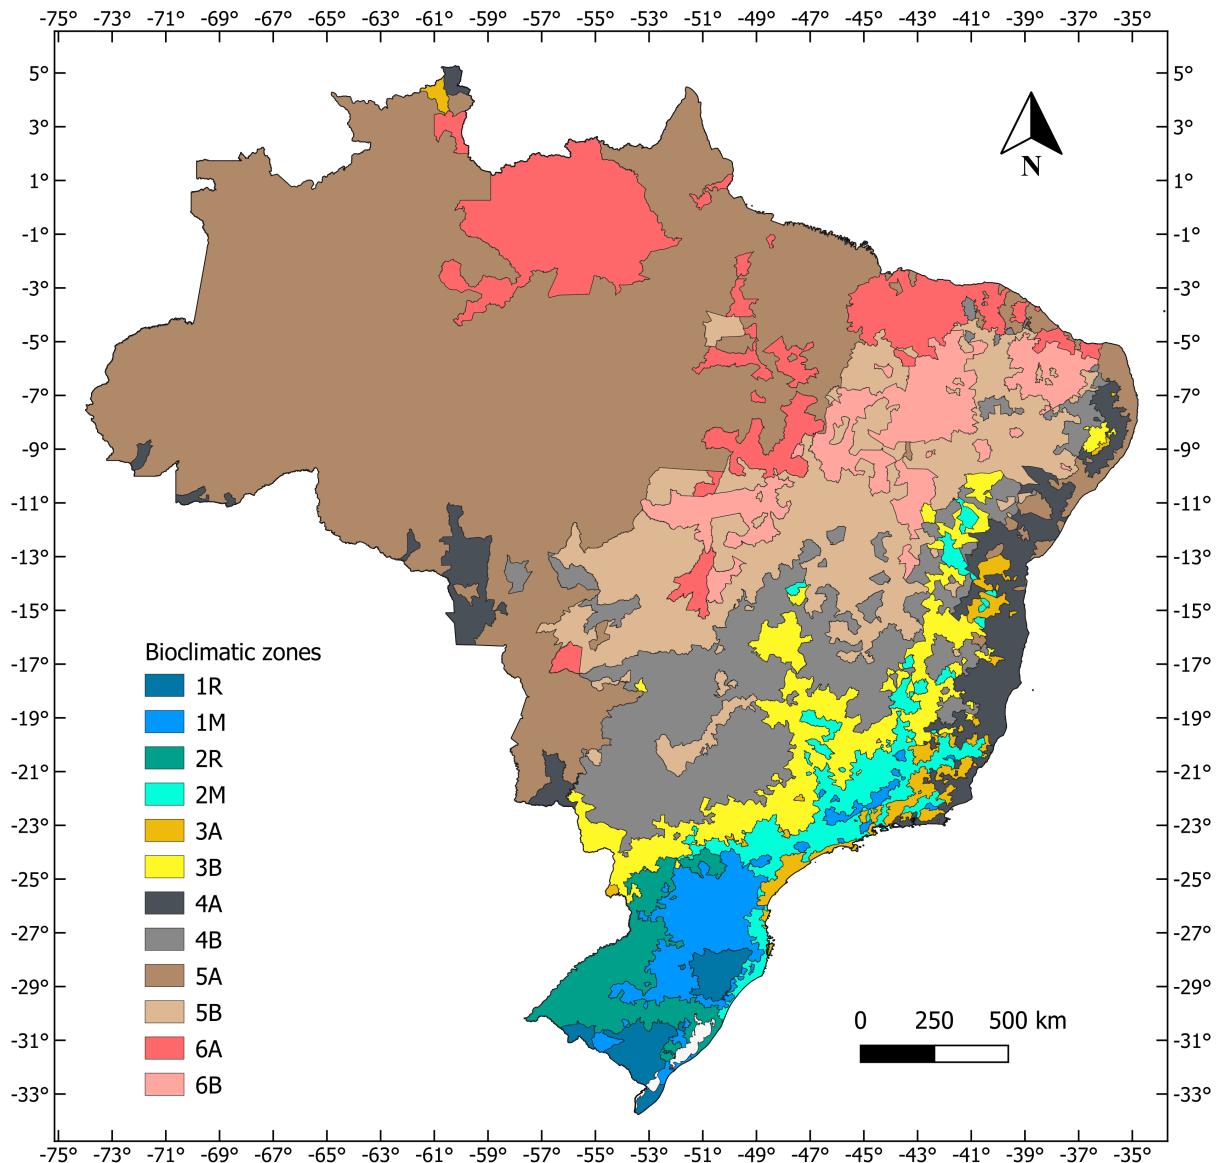


Figura 9 – Mapa da proposta final de zoneamento bioclimático brasileiro.

3.6 CONCLUSÕES

As principais conclusões obtidas dos resultados são:

- A base de dados climáticos TMYx.2007-2021 foi a mais confiável para ser usada na simulação computacional, superando outras versões do TMYx e a base de dados do INMET.
- Os indicadores climáticos mais sensíveis (DBTmean, RHmean e HDD14) são normalmente os mesmos para todas as tipologias. A consideração desses indi-

cadores climáticos em um método de classificação estabelece um sistema de zoneamento de alto desempenho.

- DBTmean tem alta correlação com a carga térmica de resfriamento (CgTr) e o PHsFT. O HDD14 possui alta correlação com a carga térmica de aquecimento (CgTa) e o PHiFT.
- A umidade relativa média anual (RHmean) apresentou a maior correlação com os indicadores de desempenho relacionados à umidade (PHRi30 e PHRs70). Este indicador de umidade climática necessita de melhorias devido aos seus baixos valores de correlação (aproximadamente 60%), embora ainda esteja dentro de um intervalo aceitável.
- Desenvolver um método de zoneamento baseado apenas no desempenho térmico coloca os biomas Amazônia e Caatinga, que são muito distintos, na mesma zona. Por esta razão, foi importante incluir indicadores de desempenho dos edifícios relacionados com a umidade.
- O método baseado em desempenho teve melhores pontuações porque usou os mesmos dados para agrupamento e validação. A árvore de decisão e o K-means baseada no clima produzem os melhores resultados quando a validação foi realizada usando indicadores climáticos. Assim, a consideração direta do clima é mais eficaz do que um método de zoneamento baseado no desempenho para a caracterização climática.
- O zoneamento bioclimático final provou ser mais preciso do que os zoneamentos climáticos existentes quando validado para quatro tipologias de edifícios e duas métricas de desempenho de agrupamento.
- Para classificar os municípios brasileiros sem estações meteorológicas, foram treinadas redes neurais artificiais do DBTmean, RHmean e HDD14 que se mostraram muito precisas, mas o ERA5-Land também apresentou excelentes resultados para a DBTmean.

4 ANÁLISE DE INCERTEZA

Esse capítulo é um resumo expandido do artigo presente no Apêndice B intitulado "*The impact of climate data uncertainty on bioclimatic zoning for building design*". Esse artigo foi submetido na revista *Building and Environment* em Julho de 2024.

4.1 MÉTODO

Esta seção apresenta os métodos utilizados para investigar o impacto da incerteza no zoneamento bioclimático desenvolvido para o Brasil. Várias fontes de incerteza foram avaliadas. As fontes de incerteza são: (1) acurácia da base de dados, (2) micro-clima e (3) clima futuro.

4.1.1 Avaliando a acurácia do banco de dados

A acurácia da base de dados climáticos é a primeira fonte de incerteza avaliada neste trabalho. Para isso, foram considerados os dados climáticos medidos nas estações meteorológicas que deram origem aos TMYx.2007-2021 como valores mais acurados quanto ao comportamento real. Portanto, a incerteza nos equipamentos de medição foi desconsiderada como uma análise possível, visto os dados disponíveis para tal estudo. Com base nessa premissa, foram realizadas duas análises quanto à acurácia dos bancos de dados: (1) uma comparação entre os dados de temperatura de bulbo seco (ERA5-Land) e umidade relativa (ANN) com dados obtidos do TMYs, e (2) um potencial erro na classificação bioclimática final dos municípios sem TMY válido.

4.1.1.1 Incerteza relacionada à temperatura e umidade relativa

O zoneamento bioclimático avaliado neste trabalho tem a temperatura de bulbo seco e a umidade relativa como principais indicadores climáticos para a classificação de cada município. Portanto, a incerteza na acurácia destes indicadores será previamente analisada. Para isso foram calculados os valores médios anuais de ambos os indicadores climáticos (DBTmean e RHmean). Este cálculo ocorreu para as bases de dados utilizadas na elaboração do zoneamento bioclimático (ERA5-Land, ANN e TMY). Posteriormente, foram calculadas diferenças em relação ao TMY para DBTmean e RHmean. Utilizando o software QGIS, essas diferenças foram interpoladas através do método de interpolação *Inverse Distance Weighted* (IDW) com peso 2 e apresentadas em um mapa com o objetivo de compreender a distribuição espacial deste erro.

4.1.1.2 O impacto da acurácia do banco de dados na classificação climática

Esta seção avalia como a acurácia das bases de dados climáticos de alta resolução espacial pode estar influenciando a classificação bioclimática final dos municípios

brasileiros (5570). Para isso, a incerteza apresentada na forma de RMSE (MACHADO *et al.*, 2024) para a temperatura média anual de bulbo seco (ERA5-Land) e umidade relativa (ANN) foi utilizada como desvio padrão para gerar uma amostra aleatória de 10 mil casos, para cada município brasileiro, com distribuição normal, usando o módulo Numpy do Python. Essa amostra apresenta variações na temperatura e umidade devido à incerteza em seu real valor. Para a temperatura média anual de bulbo seco o RMSE foi de 0,63 °C e para a umidade relativa média anual o RMSE foi de 2,95%. Cada caso desta amostra foi classificado de acordo com o zoneamento bioclimático. Por fim, foi calculado o percentual de casos em cada zona bioclimática.

4.1.2 Avaliando o microclima

Os climas locais ou microclimas urbanos e rurais estabelecem comportamentos climáticos específicos que podem diferir consideravelmente entre si. Por isso, entender como isso pode promover mudanças na classificação bioclimática final é algo muito importante a ser analisado neste trabalho. Dependendo da localização do edifício, pode haver o efeito de ilha de calor urbano ou mesmo a ilha de frescor. Quando a área circundante tem muita vegetação ou grandes massas de água próximas, esses locais podem sofrer um aumento significativo na umidade relativa local. Neste contexto, duas ferramentas surgem como muito úteis para a análise microclimática: *Local Climate Zones* (LCZs) e *Urban Weather Generator* (UWG). Assim, nesta seção foram realizadas duas análises sobre o impacto do microclima em uma classificação climática: (1) foi examinado o número de zonas climáticas no território de cada município usando dados climáticos detalhados, e (2) posteriormente foi analisado o microclima em vários contextos urbanos usando modelagem microclimática e dados medidos.

4.1.2.1 Incerteza sobre o clima local usando dados climáticos de alta resolução espacial

Dados de alta resolução espacial são avaliados para entender sua variação dentro do território de cada município brasileiro, permitindo entender o quão representativo cada dado pode ser. Idealmente, dentro do território de um município, deveria existir apenas um tipo de zona bioclimática, mas existe a possibilidade que existam mais. Usando dados do ERA5-Land para temperatura média anual de bulbo seco e uma rede neural artificial (ANN) para umidade relativa, 70.841 locais foram classificados de acordo com o zoneamento bioclimático. Estas localidades foram estabelecidas de acordo com a distribuição espacial do ERA5-Land. Foram consideradas apenas localidades dentro do território brasileiro. A altitude considerada como entrada na predição da ANN foi obtida utilizando o *Global 30 Arc-Second Elevation* (GTOPO30) (WEBGIS, 2009), que é um modelo digital de elevação (DEM) com resolução espacial de aproximadamente 900 metros. O último procedimento foi selecionar cada um dos 5.570

Tabela 3 – Valores mínimos e máximos das entradas do UWG usados na calibração.

Name	Minimum	Maximum
Average Building Height (m) - bldHeight	3	10
Urban area vertical to horizontal ratio - verToHor	0.5	2
Fraction of HVAC waste heat set to the street - h_mix	0	1
Road Albedo - albRoad	0.12	0.25
Non-building sensible heat at street level (W/m ²) - sensAnth	0	25
Tree Cover - treeCover	0.01	0.05
Vegetation Albedo - albVeg	0.2	0.3
Roof Albedo - albRoof	0.12	0.25
Wall Albedo - albWall	0.2	0.8
Sensible heat per occupant (W) - sensOcc	81	108
Urban boundary layer height during the day (m) - h_ubl1	500	1500
Urban boundary layer height during the night (m) - h_ubl2	50	100
Inversion height (m) - h_ref	100	200

municípios brasileiros e calcular o percentual de ocorrência onde um determinado município possui climas de uma zona bioclimática ou mais. Por exemplo, um município com 20 pontos com dados climáticos em seu território poderá ter 30% desses locais em uma zona bioclimática e 70% em outra.

4.1.2.2 O impacto do microclima urbano na classificação climática

Para investigar a incerteza relativa ao microclima urbano, foi analisada a DBTmean dos TMYs dentro e fora do perímetro urbano. Esses climas também foram classificados de acordo com o zoneamento bioclimático. Os TMYs são os mesmos utilizados no desenvolvimento do zoneamento bioclimático (TMYx.2007-2021). Imagens de satélite foram utilizadas para avaliar as características de cobertura e uso da terra no entorno das estações meteorológicas, incluindo áreas urbanas, vegetação e corpos d'água. Uma dessas cidades foi selecionada para passar por um processo de calibração do UWG. Foi utilizada a classificação LCZ para estabelecer uma variedade de variáveis urbanísticas que têm impacto no clima local. Todas as variáveis envolvidas no processo de otimização/calibração estão listadas na Tabela 3. Ao incluir esses dados no processo de calibração, o clima urbano é representado com maior acurácia. As demais entradas do UWG foram apresentadas no Apêndice A do Artigo 2.

O algoritmo de otimização utilizado no processo de calibração foi o *Particle Swarm Optimization* (PSO), através do módulo pyswarms do Python. Foram avaliadas duas combinações de hiperparâmetros, uma que explora mais o espaço amostral (PSO 1) e outra que foca mais nos melhores resultados (PSO 2), Tabela 4. O componente cognitivo, conhecido como C1, representa como uma partícula é atraída para sua melhor posição pessoal. Representando a inclinação da partícula em direção a melhor posição global, C2 serve como componente social no algoritmo de otimização. O peso de inércia, denotado por W, determina o impacto da velocidade anterior de uma partícula na sua velocidade atual. Considerando 1.000 iterações e 12 partículas, 12.000 simulações UWG foram realizadas para cada combinação. Além disso, também foi realizada uma amostragem de 12 mil casos utilizando a Sequência de Sobol para

Tabela 4 – Combinações de parâmetros usados no algoritmo PSO.

Combination	C1	C2	W
PSO 1	2	2	0.9
PSO 2	0.5	0.5	0.7

competir com o algoritmo de otimização.

Na última década, muitos estudos têm discutido a ilha de calor urbano, analisando especialmente como o clima urbano se comporta em relação ao desempenho energético dos edifícios. Para isso, os pesquisadores têm utilizado modelos que permitem calcular o comportamento do clima urbano considerando uma série de parâmetros urbanos, como é o caso do *Urban Weather Generator* (UWG). Portanto, para avaliar a incerteza quanto ao microclima urbano, com base no modelo calibrado, alguns contextos urbanos (Apêndice B do Artigo 2) serão simulados no UWG e posteriormente analisados. Estes contextos urbanos foram baseados na *Local Climate Zones* (LCZ) estabelecida por Stewart e Oke (2012). Aqui se optou por avaliar contextos urbanos densos e abertos com edifícios altos, médios e baixos. Somente os contextos urbanos abertos possuem vegetação, representada por gramas e árvores. O calor antropogênico também foi estabelecido com base neste mesmo estudo e foi fixado de acordo com o nível de adensamento dos edifícios. Quanto mais denso for, maior será o calor antropogênico estabelecido.

4.1.3 Avaliando as mudanças climáticas

No que diz respeito às mudanças climáticas, nesta fase, é essencial compreender as técnicas utilizadas para determinar estes climas futuros. Os modelos climáticos utilizados para prever as condições futuras variam em escala e complexidade. Certos modelos simulam o clima futuro em escala global e são chamados de Modelos Climáticos Globais, Modelos de Circulação Geral ou Modelos de Circulação Global (GCMs), que consideram interações complexas entre a atmosfera, os oceanos, a superfície terrestre e as camadas de gelo (NIK, 2016). Outros modelos têm enfoque regional, simulando o comportamento de regiões geográficas específicas, o que é definido como Modelos Climáticos Regionais (RCMs). RCMs são usados como método de *downscaling* (ZOU *et al.*, 2023). Em geral, os RCMs utilizam os GCMs como condições de contorno, estabelecendo maior resolução espacial e temporal (ABOLHASSANI *et al.*, 2023). Esses modelos consideram diferentes cenários de emissões de gases do efeito estufa, representando caminhos possíveis para o desenvolvimento socioeconômico futuro e esforços de mitigação (BAMDAD *et al.*, 2021). Os cenários de emissões são descritos como Caminhos de Concentração Representativos (RCPs), que vão desde um aumento substancial nas emissões (RCP8.5) até uma diminuição drástica (RCP2.6), resultando numa série de potenciais climas futuros (ZOU *et al.*, 2023).

Como existem diversos modelos e cenários de emissões de poluentes, o clima

futuro simulado poderá apresentar comportamentos distintos. Neste sentido, é importante compreender que o clima futuro simulado não expressa uma certeza do que acontecerá ao clima, mas uma indicação do que poderá acontecer no futuro se o nível de impacto ambiental for aumentado, reduzido ou mantido. Dada a impossibilidade de prever o futuro com precisão, existe uma grande incerteza sobre qual modelo e cenário está mais próximo do comportamento climático futuro. Por esse motivo, nesta subseção serão realizadas duas análises: (1) o comportamento dos modelos e cenários (modelagem) em termos de temperatura de bulbo seco e umidade relativa; (2) o impacto das mudanças climáticas na classificação climática das cidades brasileiras.

4.1.3.1 Incerteza sobre a modelagem do clima futuro

Para avaliar as mudanças climáticas estamos utilizando arquivos meteorológicos desenvolvidos por Bracht *et al.* (2024) para todas as capitais do Brasil. Esses arquivos climáticos consideram dois cenários de emissões (RCP2.6 e RCP8.5), três modelos GCMs (HadGEM2, MPI-ESM e NorESM1) e dois modelos RCMs (RegCM e REMO). Para criar esses arquivos, os pesquisadores usaram a mesma metodologia usada no IEA EBC Annex 80. Para cada arquivo climático, a temperatura média anual de bulbo seco e a umidade relativa média anual foram analisadas. Ao realizar uma análise exploratória desses dados será possível estabelecer as capitais com maiores variações nos indicadores climáticos avaliados. Esta análise exploratória considerou o comportamento climático de três décadas diferentes (2010, 2050 e 2090).

4.1.3.2 Impacto do clima futuro na classificação climática

Nesse sentido, entender como uma cidade pode mudar sua classificação climática ao longo dos anos é muito interessante de ser explorado em um estudo que trata da incerteza. Este tipo de análise poderia ser realizada em relação ao comportamento climático passado, mas neste estudo avaliamos como a classificação climática pode mudar no futuro. Nessa análise Brasília foi selecionada. Entende-se que até 2050 será necessário desenvolver um novo zoneamento bioclimático, pois o método de zoneamento bioclimático utilizado como base deste artigo pode estar desatualizado. Porém, é importante entender como seria a classificação climática em três décadas diferentes.

4.2 RESULTADOS E DISCUSSÕES

Esta seção apresenta e discute os resultados relativos às diferentes fontes de incerteza consideradas, isto é: (1) a acurácia dos bancos de dados climáticos; (2) o comportamento da temperatura e da umidade de áreas rurais e urbanas; e (3) as mudanças climáticas para as décadas de 2010, 2050 e 2090. Todas as análises realizadas neste capítulo estão dentro do contexto climático brasileiro. Em particular,

é realizada uma análise profunda de várias cidades selecionadas para compreender o impacto das incertezas na classificação climática. Vale lembrar que o zoneamento climático empregado nesta pesquisa foi desenvolvido por Machado *et al.* (2024) e apresentado no capítulo 3.

4.2.1 Incertezas motivadas pela acurácia dos dados meteorológicos

A primeira fonte de incerteza analisada neste artigo refere-se à acurácia das bases de dados climáticos (ERA5-Land e ANN). Embora a acurácia das medições seja uma importante fonte de incerteza, não é fácil realizar uma análise adequada sem informações sobre calibrações e características dos equipamentos. Por este motivo, a temperatura de bulbo seco e a umidade relativa das estações meteorológicas incluídas na base de dados TMYx.2007-2021 são consideradas perfeitamente calibradas.

4.2.1.1 Incerteza associada à temperatura e umidade relativa

O zoneamento bioclimático utilizado neste estudo considerou dois principais conjuntos de dados espaciais de alta resolução (ERA5-Land e ANN) para a classificação dos municípios. No entanto, quando os municípios tinham dados medidos de estações meteorológicas (ou seja, TMYx.2007-2021), nós os utilizamos devido a sua potencial maior acurácia. Para entender o erro de considerar apenas dados espaciais de alta resolução, é realizada uma comparação com TMYs. Assim, é avaliado o erro entre os dados espaciais de alta resolução e os dados TMY. Esses valores são posteriormente interpolados para todo o Brasil. Valores negativos indicam que os TMYs possuem valores mais elevados que os dados espaciais de alta resolução, enquanto valores positivos indicam que os dados espaciais de alta resolução possuem valores mais elevados que os TMYs.

A Figura 10 mostra os resultados obtidos nesta análise para a temperatura média anual de bulbo seco (DBTmean) e umidade relativa (RHmean), que são as principais variáveis climáticas do método de zoneamento bioclimático usado.

Em relação a DBTmean, é possível observar que grande parte do território brasileiro está na faixa de -0,4 °C a 0,1 °C. Isto indica que um número considerável de TMYs apresenta valores superiores aos do ERA5-Land. Além disso, pode-se afirmar que este é o intervalo com os menores erros possíveis. Para dar uma descrição geral deste erro, pode-se dizer que a média é de -0,13 °C, com mínima de -2,46 °C, máxima de 1,95 °C e mediana de -0,11 °C. Para a umidade relativa média anual (RHmean), é possível observar que grande parte do território brasileiro está na faixa de -2,1% a 0,5%. Para dar uma descrição geral desse erro, pode-se dizer que a média é de 0,32%, com mínima de -13,75%, máxima de 8,97% e mediana de 0,29%.

Também é possível observar que a DBTmean do ERA5-Land é maior nas regiões de alta altitude da região Sul (Rio Grande do Sul e Santa Catarina) e em algumas

regiões do centro do país. Por outro lado, no Nordeste e Norte do Brasil, a tendência é que a DBTmean do ERA5-Land seja inferior ao TMYx.2007-2021.

Em relação à RHmean, o ERA5-Land superestima os valores na maioria das localidades entre as latitudes -19° e -30° . Esse mesmo comportamento é observado nas regiões Norte e Nordeste. Com esta análise é possível identificar onde essas variáveis climáticas (DBTmean e RHmean) precisam ser melhoradas. Contudo, é possível concluir que os dados são robustos o suficiente para todo o território brasileiro e, na maioria das localidades, o erro é próximo de 0.

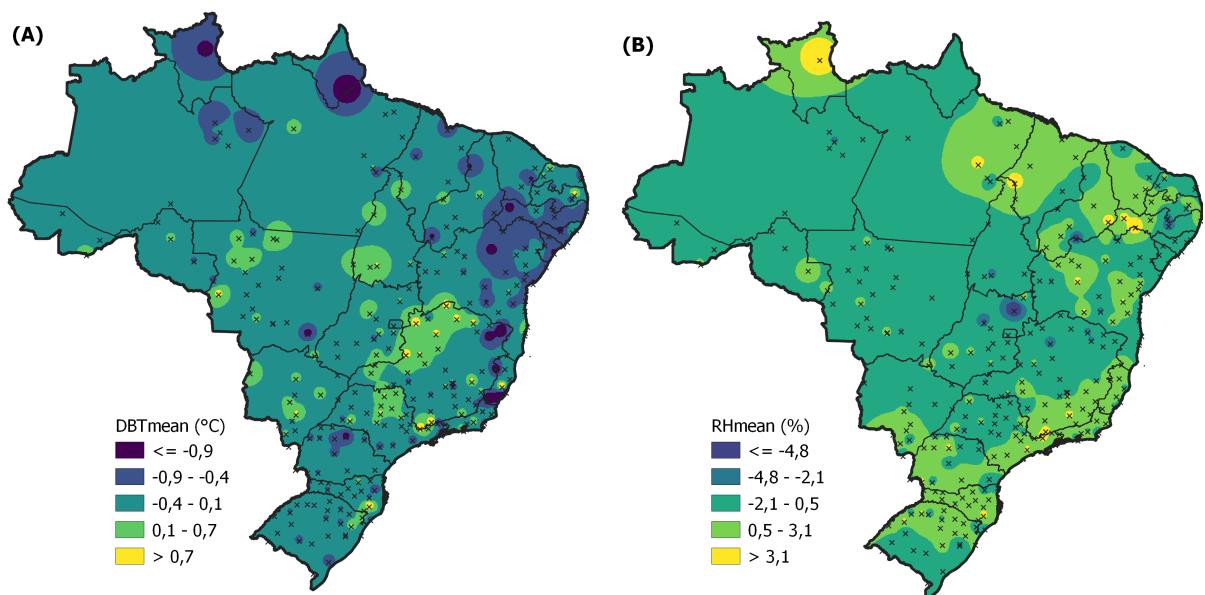


Figura 10 – Mapa de valores interpolados da diferença entre os dados espaciais de alta resolução (ERA5-Land e ANN) e os dados do TMY (TMYx.2007-2021): (A) DBTmean e (B) RHmean

4.2.1.2 O impacto da acurácia na classificação bioclimática

Para entender como a acurácia do conjunto de dados climáticos de alta resolução pode impactar a classificação bioclimática final é realizada uma amostra de distribuição normal de 10.000 casos para cada município, considerando o desvio padrão igual ao RMSE calculado para o ERA5-Land e o modelo ANN. Esta abordagem é estatisticamente consistente, uma vez que o RMSE pode ser entendido como o desvio padrão dos valores residuais. Assim, cada caso desta amostra é classificado em uma zona bioclimática, e é calculada a porcentagem relativa da frequência de ocorrência em cada zona bioclimática. Por exemplo, a Tabela 5 mostra os resultados para três localidades (Santarém, Rondonópolis e Piripiri).

Como os principais indicadores climáticos do método de zoneamento bioclimático são caracterizados pela DBTmean e RHmean, alterações podem ocorrer por incerteza em um desses indicadores ou em ambos simultaneamente. No caso de San-

Tabela 5 – Três cidades com alterações na zona bioclimática devido à incerteza na acurácia dos dados.

Municipality	DBTmean	RHmean	Zone	4B	5A	5B	6A	6B
Santarém	27,1 °C	82%	6A	-	43%	-	57%	-
Rondonópolis	26,3 °C	68%	5B	2%	35%	50%	8%	4%
Piripiri	28,6 °C	68%	6A	-	-	-	66%	34%

tarém, que anteriormente estava classificada na zona bioclimática 6A, com inclusão da incerteza, 57% dos 10 mil casos são classificados como 6A e 43% como 5A. Essa alteração ocorreu apenas devido à incerteza na DBTmean. Em Rondonópolis, a análise de incerteza indica que esta localização pode estar em cinco zonas bioclimáticas: 4B, 5A, 5B, 6A ou 6B. Nesse caso, as alterações são estabelecidas tanto pela DBTmean quanto pela RHmean. Em Piripiri, a incerteza na RHmean estabelece que é mais provável que este local esteja em zona úmida (6A) do que em zona seca (6B).

Como foi constatado na Tabela 5, quando a classificação climática é realizada de forma probabilística, o impacto da incerteza quanto aos indicadores climáticos estabelece que um determinado local poderia ser classificado em uma ou mais zonas bioclimáticas. Para compreender quantas zonas bioclimáticas poderiam existir potencialmente em cada município brasileiro, essa análise da frequência de ocorrência foi ampliada para as demais cidades. Observa-se que apenas 1,1% dos municípios apresentaram apenas uma zona bioclimática nos 10 mil casos avaliados por localidade. Para a maioria dos municípios (33,9%), o território pode ter três zonas bioclimáticas diferentes. Além disso, muitos municípios (27,88%) podem apresentar até quatro zonas diferentes, enquanto 13,59% dos municípios podem possuir até cinco zonas diferentes.

4.2.2 Impacto do microclima

Devido à existência de microclimas, os indicadores climáticos podem variar espacialmente dependendo da localização. Por exemplo, as zonas rurais apresentam temperaturas mais baixas e uma umidade relativa mais elevada do que as zonas urbanas durante as estações quentes. Para avaliar o impacto desses microclimas no zoneamento climático, são realizadas duas análises: (1) Análise de incerteza na classificação climática de dados espaciais de alta resolução dentro de cada território municipal, considerando áreas rurais e urbanas, utilizando dados do ERA5-Land e ANN. (2) Análise do impacto dos microclimas urbanos na classificação climática utilizando Anos Meteorológicos Típicos (TMYs) de estações meteorológicas, especificamente TMYx.2007-2021. Além disso, os dados climáticos urbanos são calibrados para uma cidade usando o software *Urban Weather Generator* (UWG), o algoritmo *Particle Swarm Optimization* (PSO) e amostragem através da Sequência de Sobol.

4.2.2.1 Incerteza sobre o clima local usando dados climáticos de alta resolução espacial

A temperatura do ar pode ser significativamente influenciada por vários fatores geoespaciais, como altitude e latitude. Para analisar isso, a Figura 11 apresenta os dados de temperatura média de bulbo seco (DBTmean) do banco de dados ERA5-Land para 5.570 municípios brasileiros. O eixo x representa o DBTmean, o eixo y representa a altitude e as faixas de latitude são indicadas por diferentes cores. Os resultados mostram que à medida que a latitude diminui, a temperatura do bulbo seco também diminui. Além disso, pode-se observar que à medida que a altitude aumenta, a temperatura geralmente diminui.

Devido ao tamanho relativamente pequeno de cada cidade, o efeito da latitude no zoneamento climático não é significativo dentro do domínio territorial. Por outro lado, o efeito da altitude dentro do território municipal pode influenciar fortemente o comportamento climático da temperatura de bulbo seco. Este maior foco na temperatura de bulbo seco ocorre porque a maioria dos zoneamentos climáticos consideram este indicador de alguma forma, tornando-o um dos indicadores mais importantes.

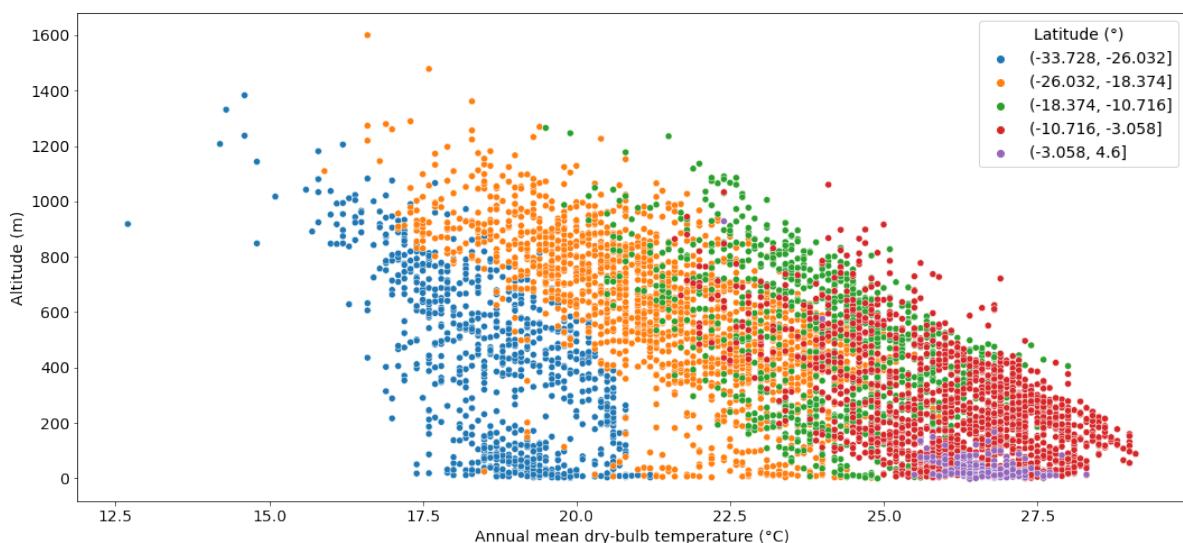


Figura 11 – Relação entre temperatura média anual de bulbo seco, altitude e latitude.

A classificação climática desenvolvida por Machado *et al.* (2024) estabelece que um único ponto dentro do município classifica todo o seu território. Portanto, não foram consideradas possíveis variações de altitude em áreas urbanas ou rurais. Para entender como essas variações podem impactar a classificação climática, observa-se a DBTmean do ERA5-Land, onde são selecionados apenas os dados contidos em cada município. A Figura 12a apresenta um histograma com a diferença de temperatura observada na DBTmean dos dados do ERA5-Land dentro de cada território municipal. São considerados aqui apenas municípios com mais de uma localidade com dados.

O desvio-padrão da DBTmean referente a cada município são observados na Figura 12b.

Os resultados indicam que a diferença na DBTmean dentro de um território municipal pode chegar a 8,66 °C, com média de 0,68 °C. Valores iguais a 0 são desconsiderados, caso contrário, seria observada uma frequência maior em amplitude igual a 0, uma vez que alguns municípios possuíam apenas um único dado de temperatura disponível em seu território. Para o desvio padrão, a média é de 0,30 °C, onde os maiores valores chegam a 2,34 °C. Embora a diferença seja em sua maioria inferior a 1 °C, isso é suficiente para alterar a classificação climática dependendo do ponto considerado. É importante destacar que dentro do território brasileiro são identificados 70.841 pontos com dados válidos obtidos por meio do ERA5-Land.

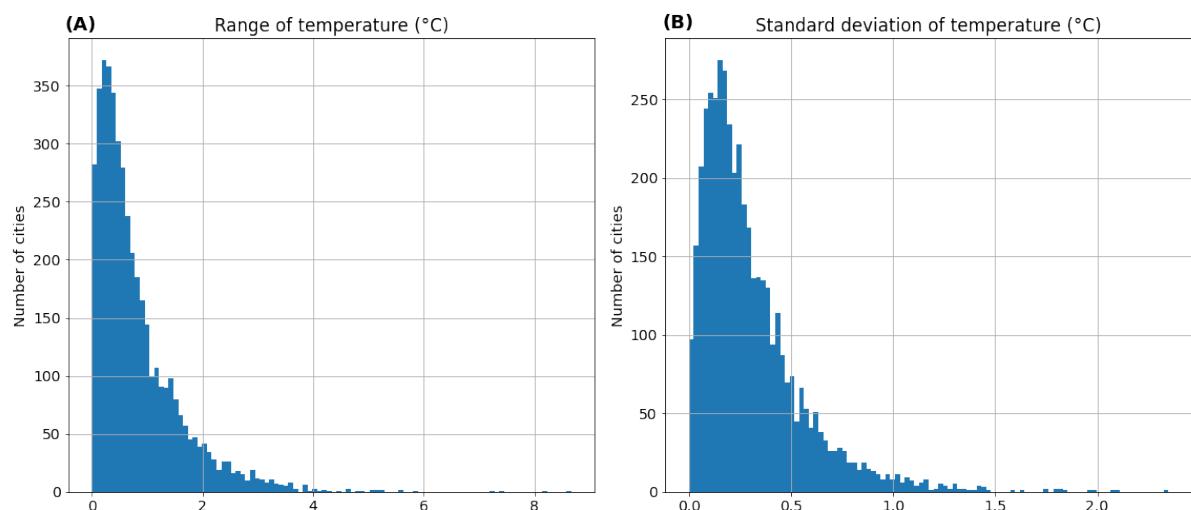


Figura 12 – Histogramas da diferença entre a temperatura média anual máxima e mínima de bulbo seco observada no território de cada município brasileiro: (A) amplitude e (B) desvio-padrão.

Como a umidade relativa média (RHmean) foi obtida utilizando um modelo de ANN em Machado *et al.* (2024), uma nova predição foi realizada para os mesmos 70.841 pontos do ERA5-Land. A altitude utilizada na entrada do modelo de ANN é obtida a partir do modelo digital de elevação GTOPO30 (WEBGIS, 2009). Outras entradas para o modelo de ANN incluem latitude, longitude, temperatura de bulbo seco, valores interpolados para umidade relativa e valores interpolados de radiação global horizontal. Estes valores interpolados são obtidos utilizando o método *Inverse Distance Weighted* (IDW) (QGIS DEVELOPMENT TEAM, 2023), e os indicadores climáticos são derivados da base de dados TMYx.2007-2021.

Para entender como as diferenças nos valores médios de DBT podem influenciar na classificação climática final, cada ponto com dados válidos foi classificado e agrupado de acordo com seu território municipal. A maioria das cidades (67,44%)

Tabela 6 – Quatro cidades com alterações na zona bioclimática devido à incerteza na análise climática local.

Municipality	Altitude Diff.	DBTmean Diff.	Zone	4B	5A	5B	6A	6B
Cuiabá	565 m	2.34 °C	5B	9%	9%	82%	-	-
Boa Vista	98 m	1.26 °C	6A	-	23%	-	77%	-
Teresina	139 m	0.55 °C	6A	-	-	-	55%	45%
Palmas	415 m	2.39 °C	6B	-	-	64%	12%	24%

possui apenas um tipo de zona climática em seu território, o que é altamente desejável para o desenvolvimento de normativas nacionais. Contudo, muitos municípios (27,48%) possuem duas zonas climáticas em seu território, o que pode ser influenciado pela sua localização, por exemplo, em regiões de transição entre duas zonas climáticas.

Nesse contexto, quatro capitais de estado são analisadas na Tabela 6. Os resultados mostram capitais com grande incerteza na classificação climática regional, pois possuem pontos em seu território que são classificados em diferentes zonas bioclimáticas. Cuiabá e Palmas são as capitais onde a diferença de altitude é maior, com 565 m e 415 m, respectivamente. Analisando a classificação de cada dado do ERA5-Land dentro dos territórios desses municípios, observa-se que Cuiabá e Palmas possuem três zonas bioclimáticas distintas, enquanto Boa Vista e Teresina são classificadas em duas zonas bioclimáticas distintas. Os percentuais de incerteza mostram que a representação regional está relativamente bem estabelecida em Cuiabá (82% dos pontos como 5B) e Boa Vista (77% dos pontos como 6A). Em Teresina, quase metade dos pontos (45% dos pontos como 6B) estão classificados em zona diferente daquela observada para um ponto mais próximo do perímetro urbano do município (6A). O caso de Palmas é o mais sensível a esta incerteza na representação regional, pois o maior percentual de pontos (64%) classifica o clima como zona 5B e apenas 24% dos pontos como zona 6B.

4.2.2.2 Impacto do microclima urbano na classificação climática

Quando analisados detalhadamente os TMYs de diversas cidades brasileiras, empregados no zoneamento bioclimático, observa-se que algumas cidades podem ter diferentes classificações climáticas dependendo da estação meteorológica considerada.

A Figura 13 analisa os valores médios de DBT para três cidades brasileiras (Manaus, Ilhéus e Marabá) da base de dados TMYx.2007-2021, representando cada zona climática com uma cor diferente. Observa-se que dependendo da estação meteorológica escolhida, a DBTmean pode fazer com que a cidade seja classificada em diferentes zonas climáticas. Isso ocorre principalmente porque as temperaturas dessas cidades estão próximas dos limites de transição do método de classificação (25°C e 27°C). Em Manaus-AM, duas estações classificam esta cidade como Zona 6 e uma se classifica como Zona 5. Marabá-PA também pode ser classificada como Zona 6 ou

Zona 5. No caso de Ilhéus-BA, o clima pode ser classificado como Zona 5 ou Zona 4.

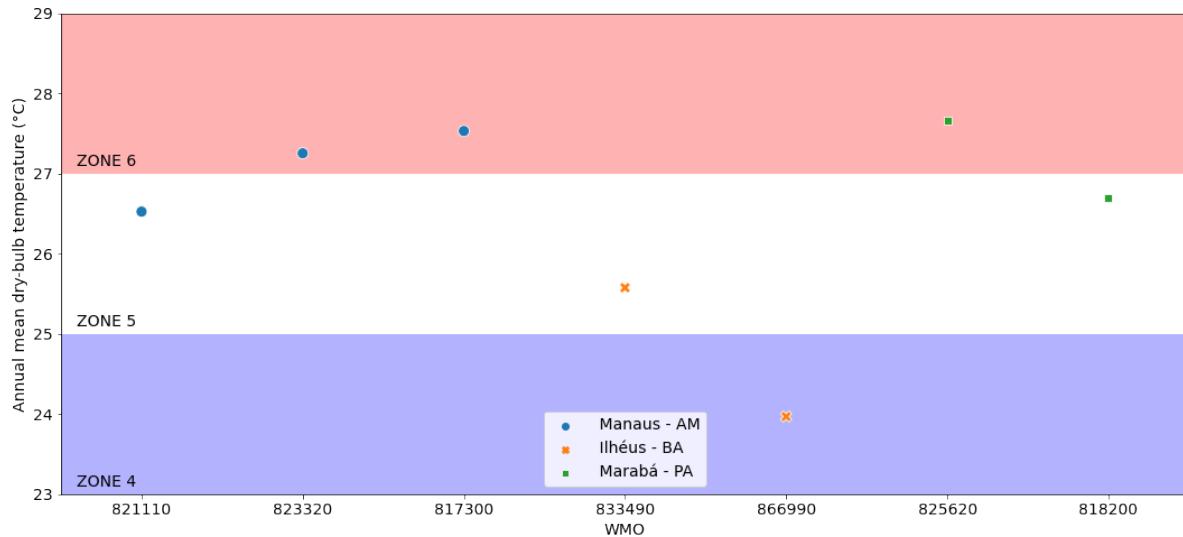


Figura 13 – Mudanças na classificação climática de três cidades devido à temperatura de bulbo seco observada em diferentes estações meteorológicas.

As características do entorno da estação meteorológica podem influenciar o comportamento climático registrado pela estação meteorológica. Portanto, quando existem diversas estações meteorológicas em uma mesma cidade, o ideal é classificar o município de acordo com a zona climática que aparece com maior frequência. A correta classificação climática do município torna-se duvidosa quando duas ou mais zonas bioclimáticas aparecem com maior frequência dentro de uma cidade. Assim, utilizar dados de reanálise e ANN pode ser uma excelente solução para classificar a cidade. Outra solução é analisar as estações meteorológicas do entorno e estabelecer, através de alguns critérios objetivos, qual estação meteorológica está mais qualificada para representar o clima daquela cidade.

As cidades analisadas possuem climas úmidos com altos índices de precipitação durante o ano, e possuem rios e mares no entorno. Por conta disso, todas as cidades são classificadas com a letra "A". Por outro lado, em Manaus duas estações meteorológicas são classificadas como 6A (uma está em um aeroporto) e outra como 5A (também em um aeroporto). O ponto a ser destacado aqui é que as estações mais próximas de regiões mais urbanizadas apresentam temperaturas mais elevadas (Zona 6) do que aquelas do aeroporto um pouco mais afastado da cidade (Zona 5). Isto mostra que o microclima estabelecido pelo entorno pode influenciar o comportamento térmico destas estações meteorológicas. O mesmo comportamento ocorre em Marabá-PA e Ilhéus-BA, onde a estação meteorológica da área urbanizada apresenta clima mais quente que as estações da área rural.

Para avaliar diferentes contextos urbanos, o software UWG é adotado para modelagem climática, e uma calibração do modelo baseada em otimização é realizada

usando o algoritmo de otimização PSO. Além disso, uma amostragem utilizando a Sequência de Sobol é implementada para comparar com a calibração anterior. Certos parâmetros do UWG são fixados com base em imagens de satélite processadas com software QGIS (ver Apêndice A do Artigo 2). Este estudo é aplicado em Ilhéus-BA, onde estão localizadas tanto uma estação meteorológica rural quanto uma mais urbanizada.

A Figura 14 mostra o histograma do RMSE da temperatura média anual de bulbo seco para a estação meteorológica rural em comparação com a estação mais urbanizada. O algoritmo PSO 1 apresenta ampla faixa de RMSE, com valores comparáveis aos obtidos pela Sequência de Sobol. Notavelmente, a configuração PSO 2 produz os melhores resultados. Isso indica que enquanto o PSO 1 explora uma gama mais ampla do espaço amostral sem focar muito nos casos ótimos, o PSO 2 visa especificamente os melhores resultados. Apesar das metodologias variadas, os resultados ótimos são semelhantes em todas as três abordagens ($1,1851^{\circ}\text{C}$ para PSO 1, $1,1836^{\circ}\text{C}$ para PSO 2 e $1,1848^{\circ}\text{C}$ para Sequência Sobol). Entre todas as simulações, o caso ótimo é produzido pelo PSO 2, com um RMSE de $1,1836^{\circ}\text{C}$, classificando a estação mais urbanizada como Zona Climática Local 6 (LCZ6).

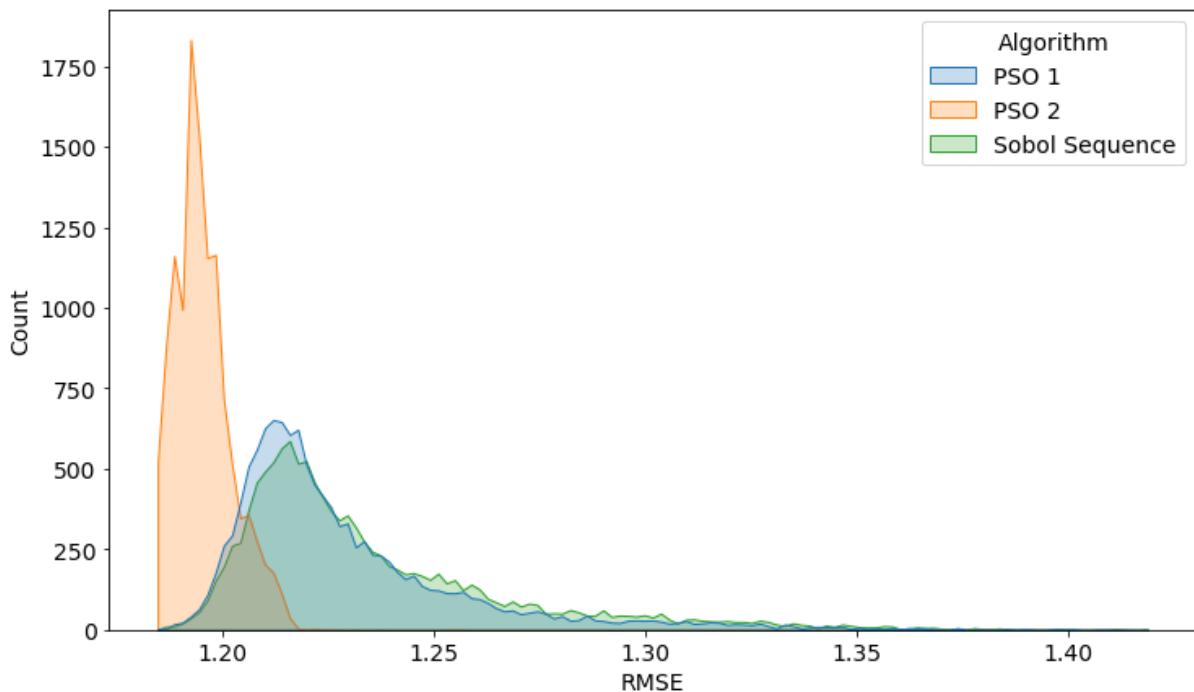


Figura 14 – Histogramas do RMSE da temperatura média anual de bulbo seco do PSO e da Sequência de Sobol.

A Figura 15 ilustra os resultados médios horários de temperatura de bulbo seco e umidade relativa para o mês de calibração (Dezembro de 2018) nos três cenários (Rural, UWG e Urbano). Estes resultados demonstram que o UWG transforma eficazmente os dados climáticos rurais em dados climáticos urbanos. A concordância entre os dados urbanos e os resultados do UWG é notável para a temperatura de bulbo seco.

No entanto, os resultados de umidade relativa são menos satisfatórios. Esta discrepância pode ser atribuída à proximidade da estação urbana ao mar, em contraste com a estação rural que fica mais no interior. O contexto real da estação meteorológica é provavelmente mais complexo do que o algoritmo do UWG, levando a imprecisões na modelagem da umidade relativa ao longo do dia.

Apesar destes desafios, a estação urbana é caracterizada com sucesso como Zona Climática Local 6 (LCZ6) através de calibração. Consequentemente, os parâmetros de entrada são ajustados para outras Zonas Climáticas Locais (LCZ1 - LCZ5), e outras simulações são realizadas usando UWG, conforme detalhado no Apêndice B do Artigo 2.

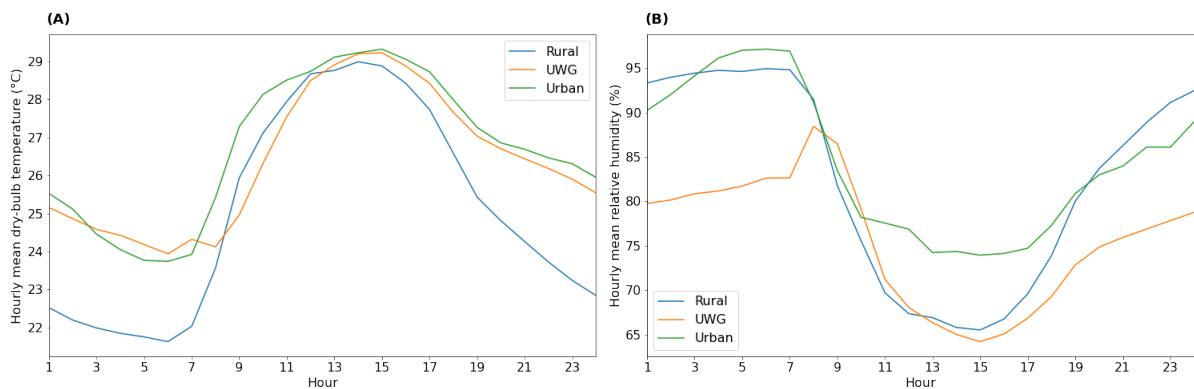


Figura 15 – Comparação dos valores médios horários de dezembro de 2018 considerando a simulação no UWG e as estações meteorológicas rurais e urbanizadas: (A) temperatura de bulbo seco e (B) umidade relativa.

A Figura 16 mostra a temperatura de bulbo seco e a umidade relativa obtidas do arquivo meteorológico para melhor compreender o comportamento higrotérmico dessas LCZs. "Maximum" representa a média das máximas diárias, "Minimum" representa a média das mínimas diárias e "Mean" representa a média anual de cada variável climática avaliada.

Os resultados indicam que temperaturas mais elevadas são observadas em ambientes urbanos mais densos. Esta tendência é consistente em todas as métricas de temperatura (máxima, média e mínima). As maiores diferenças chegam a 0,61 °C para a temperatura média, 0,49 °C para a temperatura mínima e 0,24 °C para a temperatura máxima. Por outro lado, a umidade relativa é maior em ambientes urbanos menos densos. Para a umidade relativa observa-se uma diminuição significativa, com média de aproximadamente 2,80%. Para a umidade relativa máxima, a redução fica próxima de 1,99%.

Em relação à zona bioclimática, o arquivo meteorológico base estabelece que Ilhéus-BA está na Zona Bioclimática 4A. Contudo, a classificação muda para a zona 5A em todos os contextos urbanos simulados. Isso indica que a incerteza no contexto

urbano pode fazer com que a cidade seja classificada em zona diferente daquela indicada pela estação meteorológica rural.

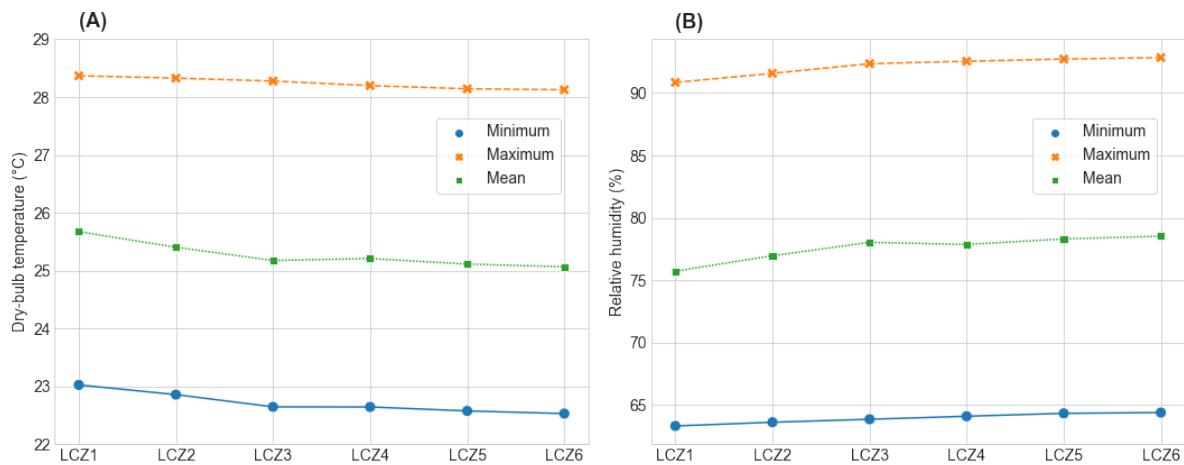


Figura 16 – Valores máximos, mínimos e médios de acordo com seis zonas climáticas locais: (A) temperatura de bulbo seco e (B) umidade relativa.

4.2.3 Impacto das mudanças climáticas

Os pesquisadores têm feito grandes esforços para analisar os climas futuros, desenvolvendo e aplicando diversos modelos e cenários, resultando em simulações numéricas que requerem elevados recursos computacionais. Embora atualmente seja possível obter os resultados destas simulações, saber qual o modelo e cenário mais apropriado para estimar os climas futuros é uma questão de considerável incerteza. Além disso, como é provável que o clima mude, espera-se também que a classificação climática mude.

4.2.3.1 Incerteza sobre a modelagem do clima futuro

O zoneamento climático é geralmente desenvolvido usando dados climáticos históricos. Embora possam estar associadas incertezas a estes dados, ainda é possível realizar uma validação numérica da base de dados climáticos. No entanto, o zoneamento climático foi concebido para ser utilizado no futuro, onde o comportamento dos climas é muito incerto. Atualmente, existem diferentes modelos disponíveis para prever climas futuros, permitindo a representação das mudanças climáticas ao longo dos anos. Nesta seção, a incerteza associada a alguns desses modelos (HadGEM2 + RegCM, MPI-ESM + RegCM, NorESM1 + RegCM, HadGEM2 + REMO, MPI-ESM + REMO, NorESM1 + REMO) (BRACHT *et al.*, 2024) para os cenários de baixas e altas emissões (RCP 2.6 e RCP 8.5) nas décadas de 2010, 2050 e 2090 são investigados, considerando as duas principais variáveis climáticas do método de classificação bio-

climática, ou seja, DBTmean e RHmean. As Figuras 17 e 18 mostram os resultados obtidos para esta análise em todas as capitais brasileiras.

Os resultados mostram que para o cenário de baixas emissões (RCP 2.6), no futuro a DBTmean (2050 e 2090) será superior à de 2010 em quase todos os modelos e capitais; veja a Figura 17a. Vale ressaltar que a temperatura em 2050 pode ser superior à de 2090 dependendo do modelo considerado. Porém, os *boxplots* destas duas décadas apresentam dispersões semelhantes e resultados quase equivalentes. Para esse cenário, as capitais apresentam dispersão média de 1,21 °C, considerando as três décadas analisadas. Porto Alegre-RS é a capital com menor dispersão de temperatura com 0,77 °C, enquanto Boa Vista-RR tem a maior dispersão com 2,22 °C.

Para o cenário de altas emissões (RCP 8.5), a dispersão da temperatura não se sobrepõe entre as três décadas; veja a Figura 17b. É evidente que com o aumento das emissões a temperatura também aumentará, principalmente com o passar do tempo, uma vez que a década de 2090 apresenta valores muito superiores aos do passado e o mesmo ocorre para a década de 2050. Embora não haja sobreposição, há uma grande dispersão entre os modelos. Além disso, esta dispersão aumenta com o tempo; ou seja, a década de 2090 é superior à década de 2050, e a década de 2050 é superior a 2010. Para este cenário, a média das capitais teve uma dispersão de 4,8 °C considerando as três décadas analisadas; Florianópolis-SC foi a capital com menor dispersão de temperatura, com 3,08 °C; e Manaus-AM foi a capital com maior dispersão, com 7,97 °C.

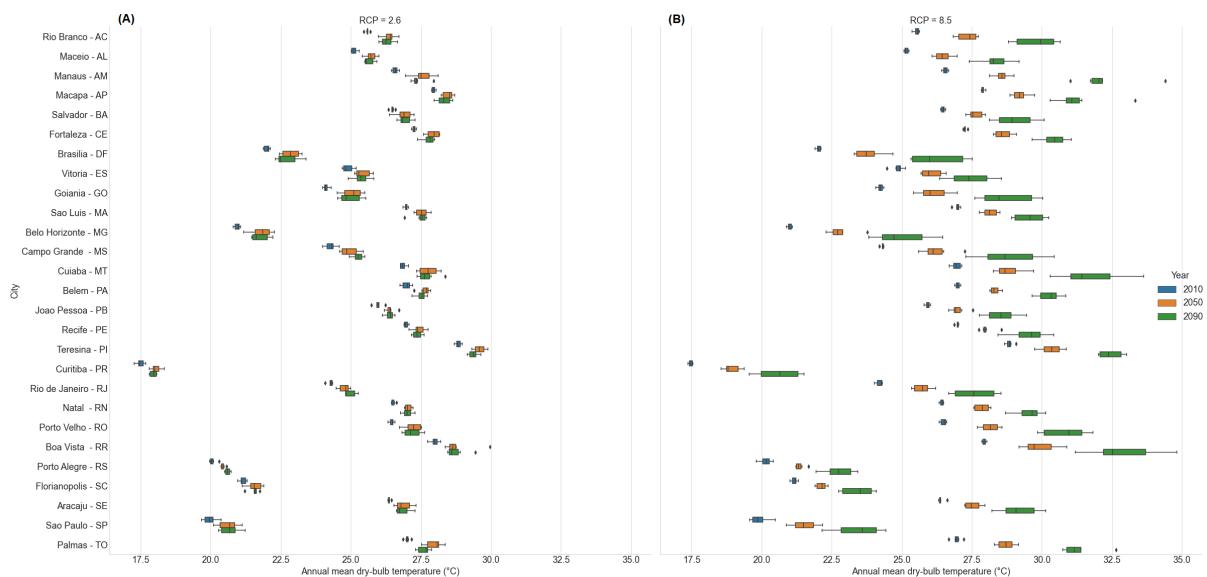


Figura 17 – DBTmean em diferentes cenários de emissões: (A) baixas emissão e (B) alta emissão.

A Figura 18a mostra os resultados para o cenário de baixas emissões (RCP 2.6) para umidade relativa. Há uma grande sobreposição na umidade relativa média

anual dos modelos entre as décadas analisadas. Em muitos casos, a sobreposição praticamente equivale os *boxplots* das três décadas, como ocorre em Recife-PE, São Luís-MA e Vitória-ES, entre outros. Comportamentos inversos também são observados, por exemplo, em Palmas-TO muitos modelos indicam que na década de 2050 será mais seco que na década de 2090, enquanto em Boa Vista-RR há um indicativo de que na década de 2090 será mais seco que na década de 2050. Para este cenário, a média das capitais apresenta uma dispersão de 3,92% considerando as três décadas analisadas; Recife-PE é a capital com menor dispersão na umidade relativa, com 1,33%; Boa Vista-RR é a capital com maior dispersão, com 10%.

Em relação ao cenário de altas emissões (RCP 8.5), a dispersão na umidade relativa mostra uma sobreposição entre as três décadas; veja a Figura 18b. Contudo, a tendência geral é que na década de 2090 a umidade relativa seja inferior à da década de 2050. Da mesma forma que no caso das temperaturas futuras, a dispersão entre os modelos aumenta ao longo do tempo para a umidade relativa. Apesar disso, também é possível observar capitais com *boxplots* muito sobrepostos, quase equivalentes, tendo baixa dispersão, como João Pessoa-PA, São Luís-MA e Vitória-ES. Para este cenário de altas emissões, a média das capitais apresenta uma dispersão de 9,2% considerando as três décadas analisadas; Salvador-BA é a capital com menor dispersão na umidade relativa (1,33%); Manaus-AM é a capital com maior dispersão (28,5%).

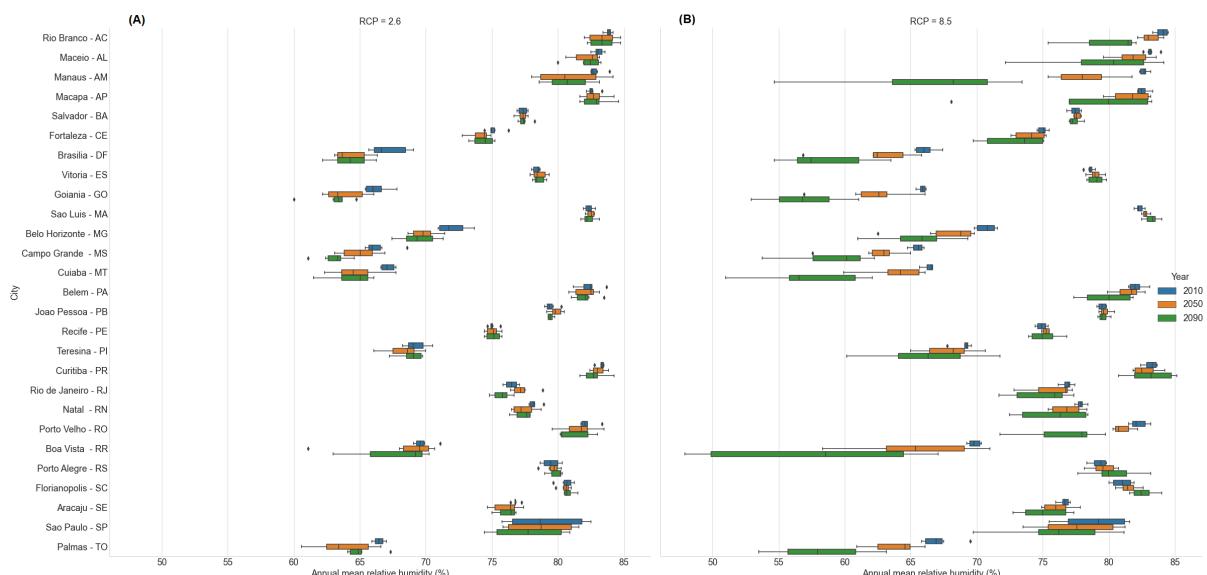


Figura 18 – RHmean em diferentes cenários de emissões: (A) baixa emissão e (B) alta emissão.

4.2.3.2 Impacto das mudanças climáticas na classificação climática

Na seção anterior foi possível observar diferenças significativas entre os cenários e modelos climáticos futuros. No entanto, a análise foi realizada para ter uma

magnitude global das incertezas (ou seja, para todos os modelos). Nesta seção, os resultados de todos os modelos são analisados detalhadamente para a cidade de Brasília, para melhor compreender o impacto das mudanças climáticas no zoneamento climático resultante. Brasília foi selecionada por ser uma das cidades mais importantes do Brasil, sendo a capital federal. Além disso, esta cidade é uma boa representação dos climas brasileiros, com comportamento intermediário, o que nos permite avaliar melhor as potenciais mudanças climáticas.

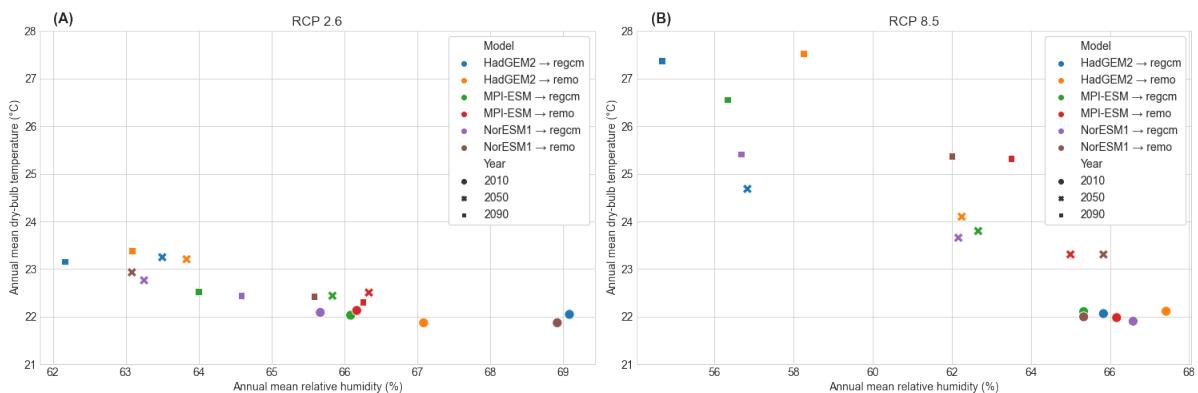


Figura 19 – DBTmean e RHmean para Brasília, considerando vários modelos e décadas: (A) cenário de baixa emissão e (B) cenário de alta emissão.

Independentemente do cenário e do modelo considerado, a DBTmean está em torno de 22 °C na década de 2010; ver Figura 19. Para os outros anos, a temperatura média anual no cenário de emissões elevadas (RCP 8.5) estabelece temperaturas muito mais elevadas do que no cenário de baixas emissões (RCP 2.6). Para o RCP 8.5 as temperaturas também aumentam com o passar dos anos, o que não é muito perceptível para o RCP 2.6, dependendo do modelo considerado. O modelo com a temperatura mais alta nas décadas de 2050 e 2090 é o HadGEM2 com REMO, seguido pelo HadGEM2 com RegCM. Portanto, para uma melhor compreensão, é realizada uma análise de como o zoneamento climático pode ser afetado por este modelo que apresenta a temperatura mais elevada (HadGEM2 com REMO).

Esses resultados indicam que se o RCP for alto, Brasília aumentará sua temperatura e diminuirá sua umidade relativa no futuro. A temperatura média anual de bulbo seco resultante para a década de 2010 é de 22,1 °C, que poderá subir para 27,5 °C na década de 2090. Consequentemente, a classificação climática da cidade é alterada. Brasília é classificada como 3B (clima misto e seco) na década de 2010, passando para 4B (ligeiramente quente e seco) na década de 2050, e passando para 6B (muito quente e seco) na década de 2090. Estes resultados mostram que as mudanças climáticas impactam fortemente a classificação climática da cidade avaliada. No entanto, comportamento semelhante também pode ser observado em muitas outras cidades do mundo.

Para o cenário de baixas emissões (RCP 2.6), nas décadas de 2050 e 2090, a temperatura média anual de bulbo seco aumenta 1,3-1,5 °C, enquanto a RHmean diminui 3,2-3,8%. Embora as diferenças entre as décadas de 2050 e 2090 sejam menores para este cenário, as mudanças climáticas ainda modificam a classificação climática de 3B para 4B. Assim, mesmo em um cenário otimista de emissões (baixas emissões), o aquecimento global impactará significativamente Brasília. Além disso, comparando os dados dos cenários de baixas e altas emissões, podem ser observadas diferenças nas temperaturas: 0,9°C na década de 2050 e 4,1°C na década de 2090.

4.3 CONCLUSÕES

As principais conclusões obtidas dos resultados são:

- A análise comparativa entre dados de alta resolução espacial (ERA5-Land e ANN) e dados de estações meteorológicas (TMYx.2007-2021) revelou que, em grande parte do território brasileiro, os dados de alta resolução espacial apresentam erros menores que 0,4 °C para a temperatura média anual de bulbo seco e menos de 2,1% para a umidade relativa média anual.
- Dados de alta resolução mostraram erros um pouco maiores em determinadas regiões, como Sul e Nordeste do país, o que evidencia a necessidade de melhorias nessas localidades. Contudo, é possível afirmar que os dados são suficientemente robustos para todo o território brasileiro e, na maioria dos locais, o erro é próximo de zero.
- Para classificar o clima de cada município, ao considerar a incerteza nos dados de temperatura e umidade, constatou-se que apenas 1,1% dos municípios possuem apenas uma zona bioclimática, enquanto 33,9% possuem três zonas bioclimáticas. Isto sugere que a incerteza nos dados climáticos pode levar a classificações bioclimáticas diferentes daquelas previamente estabelecidas.
- Muitos municípios possuem mais de uma zona bioclimática em seu território, sendo influenciados principalmente pela altitude, que pode provocar variações de temperatura dentro de um mesmo município de até 8,66 °C. Isto sugere que a altitude é crítica para uma classificação climática precisa e realista de cada pixel avaliado.
- Ao analisar os TMYs, observou-se que a classificação climática pode variar dependendo da estação meteorológica considerada, levando a diferentes zonas bioclimáticas para uma mesma cidade. Isso ocorreu principalmente quando as temperaturas estavam próximas das transições de 25 °C e 27 °C. Além disso, as

características do entorno próximo à estação podem influenciar o comportamento climático da estação meteorológica.

- Quanto à Ilha de Calor Urbana, os resultados sugerem que a incerteza sobre o contexto urbano pode levar à classificação de uma cidade em uma zona diferente daquela observada na estação meteorológica rural, com uma diferença de 0,61 °C na temperatura média anual observada entre contextos urbanos.
- No que diz respeito às mudanças climáticas, a análise dos modelos para cenários de baixa (RCP 2.6) e alta emissão (RCP 8.5) mostra que a temperatura e a umidade relativa nas capitais variam consideravelmente dependendo do modelo. No cenário de baixas emissões, a temperatura e a umidade relativa tendem a ser mais estáveis ao longo do tempo. No cenário de altas emissões, a temperatura aumenta e a umidade relativa diminui ao longo do tempo, com grande dispersão entre os modelos.
- Quanto às mudanças climáticas observadas em Brasília, independente do cenário de emissões, a temperatura média anual tende a aumentar ao longo do tempo, enquanto a umidade relativa tende a diminuir. No cenário de altas emissões, a temperatura poderá aumentar em até 5,4 °C até 2090, alterando a classificação climática da cidade de 3B (clima misto e seco) para 6B (muito quente e seco). No cenário de baixas emissões, a temperatura aumenta até 1,5°C até 2090, alterando a classificação climática para 4B (ligeiramente quente e seco).

5 CONSIDERAÇÕES FINAIS

O presente estudo abordou o desenvolvimento de um zoneamento bioclimático para o Brasil, bem como a avaliação da incerteza em relação aos dados climáticos frente à classificação climática final. Ao longo do texto foram apresentados dois artigos científicos que abordam essa temática. O primeiro artigo, intitulado "*Bioclimatic zoning for building performance using tailored clustering method and high-resolution climate data*", além de tratar do desenvolvimento de um zoneamento bioclimático, também valida base de dados climáticos para simulação computacional e clusterização, realiza análise de sensibilidade de indicadores climáticos e de desempenho de edificações comerciais e residenciais, avalia três abordagens para a clusterização, valida a proposta de zoneamento bioclimático contra zoneamentos existentes e estabelece dados apropriados para classificar o clima das cidades sem dados climáticos válidos através de dados de alta resolução espacial. O segundo artigo, intitulado "*The impact of climate data uncertainty on bioclimatic zoning for building design*", explora a incerteza da acurácia dos dados climáticos, do microclima e do clima futuro, bem como o impacto disso na classificação climática final.

Foram validadas quatro bases de dados climáticos que comumente são usadas na simulação energética de edificações. Os resultados mostraram que a base mais confiável é a TMYx.2007-2021, superando as outras duas versões do TMYx (2003-2017 e 2004-2018) e o INMET (2001-2010). O número de dados faltantes na versão mais recente do TMYx foi muito menor que na sua versão anterior. Isso salienta a importância de escolher cuidadosamente a base de dados climáticos para garantir a acurácia dos resultados da simulação energética de edificações comerciais e residenciais.

Os TMYx foram construídos usando dados da ISD. Por conta disso, um fato negativo é a existência de várias estações meteorológicas com temperaturas com valores arredondados para inteiros. Isso ocorre especialmente no Brasil. Todavia, é importante ressaltar que isso não é um problema quando tratamos de valores médios anuais pois existe uma compensação que torna a temperatura média anual muito semelhante entre valores arredondados e não arredondados.

Dependendo do indicador de desempenho do edifício considerado, determinado indicador climático pode ser mais ou menos sensível. Nesse sentido, foi observado que os indicadores climáticos mais sensíveis, como DBTmean, RHmean e HDD14, são geralmente os mesmos para tipologias residenciais e comerciais. Quando usamos esses indicadores para desenvolver um zoneamento bioclimático, é esperado que o mesmo apresente um alto desempenho quando combinados.

DBTmean tem alta correlação com a carga térmica de resfriamento e o PHsFT, enquanto HDD14 possui alta correlação com a carga térmica de aquecimento e o PHiFT. A umidade relativa média anual (RHmean) precisa de melhorias devido aos

seus baixos valores de correlação com indicadores de desempenho relacionados à umidade. No entanto, esse indicador ainda é muito útil e pode fornecer informações valiosas sobre as condições climáticas. Além disso, a inclusão de indicadores de desempenho dos edifícios relacionados com a umidade é essencial para uma caracterização bioclimática mais precisa.

O desenvolvimento de um método de zoneamento baseado no desempenho higrotérmico e energético de edifícios teve melhores pontuações porque usou os mesmos dados para o agrupamento e validação. Resultados semelhantes foram encontrados quando a clusterização foi feita e validada usando dados climáticos. Assim, a consideração direta do clima é mais eficaz do que um método de zoneamento baseado no desempenho para a caracterização climática. Por esse motivo foi selecionada a árvore de decisão para ser usada na proposta final, pois o clima estaria sendo bem caracterizado e o comportamento da edificação também estaria sendo considerado através das saídas do modelo. Nesse contexto, o zoneamento bioclimático final provou ser mais acurado do que os zoneamentos climáticos existentes (ASHRAE 169, NBR 15220 e Köppen-Geiger) quando validado para quatro tipologias de edifícios e duas métricas de desempenho de agrupamento.

Bases de dados climáticos de alta resolução espacial (ERA5-Land, NASA POWER e CRU) foram avaliadas e o ERA5-Land se mostrou muito acurado para a temperatura. Além disso, redes neurais artificiais (ANNs) foram treinadas para prever o comportamento climático de municípios brasileiros sem dados válidos de estações meteorológicas. Os resultados das ANNs foram muito promissores, mostrando que o método adotado no treinamento dos modelos foi muito eficiente para prever a DTBmean, RHmean e HDD14. Para as cidades que possuíam estações meteorológicas com dados confiáveis, optou-se por usar os valores obtidos no TMYx.2007-2021. Quando a cidade não possuía dados de qualidade, para a DTBmean optou-se por usar os dados do ERA5-Land, já para a RHmean usou-se a ANN.

Mesmo que essas bases de dados climáticos de alta resolução espacial tenham apresentado bons resultados quanto a sua acurácia, especialmente a ERA5-Land e a ANN, ainda sim existe um erro associado aos valores observados nelas. Essa incerteza, em grande parte do território brasileiro, foi inferior a 0,4 °C para a temperatura média anual de bulbo seco e menor que 2,1% para a umidade relativa média anual. Esses erros são considerados baixos, porém é necessário salientar que é o suficiente para promover mudanças na classificação bioclimática estabelecida pelo método de zoneamento proposto nesse estudo. Isso é mais problemático em cidades que possuem climas próximos dos valores de temperatura e umidade que delimitam as zonas.

Baseado nas análises apresentadas nesse trabalho, algumas premissas básicas foram confirmadas, mas que vale ressaltar. Por exemplo, observando o território brasileiro foi possível notar que quanto mais ao sul, menores são as temperaturas.

Isso evidencia o forte impacto da latitude no zoneamento climático. Todavia, a altitude também mostrou ser um fator crítico para uma classificação climática mais acurada e realista. No caso da altitude, quanto maior ela for, menor tende a ser a temperatura. O efeito da altitude pode também impactar fortemente o microclima. Nesse contexto, a classificação bioclimática também pode variar dependendo da estação meteorológica considerada, por conta do microclima referente ao contexto urbano, o que pode levar a diferentes zonas bioclimáticas para uma mesma cidade. Isso ocorreu principalmente quando as temperaturas estavam próximas das transições de 25 °C e 27 °C. Assim, os resultados explicitaram que a incerteza sobre o contexto urbano pode levar à classificação de uma cidade em uma zona diferente daquela observada na estação meteorológica rural, com uma diferença de 0,61 °C na temperatura média anual observada entre contextos urbanos.

Em relação às mudanças climáticas, a análise de modelos para cenários de baixa e alta emissão revela que a temperatura e a umidade relativa nas capitais variam significativamente dependendo do modelo utilizado. Enquanto o cenário de baixa emissão apresenta uma tendência de estabilidade na temperatura e umidade relativa ao longo do tempo, o cenário de alta emissão mostra um aumento na temperatura e uma diminuição na umidade relativa, com grande dispersão entre os modelos. No caso específico de Brasília, independentemente do cenário de emissões, a temperatura média anual tende a aumentar ao longo do tempo, enquanto a umidade relativa tende a diminuir. Isso pode levar a alterações significativas na classificação climática da cidade, com um aumento de até 5,4 °C até 2090 no cenário de alta emissão, ou de até 1,5 °C no cenário de baixa emissão.

5.1 LIMITAÇÕES

As limitações são listadas abaixo:

- O método de zoneamento bioclimático foi desenvolvido apenas para o território brasileiro. No entanto, outras regiões ao redor do mundo que possuem climas semelhantes ao Brasil podem classificar suas localizações, e as divisões das zonas 1 e 2 devem ser feitas através da abordagem HDD14.
- Cada estação meteorológica foi considerada como perfeitamente calibrada devido a falta de informação necessária para compreender a acurácia dos dados medidos.
- O mapa final considerou a classificação climática que ocorreria justamente em um ponto da zona urbana de cada município. Portanto, o zoneamento não é adequado para classificar o microclima. Esta é uma delimitação do estudo para facilitar a visualização das zonas bioclimáticas definidas.

- Como o zoneamento desenvolvido deveria estar alinhado com a atual ABNT-NBR 15575, os indicadores de desempenho da edificação foram calculados considerando o comportamento determinístico dos ocupantes da edificação conforme a normativa.
- As condições de contorno usadas nas simulações computacionais também entram como limitações, especialmente, a baixa taxa de infiltração do edifícios comercial.
- Apenas a temperatura de bulbo seco e a umidade relativa de bancos de dados existentes com alta resolução espacial foram validadas.
- O critério final de zoneamento para caracterização dos climas seco e úmido foi determinado pela umidade relativa. Porém, observou-se que este indicador relacionado à umidade pode ser melhorado.
- O zoneamento foi desenvolvido e validado considerando o comportamento de edifícios residenciais e comerciais de alto e baixo desempenho. Apenas duas configurações foram estabelecidas para representar esses níveis de performance para todo o Brasil.
- No estudo relacionado a acurácia da base de dados climáticos foi considerado somente um zoneamento bioclimático para o Brasil. Assim, o trabalho se limita a um contexto territorial específico. Além do mais, as bases analisadas foram as mesmas usadas na classificação bioclimática final.
- Na análise de incerteza em relação ao microclima, considerou-se dados de três cidades brasileiras, dois métodos para calibrar (PSO e *Sobol Sequence*) e simulações computacionais usando o programa UWG.
- Na análise da incerteza em relação ao clima futuro, avaliou-se apenas as capitais brasileiras, sendo realizada uma análise mais detalhada para Brasília.
- O estudo referente às incertezas não considerou resultados de simulação computacional de edificações.

5.2 TRABALHOS FUTUROS

As sugestões para trabalhos futuros são listadas abaixo:

- Seria interessante investigar como o comportamento dos diferentes ocupantes poderia impactar o zoneamento, especialmente o zoneamento baseado no desempenho.

- Uma abordagem possível para trabalho futuro seria explorar o impacto das incertezas frente a dados de simulação computacional de edifícios residenciais e comerciais.
- O efeito da continentalidade foi representado principalmente pela umidade relativa ou longitude. Isto poderia ser explorado considerando outras abordagens para melhorar a separação dos climas de acordo com a umidade e a amplitude térmica.
- Verificar o comportamento de outras tipologias de edificações frente ao zoneamento bioclimático.
- Investigar outros indicadores climáticos que descrevam melhor o nível de umidade da zona bioclimática.
- Estender a validação das bases de alta resolução espacial para outras variáveis que também impactam o desempenho do edifício.
- Sugere-se desenvolver mais arquivos climáticos futuros para outras cidades brasileiras e posteriormente analisá-las quanto a incerteza.
- Seria interessante ampliar a análise do microclima para outras localidades, testar outros métodos de calibração e programas para a modelagem microclimática.
- Sugere-se explorar outras bases de dados e métodos de zoneamento para avaliar a incerteza em relação à acurácia da base de dados climáticos.

REFERÊNCIAS

ABNT. ABNT NBR 15220-3: Desempenho térmico de edificações – Parte 3: Zoneamento bioclimático brasileiro e diretrizes construtivas para habitações unifamiliares de interesse social. Rio de Janeiro, RJ, Brazil, 2005.

ABNT. ABNT NBR 15575: Edifícios habitacionais - Desempenho. Rio de Janeiro, RJ, Brazil, 2021.

ABOLHASSANI, Soroush Samareh; MASTANI JOYBARI, Mahmood; HOSSEINI, Mirata; PARSAEE, Mojtaba; EICKER, Ursula. A systematic methodological framework to study climate change impacts on heating and cooling demands of buildings. **Journal of Building Engineering**, Elsevier BV, v. 63, p. 105428, jan. 2023. ISSN 2352-7102. DOI: 10.1016/j.jobe.2022.105428. Disponível em: <http://dx.doi.org/10.1016/j.jobe.2022.105428>.

ALLEGRINI, Jonas; DORER, Viktor; CARMELIET, Jan. Impact of radiation exchange between buildings in urban street canyons on space cooling demands of buildings. **Energy and Buildings**, v. 127, p. 1074–1084, 2016. ISSN 0378-7788. DOI: <https://doi.org/10.1016/j.enbuild.2016.06.073>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378778816305631>.

ALLEGRINI, Jonas; DORER, Viktor; CARMELIET, Jan. Influence of the urban microclimate in street canyons on the energy demand for space cooling and heating of buildings. **Energy and Buildings**, Elsevier BV, v. 55, p. 823–832, dez. 2012a. DOI: 10.1016/j.enbuild.2012.10.013. Disponível em: <https://doi.org/10.1016/j.enbuild.2012.10.013>.

ALLEGRINI, Jonas; DORER, Viktor; CARMELIET, Jan. Influence of the urban microclimate in street canyons on the energy demand for space cooling and heating of buildings. **Energy and Buildings**, v. 55, p. 823–832, 2012b. Cool Roofs, Cool Pavements, Cool Cities, and Cool World. ISSN 0378-7788. DOI: <https://doi.org/10.1016/j.enbuild.2012.10.013>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0378778812005221>.

ASCENCIO-VÁSQUEZ, Julián; BRECL, Kristijan; TOPIČ, Marko. Methodology of Köppen-Geiger-Photovoltaic climate classification and implications to worldwide mapping of PV system performance. **Solar Energy**, Elsevier BV, v. 191, p. 672–685,

out. 2019. DOI: 10.1016/j.solener.2019.08.072. Disponível em:
<https://doi.org/10.1016/j.solener.2019.08.072>.

ASHRAE. **ANSI/ASHRAE standard 169-2020**: Climatic Data for Building Design Standards. Atlanta, 2020.

ASHRAE. Standard 189.1—2011: Standard for the Design of High Performance Green Buildings Except Low-Rise Residential Buildings. Atlanta, GA, EUA, 2011.

ASHRAE. Standard 90.1-2004, Energy standard for buildings except low rise residential buildings. **American Society of Heating, Refrigerating and Air-Conditioning Engineers, Inc**, 2004.

AYOADE, JOHNSON OLANIYI. **Introdução à climatologia para os trópicos**. [S.I.]: Difel, 1986.

AZAM, Marie-Hélène; BERNARD, Jérémie; MORILLE, Benjamin; MUSY, Marjorie; ANDRIEU, Hervé. A pavement-watering thermal model for SOLENE-microclimat: Development and evaluation. **Urban Climate**, v. 25, p. 22–36, 2018. ISSN 2212-0955. DOI: <https://doi.org/10.1016/j.uclim.2018.04.005>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S2212095518301159>.

BAMDAD, Keivan; CHOLETTE, Michael E.; OMRANI, Sara; BELL, John. Future energy-optimised buildings — Addressing the impact of climate change on buildings. **Energy and Buildings**, Elsevier BV, v. 231, p. 110610, jan. 2021. ISSN 0378-7788. DOI: [10.1016/j.enbuild.2020.110610](https://doi.org/10.1016/j.enbuild.2020.110610). Disponível em: <http://dx.doi.org/10.1016/j.enbuild.2020.110610>.

BELDA, M.; HOLTANOVÁ, E.; HALENKA, T.; KALVOVÁ, J.; HLÁVKOVÁ, Z. Evaluation of CMIP5 present climate simulations using the Köppen-Trewartha climate classification. English. **Climate Research**, Inter-Research, v. 64, n. 3, p. 201–212, 2015. cited By 7. ISSN 0936577X. DOI: 10.3354/cr01316. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84941649585&doi=10.3354%2fcr01316&partnerID=40&md5=4808d3c9611e61e86ff7c3bca95d5396>.

BENEVIDES, Mariana Navarro; TEIXEIRA, David Bruno de Sousa; CARLO, Joyce Correna. Climatic zoning for energy efficiency applications in buildings based on multivariate statistics: The case of the Brazilian semiarid region. **Frontiers of Architectural Research**, Elsevier BV, v. 11, n. 1, p. 161–177, fev. 2022. ISSN

2095-2635. DOI: 10.1016/j.foar.2021.08.003. Disponível em:
<http://dx.doi.org/10.1016/j.foar.2021.08.003>.

BORGSTEIN, Edward H.; LAMBERTS, Roberto. Developing energy consumption benchmarks for buildings: Bank branches in Brazil. **Energy and Buildings**, Elsevier BV, v. 82, p. 82–91, out. 2014. DOI: 10.1016/j.enbuild.2014.07.028. Disponível em: <https://doi.org/10.1016/j.enbuild.2014.07.028>.

BRACHT, Matheus K.; OLINGER, Marcelo S.; KRELLING, Amanda F.; GONÇALVES, André R.; MELO, Ana Paula; LAMBERTS, Roberto. Multiple regional climate model projections to assess building thermal performance in Brazil: Understanding the uncertainty. **Journal of Building Engineering**, Elsevier BV, v. 88, p. 109248, jul. 2024. ISSN 2352-7102. DOI: 10.1016/j.jobe.2024.109248. Disponível em: <http://dx.doi.org/10.1016/j.jobe.2024.109248>.

BRE, Facundo; ROMAN, Nadia; FACHINOTTI, Víctor D. An efficient metamodel-based method to carry out multi-objective building performance optimizations. **Energy and Buildings**, v. 206, p. 109576, jan. 2020. ISSN 03787788. DOI: 10.1016/j.enbuild.2019.109576. Disponível em:
<https://linkinghub.elsevier.com/retrieve/pii/S0378778819323047>. Acesso em: 14 nov. 2019.

BRE, Facundo; SILVA, Arthur Santos; GHISI, Enedir; FACHINOTTI, Víctor D. Residential building design optimisation using sensitivity analysis and genetic algorithm. **Energy and Buildings**, v. 133, p. 853–866, dez. 2016. ISSN 03787788. DOI: 10.1016/j.enbuild.2016.10.025. Disponível em:
<https://linkinghub.elsevier.com/retrieve/pii/S0378778816312440>. Acesso em: 14 nov. 2019.

BRUSE, Michael. ENVI-met 3.0: updated model overview. **University of Bochum**. Retrieved from: www.envi-met.com, 2004.

BUENO, Bruno; NAKANO, Aiko; NORFORD, Leslie. Urban weather generator: a method to predict neighborhood-specific urban temperatures for use in building energy simulations. In: PROCEEDINGS of the Ninth International Conference on Urban Climate (ICUC9) jointly with 12 Symposium on the Urban Environment. [S.l.: s.n.], 2015.

CANNON, A.J. Köppen versus the computer: Comparing Köppen-Geiger and multivariate regression tree climate classifications in terms of climate homogeneity. English. **Hydrology and Earth System Sciences**, v. 16, n. 1, p. 217–229, 2012. cited By 10. ISSN 10275606. DOI: 10.5194/hess-16-217-2012. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84865315564&doi=10.5194%2fhes-16-217-2012&partnerID=40&md5=c39d3049b130fde3eedb2575df88726>.

CARPIO, M.; JÓDAR, J.; RODÍGUEZ, M.L.; ZAMORANO, M. A proposed method based on approximation and interpolation for determining climatic zones and its effect on energy demand and CO₂ emissions from buildings. English. **Energy and Buildings**, Elsevier Ltd, v. 87, p. 253–264, 2015. cited By 12. ISSN 03787788. DOI: 10.1016/j.enbuild.2014.11.041.

CASTINO, F.; RUSCA, L.; SOLARI, G. Wind climate micro-zoning: a pilot application to Liguria Region (North Western Italy). **Journal of Wind Engineering and Industrial Aerodynamics**, Elsevier BV, v. 91, n. 11, p. 1353–1375, nov. 2003. DOI: 10.1016/j.jweia.2003.08.004. Disponível em: <https://doi.org/10.1016/j.jweia.2003.08.004>.

CHAKRABORTY, Debaditya; ALAM, Arafat; CHAUDHURI, Saptarshi; BAŞAĞAOĞLU, Hakan; SULBARAN, Tulio; LANGAR, Sandeep. Scenario-based prediction of climate change impacts on building cooling energy consumption with explainable artificial intelligence. **Applied Energy**, Elsevier BV, v. 291, p. 116807, jun. 2021. ISSN 0306-2619. DOI: 10.1016/j.apenergy.2021.116807. Disponível em: <http://dx.doi.org/10.1016/j.apenergy.2021.116807>.

COLLINS, J.A. Limitations of the arithmetic mean in climatic classification. English. **Australian Geographer**, v. 6, n. 3, p. 7–8, 1954. cited By 0. ISSN 00049182. DOI: 10.1080/00049185408702293. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84946257624&doi=10.1080%2f00049185408702293&partnerID=40&md5=038957a683b106a9edaa5aa37df2ac1a>.

DASH, P.K.; GUPTA, N.C.; RAWAT, R.; PANT, P.C. A novel climate classification criterion based on the performance of solar photovoltaic technologies. English. **Solar Energy**, Elsevier Ltd, v. 144, p. 392–398, 2017. cited By 12. ISSN 0038092X. DOI: 10.1016/j.solener.2017.01.046. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85010871800&doi=10.1016%2fj.solener.2017.01.046&partnerID=40&md5=2cd1462f7289e144456f130e6d26ce1d>.

DEGAETANO, A.T. Delineation of mesoscale climate zones in the northeastern United States using a novel approach to cluster analysis. English. **Journal of Climate**, American Meteorological Society, v. 9, n. 8, p. 1765–1782, 1996. cited By 51. ISSN 08948755. DOI: 10.1175/1520-0442(1996)009<1765:DOMCZI>2.0.CO;2. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0030428682&doi=10.1175%2f1520-0442%281996%29009%3c1765%3aDOMCZI%3e2.0.CO%3b2&partnerID=40&md5=ad040c749562b68693dc55d93f65a179>.

DEGAETANO, A.T.; SHULMAN, M.D. A climatic classification of plant hardiness in the United States and Canada. English. **Agricultural and Forest Meteorology**, v. 51, n. 3-4, p. 333–351, 1990. cited By 31. ISSN 01681923. DOI: 10.1016/0168-1923(90)90117-0. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0025675064&doi=10.1016%2f0168-1923%2890%2990117-0&partnerID=40&md5=1101f7a804d4495e40e9bae794120d93>.

DI GIUSEPPE, E.; JONA LASINIO, G.; ESPOSITO, S.; PASQUI, M. Functional clustering for Italian climate zones identification. English. **Theoretical and Applied Climatology**, Springer-Verlag Wien, v. 114, n. 1-2, p. 39–54, 2013. cited By 8. ISSN 0177798X. DOI: 10.1007/s00704-012-0801-0. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84884592514&doi=10.1007%2fs00704-012-0801-0&partnerID=40&md5=b252f863c043032c394724859399f44f>.

DOE. **EnergyPlus Development Repository: Version 8.9.** <<https://github.com/NREL/EnergyPlus>>, Maio 2018.

DUAN, Shuangping; LUO, Zhiwen; YANG, Xinyan; LI, Yuguo. The impact of building operations on urban heat/cool islands under urban densification: A comparison between naturally-ventilated and air-conditioned buildings. **Applied Energy**, Elsevier BV, v. 235, p. 129–138, fev. 2019. DOI: 10.1016/j.apenergy.2018.10.108. Disponível em: <https://doi.org/10.1016/j.apenergy.2018.10.108>.

EPE. Ações para promoção da eficiência energética nas edificações brasileiras: no caminho da transição energética. **Empresa de Pesquisa Energética - Nota Técnica da EPE, Rio de Janeiro**, p. 66, 2020.

EVINS, Ralph; DORER, Viktor; CARMELIET, Jan. Simulating external longwave radiation exchange for buildings. **Energy and Buildings**, Elsevier BV, v. 75,

p. 472–482, jun. 2014. DOI: 10.1016/j.enbuild.2014.02.030. Disponível em: <https://doi.org/10.1016/j.enbuild.2014.02.030>.

FENG, K.; TIAN, J. Analysis of variation characteristics of extreme precipitation events in hetao area, China based on fuzzy clustering climate zoning. English. **Applied Ecology and Environmental Research**, Corvinus University of Budapest, v. 16, n. 5, p. 6299–6316, 2018. cited By 1. ISSN 15891623. DOI: 10.15666/aeer/1605_62996316. Disponível em: https://www.scopus.com/inward/record.uri?eid=2-s2.0-85056147238&doi=10.15666%2faeer%2f1605_62996316&partnerID=40&md5=7e437c281c5db25758f393441972c2a5.

GARCIA, Jayne. **Análise do desempenho termoenergético da envoltória em habitações de interesse social de Joinville/SC**. 2020. Diss. (Mestrado) – Universidade do Estado de Santa Catarina, Joinville, SC.

GELETIČ, Jan; LEHNERT, Michal; DOBROVOLNÝ, Petr; ŽUVELA-ALOISE, Maja. Spatial modelling of summer climate indices based on local climate zones: expected changes in the future climate of Brno, Czech Republic. **Climatic Change**, Springer Science e Business Media LLC, v. 152, n. 3-4, p. 487–502, jan. 2019. DOI: 10.1007/s10584-018-2353-5. Disponível em: <https://doi.org/10.1007/s10584-018-2353-5>.

GIVONI, Baruch. Comfort, climate analysis and building design guidelines. **Energy and Buildings**, Elsevier BV, v. 18, n. 1, p. 11–23, jan. 1992. DOI: 10.1016/0378-7788(92)90047-k. Disponível em: [https://doi.org/10.1016/0378-7788\(92\)90047-k](https://doi.org/10.1016/0378-7788(92)90047-k).

GOMES, Wellison J.S.; BECK, André T.; LOPEZ, Rafael H.; MIGUEL, Leandro F.F. A probabilistic metric for comparing metaheuristic optimization algorithms. **Structural Safety**, Elsevier BV, v. 70, p. 59–70, jan. 2018. DOI: 10.1016/j.strusafe.2017.10.006. Disponível em: <https://doi.org/10.1016/j.strusafe.2017.10.006>.

HAN, Jiawei. **Data mining : concepts and techniques**. Burlington: Elsevier Science, 2011. ISBN 978-0-12-381479-1.

HARKOUSS, Fatima; FARDOUN, Farouk; BIWOLE, Pascal Henry. Passive design optimization of low energy buildings in different climates. **Energy**, Elsevier BV, v. 165,

p. 591–613, dez. 2018. DOI: 10.1016/j.energy.2018.09.019. Disponível em: <https://doi.org/10.1016/j.energy.2018.09.019>.

HOUET, T.; PIGEON, G. Mapping urban climate zones and quantifying climate behaviors - An application on Toulouse urban area (France). English. **Environmental Pollution**, v. 159, n. 8-9, p. 2180–2192, 2011. cited By 51. ISSN 02697491. DOI: 10.1016/j.envpol.2010.12.027. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-79958831400&doi=10.1016%2fj.envpol.2010.12.027&partnerID=40&md5=8d16cd952a6f96e1a92ab5c93158371c>.

IEA. **Tracking Clean Energy Progress 2017.** [S.I.]: Paris: Organization for Economic Co-operation e Development (OECD), 2017.

INMETRO. **Portaria N. 309 – Instruções Normativas e Requisitos de Avaliação da Conformidade para a Eficiência Energética das Edificações Comerciais, de Serviços e Públicas e Residenciais.** Brazil, 2022.

IPCC, Intergovernmental Panel on Climate Change -. **Climate change 2014: Mitigation of climate change.** [S.I.]: Cambridge University Press, 2015. v. 3.

ISMAIL, Fathin Haji; SHAHRESTANI, Mehdi; VAHDATI, Maria; BOYD, Philippa; DONYAVI, Sohrab. Climate change and the energy performance of buildings in the future – A case study for prefabricated buildings in the UK. **Journal of Building Engineering**, Elsevier BV, v. 39, p. 102285, jul. 2021. ISSN 2352-7102. DOI: 10.1016/j.jobe.2021.102285. Disponível em: <http://dx.doi.org/10.1016/j.jobe.2021.102285>.

ISO. **52003-1: Energy Performance of Buildings — Indicators, Requirements, Ratings and Certificates — Part 1: General Aspects and Application to the Overall Energy Performance.** [S.I.: s.n.], 2017.

ISO. **ISO 16346: Energy performance of buildings – Assessment of overall energy performance.** [S.I.: s.n.], 2013.

JACOBET, J. Classifications in climate research. English. **Physics and Chemistry of the Earth**, v. 35, n. 9-12, p. 411–421, 2010. cited By 36. ISSN 14747065. DOI: 10.1016/j.pce.2009.11.010. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-77954954806&doi=10.1016%2fj.pce.2009.11.010&partnerID=40&md5=0ff0010ee326107879c066431fea2ba>.

KALKSTEIN, Laurence S.; TAN, Guanri; SKINDLOV, Jon A. An Evaluation of Three Clustering Procedures for Use in Synoptic Climatological Classification. **Journal of Climate and Applied Meteorology**, American Meteorological Society, v. 26, n. 6, p. 717–730, jun. 1987. DOI: 10.1175/1520-0450(1987)026<0717:aeotcp>2.0.co;2. Disponível em:
[https://doi.org/10.1175/1520-0450\(1987\)026%3C0717:aeotcp%3E2.0.co;2.](https://doi.org/10.1175/1520-0450(1987)026%3C0717:aeotcp%3E2.0.co;2)

KARKI, R.; TALCHABHADEL, R.; AALTO, J.; BAIDYA, S.K. New climatic classification of Nepal. English. **Theoretical and Applied Climatology**, Springer-Verlag Wien, v. 125, n. 3-4, p. 799–808, 2016. cited By 24. ISSN 0177798X. DOI: 10.1007/s00704-015-1549-0. Disponível em:
<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84981170168&doi=10.1007%2fs00704-015-1549-0&partnerID=40&md5=7041f54ae9cfcd1f06de111fcf269885>.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. World map of the Köppen-Geiger climate classification updated. English. **Meteorologische Zeitschrift**, v. 15, n. 3, p. 259–263, 2006a. cited By 3712. ISSN 09412948. DOI: 10.1127/0941-2948/2006/0130. Disponível em:
<https://www.scopus.com/inward/record.uri?eid=2-s2.0-33745866181&doi=10.1127%2f0941-2948%2f2006%2f0130&partnerID=40&md5=fba1e5c80cd015caf836550b96ecbf06>.

KOTTEK, Markus; GRIESER, Jürgen; BECK, Christoph; RUDOLF, Bruno; RUBEL, Franz. World Map of the Köppen-Geiger climate classification updated. **Meteorologische Zeitschrift**, Schweizerbart, v. 15, n. 3, p. 259–263, jul. 2006b. DOI: 10.1127/0941-2948/2006/0130. Disponível em:
<https://doi.org/10.1127/0941-2948/2006/0130>.

KOZJEK, K.; DOLINAR, M.; SKOK, G. Objective climate classification of Slovenia. English. **International Journal of Climatology**, John Wiley e Sons Ltd, v. 37, p. 848–860, 2017. cited By 5. ISSN 08998418. DOI: 10.1002/joc.5042. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85016619568&doi=10.1002%2fjoc.5042&partnerID=40&md5=94c50c5d7152730705925164460a5b3d>.

KWOK, Yu Ting; SCHOETTER, Robert; LAU, Kevin Ka-Lun; HIDALGO, Julia; REN, Chao; PIGEON, Grégoire; MASSON, Valéry. How well does the local climate zone scheme discern the thermal environment of Toulouse (France)? An analysis using numerical simulation data. **International Journal of Climatology**, Wiley, v. 39,

n. 14, p. 5292–5315, jun. 2019. DOI: 10.1002/joc.6140. Disponível em:
<https://doi.org/10.1002/joc.6140>.

LECONTE, Francois; BOUYER, Julien; CLAVERIE, Rémy; PÉTRISSANS, Mathieu. Using Local Climate Zone scheme for UHI assessment: Evaluation of the method using mobile measurements. **Building and Environment**, Elsevier BV, v. 83, p. 39–49, jan. 2015. DOI: 10.1016/j.buildenv.2014.05.005. Disponível em:
<https://doi.org/10.1016/j.buildenv.2014.05.005>.

LEE, D.; OH, K.; JUNG, S. Classifying urban climate zones (UCZs) based on spatial statistical analyses. English. **Sustainability (Switzerland)**, MDPI AG, v. 11, n. 7, 2019. cited By 0. ISSN 20711050. DOI: 10.3390/su11071915. Disponível em:
<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85064073916&doi=10.3390%2fsu11071915&partnerID=40&md5=d56d12cff1e24f608ffc0239dd8db11d>.

LEE, Dongwoo; OH, Kyushik. Classifying urban climate zones (UCZs) based on statistical analyses. **Urban Climate**, Elsevier BV, v. 24, p. 503–516, jun. 2018. DOI: 10.1016/j.uclim.2017.06.005. Disponível em:
<https://doi.org/10.1016/j.uclim.2017.06.005>.

LEE, Wen-Shing; KUNG, Chung-Kuan. Using climate classification to evaluate building energy performance. **Energy**, Elsevier BV, v. 36, n. 3, p. 1797–1801, mar. 2011. DOI: 10.1016/j.energy.2010.12.034. Disponível em:
<https://doi.org/10.1016/j.energy.2010.12.034>.

LEHNERT, M.; GELETIČ, J.; HUSÁK, J.; VYSOUDIL, M. Urban field classification by “local climate zones” in a medium-sized Central European city: the case of Olomouc (Czech Republic). English. **Theoretical and Applied Climatology**, Springer-Verlag Wien, v. 122, n. 3-4, p. 531–541, 2015. cited By 38. ISSN 0177798X. DOI: 10.1007/s00704-014-1309-6. Disponível em:
<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84944275613&doi=10.1007%2fs00704-014-1309-6&partnerID=40&md5=36a58649dc12185af6321d26e3d0135f>.

LI, Hongzong; WANG, Jun. From Soft Clustering to Hard Clustering: A Collaborative Annealing Fuzzy c-Means Algorithm. **IEEE Transactions on Fuzzy Systems**, Institute of Electrical e Electronics Engineers (IEEE), v. 32, n. 3, p. 1181–1194, mar. 2024. ISSN 1941-0034. DOI: 10.1109/tfuzz.2023.3319663. Disponível em:
<http://dx.doi.org/10.1109/TFUZZ.2023.3319663>.

LI, Mingcai; CHENG, Shanjun; FANG, Xiaoyi. An efficient performance assessing index for building climatic zoning methods based on probability density functions.

Energy and Buildings, Elsevier BV, v. 271, p. 112323, set. 2022. DOI:

10.1016/j.enbuild.2022.112323. Disponível em:

<https://doi.org/10.1016/j.enbuild.2022.112323>.

MACHADO, Rayner Maurício e Silva; BRE, Facundo; MAZZAFERRO, Leonardo; MELO, Ana Paula; LAMBERTS, Roberto. Bioclimatic zoning for building performance using tailored clustering method and high-resolution climate data. **Energy and Buildings**, Elsevier BV, v. 311, p. 114157, mai. 2024. ISSN 0378-7788. DOI:

10.1016/j.enbuild.2024.114157. Disponível em:

<http://dx.doi.org/10.1016/j.enbuild.2024.114157>.

MACHADO, Rayner Maurício e Silva *et al.* Metamodel to predict annual cooling thermal load for commercial, services and public buildings: A country-level approach to support energy efficiency regulation. **Energy and Buildings**, Elsevier BV, v. 301, p. 113690, dez. 2023. ISSN 0378-7788. DOI: 10.1016/j.enbuild.2023.113690. Disponível em: <http://dx.doi.org/10.1016/j.enbuild.2023.113690>.

MALMGREN, B.A.; WINTER, A. Climate zonation in Puerto Rico based on principal components analysis and an artificial neural network. English. **Journal of Climate**, American Meteorological Soc, v. 12, n. 4, p. 977–985, 1999. cited By 62. ISSN 08948755. DOI: 10.1175/1520-0442(1999)012<0977:CZIPRB>2.0.CO;2. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0033117454&doi=10.1175%2f1520-0442%281999%29012%3c0977%3aCZIPRB%3e2.0.CO%2b2&partnerID=40&md5=52f4833089420208a4deba81a57794c>.

MAO, Jiachen; FU, Yangyang; AFSHARI, Afshin; ARMSTRONG, Peter R.; NORFORD, Leslie K. Optimization-aided calibration of an urban microclimate model under uncertainty. **Building and Environment**, Elsevier BV, v. 143, p. 390–403, out. 2018. ISSN 0360-1323. DOI: 10.1016/j.buildenv.2018.07.034. Disponível em: <http://dx.doi.org/10.1016/j.buildenv.2018.07.034>.

MAO, Jiachen; YANG, Joseph H.; AFSHARI, Afshin; NORFORD, Leslie K. Global sensitivity analysis of an urban microclimate system under uncertainty: Design and case study. **Building and Environment**, Elsevier BV, v. 124, p. 153–170, nov. 2017.

DOI: 10.1016/j.buildenv.2017.08.011. Disponível em:

<https://doi.org/10.1016/j.buildenv.2017.08.011>.

MARTINS, T. De. **Condicionantes solares a oportunidades de desenho urbano: Otimização de tipo-morfologias urbanas em contexto de clima tropical**. 2014. Diss. (Mestrado) – Universidade Federal do Rio de Janeiro, Rio de Janeiro, RJ.

MAZZAFERRO, Leonardo; MACHADO, Rayner M.S.; MELO, Ana Paula; LAMBERTS, Roberto. Do we need building performance data to propose a climatic zoning for building energy efficiency regulations? **Energy and Buildings**, Elsevier BV, v. 225, p. 110303, out. 2020. DOI: 10.1016/j.enbuild.2020.110303. Disponível em: <https://doi.org/10.1016/j.enbuild.2020.110303>.

MCBRATNEY, A.B.; MOORE, A.W. Application of fuzzy sets to climatic classification. English. **Agricultural and Forest Meteorology**, v. 35, n. 1-4, p. 165–185, 1985. cited By 195. ISSN 01681923. DOI: 10.1016/0168-1923(85)90082-6. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0000118514&doi=10.1016%2f0168-1923%2885%2990082-6&partnerID=40&md5=31b06ea635b2ee2ceca8d10afafb5357>.

MENDONÇA, Francisco; DANNI-OLIVEIRA, Inês Moresco. **Climatologia: noções básicas e climas do Brasil**. [S.I.]: Oficina de textos, 2017.

MILLER, Clayton; THOMAS, Daren; KÄMPF, Jérôme; SCHLUETER, Arno. Long wave radiation exchange for urban scale modelling within a co-simulation environment. In: LESO-PB, EPFL, EPFL-CONF-213432. PROCEEDINGS of International Conference CISBAT 2015 Future Buildings and Districts Sustainability from Nano to Urban Scale. [S.I.: s.n.], 2015. P. 871–876.

MIRZAEI, Parham A. Recent challenges in modeling of urban heat island. **Sustainable Cities and Society**, Elsevier BV, v. 19, p. 200–206, dez. 2015. DOI: 10.1016/j.scs.2015.04.001. Disponível em: <https://doi.org/10.1016/j.scs.2015.04.001>.

MIRZAEI, Parham A.; HAGHIGHAT, Fariborz. Approaches to study Urban Heat Island – Abilities and limitations. **Building and Environment**, Elsevier BV, v. 45, n. 10, p. 2192–2201, out. 2010. DOI: 10.1016/j.buildenv.2010.04.001. Disponível em: <https://doi.org/10.1016/j.buildenv.2010.04.001>.

MOONEN, Peter; DEFRAEYE, Thijs; DORER, Viktor; BLOCKEN, Bert; CARMELIET, Jan. Urban Physics: Effect of the micro-climate on comfort, health and energy demand. **Frontiers of Architectural Research**, Elsevier BV, v. 1, n. 3,

p. 197–228, set. 2012. DOI: 10.1016/j.foar.2012.05.002. Disponível em:
<https://doi.org/10.1016/j.foar.2012.05.002>.

MOREIRA, E. B. M. **Balanço de energia e evapotranspiração na cidade do Recife-PE por sensoriamento remoto**. 2014. Tese (Doutorado) – Universidade Federal de Pernambuco, Recife, PE.

MU, Qingchen; MIAO, Shiguang; WANG, Yongwei; LI, Yuhuan; HE, Xiaodong; YAN, Chao. Evaluation of employing local climate zone classification for mesoscale modelling over Beijing metropolitan area. **Meteorology and Atmospheric Physics**, Springer Science e Business Media LLC, ago. 2019. DOI: 10.1007/s00703-019-00692-7. Disponível em:
<https://doi.org/10.1007/s00703-019-00692-7>.

MUGHAL, M. O.; LI, Xian-Xiang; YIN, Tiangang; MARTILLI, Alberto; BROUSSE, Oscar; DISSEGNA, Maria Angela; NORFORD, Leslie K. High-Resolution, Multilayer Modeling of Singapore's Urban Climate Incorporating Local Climate Zones. **Journal of Geophysical Research: Atmospheres**, American Geophysical Union (AGU), v. 124, n. 14, p. 7764–7785, jul. 2019. DOI: 10.1029/2018jd029796. Disponível em: <https://doi.org/10.1029/2018jd029796>.

NETZEL, P.; STEPINSKI, T. On using a clustering approach for global climate classification. English. **Journal of Climate**, American Meteorological Society, v. 29, n. 9, p. 3387–3401, 2016. cited By 15. ISSN 08948755. DOI: 10.1175/JCLI-D-15-0640.1. Disponível em:
<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84966350041&doi=10.1175%2fJCLI-D-15-0640.1&partnerID=40&md5=b541498dd8be24eb8b4fc681f0a5a4e3>.

NGUYEN, Anh-Tuan; REITER, Sigrid. A performance comparison of sensitivity analysis methods for building energy models. In: SPRINGER, 6. BUILDING Simulation. [S.I.: s.n.], 2015. P. 651–664.

NIK, Vahid M. Making energy simulation easier for future climate – Synthesizing typical and extreme weather data sets out of regional climate models (RCMs). **Applied Energy**, Elsevier BV, v. 177, p. 204–226, set. 2016. ISSN 0306-2619. DOI: 10.1016/j.apenergy.2016.05.107. Disponível em:
<http://dx.doi.org/10.1016/j.apenergy.2016.05.107>.

- NIKKHO, Saber Khoshdel; HEIDARINEJAD, Mohammad; LIU, Jiying; SREBRIC, Jelena. Quantifying the impact of urban wind sheltering on the building energy consumption. **Applied Thermal Engineering**, Elsevier BV, v. 116, p. 850–865, abr. 2017. DOI: 10.1016/j.applthermaleng.2017.01.044. Disponível em: <https://doi.org/10.1016/j.applthermaleng.2017.01.044>.
- OKE, Timothy R. **Boundary layer climates**. [S.I.]: Routledge, 2002.
- OKE, Timothy R; MILLS, Gerald; CHRISTEN, Andreas; VOOGT, James A. **Urban climates**. [S.I.]: Cambridge University Press, 2017.
- OLINGER, Marcelo Salles; MELO, Ana Paula; LAMBERTS, Roberto. Developing a surrogate model for naturally ventilated cellular offices in Brazil. **Building and Environment**, Elsevier BV, v. 233, p. 110075, abr. 2023. ISSN 0360-1323. DOI: 10.1016/j.buildenv.2023.110075. Disponível em: <http://dx.doi.org/10.1016/j.buildenv.2023.110075>.
- OMAROV, Bekarys; MEMON, Shazim Ali; KIM, Jong. A novel approach to develop climate classification based on degree days and building energy performance. **Energy**, Elsevier BV, v. 267, p. 126514, mar. 2023. DOI: 10.1016/j.energy.2022.126514. Disponível em: <https://doi.org/10.1016/j.energy.2022.126514>.
- ØSTERGÅRD, Torben; JENSEN, Rasmus L.; MAAGAARD, Steffen E. Building simulations supporting decision making in early design – A review. **Renewable and Sustainable Energy Reviews**, Elsevier BV, v. 61, p. 187–201, ago. 2016. DOI: 10.1016/j.rser.2016.03.045. Disponível em: <https://doi.org/10.1016/j.rser.2016.03.045>.
- PALLA, A.; GNECCO, I.; LANZA, L.G.; BARBERA, P. La. Performance analysis of domestic rainwater harvesting systems under various European climate zones. **Resources, Conservation and Recycling**, Elsevier BV, v. 62, p. 71–80, mai. 2012. DOI: 10.1016/j.resconrec.2012.02.006. Disponível em: <https://doi.org/10.1016/j.resconrec.2012.02.006>.
- PALME, M.; INOSTROZA, L.; VILLACRESES, G.; LOBATO-CORDERO, Andrea; CARRASCO, C. From urban climate to energy consumption. Enhancing building performance simulation by including the urban heat island effect. **Energy and Buildings**, Elsevier BV, v. 145, p. 107–120, jun. 2017. DOI:

10.1016/j.enbuild.2017.03.069. Disponível em:
<https://doi.org/10.1016/j.enbuild.2017.03.069>.

PARDO, Angel; MENEU, Vicente; VALOR, Enric. Temperature and seasonality influences on Spanish electricity load. **Energy Economics**, Elsevier BV, v. 24, n. 1, p. 55–70, jan. 2002. DOI: 10.1016/s0140-9883(01)00082-2. Disponível em:
[https://doi.org/10.1016/s0140-9883\(01\)00082-2](https://doi.org/10.1016/s0140-9883(01)00082-2).

PEIRÓ, M. Núñez; SÁNCHEZ, C. Sánchez-Guevara; GONZÁLEZ, F.J. Neila. Source area definition for local climate zones studies. A systematic review. **Building and Environment**, Elsevier BV, v. 148, p. 258–285, jan. 2019. DOI: 10.1016/j.buildenv.2018.10.050. Disponível em:
<https://doi.org/10.1016/j.buildenv.2018.10.050>.

PEREZ, JC; SÁNCHEZ, MAV; BARRADAS, Víctor L. Clima, urbanización y uso del suelo en ciudades tropicales de Mexico. **Red Nacional de Investigación Urbana, Puebla, México, Ciudades**, v. 51, 2001.

PIRI, I.; KHANAMANI, A.; SHOJAEI, S.; FATHIZAD, H. Determination of the best geostatistical method for climatic zoning in Iran. English. **Applied Ecology and Environmental Research**, Corvinus University of Budapest, v. 15, n. 1, p. 93–103, 2017. cited By 5. ISSN 15891623. DOI: 10.15666/aeer/1501_093103. Disponível em:
https://www.scopus.com/inward/record.uri?eid=2-s2.0-85013157633&doi=10.15666%2faeer%2f1501_093103&partnerID=40&md5=655b215853889f0d8c0ca78edebfa3a3.

PRAENE, Jean Philippe; MALET-DAMOUR, Bruno; RADANIELINA, Mamy Harimisa; FONTAINE, Ludovic; RIVIÈRE, Garry. GIS-based approach to identify climatic zoning: A hierarchical clustering on principal component analysis. **Building and Environment**, Elsevier BV, v. 164, p. 106330, out. 2019. DOI: 10.1016/j.buildenv.2019.106330. Disponível em: <https://doi.org/10.1016/j.buildenv.2019.106330>.

QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System**. [S.I.], 2023. Disponível em: <https://www.qgis.org>.

RAHIMI, Jaber; KHALILI, Ali; BUTTERBACH-BAHL, Klaus. Projected changes in modified Thornthwaite climate zones over Southwest Asia using a CMIP5 multi-model ensemble. **International Journal of Climatology**, Wiley, v. 39, n. 12, p. 4575–4594,

mai. 2019. DOI: 10.1002/joc. 6088. Disponível em:
<https://doi.org/10.1002/joc. 6088>.

RIZWAN, Ahmed Memon; DENNIS, Leung Y.C.; LIU, Chunho. A review on the generation, determination and mitigation of Urban Heat Island. **Journal of Environmental Sciences**, Elsevier BV, v. 20, n. 1, p. 120–128, jan. 2008. DOI: 10.1016/s1001-0742(08)60019-4. Disponível em:
[https://doi.org/10.1016/s1001-0742\(08\)60019-4](https://doi.org/10.1016/s1001-0742(08)60019-4).

ROMERO, Marta Adriana Bustos. **Princípios bioclimáticos para o desenho urbano.** [S.I.]: ProEditores Associados, 2001.

ROMERO RODRÍGUEZ, Laura; SÁNCHEZ RAMOS, José; ÁLVAREZ DOMÍNGUEZ, Servando. Simplifying the process to perform air temperature and UHI measurements at large scales: Design of a new APP and low-cost Arduino device. **Sustainable Cities and Society**, Elsevier BV, v. 95, p. 104614, ago. 2023. ISSN 2210-6707. DOI: 10.1016/j.scs.2023.104614. Disponível em:
<http://dx.doi.org/10.1016/j.scs.2023.104614>.

RORIZ, Maurício. **Classificação De Climas Do Brasil:** Versão 3.0. Porto Alegre, RS, Brazil, 2014.

SALTELLI, Andrea; TARANTOLA, Stefano; CAMPOLONGO, Francesca; RATTO, Marco. **Sensitivity analysis in practice: a guide to assessing scientific models.** [S.I.]: John Wiley & Sons, 2004.

SAMUELSON, Holly; CLAUSSNITZER, Sebastian; GOYAL, Apoorv; CHEN, Yujiao; ROMO-CASTILLO, Alejandra. Parametric energy simulation in early design: High-rise residential buildings in urban contexts. **Building and Environment**, Elsevier BV, v. 101, p. 19–31, mai. 2016. DOI: 10.1016/j.buildenv.2016.02.018. Disponível em:
<https://doi.org/10.1016/j.buildenv.2016.02.018>.

SANTAMOURIS, M.; CARTALIS, C.; SYNNEFA, A.; KOLOKOTSA, D. On the impact of urban heat island and global warming on the power demand and electricity consumption of buildings—A review. **Energy and Buildings**, Elsevier BV, v. 98, p. 119–124, jul. 2015. DOI: 10.1016/j.enbuild.2014.09.052. Disponível em:
<https://doi.org/10.1016/j.enbuild.2014.09.052>.

SEMAAN, Mary; DAY, Susan D.; GARVIN, Michael; RAMAKRISHNAN, Naren; PEARCE, Annie. Optimal sizing of rainwater harvesting systems for domestic water usages: A systematic literature review. **Resources, Conservation & Recycling**: X, Elsevier BV, p. 100033, fev. 2020. DOI: 10.1016/j.rcrx.2020.100033. Disponível em: <https://doi.org/10.1016/j.rcrx.2020.100033>.

SHI, Yurong; XIANG, Yirui; ZHANG, Yufeng. Urban Design Factors Influencing Surface Urban Heat Island in the High-Density City of Guangzhou Based on the Local Climate Zone. **Sensors**, MDPI AG, v. 19, n. 16, p. 3459, ago. 2019. DOI: 10.3390/s19163459. Disponível em: <https://doi.org/10.3390/s19163459>.

SHRIVASTAVA, R.L.; KUMAR, Vinod; UNTAWALE, S.P. Modeling and simulation of solar water heater: A TRNSYS perspective. **Renewable and Sustainable Energy Reviews**, Elsevier BV, v. 67, p. 126–143, jan. 2017. DOI: 10.1016/j.rser.2016.09.005. Disponível em: <https://doi.org/10.1016/j.rser.2016.09.005>.

SOUZA, Lea Cristina Lucas de. Relações entre ilhas de calor, geometria urbana e consumo de energia elétrica. **Fórum Patrimônio: Ambiente Construído e Patrimônio Sustentável**, v. 3, n. 2, 2010.

SREBRIC, Jelena; HEIDARINEJAD, Mohammad; LIU, Jiying. Building neighborhood emerging properties and their impacts on multi-scale modeling of building energy and airflows. **Building and Environment**, v. 91, p. 246–262, 2015. Fifty Year Anniversary for Building and Environment. ISSN 0360-1323. DOI: <https://doi.org/10.1016/j.buildenv.2015.02.031>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0360132315000888>.

STEWART, I.D.; OKE, T.R. Local climate zones for urban temperature studies. English. **Bulletin of the American Meteorological Society**, v. 93, n. 12, p. 1879–1900, 2012. cited By 854. ISSN 00030007. DOI: 10.1175/BAMS-D-11-00019.1. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84871311007&doi=10.1175%2fBAMS-D-11-00019.1&partnerID=40&md5=515beee5c2f5f3e86bc277eca34d80f3>.

STEWART, I.D.; OKE, T.R.; KRAYENHOFF, E.S. Evaluation of the 'local climate zone' scheme using temperature observations and model simulations. English. **International Journal of Climatology**, v. 34, n. 4, p. 1062–1080, 2014. cited By 157. ISSN 08998418. DOI: 10.1002/joc.3746. Disponível em:

[https://www.scopus.com/inward/record.uri?eid=2-s2.0-84900604709&doi=10.1002%2fjoc.3746&partnerID=40&md5=5a16e8a751c17018e9088c4c075446b7.](https://www.scopus.com/inward/record.uri?eid=2-s2.0-84900604709&doi=10.1002%2fjoc.3746&partnerID=40&md5=5a16e8a751c17018e9088c4c075446b7)

STREET, Michael Anthony. **Comparison of simplified models of urban climate for improved prediction of building energy use in cities**. 2013. Tese (Doutorado) – Massachusetts Institute of Technology.

SUDHAKAR, K.; JENKINS, Matthew S.; MANGAL, Shiy; PRIYA, S. Shanmuga. Modelling of a solar desiccant cooling system using a TRNSYS-MATLAB co-simulator: A review. **Journal of Building Engineering**, Elsevier BV, v. 24, p. 100749, jul. 2019. DOI: 10.1016/j.jobe.2019.100749. Disponível em:
<https://doi.org/10.1016/j.jobe.2019.100749>.

TANOORI, Ghazaleh; SOLTANI, Ali; MODIRI, Atoosa. Machine Learning for Urban Heat Island (UHI) Analysis: Predicting Land Surface Temperature (LST) in Urban Environments. **Urban Climate**, Elsevier BV, v. 55, p. 101962, mai. 2024. ISSN 2212-0955. DOI: 10.1016/j.uclim.2024.101962. Disponível em:
<http://dx.doi.org/10.1016/j.uclim.2024.101962>.

TERCEK, M.T.; GRAY, S.T.; NICHOLSON, C.M. Climate zone delineation: Evaluating approaches for use in natural resource management. English. **Environmental Management**, Springer New York LLC, v. 49, n. 5, p. 1076–1091, 2012. cited By 8. ISSN 0364152X. DOI: 10.1007/s00267-012-9827-4. Disponível em:
<https://www.scopus.com/inward/record.uri?eid=2-s2.0-84865337479&doi=10.1007%2fs00267-012-9827-4&partnerID=40&md5=3d874162d2570373460720320a4d1f61>.

TIAN, Wei. A review of sensitivity analysis methods in building energy analysis. **Renewable and Sustainable Energy Reviews**, Elsevier BV, v. 20, p. 411–419, abr. 2013. DOI: 10.1016/j.rser.2012.12.014. Disponível em:
<https://doi.org/10.1016/j.rser.2012.12.014>.

VALLATTI, A.; MAURI, L.; COLUCCI, C.; OCŁON, P. Effects of radiative exchange in an urban canyon on building surfaces' loads and temperatures. **Energy and Buildings**, v. 149, p. 260–271, 2017. ISSN 0378-7788. DOI:
<https://doi.org/10.1016/j.enbuild.2017.05.072>. Disponível em:
<http://www.sciencedirect.com/science/article/pii/S0378778817311076>.

VANKERKOM, Jean; VOS, Peter; MAIHEU, Bino; NIKOLOVA, Irina; DE MAERSCHALCK, Bart; JANSSEN, Stijn. VITO extensions to the ENVI-met model, 2012.

VERDONCK, Marie-Leen; DEMUZERE, Matthias; HOOYBERGHS, Hans; BECK, Christoph; CYRYS, Josef; SCHNEIDER, Alexandra; DEWULF, Robert; COILLIE, Frieke Van. The potential of local climate zones maps as a heat stress assessment tool, supported by simulated air temperature data. **Landscape and Urban Planning**, Elsevier BV, v. 178, p. 183–197, out. 2018. DOI: 10.1016/j.landurbplan.2018.06.004. Disponível em: <https://doi.org/10.1016/j.landurbplan.2018.06.004>.

VERICHEV, Konstantin; CARPIO, Manuel. Climatic zoning for building construction in a temperate climate of Chile. **Sustainable Cities and Society**, Elsevier BV, v. 40, p. 352–364, jul. 2018. DOI: 10.1016/j.scs.2018.04.020. Disponível em: <https://doi.org/10.1016/j.scs.2018.04.020>.

WALSH, Angélica; CÓSTOLA, Daniel; HENSEN, Jan L.M.; LABAKI, Lucila Chebel. Multi-criterial performance-based climatic zoning of Brazil supported by local experts. **Building and Environment**, Elsevier BV, v. 243, p. 110591, set. 2023. ISSN 0360-1323. DOI: 10.1016/j.buildenv.2023.110591. Disponível em: <http://dx.doi.org/10.1016/j.buildenv.2023.110591>.

WALSH, Angélica; CÓSTOLA, Daniel; LABAKI, Lucila C. Comparison of three climatic zoning methodologies for building energy efficiency applications. **Energy and Buildings**, Elsevier BV, v. 146, p. 111–121, jul. 2017a. DOI: 10.1016/j.enbuild.2017.04.044. Disponível em: <https://doi.org/10.1016/j.enbuild.2017.04.044>.

WALSH, Angélica; CÓSTOLA, Daniel; LABAKI, Lucila Chebel. Performance-based validation of climatic zoning for building energy efficiency applications. **Applied Energy**, Elsevier BV, v. 212, p. 416–427, fev. 2018. DOI: 10.1016/j.apenergy.2017.12.044. Disponível em: <https://doi.org/10.1016/j.apenergy.2017.12.044>.

WALSH, Angélica; CÓSTOLA, Daniel; LABAKI, Lucila Chebel. Review of methods for climatic zoning for building energy efficiency programs. **Building and Environment**, Elsevier BV, v. 112, p. 337–350, fev. 2017b. DOI: 10.1016/j.buildenv.2016.11.046. Disponível em: <https://doi.org/10.1016/j.buildenv.2016.11.046>.

WALSH, Angélica; CÓSTOLA, Daniel; LABAKI, Lucila Chebel. Review of methods for climatic zoning for building energy efficiency programs. English. **Building and Environment**, Elsevier Ltd, v. 112, p. 337–350, 2017c. cited By 22. ISSN 03601323.

DOI: 10.1016/j.buildenv.2016.11.046. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85006905669&doi=10.1016%2fj.buildenv.2016.11.046&partnerID=40&md5=0e0fa5e9e0338fd4a56ae0c70150c7fc>.

WALSH, Angélica; CÓSTOLA, Daniel; LABAKI, Lucila Chebel. Validation of the climatic zoning defined by ASHRAE standard 169-2013. **Energy Policy**, Elsevier BV, v. 135, p. 111016, dez. 2019. DOI: 10.1016/j.enpol.2019.111016. Disponível em: <https://doi.org/10.1016/j.enpol.2019.111016>.

WANG, Zhi-Hua; ZHAO, Xiaoxi; YANG, Jiachuan; SONG, Jiyun. Cooling and energy saving potentials of shade trees and urban lawns in a desert city. **Applied Energy**, v. 161, p. 437–444, 2016. ISSN 0306-2619. DOI: <https://doi.org/10.1016/j.apenergy.2015.10.047>. Disponível em: <http://www.sciencedirect.com/science/article/pii/S030626191501274X>.

WANG, Zhihao; XING, Wu; HUANG, Yi; XIE, Tongan. Studying the Urban Heat Island Using a Local Climate Zone Scheme. **Polish Journal of Environmental Studies**, HARD Publishing Company, v. 25, n. 6, p. 2609–2616, nov. 2016. DOI: 10.15244/pjoes/63672. Disponível em: <https://doi.org/10.15244/pjoes/63672>.

WEBGIS. **Worldwide - GTOPO30 Format - U.S. Geological Survey (USGS)**. [S.l.: s.n.], 2009. Accessed June, 2024. Disponível em: http://www.webgis.com/terr_world.html.

XIONG, Jie; YAO, Runming; GRIMMOND, Sue; ZHANG, Qiulei; LI, Baizhan. A hierarchical climatic zoning method for energy efficient building design applied in the region with diverse climate characteristics. **Energy and Buildings**, Elsevier BV, v. 186, p. 355–367, mar. 2019. DOI: 10.1016/j.enbuild.2019.01.005. Disponível em: <https://doi.org/10.1016/j.enbuild.2019.01.005>.

XU, Genyu; LI, Jinglei; SHI, Yurong; FENG, Xuming; ZHANG, Yufeng. Improvements, extensions, and validation of the Urban Weather Generator (UWG) for performance-oriented neighborhood planning. **Urban Climate**, Elsevier BV, v. 45, p. 101247, set. 2022. ISSN 2212-0955. DOI: 10.1016/j.uclim.2022.101247. Disponível em: <http://dx.doi.org/10.1016/j.uclim.2022.101247>.

YANG, X.; YAO, L.; JIN, T.; PENG, L.; JIANG, Z.; HU, Z.; YE, Y. Assessing the thermal behavior of different local climate zones in the Nanjing metropolis, China. **Building and Environment**, Elsevier BV, v. 137, p. 171–184, 2018. DOI: 10.1016/j.buildenv.2018.04.009. Disponível em:

<https://doi.org/10.1016/j.buildenv.2018.04.009>.

YANG, Xin-She. A new metaheuristic bat-inspired algorithm. In: NATURE inspired cooperative strategies for optimization (NICSO 2010). [S.I.]: Springer, 2010. P. 65–74.

YANG, Xinyan; LI, Yuguo; LUO, Zhiwen; CHAN, Pak Wai. The urban cool island phenomenon in a high-rise high-density city and its mechanisms. **International Journal of Climatology**, Wiley, v. 37, n. 2, p. 890–904, mai. 2016. DOI: 10.1002/joc.4747. Disponível em: <https://doi.org/10.1002/joc.4747>.

YAO, C.S. A new method of cluster analysis for numerical classification of climate. English. **Theoretical and Applied Climatology**, Springer Wien, v. 57, n. 1-2, p. 111–118, 1997. cited By 9. ISSN 0177798X. DOI: 10.1007/BF00867982. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-0031439032&doi=10.1007%2fBF00867982&partnerID=40&md5=0a56ecfbdd88874bf0795e04cc573a6e>.

ZHANG, Q. Climatic Zoning for the Thermal Design of Residences in China Based on Heating Degree-Days and Cooling Degree-Hours. English. **Journal of Asian Architecture and Building Engineering**, v. 4, n. 2, p. 533–539, 2005. cited By 5. ISSN 13467581. DOI: 10.3130/jaabe.4.533. Disponível em: <https://www.scopus.com/inward/record.uri?eid=2-s2.0-77953134152&doi=10.3130%2fjaabe.4.533&partnerID=40&md5=cf0d9b451fcf7beb25d784ab51aa07>.

ZHENG, Yingsheng; REN, Chao; XU, Yong; WANG, Ran; HO, Justin; LAU, Kevin; NG, Edward. GIS-based mapping of Local Climate Zone in the high-density city of Hong Kong. **Urban Climate**, Elsevier BV, v. 24, p. 419–448, jun. 2018. DOI: 10.1016/j.uclim.2017.05.008. Disponível em: <https://doi.org/10.1016/j.uclim.2017.05.008>.

ZOU, Jiwei; LU, Henry; SHU, Chang; JI, Lili; GAUR, Abhishek; WANG, Liangzhu (Leon). Multiscale numerical assessment of urban overheating under climate projections: A review. **Urban Climate**, Elsevier BV, v. 49, p. 101551, mai. 2023. ISSN 2212-0955. DOI: 10.1016/j.uclim.2023.101551. Disponível em: <http://dx.doi.org/10.1016/j.uclim.2023.101551>.

Apêndices

APÊNDICE A – ARTIGO 1 - ZONEAMENTO BIOCLIMÁTICO BRASILEIRO

Na sequência é apresentado na íntegra o artigo intitulado "*Bioclimatic zoning for building performance using tailored clustering method and high-resolution climate data*". Esse artigo foi publicado na revista Energy and Buildings com o DOI "<https://doi.org/10.1016/j.enbuild.2024.114157>".

AUTORIA COMPARTILHADA

Esse documento atesta que todos os coautores do artigo intitulado “*Bioclimatic zoning for building performance using tailored clustering method and high-resolution climate data*” CONCORDAM com o seu uso como parte da tese de doutorado de Rayner Maurício e Silva Machado, orientada pelo professor Roberto Lamberts e coorientada pela professora Ana Paula Melo do Programa de Pós Graduação em Engenharia Civil (PPGEC) da Universidade Federal de Santa Catarina (UFSC).

Autores: Rayner Maurício e Silva Machado, Facundo Bre, Leonardo Mazzaferro, Ana Paula Melo, Roberto Lamberts

Revista: Energy and Buildings

DOI: <https://doi.org/10.1016/j.enbuild.2024.114157>



Facundo Bre

Documento assinado digitalmente
 LEONARDO MAZZAFERRO
Data: 17/07/2024 10:42:33-0300
Verifique em <https://validar.itd.gov.br>

Leonardo Mazzaferro

Florianópolis, 16 de Julho de 2024.

1 Bioclimatic zoning for building performance using tailored clustering method and
2 high-resolution climate data

3 Rayner Maurício e Silva Machado^a, Facundo Bre^{b,c}, Leonardo Mazzaferro^a, Ana Paula Melo^a, Roberto Lamberts^a

4 ^a*Laboratory of Energy Efficiency in Buildings (LabEEE), Department of Civil Engineering, Federal University of Santa Catarina
5 (UFSC), Florianópolis, Brazil*

6 ^b*Institute of Construction and Building Materials, Technical University of Darmstadt, Darmstadt, 64287, Germany*

7 ^c*Centro de Investigación de Métodos Computacionales (CIMEC), UNL, CONICET, Predio "Dr. Alberto Cassano", Colectora Ruta
8 Nacional 168, Paraje El Pozo, 3000, Santa Fe, Argentina*

9 **Abstract**

10 Building environments are specific and complex bioclimatic systems. Thus, well-suited climate classification methods
11 for buildings are essentially needed to develop building design guidelines and standards. To address it, the present
12 research introduces a novel fit-for-purpose clustering method for bioclimatic zoning based on the hygrothermal and
13 energy performance of buildings. This bioclimatic zoning was developed to update the Brazilian standard and has
14 been validated across various climates and building typologies (residential and commercial) in Brazil. In a preliminary
15 analysis, three classification methods were developed using K-means and Decision Tree to classify climates according
16 to building performance. Subsequently, a final bioclimatic zoning method was developed using a tailored version of
17 the best method designed for real-world applications (Decision Tree) in the Brazilian context. The performance of the
18 bioclimatic zoning achieved was compared with three existing climate classifications: Köppen-Geiger, ASHRAE 169-
19 2020, and ABNT-NBR 15220-3 (Brazilian Standard). The results showed that the new bioclimatic zoning method
20 outperformed the existing ones to cluster the building performance indicators. Moreover, high-resolution spatial
21 climate databases, such as NASA-POWER, CRU, and ERA5-Land, were processed and analyzed to be employed in
22 locations without properly measured data. Three metamodels of climate indicators were developed and compared
23 with these databases to select the most accurate climate data sources. Finally, these databases were employed to
24 classify all 5570 Brazilian municipalities according to the final bioclimatic zoning, which enabled the development of
25 an accurate and high-resolution map.

26 **Keywords:** Climatic zoning, Clustering analysis, Metamodel, Building Performance.

27 **Highlights**

- 28
- 29 • Development of a novel fit-for-purpose bioclimatic zoning based on hygrothermal and energy performance of
30 buildings.
 - 31 • The new method outperformed existing climate classifications: Köppen-Geiger, ASHRAE 169-2020, and ABNT-
32 NBR 15220.
 - 33 • Analysis and validation of high-resolution climate databases: ERA5-Land, NASA-POWER and CRU.
 - 34 • Development of climate indicator metamodels for a more accurate climate classification.

- 35 • Classification of 5570 Brazilian municipalities, generating an accurate and high-resolution map.

36 **List of Symbols**

Symbol	Description
ABNT	Brazilian Association of Technical Standards
ANN	Artificial Neural Networks
ASHRAE	American Society of Heating, Refrigerating and Air-Conditioning Engineers
CgTa	Annual heating thermal load
CgTr	Annual cooling thermal load
CRU	Climatic Research Unit
DBTamp	Annual mean of daily dry-bulb temperature amplitude
DBTmean	Annual mean dry-bulb temperature
DPTmean	Annual mean dew point temperature
ERA5	ECMWF Reanalysis v5
GHRmean	Annual mean of daily global horizontal radiation
HDD14	Heating degree-day using 14 °C as the base temperature
HVAC	Heating, Ventilation and Air Conditioning
IBGE	Brazilian Institute of Geography and Statistics
IDW	Inverse Distance Weighted
INI-C	Standard for energy efficiency of commercial, services, and public buildings
ISD	Integrated Surface Database
KPIs	PHiFT, PHsFT, CgTa, and CgTr
MAE	Mean Absolute Error
MAX.ERROR	Maximum Error
NASA-POWER	Prediction Of Worldwide Energy Resources (NASA)
NBR	Brazilian Standard
PHiFT	Percentage of hours with an operative temperature below 18 °C
PHRi30	Percentage of hours with a relative humidity below 30%
PHRs70	Percentage of hours with a relative humidity above 70%
PHsFT	Percentage of hours with an operative temperature above 26 °C
PV	Photovoltaic System
R ²	Coefficient of Determination
RHmean	Annual mean relative humidity
RMSE	Root-Mean-Square Error
SGD	Stochastic Gradient Descent
SOM	Self-Organizing Map
TIN	Triangulated Irregular Network
TMY	Typical Meteorological Year
TRY	Test Reference Year
WSmean	Annual mean wind speed

37 **1. Introduction**

38 Climate change has involved scientists from various areas of knowledge to reduce the environmental impact
 39 caused by agents that can negatively change the natural cycle of the climate system. One of the main aspects
 40 to be faced and mitigated worldwide is the use of fossil fuels [1, 2] and energy consumption in buildings [3, 4].
 41 In this context, the idealization of a world with a more sustainable consumption profile justifies regulations with
 42 a strong environmental appeal, especially regarding buildings. One way to achieve more effective standards is to
 43 establish well-founded analysis methods to turn building designs more suitable for the climate. As these standards
 44 establish their applicability in a limited territorial context, which has implicit climatic diversity, climate zoning allows

45 generalizing guidelines according to the climatic types included in the covered area. Therefore, the ability to group
46 similar climates makes zoning a powerful tool for generalizing recommendations and predicting results [5].

47 When a building is evaluated in several climates, the behavior should be similar in those locations with the same
48 climate classification. Therefore, when a study concludes that a particular system or even a bioclimatic strategy
49 may be inappropriate for a location, it is likely that similar behavior will be observed in other areas that have the
50 same climate classification [6]. However, this assertion will only be valid if the system studied is susceptible to the
51 climate, and the climate zoning considers climate indicators that affect the system's response [7, 8].

52 In the current literature, climate zoning is widely used to generalize architectural solutions [9], to establish the
53 behavior of photovoltaic modules [10], to size air conditioning systems, and to design rainwater harvesting systems [11]
54 and wind turbines [12]. Thus, constructing a single climate classification for all purposes may not be workable since
55 the sensitivity of climate indicators is different according to the considered system. For example, in zoning dedicated
56 to photovoltaic systems (PV), solar radiation is the primary indicator to establish the PVs' energy production level
57 [13]. However, outdoor temperatures are more relevant for climate zoning regarding building thermal performance
58 [5]. Thus, there is a strong possibility that a particular climate zoning will be accurate for one purpose but less for
59 other applications.

60 Limitations can be found in existing climate classification methods. For example, Köppen-Geiger is not very
61 accurate for the energy efficiency of buildings [8], even though it is cited in many studies related to the subject
62 [14]. The current bioclimatic zoning of ABNT-NBR 15220 [15] also proved to be not very accurate [8], and needs
63 to be updated, since the current version is from 2005. Overall, ASHRAE 169-2020 [16] proved to be accurate [8],
64 however, in Brazil, it groups climates into a few climate zones, which means that regions with different climatic and
65 environmental characteristics are in the same climate zone. Although ASHRAE 169-2020 classifies only a few cities
66 here in Brazil, there is a map that allows you to understand the climate behavior of each Brazilian region. Still,
67 the resolution of this map is not very high. Furthermore, ASHRAE 169-2020 has difficulty separating dry and wet
68 areas in Brazil. All of this justifies the development of a new fit-for-purpose bioclimatic zoning that solves all the
69 limitations listed here.

70 It is possible to find several studies that deal with climate zoning for diverse purposes. However, there are only a
71 few research efforts regarding the development of climate zoning to evaluate the thermal and energy performance of
72 buildings. Building energy simulation was recently incorporated into developing climate zoning methods to establish
73 a climate classification method suitable for a particular purpose. In addition, this simulation-based approach also
74 allows for validating any existing climate zoning [6–8]. However, building energy simulation requires representative
75 weather data, e.g., typical meteorological years (TMYs), information often limited by the number of meteorological
76 stations available worldwide.

77 Climate zoning is usually constructed with historical climate data that helps the clustering process [17, 18]. The
78 choice of climate indicators used in the zoning development method may be related to the availability and quality
79 of the database. Thus, solar radiation data quality is a critical problem observed in the literature [19], especially
80 regarding the decomposition of global radiation into direct and diffuse, usually performed through mathematical
81 models [20, 21]. The uncertainty of these models implies less reliability in solar radiation data. The geographical
82 distribution of the available measured climate data is another critical issue for developing more comprehensive zoning

[22], since locations without climate data will always exist worldwide. Therefore, developing methods to overcome these circumstances is vital to developing reliable zoning.

Omarov et al. [23] developed a climate classification method based on the cooling and heating degree-day and energy consumption of a small office building. The degree-day indicators were calculated using hourly data from TMYs, and the energy consumption was obtained through EnergyPlus simulations. To ensure suitable climate diversity for the analysis, the authors previously selected 90 locations around the world according to the Köppen-Geiger climate classification. As for the climate data, a comparison of the degree-days of two periods of TMY was performed. Four heating and cooling degree-day calculation techniques were analyzed, and the best one was finally selected. New zones were proposed when the cities showed inconsistent values for degree-days and energy consumption. Only the locations that had TMYs were analyzed and classified, and no detailed territorial maps containing the classification were developed. The study was conducted using only one commercial building typology to evaluate energy consumption. Residential buildings and buildings using natural ventilation are not evaluated.

Walsh et al. [24] established a climate zoning method based on the energy performance of 52 building archetypes. These building models were simulated using the EnergyPlus software. K-means was the clustering method used to establish the zoning, which considered the results of heating and cooling energy demand as inputs. Climate variables are not directly considered by this zoning method. The proposed method was applied in a case study developed in the southeastern United States of America, producing maps based on 3, 4, and 5 climatic zones. Based on the energy performance of archetypes, the established groupings were compared with the ASHRAE 169-2013 and ASHRAE 169-2009 zoning, using the Mean Percentage of Misclassified Areas as the indicator. The authors considered only the demand for cooling and heating as indicators of building performance to develop and evaluate zoning methods. Therefore, the humidity level was not used to characterize the different climates, and natural ventilation was not considered in the building performance simulation.

Li et al. [25] emphasize that the validation of climate zoning methods is typically limited. For this reason, they developed an indicator to evaluate zoning methods and applied it in the Chinese climate context. A new zoning method based on the K-means method was proposed and compared with two existing methods. For this proposal, using principal component analysis, the number of inputs was reduced from 7 climate variables to 4 principal components. The proposed method was the one that presented the best results. It is worth noting that the proposed indicator used in the assessment considered only climate data to perform the calculation.

Brazil is a large country that currently has a zoning based on bioclimatic strategies (ABNT-NBR 15220-3 [15]), which groups locations into eight bioclimatic zones. However, Mazzaferro et al. [8] demonstrated that bioclimatic zoning is inaccurate for energy applications, requiring the development of a fit-for-purpose climate zoning. To conduct the study, the authors considered the cooling thermal loads of office buildings, being uncertain how the behavior would be for dwellings, naturally ventilated buildings, and heating thermal loads. Moreover, the authors considered that the ASHRAE Standard 169-2020 is a reliable climate zoning for building energy applications because it considers aspects regarding moisture, cooling, and heating. This zoning method groups the Brazilian territory into nine zones, with four macro-zones based on thermal characteristics, ranging from extremely hot to warm. The cooling thermal load is predominant in most Brazilian municipalities, but the heating loads are also present in the coldest regions and cannot be discarded. Given the current zoning standard and the particular characteristics of Brazilian climates,

121 the development of new fit-for-purpose building zoning with a high resolution (i.e., municipality level) would be a
122 valuable contribution to advancing the building energy regulations of the country.

123 These previous studies leave aside aspects regarding the best method to classify locations without meteorological
124 stations. Furthermore, the quality of climate databases is not analyzed in depth, despite this being essential for
125 accurate classification. The development of new climate zoning methods based on the energy performance of buildings
126 is not entirely novel. However, most of the current achievements are isolated efforts with a lack of a detailed framework
127 for all the important methodology stages, which prevents generalization in several locations and building typologies.

128 Due to these needs and challenges to achieve a well-suited bioclimatic zoning for building regulations, a working
129 group started updating the bioclimatic zoning of ABNT-NBR 15220-3 [15], establishing a new zoning proposal. Two
130 main proposals have emerged from this working group. One of the proposals was recently published by Walsh et al.
131 [26], and the other proposal is described in this article, which is the one selected to be sent for public review. During
132 the development of the final version, the two proposals benefited from each other.

133 The proposal developed by Walsh et al. [26] considers that the climate can be grouped through building per-
134 formance indicators, i.e., assuming the climate indirectly. For this, the authors grouped the climates by applying
135 K-means to the thermal load, thermal discomfort, and mold risk data of 100 variations of a residential archetype.
136 Initially, the authors separated the Brazilian territory into macro-zones, delimiting the regions that have energy
137 demand for artificial heating and cooling and another macro-zone where there is only the need for cooling, being
138 divided into two and eight groups, respectively. The study was developed and validated for residential buildings and
139 has not been validated for commercial buildings.

140 Both proposals addressed the challenge of classifying cities lacking climate data. Walsh et al. [26] performed a
141 linear interpolation and the opinion of specialists to classify the Brazilian municipalities without valid weather files.
142 Because these studies were developed simultaneously, the proposals have some similarities, but notable differences
143 are also evident.

144 Therefore, the present paper aims to propose and validate a novel fit-for-purpose bioclimatic clustering method-
145 ology based on the hygrothermal and energy performance of buildings in Brazil. Several contributions were achieved
146 related to this work, such as the validation of climate databases, sensitivity analysis according to climate indicators
147 and building performance indicators, validation in residential and commercial buildings, analysis of three clustering
148 protocols, contingency analysis, and validation of climate zoning methods. Furthermore, a major contribution was
149 attained regarding the generalization of the classification throughout all climates and municipalities in Brazil by a
150 novel combination of artificial neural network-based interpolations with a reanalysis climate database.

151 **2. Methodology overview**

152 This section presents an overview of the methods used in this study. This will make it easier to understand how
153 the study was conducted, but more details on each method will be presented throughout the text. For a better
154 visualization of the processes, Figure 1 shows each step taken to develop the proposed bioclimatic zoning, where each
155 step is identified according to its respective section.

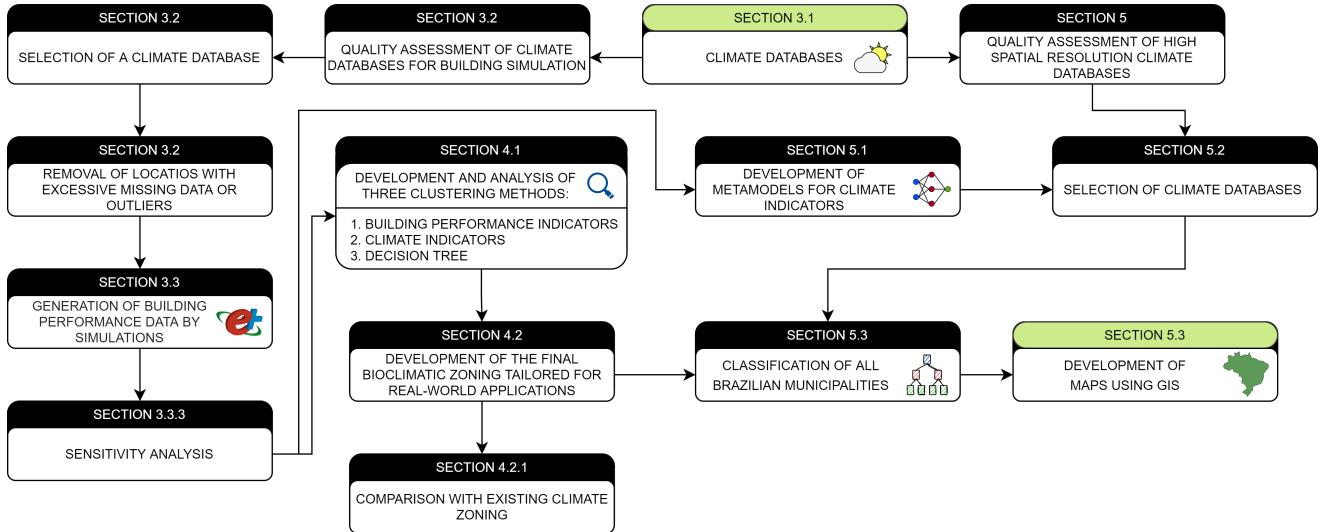


Figure 1: Flowchart of the methods used in this study.

156 In studies regarding the development of zoning methods, climate data are an important part of the process.
 157 Section 3.1 presents a description of the main climate databases. The quality of these databases is later analyzed.
 158 This analysis allowed filtering only the best-qualified databases. As can be seen, the climate data were divided
 159 into two main groups: hourly climate data for computational simulation and establishment of the zoning method
 160 (Section 3.2); and climate data with high spatial resolution represented by climate indicators to classify each Brazilian
 161 municipality according to the previously developed bioclimatic zoning method (Section 5).

162 The climate data used in the building energy simulations represent the climatic behavior observed in meteorolog-
 163 ical stations in a pre-established period. This behavior is primarily established through TMYs. They are generally
 164 available in EPW format for use in computational simulations using the EnergyPlus (Section 3.3) software. Thus,
 165 several building typologies (Section 3.3.1) were simulated in all best-qualified TMY files. Furthermore, through the
 166 climate variables contained in these files, climate indicators are calculated and used to establish new zoning methods.
 167 Furthermore, in this study, a sensitivity analysis was performed between climate indicators and building performance
 168 indicators (Section 3.3.3). Through this analysis, it was possible to verify which climatic variables had the greatest
 169 impact on the performance of the evaluated buildings. With this information, it is possible to identify the typology
 170 that is more sensitive to climate, which was used to develop the bioclimatic zoning.

171 A preliminary analysis was performed with three classification methods (Section 4.1) based on: (1) building
 172 performance indicators, (2) climate indicators, and (3) Decision Tree. The building-based method considers K-
 173 means applied to building performance indicators. The climate-based approach involves the application of K-means
 174 to climate indicators. It is important to point out that in the Decision Trees, climate indicators are considered
 175 inputs and building performance indicators are outputs. In this preliminary analysis, several zone numbers, building
 176 performance indicators, and climate indicators were included in the clustering process. Thus, it was possible to
 177 identify the best clustering approach for real-world applications in the Brazilian context. This selected clustering
 178 approach was used to develop the final bioclimatic zoning (Section 4.2). A working group previously established
 179 some characteristics that the proposal should contemplate. This final proposal was compared (Section 4.2.1) with

180 ABNT-NBR 15220-3 (2005), Köppen-Geiger, and ASHRAE 169.

181 As the number of locations with TMYs tends to be limited because of the number of meteorological stations (Section
182 3.2), it is only possible to develop a new bioclimatic zoning method and classify these few locations. Therefore,
183 to classify the other municipalities, it was necessary to use other climate databases with better spatial resolution
184 (Section 5). In this context, metamodels of climate indicators (Section 5.1) were developed for the annual mean dry-
185 bulb temperature, relative humidity, and HDD14. These metamodels were compared with databases (Section 5.2)
186 derived from models, interpolations, and satellite data, allowing the choice of the most adequate approach. Finally,
187 after choosing the database for each climate indicator, a high-resolution map was generated using QGIS software
188 (Section 5.3).

189 **3. Analysis of climate and building simulation databases**

190 Before starting the development of bioclimatic zoning, analyzes related to climatic databases and computational
191 simulations of buildings were performed. Thus, in this section there is a description of the main climate databases,
192 selection of one of them to use in computational simulation and in establishing bioclimatic zoning, characterization of
193 building typologies, description of building performance indicators used in computational simulation, and a sensitivity
194 analysis that relates climatic data and building performance data.

195 *3.1. Existing climate databases*

196 When the investigation focuses on building energy simulations, the climate data can be presented as design
197 days or through annual weather files with hourly values. Design days allow the sizing of equipment through the
198 determination of operating peaks [27]. Considering that the work detailed in this article intends to establish qualified
199 climatic zoning to group the annual performance of residential and commercial buildings, the data from design days
200 was disregarded.

201 Weather files are used in building energy simulation to analyze the annual thermal performance of buildings
202 [23], which are established by methods, such as Test Reference Year (TRY) and TMY. These files can be accessed
203 on the Climate.OneBuilding.Org [28] repository, which has weather files available for a wide range of locations
204 worldwide. Considering the Brazilian territory, it is possible to find weather data files compiled according to the
205 following types: TMYx, TMYx.2004–2018, TMYx.2007–2021, INMET, and TRY. That repository previously con-
206 tained TMYx.2003–2017, later replaced by TMYx.2004–2018. Bre et al. [19] described these databases, noting that
207 the TMYs are developed using hourly data measured at meteorological stations and made available by the Integrated
208 Surface Database (ISD) repository.

209 Data reliability from meteorological stations is usually high if the measuring equipment is calibrated correctly.
210 However, the number of meteorological stations in each territory is limited. This prevents buildings from having
211 their thermal performance simulated in a location without a meteorological station. When these data are applied
212 in a climate classification process where each location of a particular territory must be classified, such data are
213 insufficient. Therefore, it is necessary to use databases with better spatial resolution to apply a climate zoning
214 method in locations without meteorological stations. Table 1 presents the spatial resolution of the main climate
215 databases that are currently available.

Table 1: Spatial resolution of main climate databases available

	CRU	NASA-POWER	ERA5-Land
Latitude	0.5°	0.5°	0.1°
Longitude	0.5°	0.625°	0.1°

To establish data with a better spatial resolution, it is possible to use interpolation methods that start from measured data, thus determining the behavior of locations that do not have meteorological stations. A database built similarly to this one is the Climatic Research Unit (CRU), which has a spatial resolution of 0.5° of latitude and 0.5° of longitude. Among the variables, this database has dry-bulb temperature and precipitation [29], but they are available on a monthly scale.

Using satellite-derived data is another possibility for developing a spatially more comprehensive database. NASA-POWER [30] is an excellent example of a database using satellite-derived data coupled with models. Its spatial resolution is 0.5° x 0.625° [31]. This database has a platform that provides a series of climate variables. One possibility is downloading climate data already compiled in EPW format, which can be used in building energy simulations. It is possible to get data on hourly, daily, monthly, and annual scales.

ERA5-Land [32, 33] has the best spatial resolution, with 0.1° latitude and 0.1° longitude. This base was built using data from climate reanalysis, which considers the use of models, observations, and laws of physics. This database has dry-bulb temperature, dew point, wind speed, solar radiation, and precipitation, among other variables. These climate variables can be obtained on an hourly and monthly scale.

3.2. On the quality of existing climate databases for building performance simulation

The initial stage in the development of bioclimatic zoning for building performance involves evaluating the characteristics and quality of climate databases. It makes the building energy simulation more reliable and makes the final classification more accurate. Working with low-uncertainty data in weather data and building energy simulation data favors the accuracy of the zoning method. Therefore, it is important to select reliable weather data to provide high-quality building performance data through simulation. Most existing methods classify each location according to monthly or annual climate indicators. However, for zoning driven by annual building performance simulations, high-quality hourly weather data is necessary, containing variables measured at meteorological stations.

An exploratory analysis was performed on four weather file databases (the INMET and three versions of TMYx) to define the most suitable for the clustering protocol. Here, the reliability of the climate data is analyzed according to the historical representativeness, number of locations, amount of missing data, and outliers. It is important that each location properly represents the historical series and be well spatially distributed. For this to occur, it is essential that the historical series be free of significant periods with missing data and that the number of locations be as large as possible. To understand how the databases behave in these two aspects, Figure 2a shows the number of years present in each weather file, and Figure 2b establishes the number of locations.

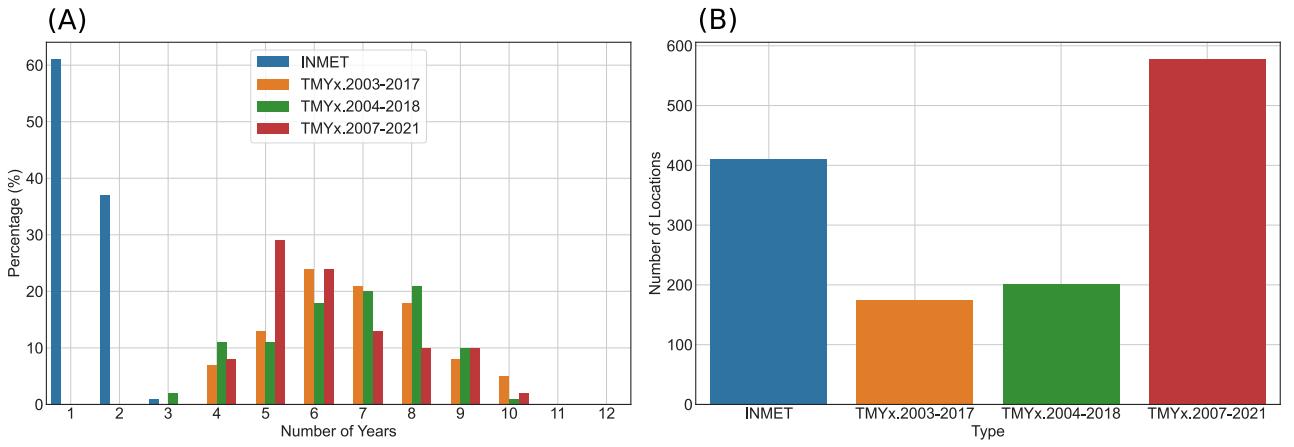


Figure 2: Percentage of years per climate present on each database (A) and number of locations per database (B).

The histograms show the INMET having over 60% of locations with only one year, thus being practically an actual year. In the INMET database, the maximum was three different years out of 12 possible. For the other databases, such values show higher variability, with medians between 5 and 8 years. The documentation describes that the INMET files have data from 2001 to 2010. However, there is a sign that the INMET was derived from measured data with substantial limitations in availability. This assumption is confirmed since the number of meteorological stations has increased, mainly between 2006 and 2008, from 154 locations to 417. Thus, only the last two versions of TMYs will be analyzed in Figure 3.

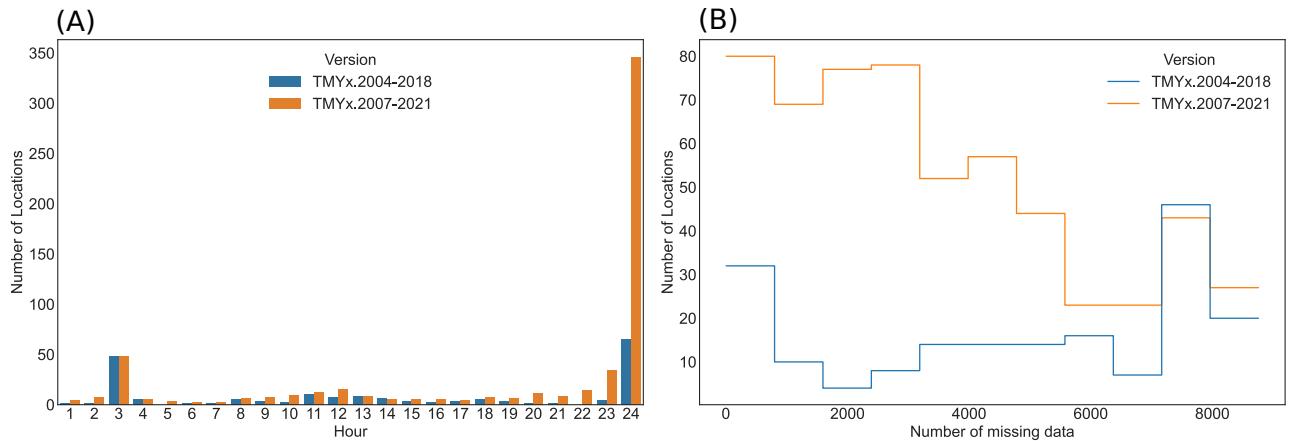


Figure 3: Histogram of the number of locations according to the number of hour measured per day (A) and histogram of the number of locations according to the sum of hours with missing data along the year in TMYx.2004-2018 and TMYx.2007-2021 (B).

It is necessary to follow some procedures to fill in missing data and analyze the combination of months to define a typical meteorological year with a behavior close to that presented by the historical series to compile a weather file. To check the missing data for each TMY version, each typical month was compared with the respective historical series data available on the ISD-Lite platform [34]. According to Figure 3a, it is possible to see that TMYx.2007-2021 has many meteorological stations with 24 hours of measurements. However, the results also show that in both versions of

257 the TMY databases, some locations do not take measures at all hours of the day. When these measurements are not
258 conducted 24 hours a day, filling in the missing data is necessary, which introduces uncertainty in the reliability of
259 the processed data. Missing data can also occur because of missing measurements, such as power failure, equipment
260 breakdown, maintenance, etc. Figure 3b presents missing data over the year, showing that the most recent version
261 of TMY has more measured data than TMYx.2004-2018. One possibility to improve the reliability of the database
262 is to remove locations when they have several missing data measurements greater than a specific limit. As several
263 locations have much missing data and problems with values greater or less than expected, only 298 weather files that
264 met the criteria presented in Appendix A were selected to be used in the clustering protocol.

265 To summarize this section, the INMET database has unreliable data regarding the representativeness of the
266 historical series, even presenting a considerable number of weather files. The databases of TMYs show a satisfac-
267 tory number of years within their typical meteorological months, and TMYx.2007-2021 has the greatest number
268 of locations and fewer missing data. Therefore, the TMYx.2007-2021 database was chosen to be part of the other
269 detailed procedures in this study. Nevertheless, 279 locations with outliers or large numbers of missing data have
270 been removed from the TMYx.2007-2021 database, so 298 weather files remained.

271 *3.3. Generation of building performance data by computational simulations*

272 In the zoning method proposed in this article, it is essential to establish a hygrothermal and energy database via
273 computational simulation of commercial and residential buildings. It is important to choose the building typology,
274 since the building performance can significantly vary depending on its construction, geometric characteristics, the
275 solar absorptance of external surfaces, internal loads, and operating patterns. The hygrothermal and energy perfor-
276 mances of the building need to be quantified through performance indicators. This study uses pre-established metrics
277 in the simulation method of ABNT-NBR 15575 [35–37] and two performance indicators to detail how indoor relative
278 humidity behaves. Including moisture-related performance indicators occurred to make the zoning method aligned
279 with bioclimatic aspects. Through such performance indicators, it will be possible to understand how each typology
280 behaves against the climate indicators. These typologies were simulated using version 9.0 of the EnergyPlus software
281 for the selected 298 locations with good-quality weather files from the TMYx.2007–2021 database.

282 *3.3.1. Building typologies*

283 To analyze whether the proposed climate zoning method would apply to different typologies, it is important to
284 verify the hygrothermal and energy performance of naturally ventilated and artificially conditioned buildings against
285 the climate indicators using sensitivity analysis. For this end, models of artificially conditioned offices and mix-
286 mode residential buildings (naturally ventilated and artificially conditioned) were used, as shown in Figure 4. The
287 residential building was also used to develop the Brazilian standard ABNT-NBR 15575 [37], and is a representative
288 building typology for social housing in Brazil [38]. The commercial building was used to develop the Brazilian
289 standard for energy efficiency in commercial, service and public buildings known as INI-C [39].

290 Two sets of constructive components were evaluated in the sensitivity analysis of each building typology: a low-
291 energy performance model (reference building) and another with a high-energy performance (target building). The
292 office buildings follow the procedures presented in Inmetro Normative Instruction for the Classification of energy
293 efficiency of commercial, services, and public buildings (INI-C) [40], and residential buildings are modeled according

294 to the procedures of a Brazilian technical standard for thermal performance of residential buildings, published by
295 the Brazilian Association of Technical Standards (ABNT-NBR 15575 [37]).

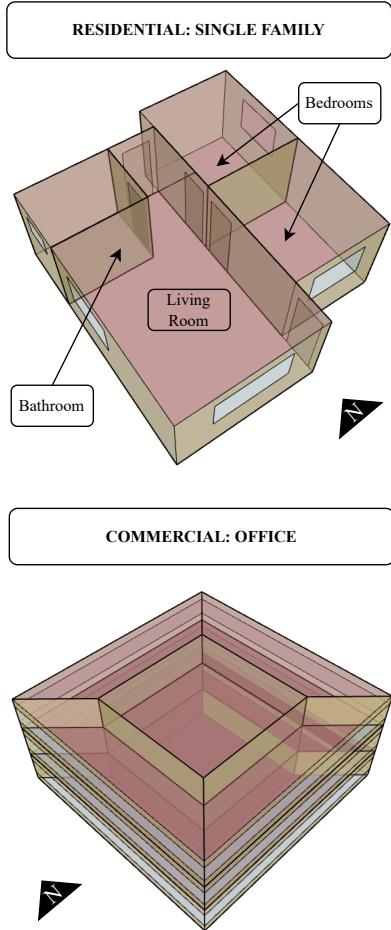


Figure 4: Commercial and residential buildings that were used for bioclimatic zoning development and validation.

296 For the low-performance model, reference cases were used according to INI-C [40] for office buildings, and ABNT-
297 NBR 15575 [37] for residential buildings. Therefore, on the walls of the office-building model, hollow brick coated
298 with mortar was used, and on the residential building, 10 cm of concrete was used. The office-building model has
299 solar absorptances of 0.5 and 0.8 for the external walls and roofs, respectively. The residential building has solar
300 absorptances of 0.58 and 0.65 for the exterior walls and roofs, respectively. Both models feature clear single-pane
301 glass.

302 In the high-performance model of commercial and residential buildings, the Light Steel Frame system was used.
303 The solar absorptance of the external wall was 0.38 and 0.35 for the roof and double-glazing. The office building has
304 solar control glass, and the residential building uses shutters with horizontal fins and a 45° angle, which are activated
305 when the external temperature is above 26 °C.

306 More information about the building envelope is in Table B.6. However, further information about the modeling
307 of these building typologies also can be found in [19], where all these models were used to evaluate the impact of the
308 quality of solar radiation data on the performance of buildings in Brazilian climates. Figure 5 shows the occupancy
309 and the internal gain from people, lights, and equipment.

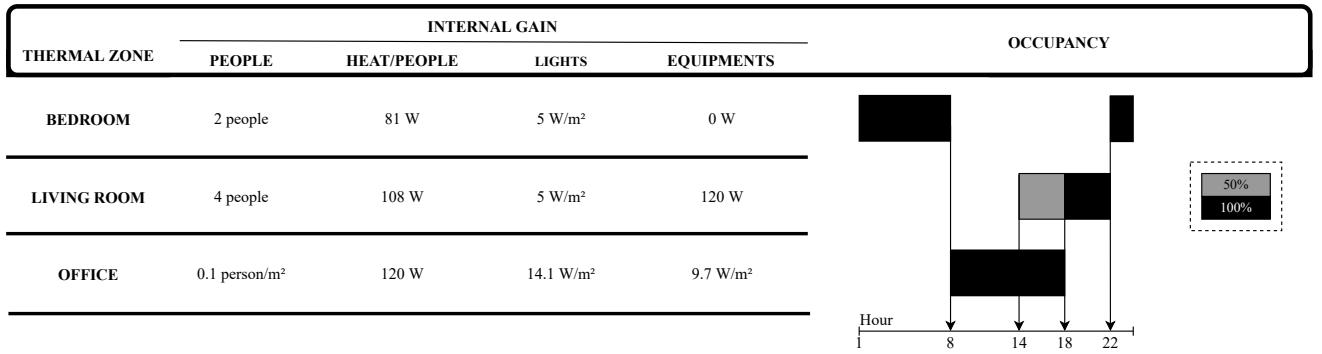


Figure 5: Occupancy and internal gain of residential and office building models.

3.3.2. Building performance indicators

To evaluate the energy performance of office models, total cooling ($CgTr$) and heating ($CgTa$) thermal loads were employed. These thermal loads were calculated considering only occupied hours by users. A setpoint temperature of 18°C for heating and 24°C for cooling was considered in calculating these indicators. For this typology, it was defined that each zone has a constant infiltration rate of 0.3 air changes per hour, and the air conditioning system has a flow of $0.0075 \text{ m}^3/\text{s}$ for the external air flow per person.

For performance indicators regarding residential buildings, indicators regarding hygrothermal comfort (PHsFT, PHRs70, and PHRi30) and energy consumption ($CgTa$ and $CgTr$) were used. The indicators related to hygrothermal comfort were obtained by simulating a naturally ventilated building model, and the energy consumption was obtained from an artificially conditioned building model. The PHsFT can be understood as the percentage of occupied hours where the operative temperature is above 26°C , and the PHiFT is the percentage when this operative temperature is below 18°C . Therefore, PHiFT and PHsFT can be understood as discomfort occasioned by cold and heat, respectively. PHRs70 is the percentage of occupied hours where the relative humidity inside the building is greater than 70%, and PHRi30 is the percentage of occupied hours where the relative humidity is lower than 30%. $CgTa$ is the sum of the heating thermal load of the artificially conditioned model when the indoor operative temperature of the naturally ventilated model is lower than 18°C during occupied hours. The calculation of the $CgTr$ is like the $CgTa$, but the sum of the cooling thermal load of the artificially conditioned model occurs when the operative temperature of the naturally ventilated model exceeds 26°C . $CgTa$ and $CgTr$ are indicators calculated by the EnergyPlus software using ideal loads. All indicators consider only the building zones that have been occupied for a long time, such as living rooms and bedrooms. For the PHsFT and PHiFT, an average is made between the thermal zones. Regarding the PHRs70 and PHRi30, the thermal zones with the highest value is selected. To determine the $CgTr$ and $CgTa$, the sum of the thermal load in all thermal zones is calculated.

3.3.3. Correlation between climate data and building performance indicators

To understand how the hygrothermal and energy performance indicators of buildings behave regarding the climate indicators, a sensitivity analysis is conducted using the coefficient of determination, which is presented in Figure 6. The results show that the reference residential and commercial typologies are more sensitive to dry-bulb temperature, especially for PHsFT and $CgTr$. The correlation of $CgTa$ with dry-bulb temperature was slightly lower, but within what is understood as a correlation. Moreover, heating degree-day using 14°C as the base temperature (HDD14)

338 is strongly correlated with performance indicators related to heating or cold discomfort. Several base temperatures
 339 (10 °C to 24 °C) for heating degree-day were analyzed and 14 °C presented the best results for Brazil. Relative
 340 humidity was the most sensitive indicator for PHRs70 and PHRi30, and these performance indicators also showed
 341 some correlation with daily global horizontal radiation, dew point, and thermal amplitude. This analysis clarifies
 342 that using dry-bulb temperature and external relative humidity to describe the performance of buildings is entirely
 343 workable. The external relative humidity (RHmean) was more impactful for the indicators regarding internal relative
 344 humidity, despite its correlation value being lower than observed in other performance indicators. In wind speed, its
 345 sensitivity was almost insignificant in all hygrothermal and energy performance indicators; however, it is understood
 346 that it is very important for specific cases, such as removing internal heat or moisture.

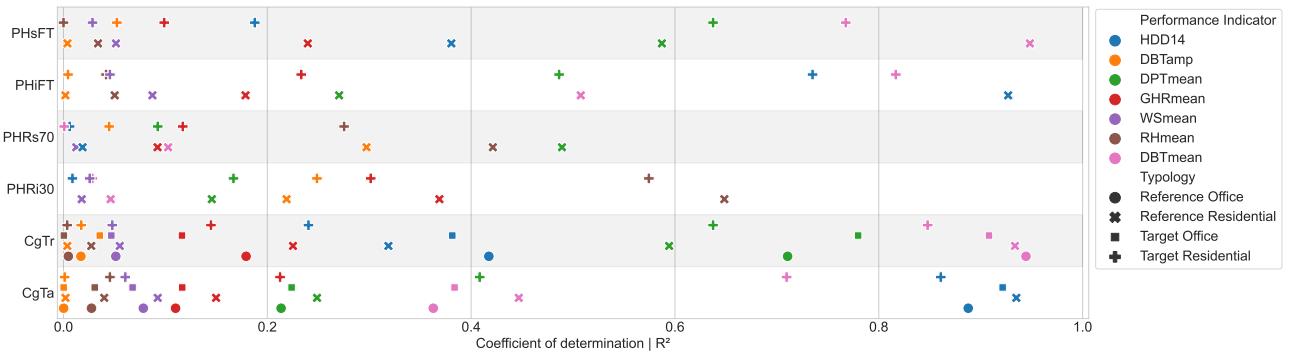


Figure 6: Sensitivity index of climate indicators against performance indicators for residential and commercial buildings.

347 This sensitivity analysis shows that these typologies may respond slightly differently to climates, but the general
 348 trends remain the same. This suggests that only one typology may be sufficient if the climatic detailing is restricted
 349 to the most sensitive indicators. A positive point about using reference typologies for bioclimatic zoning is that
 350 they are often observed in the building stock and are always modeled to assess the level of the thermal or energy
 351 performance of buildings, as occurs in ABNT-NBR 15575 [37] and INI-C [40], respectively. Furthermore, the chosen
 352 single-family residential building is more exposed to the weather than a commercial building. Because of this, the
 353 bioclimatic zoning was developed considering the reference typology of the residential building and later validated
 354 with other typologies. In addition, the reference typologies have a strong correlation with the dry-bulb temperature,
 355 especially when considering the cooling load that is predominant in the Brazilian context.

356 4. Development and analysis of climate zoning methods

357 This section investigated the accuracy of three clustering techniques for zoning applications. Two employ parti-
 358 tioning methods applied to building performance indicators or climate indicators. The last one is established by
 359 supervised machine learning, using climate indicators as inputs and performance indicators as model outputs. Within
 360 each method, various combinations of climate indicators, performance indicators, and the number of clusters were
 361 analyzed. This allows for a comprehensive analysis of which zoning method has the best cost-benefit compared to
 362 building performance and its respective ease of implementation in the real world. As the final bioclimatic zoning has
 363 practical purposes, each criterion in the proposal is detailed and justified. This final proposal and existing zoning

364 methods are evaluated by contingency analysis and performance metrics. The first one allows us to understand how
365 this new method reallocates the zones of each existing zoning. The last one establishes scores for each climate zoning
366 method, considering the performance indicators of commercial and residential buildings.

367 *4.1. Proposals for climate zoning methods*

368 The three evaluated methods here are based on building performance (Section 4.1.1), climate indicators (Section
369 4.1.2), and decision trees (Section 4.1.3). The first two methods use K-means applied to building performance or
370 climate indicators, while the decision tree considers both climate and building performance indicators simultaneously.
371 The number of climate groups varied from 6 to 12. In the climate-based method, 127 combinations of climate
372 indicators were considered for a comprehensive analysis. For the performance-based and decision tree methods, the
373 performance indicators of the building were the same as those presented in Section 3.3.2 for the reference typology
374 of residential buildings.

375 The development and evaluation of the proposed zoning methods were conducted using the Scikit-Learn module
376 of the Python programming language. Each proposal was evaluated using the Silhouette score [41] and the Calinski-
377 Harabasz score [42] available on the Scikit-Learn module. These scores allow an understanding of the ability of the
378 zoning method to produce groups that are distinct from each other based on building performance indicators. The
379 Silhouette score is 1 when each climate zone is perfectly grouped and -1 when the climate zoning is too bad. For
380 the Calinski-Harabasz score, the worst clustering can have zero as a score, and there is no pre-established maximum
381 value.

382 To calculate the Silhouette score, first the average distance of each case about the other cases of the same climate
383 group (defined as A) is calculated, second the average distance of each case about the other cases of the nearest
384 climate group (defined as B) is calculated, the score for the evaluated climate group will be B minus A divided by
385 the greater value of A or B. The Calinski-Harabasz score is the ratio of the sum between-cluster dispersion and the
386 sum within-cluster dispersion.

387 *4.1.1. Zoning using the K-means method with building performance indicators*

388 The performance-based method considers the climate indirectly because it is developed using building performance
389 indicators. The dwelling of reference is simulated in 298 weather files (TMYx.2007-2021), and the results are applied
390 in the cluster analysis. Other researchers have already explored this approach, and it is understood as defining
391 zoning with little noise between zones because it acts exactly on the performance indicators used in the validation.
392 If the validation were done through climate indicators, clustering using K-means applied to climate indicators would
393 outperform the proposal based on building performance, as presented in this section.

394 To explore the best results of the performance-based zoning method, 6 to 12 zones were considered to separate
395 the locations. The K-means clustering method, available on the Scikit-Learn module, is used to group the building
396 performance indicators. All performance indicators were normalized, considering values from 0 to 1. Figure 7 shows
397 the group of performance indicators calculated according to ABNT-NBR 15575 [37], which is called Key Performance
398 Indicators (KPIs): PHiFT, PHsFT, CgTa, and CgTr. Building performance indicators related to humidity are also
399 considered in this analysis.

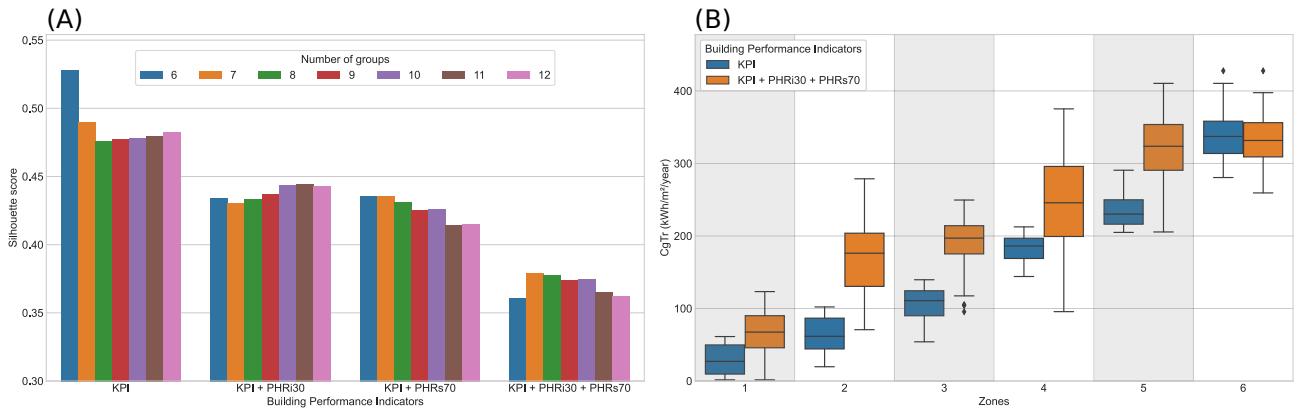


Figure 7: Zoning based on building performance: barplot of the Silhouette score of four groups of building performance indicators (A) and boxplot of the cooling thermal load of the reference building according to better and worse zoning (B).

The results show that zoning based on performance indicators regarding thermal behavior (KPIs) establishes a well-defined clustering; see Figure 7a. When uncorrelated performance indicators are added, performance-based zoning performance is noisier in transitions between climate zones. It is important to emphasize that the proposal with the highest and lowest Silhouette score was established with six groups. However, the best accuracy is observed when the zoning considers only the KPIs. The lowest accuracy was observed when it included KPIs and performance indicators related to indoor relative humidity (PHRs70 and PHRi30). Although a worse performance is seen when including indicators regarding relative humidity, detailing the relative humidity is essential in bioclimatic zoning, which is the purpose of this paper.

Figure 7b presents the dispersion of the cooling thermal load of each climate zone of the cluster with the highest and lowest Silhouette scores. The zoning divisions that consider only the KPIs are better defined. When two indicators related to relative humidity are added, a greater thermal load dispersion is observed, resulting in greater noise in zone transitions. It is important to emphasize that noise also occurs in the other performance indicators. However, the cooling thermal load was presented in Figure 7b because strategies related to cooling are predominant in Brazil, and the need for heating is zero or close to zero in a large part of the territory.

To understand whether there is a need to include indicators related to the relative humidity in the clustering process, it is first interesting to check the behavior of zoning based on KPIs only, showing whether there is any undesired diversity within its zones. Thus, it was analyzed whether the proposed 12 clusters could separate two distinct biomes, such as the Amazon and Caatinga biomes. It is important to note that both biomes have very hot climates, but the Amazon Biome is very humid, with frequent rainfall, while the Caatinga has a semi-arid climate with long periods of drought. There can also be significant differences in temperature ranges and solar radiation levels. Although the buildings have similar thermal performance, these locations are significantly different in bioclimatic terms.

Initially, one might assume that these dissimilarities would disappear with 12 zones. However, when locations in the hottest zone are analyzed, these biomes have the same climate classification, as shown in Table 2. A potential solution to this issue could involve separating the indicator for the total thermal load into its sensible and latent components. This was explored and proved effective for hot climates, but in zones with milder temperatures, this

426 division regarding latent thermal load did not occur as desired. This is precisely why the PHRs70 and PHRi30
 427 indicators were established. These two indicators were chosen instead of just one to compensate and give more
 428 importance to this characteristic, since the four KPIs used would minimize the influence of humidity on the clustering
 429 process.

Table 2: Biomes and climatic characteristics that are present in the hottest zone of the 12-cluster proposal based on the building performance of the KPIs.

City	Biome	RHmean (%)	DBTamp (°C)	GHRmean (kW/m ²)	Precipitation (mm/year)
Manaus – AM	Amazon	81.2	6.78	4726	2641
Belém – PA	Amazon	80.9	7.89	5109	2252
Ibotirama – BA	Caatinga	52.0	12.86	6013	450
Caicó – RN	Caatinga	56.7	11.10	6022	593

430 For zoning based on building performance, choosing the indicators used in clustering is extremely important. As
 431 the climates are separated indirectly, depending on the performance indicator used, there may be an inadequate
 432 grouping of locations. Furthermore, even if the number of groups is high, there will always be some variability within
 433 the cluster. For example, the hottest zone of the proposal discussed in the previous paragraph with 12 clusters has
 434 a difference of 23% between the climate with the lowest and highest total cooling thermal load.

435 *4.1.2. Zoning using the K-means method with climate indicators*

436 Commonly, climate-zoning methods use climate indicators applied in some clustering methods. Therefore, it
 437 is important to explore this way of development. To establish indicators that could represent each location, the
 438 TMYx.2007–2021 climate database was used. The climate indicators are dry-bulb temperature, global horizontal
 439 radiation, relative humidity, wind speed, and dew point. Annual averages were calculated for all these climate
 440 indicators, except for global horizontal radiation. Here, radiation considers the annual average of the daily sums.
 441 The amplitude and annual average can represent the dry-bulb temperature. The dry-bulb temperature amplitude is
 442 calculated by subtracting the annual averages from the daily maximums and minimums. Another indicator considered
 443 in this approach was heating degree-days with 14 °C as the base temperature. These climate indicators were later
 444 normalized with values between 0 and 1 and grouped via the K-Means clustering method.

445 The climate-based zoning method considered proposals that use 6–12 zones to separate the locations. All combina-
 446 tions of the seven climate indicators were analyzed to perform a comprehensive analysis. Therefore, 127 combina-
 447 tions of climate indicators were analyzed. This includes cases where only one indicator was considered and cases where
 448 two or more indicators were considered in the zoning. Following each procedure detailed here, we get the Silhouette
 449 and Calinski-Harabasz scores for all variants that follow the climate-based method, as shown in Figure 8.

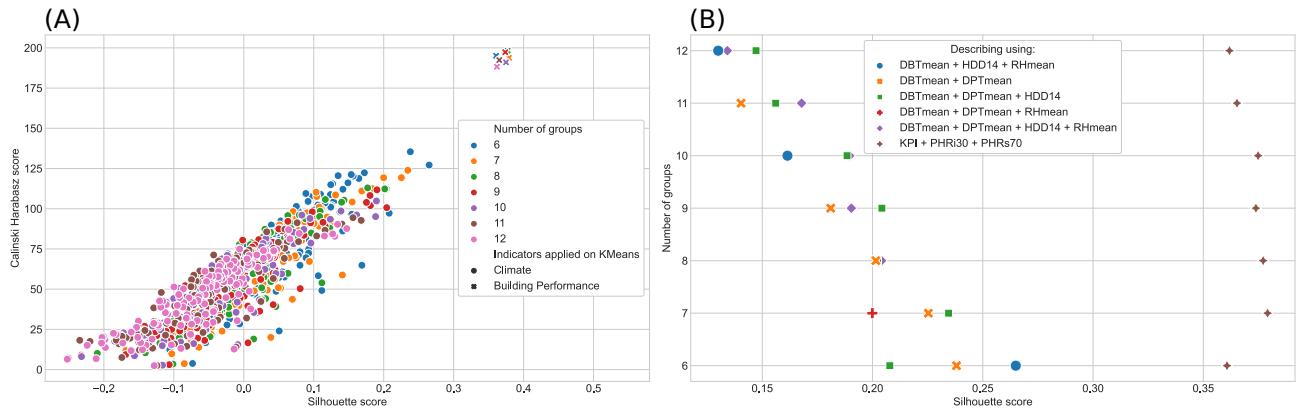


Figure 8: Zoning based on climate indicators: dispersion of the Silhouette score and the Calinski-Harabasz score, considering all combinations (A) and climate indicators of the three best combinations according to the Silhouette score (B).

Regarding the Silhouette and Calinski-Harabasz scores, in Figure 8a, it is possible to observe that for the climate-based method, the best results are those with few climate groups. For this indicator, the higher the associated value, the better the climate zoning. The results show that the same number of groups can establish proper climate zoning or poor-quality proposals. Therefore, the accuracy of the proposal depends on the climate indicators used in the clustering process.

When zoning is established with climate indicators that have little influence on the purpose of its application, its low quality can be observed through the difficulty in grouping locations whose evaluated buildings have similar behavior. Therefore, before establishing a climate zoning using hierarchical clustering or partitioning methods, it is important to conduct a sensitivity analysis to filter indicators for the clustering process. Another possibility is to perform a comprehensive search, as was done in this study, and select the best proposal using a clustering performance metric.

It is observed that the Silhouette score of performance-based zoning has the highest associated values. This shows that the grouping defined by performance-based zoning represents groups that are more cohesive and are well separated from the others. The performance-based method has this behavior because the metric is computed exactly with the indicators established in the clustering process. This becomes clear when we look at Table 3, where climate and performance indicators are used to validate the zoning with 12 clusters of the performance-based zoning method, which considers all six building performance indicators. The same was done for the method variant, with 12 clusters developed based on climate, which considered DBTmean, RHmean, and HDD14. These climate indicators were also used in this extra validation, which was the most sensitive to each performance indicator observed in the sensitivity analysis. The results show that they consistently improve when the same indicators are used for both the development and validation of the zoning. Thus, zoning based on building performance does not characterize the climate better than zoning directly based on the climate.

Table 3: Comparison of different ways of validating the best proposal of 12 clusters according to performance-based zoning or climate-based zoning.

Metric	Performance-based method		Climate-based method	
	Performance indicator	Climate indicator	Performance indicator	Climate indicator
Calinski-Harabasz	188	109	83	271
Silhouette	0.36	0.07	0.13	0.38

Figure 8b shows three combinations with the highest Silhouette score values for each number of climate groups. The results show that the best combinations are precisely those composed of the same indicators presented as the most sensitive in the sensitivity analysis conducted in Section 3.3.3. To be more explicit, the best combinations of climate indicators mainly considered the dry-bulb temperature (DBTmean), dew point temperature (DPTmean), relative humidity (RHmean), and heating degree-day using 14 °C as base temperature (HDD14). Therefore, the results presented here corroborate the idea that a sensitivity analysis is a very useful tool for selecting the climate indicators that will be used in the clustering process.

4.1.3. Zoning using the Decision Tree method

Unlike the two previous zoning methods, the Decision Tree method can define climate-based zoning that also considers building performance. For this, the same process of normalizing the indicators followed in the method based on building performance was used. For climate data, all seven climate indicators were used without normalization. To effectively execute the clustering process, the decision tree method uses the climate indicators as inputs and the normalized building performance indicators as outputs in training. The outputs are the KPIs (PHiFT, PHsFT, CgTa, and CgTr), PHRi30, and PHRs70.

Inherent to the supervised machine learning method, represented by the decision tree method, any location with valid climate indicators follows a path defined by nodes with conditional criteria. Invariably, any location will follow a particular path that satisfies all conditions of the decision tree, reaching the last node that defines predicted performance values for such climates. These last nodes (leaves) represent the climate zones. The Decision Tree method was applied, considering 6 to 12 climate groups (leaves). Following each procedure detailed here, we calculate the Silhouette and Calinski-Harabasz score results for the variants that follow the Decision Trees method; see Figure 9a.

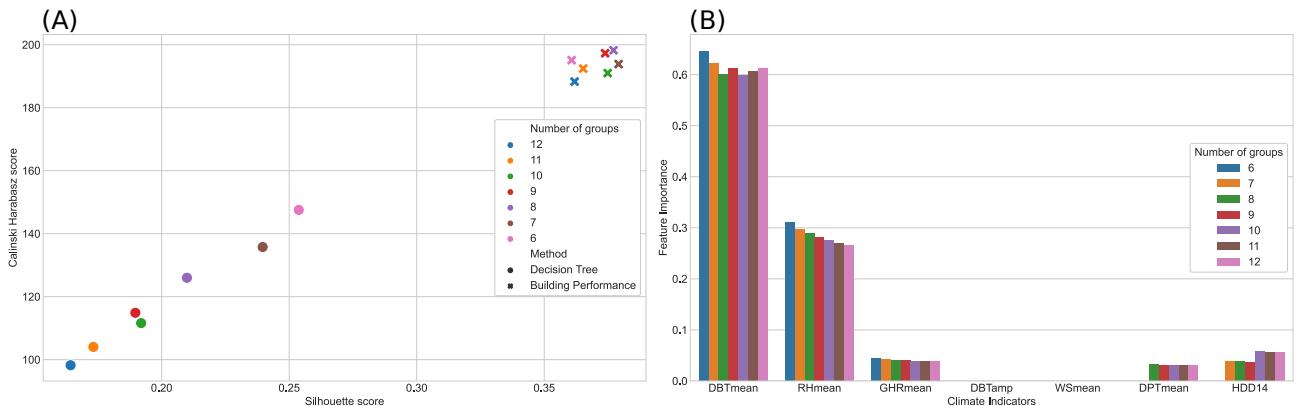


Figure 9: Zoning based on Decision Tree: Dispersion of Silhouette Score and Calinski-Harabasz Score of the best zoning for each number of groups (A) and the importance of climate indicators (B).

493 The results of the Silhouette score and Calinski-Harabasz score show that the variants with few climate zones
494 showed more accurate results, in the same way as occurred in the climate-based method. A point to be emphasized
495 here is that a proposal with few zones produces zoning with great dispersion within each climate group. When a
496 specific climate zone has a large dispersion, what happens is the grouping of very different climates in the same
497 climate zone. On the other hand, when the number of climate zones is large, the dispersion tends to be smaller.
498 Considering an excessive number of climate zones is unnecessary, as there must be dispersion in each zone. The
499 admissible dispersion must be observed, considering each climate zone.

500 Despite considering seven climate indicators, the Decision Trees method performs an importance analysis through
501 its algorithm that works as a feature selection. Thus, the climate indicators on each path or branch of the tree are
502 precisely those with the greatest sensitivity to the building performance indicators considered as output from the
503 model. Figure 9b describes the feature importance of each decision tree established here and represents the sensitivity
504 of its inputs. This information is provided by the function of the Scikit-Learn module used to train the decision
505 trees. This indicator calculates the decrease in impurity on tree leaves caused by each input, i.e., a normalized total
506 reduction.

507 As it is possible to observe, the dry-bulb temperature (DBTmean) continues to be the most important indicator.
508 Still, here the relative humidity (RHmean) got higher values than the dew point temperature (DPTmean), which is
509 more important than RHmean in the sensitivity analysis of Section 3.3.3. This occurred because the Decision Tree
510 method considered that the relative humidity (RHmean) was more adequate to separate the building performance
511 indicators related to the indoor relative humidity. Even though heating degree-days using 14 °C as base temperature
512 (HDD14) is less important than RHmean, in the sensitivity analysis, its correlation is extremely high for PHiFT
513 and CgTa, with values close to 1. This occurs because all performance indicators used as output were considered
514 simultaneously, where a large part of locations have cooling demand. The number of locations with heating demand
515 is much lower. Furthermore, the feature importance presented similar values when comparing the values in the
516 different numbers of climate groups used in training the Decision Trees method.

517 4.2. Final bioclimatic zoning for Brazil

518 To establish a bioclimatic zoning that could be used in practice and described in the national standard, the final
519 zoning proposal was developed and validated, aiming to comply with the following requirements: (1) The bioclimatic
520 zoning should not have an excessive number of zones; (2) the dispersion in each climate zone should be similar; (3)
521 separate the coldest zones; (4) differentiate dry and wet zones; (5) the zoning method should be easy to understand;
522 and (6) it should be aligned with the existing national standard.

523 The decision tree method was used to develop the final climate-zoning proposal. The choice is based on its
524 capacity to combine climate and building performance indicators simultaneously. By adopting this approach, an
525 accurate characterization of the climate is achieved while also considering the importance of building performance.
526 This method is highly suitable for practical use because of its easy understanding. Furthermore, as the decision
527 tree inputs are climate indicators, it is possible to use high spatial resolution climate databases to classify locations
528 without meteorological stations.

529 The proposal should have close to eight climate zones to avoid an excessive number of climate zones. This value
530 represents the number of zones in the ABNT-NBR 15220-3 [15] bioclimatic zoning published in 2005. It is worth

mentioning that the proposal detailed in this study was developed to be used in updating this standard. As the final zoning proposal is mainly directed towards the thermal performance of buildings, it was established that the separations according to thermal performance should not exceed eight climate zones. Thus, the divisions according to the humidity level of the zone do not enter this value.

Values lower than eight are desirable as they facilitate using the proposed bioclimatic zoning. However, when considering minimal values, the dispersion within each group is huge, and locations with very different climates are grouped in the same climate zone. When this occurs, zoning reliability tends to decrease, so the number of zones must be above a minimum value. To establish a minimum value, it was defined that the PHsFT dispersion in each zone of the final climate-zoning proposal should be close to 20–25%.

So that bioclimatic zones have a similar dispersion in terms of building performance indicators, it was decided to transform the dry-bulb temperature into categorical variables. This was essential especially to make the zones more homogeneous regarding the thermal and energy performance of the buildings, as such building performance indicators are very sensitive to the dry-bulb temperature. To be clearer, the annual mean dry-bulb temperature (DBTmean) values were previously set as a categorical variable with six values separated equidistantly for values between 12.68 and 25 °C (first interval), two values for DBTmean between 25 and 27 °C (second interval), and two values for DBTmean between 27 and 29.07 °C (third interval). These intervals previously mentioned were also defined to align with ABNT-NBR 15575 [37], a standard that evaluates the thermal performance of residential buildings. These three intervals are established in this normative using dry-bulb temperature, which defines how the performance indicators are calculated.

Subsequently, these categorical variables mentioned in the previous paragraph were transformed into dummy variables, where each category became a column of the data frame (Python's Pandas module) containing binary values. For example, if a location has a DBTmean between 23 and 25 °C, only the column in that category would have a value equal to 1, the rest would remain 0. In addition to these DBTmean dummy variables, it was included in the data frame continuous relative humidity values (RHmean). We chose to use only dry-bulb temperature and relative humidity as they were the most sensitive variables observed in the sensitivity analyzes (Figures 6 and 9b).

In each of the three intervals, a decision tree was trained. This data frame mentioned in the previous paragraph was defined as the input, and the outputs are normalized values (0 to 1) of CgTa, CgTr, PHiFT, PHsFT, PHRi30, and PHRs70. It was verified that the Decision Trees training with 10 climate zones produced dispersion close to what was previously desirable. Therefore, it was defined in the Decision Trees training that the first interval has six final leaves (zones), which produce four climate zones according to thermal performance, and two of these zones are separated according to moisture performance. For the second and third intervals, two final leaves (zones) were defined for each, where only divisions based on moisture performance were observed.

The sensitivity analysis (Section 3.3.3) shows that the heating load and PHiFT are less sensitive to the mean annual dry-bulb temperature. This is because of the strong effects of latitude and continentality. The temperature amplitude is more significant in colder zones when you are far from the ocean and further south. This makes the winters more severe and the heating demand and PHiFT greater. Because of this, zones 1 and 2 were divided after the training according to the 60° percentile of HDD14, respectively, 88 and 229. This procedure was replaced by latitude, longitude, and dry-bulb temperature criteria because the results are practically identical (Figure 10). For the coldest

group (zone 1), the climates were separated according to latitude and average annual dry-bulb temperature. A latitude limit was established for the second coldest group (zone 2), and the longitude represented the continentality.

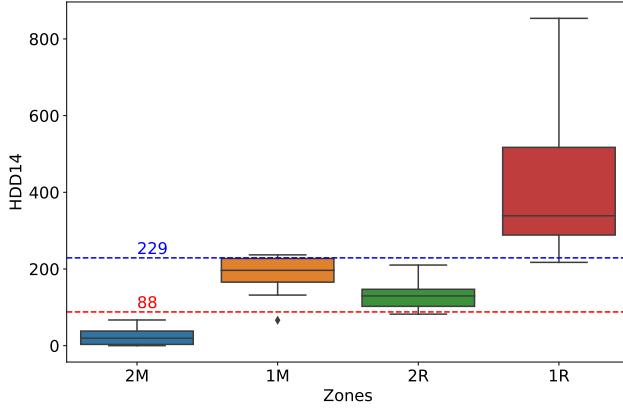


Figure 10: Boxplot of HDD14 according to the coldest zones of the final bioclimatic zoning and 60° percentile (dashed lines).

The detailing of the coldest zones, represented by Zones 1 and 2, was performed because the heating thermal load still had a considerable dispersion. However, the behavior of these zones was already similar to the cooling demand. Therefore, each zone was separated into zones where the winter is relatively more rigorous (R) or moderate (M). Finally, it is important to emphasize that all criteria are easy to understand and apply. It is easy to understand if one zone is hotter or colder than another. In addition, the combination of the temperature and intensity of winter allows for greater detail in the final bioclimatic zoning of this study.

Figure 11 shows the distribution of the climate indicators for each climate zone of the final proposal. Thus, it is possible to see that inside each zone the temperature has low dispersion, and from zone 3 until zone 6, the relative humidity divides the locations into dry and wet areas. Locations with high relative humidity tend to have low daily global horizontal radiation and a diurnal range of dry-bulb temperature. This occurs mainly in locations with a high incidence of precipitation.

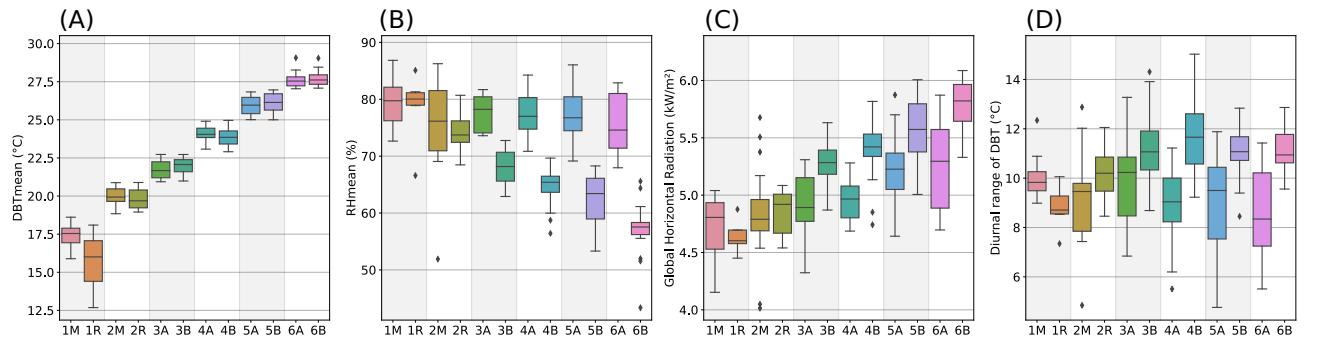


Figure 11: Boxplot of climate indicators regarding DBTmean (A), RHmean (B), GHRmean (C), and DBTamp (D) according to each zone of final bioclimatic zoning.

The criteria obtained by the Decision Tree method are presented in Table 4. To classify each location, it is first necessary to separate the climates according to the annual mean dry-bulb temperature (DBTmean), giving numbers ranging from 1 to 6. This separation already separates the climates very well according to building thermal

Table 4: Classification criteria of the final bioclimatic zoning for Brazil.

Zones	Description	Criteria 1	Criteria 2
1R	Very cold zone with severe winter	DBTmean <18.8 °C	Note 1
1M	Very cold zone with moderate winter		Criteria 2 of 1R must be false
2R	Cold zone with severe winter	18.8 °C ≤ DBTmean <20.9 °C	Note 2
2M	Cold zone with moderate winter		Criteria 2 of 2R must be false
3A	Mixed and humid zone	20.9 °C ≤ DBTmean <22.9 °C	RHmean >73.2%
3B	Mixed and dry zone		RHmean ≤ 73.2%
4A	Slightly hot and humid zone	22.9 °C ≤ DBTmean <25 °C	RHmean >70.3%
4B	Slightly hot and dry zone		RHmean ≤ 70.3%
5A	Hot and humid zone	25 °C ≤ DBTmean <27 °C	RHmean >68.7%
5B	Hot and dry zone		RHmean ≤ 68.7%
6A	Very hot and humid zone	27 °C ≤ DBTmean	RHmean >66.8%
6B	Very hot and dry zone		RHmean ≤ 66.8%

Note 1: (-30° <Latitude <-27.7° and DBTmean <17 °C) or (Latitude ≤ -30° and DBTmean <18.5 °C)

Note 2: Latitude ≤ -24.2° and Longitude ≤ -50.3°

585 performance. Besides separating according to thermal performance, separating zones 3 to 6 according to the average
 586 annual relative humidity (RHmean) was necessary, giving letters A when the RHmean is above the relative humidity
 587 limit and B when it is below. With this criterion, it was possible to separate the coastal and Amazon regions, which
 588 are more humid, from the center of the Brazilian territory, which is drier.

589 Regarding the performance of the reference typology of residential buildings (Figure 12), it is possible to observe
 590 that the zoning can separate the locations mainly about PHsFT and CgTr, which can be understood as discomfort for
 591 heat and consumption for cooling, respectively. These indicators are predominant throughout the Brazilian territory;
 592 for this reason, the climates needed to be well grouped for this indicator. When the same analysis was performed for
 593 office buildings, the graphs of that analysis were not shown here, but it can be said that the noise in the transition
 594 of the zones was much smaller. In addition, in the offices, it was possible to clearly notice that the wetter areas have
 595 a higher thermal load than the drier areas, which is explained by the latent thermal load that is more pronounced
 596 in more humid places.

597 For the indicators related to potential discomfort because of cold (PHiFT and CgTa), there was a clear separation
 598 between the locations where the winter was more or less intense. It is important to emphasize that the moderate
 599 winter of zone 1 has practically the same amount of thermal load as the severe winter of zone 2. This detail is
 600 important because, although the thermal load of cooling is similar in zones 1 or 2, the greater winter intensity
 601 can promote the need to use different strategies to achieve thermal comfort in the most extreme periods. For the
 602 indicators related to indoor moisture (PHRs70 and PHRi30), a clear separation of zones according to humidity was
 603 observed. This is desirable because the more humid climates present a more pronounced latent load, besides the
 604 fact that the thermal amplitude of the driest Brazilian zones tends to be greater than that observed in more humid
 605 zones. This is very important to establish suitable bioclimatic strategies for these locations.

606 4.2.1. Comparison with existing climate zoning

607 For a new bioclimatic zoning to be justifiable, it must be better than the other existing climate zoning, which
 608 are summarized in ABNT-NBR 15220-3 [15], Köppen-Geiger, and ASHRAE 169. The ABNT-NBR 15220-3 climate
 609 classification for each location represented in TMYx.2007–2021 was obtained using the ZBBR software [43]. Regarding

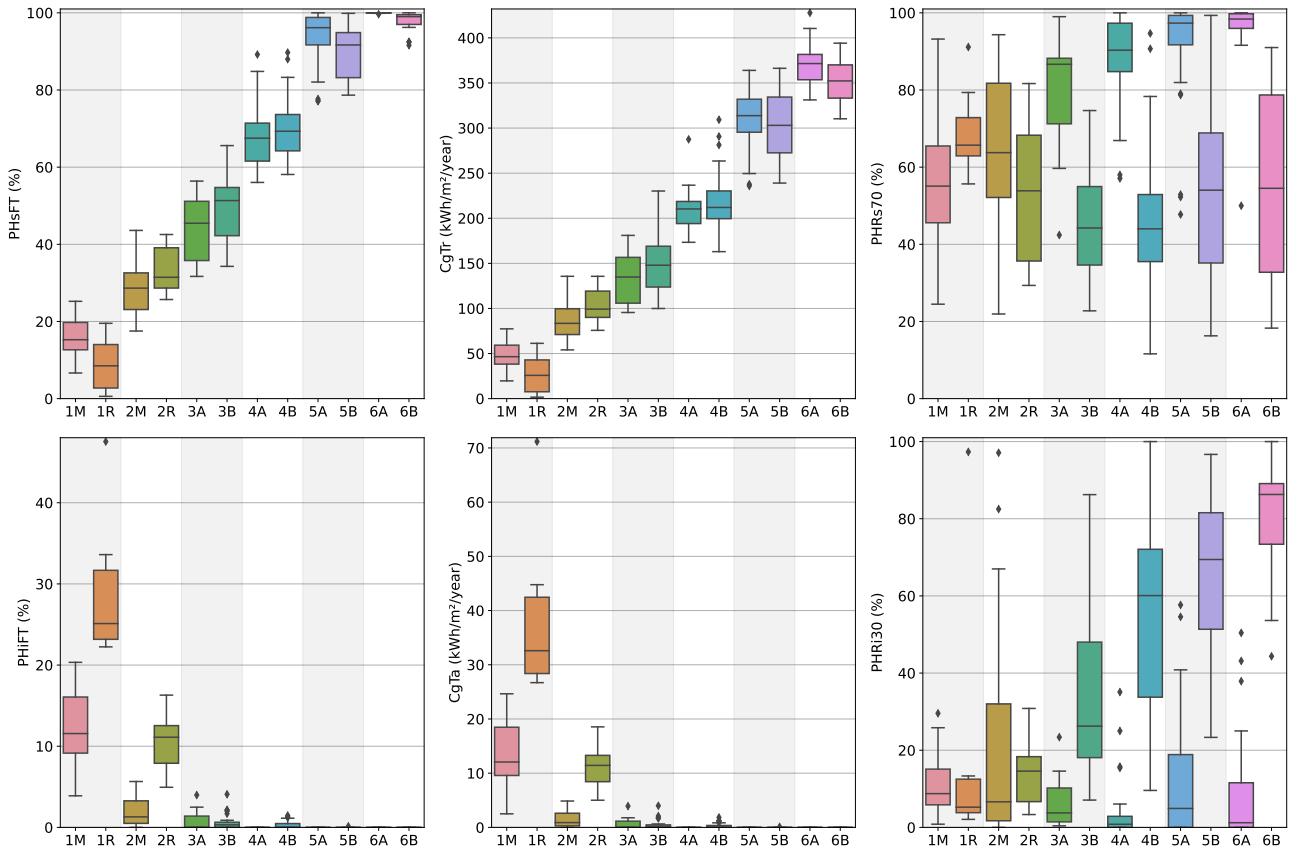


Figure 12: Boxplot of performance indicators of reference typology of the residential building according to each zone of final bioclimatic zoning.

the Köppen-Geiger classification, the zone was obtained from the STAT file that is available with TMYx.2007-2021 [28]. The ASHRAE 169 [16] classification was established based on the TMYx.2007-2021 climate variables.

To verify how the climate zones of the final proposal relate to the zones of the existing methods, an analysis of contingency was conducted for each zone (Figure 13). This form of visualization allows checking how the locations of a climate zone are distributed in the climate zones of another zoning method. This makes it possible to observe eventual equivalences for zones using different methods. If one zoning method is perfectly equivalent to another, the locations of one climate zone must be contained within a single climate zone of the other method.

The results show a lack of well-defined equivalences. These graphs clarify that there is no strong harmony between the final bioclimatic zoning proposal and the existing zoning methods. However, among the existing climate zoning, ASHRAE 169 was the closest to the zoning proposal presented in this study. It can be said that ASHRAE 169 separates Brazilian climates into fewer zones according to temperature (degree-days) than the proposed zoning. This greater detail in temperature is reflected in grouping locations with similar thermal behavior.

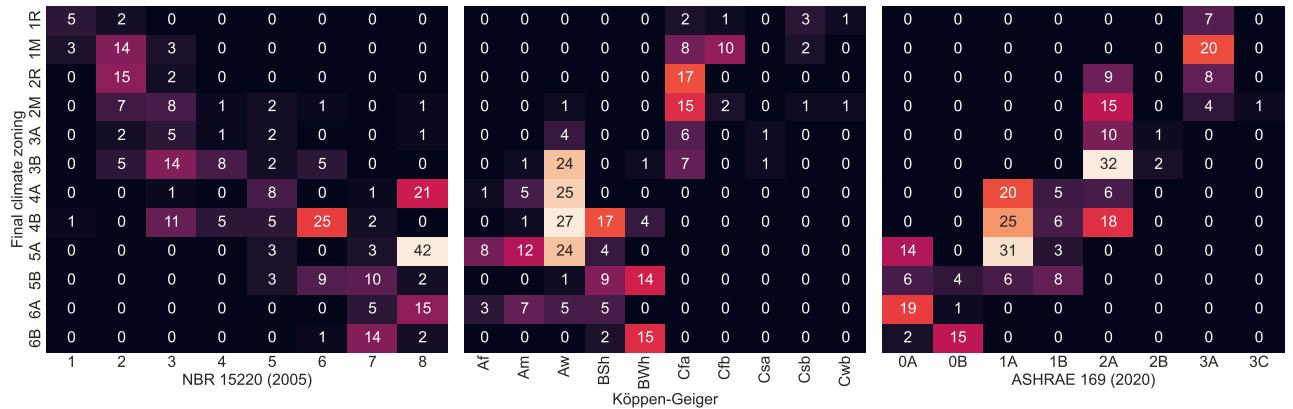


Figure 13: Contingency analysis of the final proposal for bioclimatic zoning on the Y-axis against existing climate classification methods on the X-axis.

This contingency analysis allowed us to observe directly how the zones of the final proposal for the climatic zoning of this paper are distributed according to other existing methods. However, to evaluate the performance of these methods, the Silhouette and Calinski-Harabasz scores were calculated, considering the performance indicators of four different building typologies. These typologies represent commercial and residential buildings with high (target buildings) and low (reference buildings) thermal performance, which allows for verifying the performance of zoning methods in different typologies. To facilitate the visualization of the two results presented in Figure 14, these zoning performance metrics are normalized by building typology with values between 0 and 1, where the best performance occurs when the methods are closer to 1.

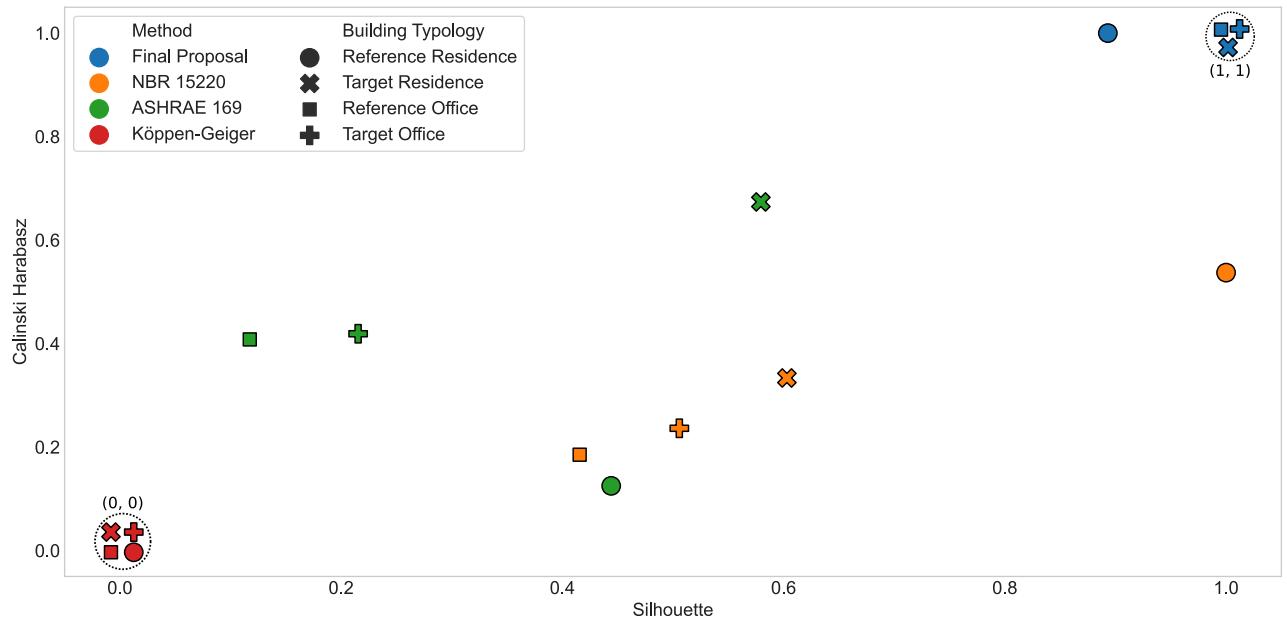


Figure 14: Evaluation of the climate zoning performance of existing methods and the final bioclimatic zoning proposal according to Silhouette and Calinski-Harabasz score.

The results show that the final proposal of the climatic zoning, represented by the blue color, presents the best

631 performance for the office buildings and target residential building. Although the Silhouette score shows that the
632 current zoning method of ABNT-NBR 15220 [15] has better performance according to the reference typology of
633 residential building, for Calinski-Harabasz, the best result is that of the final proposal in this paper. This occurred
634 mainly due to building performance indicators linked to relative humidity (PHRs70 and PHRi30), since the percentage
635 of zones that are divided between wet and dry is higher in ABNT-NBR 15220 (6 of 8 zones) than in the new proposal
636 (8 of 12 zones). This high percentage makes the nearest climate zone of each climate zone further away, influencing
637 the Silhouette results. However, it is important to highlight that the absolute number of zones divided between dry
638 and humid zones is greater in the new proposal (8 zones) than in ABNT-NBR 15220 (6 zones).

639 Thus, this indicates that the behavior of the performance indicators is better understood by the proposed method
640 in this paper. Through that analysis, we found that Köppen-Geiger presented the worst performance results in all
641 building typologies. As for ABNT-NBR 15220 and ASHRAE 169, it was observed that considering only the Silhouette
642 score, the ABNT-NBR 15220 perform better than ASHRAE 169. However, the Calinski-Harabasz metric shows that
643 ASHRAE 169 showed better performance than ABNT-NBR 15220.

644 5. Interpolation of climate data for all Brazilian municipalities

645 As only 298 good-quality weather files were selected to execute the building performance simulation and develop
646 the criteria for bioclimatic zoning, it is necessary to use some mechanism to classify the other Brazilian municipalities
647 that do not have good-quality weather files. To be more explicit, Brazil has 5570 municipalities. To understand how
648 this is a critical point, Figure 15 shows the Voronoi diagram [44] for the 298 weather files. Each polygon represents
649 the area of influence of each weather file, which can contain considerable climatic diversity because of regions with
650 high altitudes or even valleys in their interior. Therefore, classifying the other municipalities according to the Voronoi
651 diagram, considering only the 298 TMYx.2007-2021, would be risky.

652 Ideally, all Brazilian municipalities should have typical meteorological years. Implementing this would cause a
653 substantial decrease in uncertainty regarding climate data. This is not possible without valid meteorological stations
654 in all municipalities. One approach to overcome this limitation is the utilization of climate data that has been
655 modeled and established as a grid, recognizing that a higher spatial resolution improves data reliability and accuracy
656 [45]. Another way to get higher resolution data would be to apply an interpolation method in good-quality weather
657 files. This could be done if zoning was based on climate indicators or even building performance indicators.

658 In the literature, it is possible to observe a series of methods that could help in the classification of the 5570
659 Brazilian municipalities. There are interpolation methods that are present in geoprocessing systems, such as Inverse
660 Distance Weighted (IDW) [46], Triangulated Irregular Network (TIN) [44], and Kriging [47]. The latter has a higher
661 level of complexity and robustness than the previous two [46]. However, it is possible to observe in the literature
662 methods that allow a greater level of detail and accuracy, such as self-organizing maps (SOM) [48] and artificial
663 neural networks (ANN) [49].

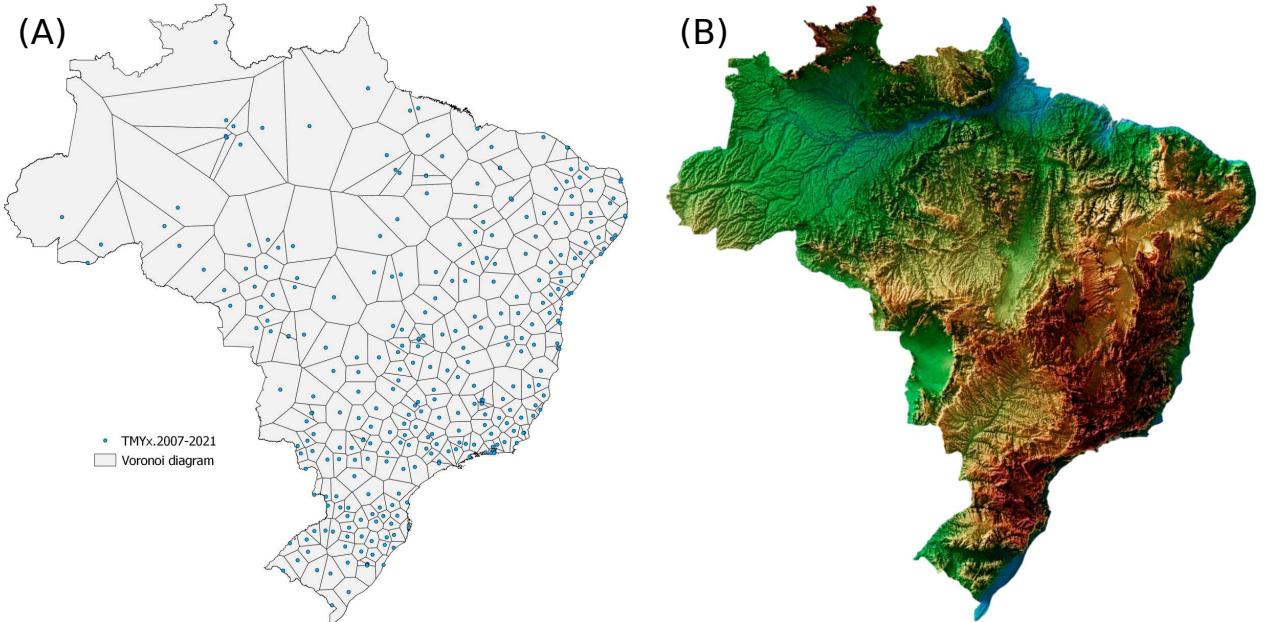


Figure 15: Area of influence of each TMYx.2007-2021 location using Voronoi diagram (A) and Three-dimensional representation of the elevation of the Brazilian territory adapted from Souza [50] (B).

Because climate zoning methods usually consider climate indicators to classify each location, one possibility is to use climate databases such as NASA-POWER, CRU, or ERA5. However, to verify the accuracy of the databases and select one, they must undergo a validation process considering the Brazilian context. To compete with the accuracy observed in each of these databases, metamodels were trained via an artificial neural network to predict climate indicators for each Brazilian municipality. Only the annual mean dry-bulb temperature (DBTmean), relative humidity (RHmean), and heating degree-day using 14 °C as base temperature (HDD14) were trained since they are the leading climate indicators in the sensitivity analysis.

5.1. Metamodeling of the climate indicators

This section presents the method used to develop and validate three climate metamodels. The outputs are the annual mean dry-bulb temperature, relative humidity, and heating degree-day using 14 °C as the base temperature. However, this method can be applied to any other climate indicator, or even for thermal and energy performance indicator of buildings. Therefore, what is presented in this section is not limited only to the indicators addressed in this study but also to other parameters of interest; the metamodel inputs must be composed of parameters that correlate with the evaluated output.

The inputs for the annual mean dry-bulb temperature are latitude, longitude, altitude, and the interpolations of the annual mean values of dry-bulb temperature, relative humidity, and daily solar radiation. These interpolated inputs are the values that would be assigned to a given location via interpolation if its weather file did not exist in the database. These interpolations were performed using the Inverse Distance Weighted (IDW) method, considering weights of 2, 3, 4, and 5. Considering the interpolated value as input if that location does not exist in the database allows us to understand the climate behavior of neighboring weather files. In the relative humidity metamodel, the annual mean dry-bulb temperature previously predicted by the metamodel replaced the interpolated dry-bulb

685 temperatures. For HDD14, the same inputs from the metamodel of RHmean were used, as well the interpolated
 686 values of HDD14 considering the same weights mentioned before.

687 To avoid over-fitting, a lean architecture with 30 neurons is being used, and training is performed considering
 688 the cross-validation method called K-Fold with 10 parts. This method separates the sample into 10 parts and uses 9
 689 parts for training and 1 for testing. An early stopping technique with a patience of 30 iterations is also used to avoid
 690 overfitting. For the other hyperparameters, a grid search was performed considering: (1) SGD and Adam as solvers;
 691 (2) logistic function and hyperbolic tangent as activation functions; and (3) constant learning rates of 0.1, 0.01,
 692 0.001, and 0.0001. To make the search more comprehensive, a random seed was not set, and each hyperparameter
 693 configuration was trained 20 times. The most accurate metamodel was selected in the end. Figure 16 shows the
 694 scatter plot of these metamodels. These graphs show the DBTmean (A), RHmean (B), and HDD14 (C) of the
 695 weather file on the X-axis and the prediction values by the metamodel on the Y-axis.

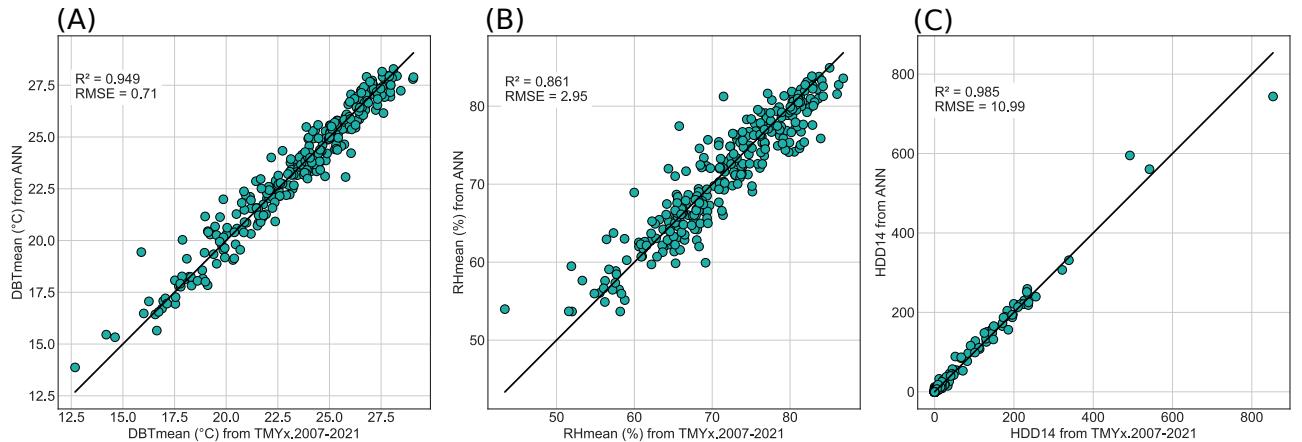


Figure 16: Validation of the metamodel results with DBTmean (A), RHmean (B), HDD14 (C).

696 The results show that the dry-bulb temperature metamodel has high accuracy based on TMYx.2007-2021. Its
 697 coefficient of determination (R^2) was 0.949, with a root-mean-square error (RMSE) of 0.71 °C. The relative humidity
 698 metamodel has a slightly lower accuracy, with an R^2 of 0.861 and an RMSE of 2.95%. The HDD14 metamodel
 699 showed the best results, with R^2 of 0.985 and RMSE of 10.99. These values are sufficiently satisfactory to be used
 700 to classify Brazilian municipalities using the bioclimatic zoning proposed in this study. However, to verify whether
 701 these results are proper, the following section presents an analysis of the accuracy of other climate databases. Since
 702 the databases evaluated do not have HDD14 data, only the DBTmean and RHmean metamodels will be compared
 703 in the next section.

704 5.2. Comparison with existing climate databases

705 Given the limited availability of typical meteorological years represented in only 298 weather files, investigating
 706 the accuracy of other databases with high spatial availability becomes necessary. As these typical meteorological
 707 years have good quality and refer to data measured at meteorological stations over up to 15 years, it is possible to
 708 make a fair comparison between the climate databases. Here, the annual mean dry-bulb temperatures (DBTmean)
 709 and relative humidity (RHmean) are analyzed.

710 For NASA-POWER and CRU, the comparison between the averages was performed considering only the typical
 711 months present in TMYx.2007–2021. In ERA5-Land, the comparison was performed using the average of 15 years.
 712 Considering the DBTmean, the results show (Table 5) that the NASA-POWER, ERA5-Land, and CRU have an R^2
 713 of 0.876, 0.960, and 0.851, respectively. Thus, the results indicate a greater accuracy of ERA5-Land compared to
 714 the other databases. The RMSE allows for verifying that NASA-POWER and CRU have an associated error of 1.11
 715 °C and 1.22 °C, respectively. On the other hand, the RMSE of ERA5-Land was 0.63 °C. Observing these results,
 716 it is possible to see that the ERA5-Land has very similar values to the dry-bulb temperature metamodel presented
 717 in the previous section. This indicates that, for the final classification of Brazilian municipalities, the temperature
 718 considered may come from the metamodel or even from ERA5-Land, with little difference in the accuracy of the
 719 data. It is important to emphasize that the DBTmean metamodel presented an R^2 of 0.949 and an RMSE of 0.71 °C,
 720 being trained only with the 298 climate files. With these results, ERA5-Land slightly outperformed the metamodel,
 721 but when metamodel training occurred with all 577 climate files, DBTmean metamodel results were better than
 722 ERA5-Land. This shows that the greater the number of weather files used in training, the better the performance
 723 of the developed metamodel will be.

Table 5: Analysis of the accuracy of the data from NASA-POWER, ERA5-Land, and CRU compared with TMYx.2007-2021 data.

Variable	Source	R^2	RMSE	MAE	MAX.ERROR
DBTmean (°C)	ANN	0.949	0.71	0.52	3.55
	ERA5-Land	0.960	0.63	0.47	2.46
	NASA-POWER	0.876	1.11	0.84	4.45
	CRU	0.851	1.22	0.93	4.92
RHmean (%)	ANN	0.861	2.95	2.20	11.68
	ERA5-Land	0.695	4.36	3.30	16.08
	NASA-POWER	0.643	4.70	3.67	18.73

724 Regarding the RHmean, only NASA-POWER and ERA5-Land have relative humidity data. Therefore, only
 725 these databases will have their accuracy verified for this indicator. In the same way, as occurred for temperature, for
 726 NASA-POWER, the comparison was made considering only the periods referring to the typical months present in
 727 TMYx.2007–2021, and for ERA5–Land, the comparison was made using the average of the 15 years. Thus, the results
 728 show that NASA-POWER and ERA5-Land have R^2 of 0.643 and 0.695, respectively. The RMSE allowed for verifying
 729 that NASA-POWER has an associated error of 4.7% and ERA5-Land of 4.36%. Through deep analysis, it was found
 730 that this climate indicator, which was calculated considering average annual values of dry-bulb temperature and
 731 dew point, establishes relative humidity far from what it should be. If the relative humidity calculation were done
 732 for hourly values, the annual average of ERA5-Land would be more accurate. Finally, by observing these results,
 733 it is possible to verify that the metamodel presented better results for relative humidity than those observed in all
 734 existing databases, with R^2 of 0.861 and RMSE of 2.95%.

735 5.3. Map of the final bioclimatic zoning for Brazil

736 To classify the 5570 Brazilian municipalities (Figure 17), ERA5-Land was used for annual mean dry-bulb temper-
 737 ature (DBTmean) and the metamodel for annual mean relative humidity (RHmean). Subsequently, each municipal
 738 territory was identified by the color corresponding to its climate zone using QGIS software [51]. The shapefile of
 739 municipal territories was obtained from IBGE [52]. The latitude, longitude, and altitude of Brazilian municipalities

740 are available on Github [53, 54]. For municipalities that have one or more valid TMYs contained in their territory,
741 the classification established by these files was used. When the TMYs of a municipality have different classifications,
742 it was established that the final climate classification that will go on the map will be exactly the one that appears at
743 greater frequency in the TMYs of that municipality. If the two highest frequencies are equal, the climate classification
744 adopted will be the same as that obtained using ERA5-Land for DBTmean and the metamodel for RHmean.

745 In this way, it was possible to verify that the following predominate: (1) the coldest zones are found further to
746 the south and in regions of high altitude; (2) the warmest zones are further north; and (3) the wettest areas are
747 predominantly in the Amazon region or close to the Brazilian coast. Most regions have transition zones between
748 warmer and colder zones. However, this transition hardly appears in regions with very rough terrain and large
749 variations in altitude.

750 Depending on the size of the municipal territory, it is difficult to visualize its climate classification on the map
751 without zooming in considerably. To make the map cleaner, even in municipalities with small territorial areas and
752 climate classifications different from those observed in their surroundings, it would be necessary to have a more
753 homogeneous zoning with little fragmentation. However, for this to happen, it would be necessary to reduce the
754 accuracy of the zoning method, which the authors understand as something to be avoided. Therefore, a table is being
755 provided in supplementary data with the classification of each Brazilian municipality and their respective climate
756 indicators. With this information, it will be possible to verify which weather file can be used in computational
757 simulations of buildings in cities that do not have valid meteorological stations, since it is enough to choose the
758 weather file of a city that has similar climate characteristics by just changing the geographic coordinates beforehand
759 to perform a computational simulation.

760 6. Discussions

761 The present study explored several issues and approaches regarding climate zoning. Their specific objectives were
762 established to develop a method that would be accurate and validated for different building typologies, such as com-
763 mercial or residential buildings. Therefore, in this section, each approach followed will be discussed to complement,
764 justify, or highlight the most important points of this work.

765 An analysis of the weather files was performed to remove files with some anomalies. It is understood that the
766 most accurate and precise solution would be to adjust the base by treating only the hours that have some anomalies.
767 However, to treat the base, it would be necessary to perform an analysis that would increase the level of complexity,
768 without this having a close relationship with the main aim of this study.

769 Several locations were removed because of excessive missing data. This can be because of the reduced number of
770 hours measured throughout each day or any problem related to the measurement equipment. Filling in these missing
771 data points is an essential task to have a complete database ready to be used in building performance simulations.
772 However, when the missing data occurs when the temperature is more extreme, the maximum and minimum values
773 become uncertain.

774 When there is a significant uncertainty in high or low temperatures, there is consequently a compromise in the
775 results obtained in the simulation. This can be a critical issue, especially for sizing HVAC systems or even for
776 understanding how resilient a building is. In the computational simulation method of the thermal performance

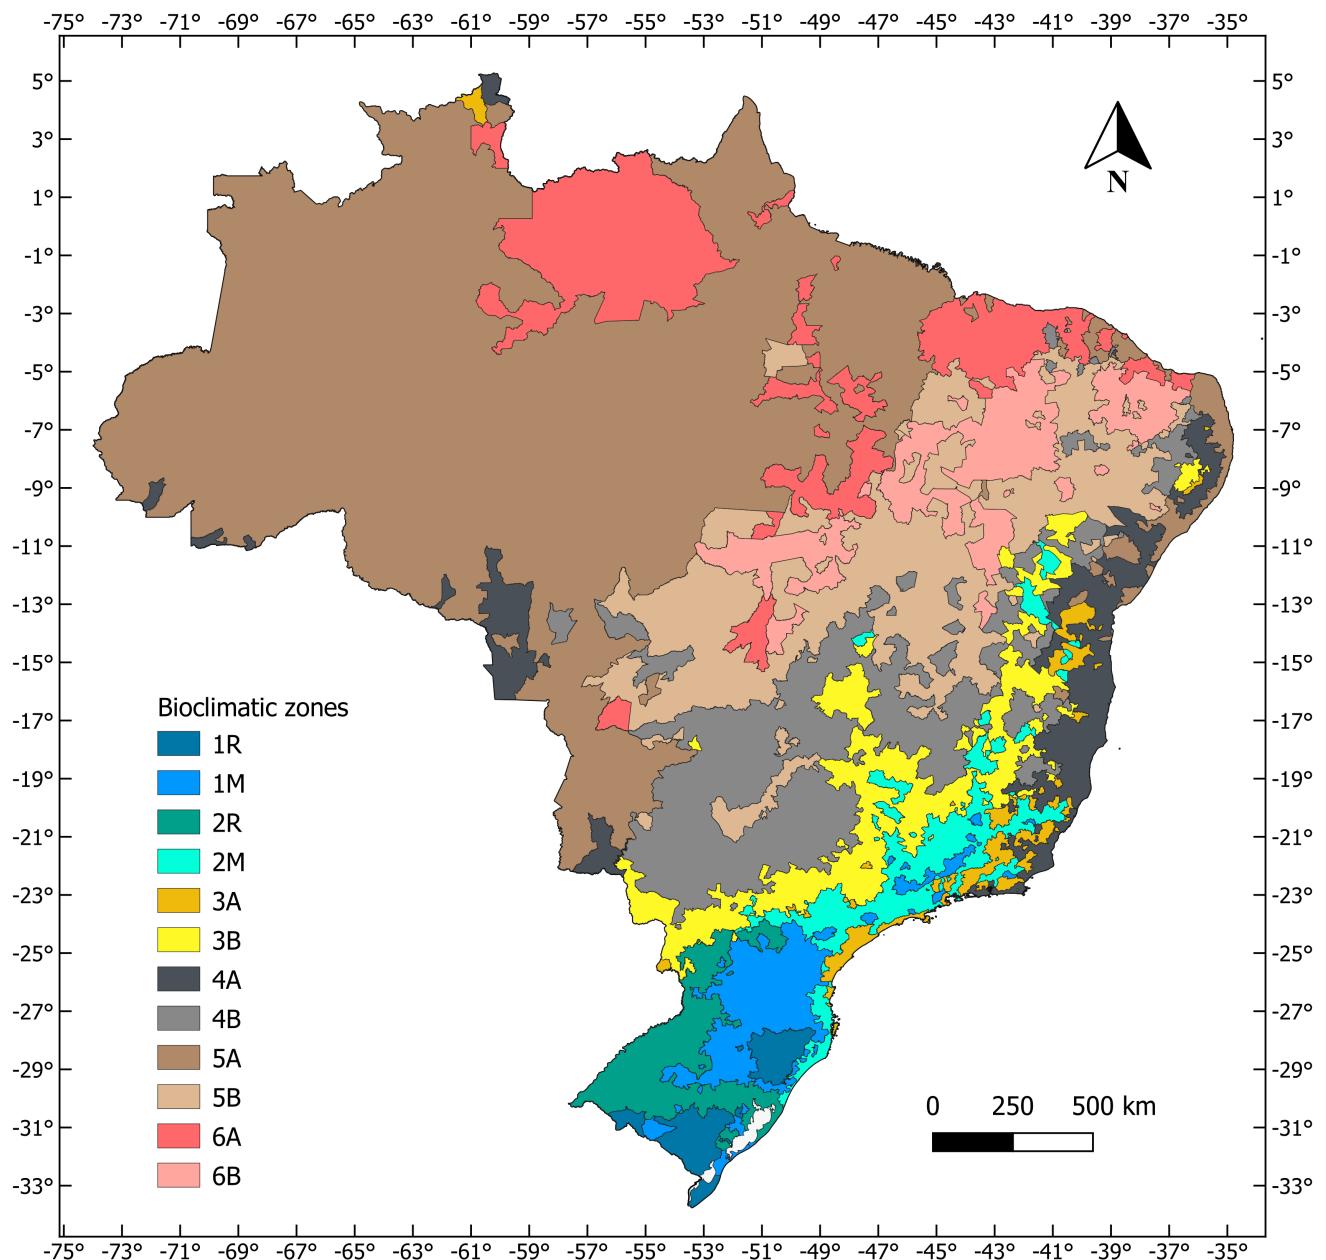


Figure 17: Map of the final proposal for Brazilian bioclimatic zoning.

777 for residential buildings of the ABNT-NBR 15575 standard [37], an item establishes that, throughout the year, all
778 living rooms and bedrooms in a building must present an operative temperature between a minimum and maximum
779 admissible value. These admissible values are obtained by observing the thermal performance of a reference building.
780 Therefore, for this operative temperature analysis to be reliable, the weather files must be reliable, even in their
781 extreme values.

782 A significant part of the development of climate zoning is the choice of building typologies, performance indicators,
783 climate indicators, and the clustering method. If this choice is not made carefully, zoning may behave far from what is
784 expected. To understand the most appropriate climate indicators, it is essential to perform a sensitivity analysis that
785 relates building performance indicators to climate indicators. In this context, the study showed that the sensitivity
786 of a performance indicator behaves similarly in different typologies. This indicates that choosing a single typology
787 for the development of climate zoning would be sufficient, remembering that in this paper, the reference typology of
788 residential buildings was chosen.

789 Performance-based zoning showed the highest Silhouette and Calinski-Harabasz score values. This occurred
790 because these scores were calculated considering the same performance indicators used in the clustering process. It
791 would be the same as grouping climates according to climate indicators and validating them with the same climate
792 indicators. However, for this reason, the performance-based zoning do not characterize a climate better than one
793 based on climate indicators. Even so, as the bioclimatic zoning proposed in this study is built for the performance
794 of commercial and residential buildings, it is understood to be important to validate according to performance
795 indicators. Furthermore, just as it is important to have adequate climate indicators, it is also necessary that the
796 building performance indicators can also describe the main aspects that characterize the climate. Maybe a good
797 approach would be to include building performance indicators and climate indicators as inputs of the K-means.

798 A very positive point of climate zoning based on the Decision Trees method is the possibility of relating hy-
799 grothermal and energy performance with climate indicators. To be clearer, the climate indicators correspond to the
800 inputs of the decision tree-based model, and each leaf (final node) corresponds to a distinct climate group. In the
801 Decision Trees approach, even if two locations have the same performance indicators but different climate indicators,
802 each one would follow a different path. This is something that makes sense in climate zoning methods. When zoning
803 is applied directly to performance indicators, the grouping of locations with similar performances happens even if
804 this performance occurs for different reasons. For example, a location with a high level of solar radiation and high
805 wind speed may be in the same zone as another location with a low level of solar radiation and low wind speed.
806 This can occur implicitly when the zoning is based solely on building performance indicators. However, when zoning
807 considers climate indicators in the zoning criteria, the behavior of each group is explicitly described through climate
808 indicators.

809 When zoning is developed via automatic methods with minor intervention by the researcher, the database com-
810 position strongly impacts the results obtained. Depending on the database and methods used, there may be an
811 inadequate grouping of climate indicators. For example, relative humidity can be divided into three levels when two
812 levels would be enough. Moreover, in the final proposal for bioclimatic zoning developed in this study, it was nec-
813 essary to place restrictions to align with the conditions presented in ABNT-NBR 15575 [37], which already divided
814 the Brazilian territory into three main groups.

815 Based on the final proposal for bioclimatic zoning, it was possible to see through the contingency analysis that
816 the zoning of ASHRAE 169 presents some agreement with the final proposal. One downside is that ASHRAE 169
817 divisions, according to thermal zones, should be more detailed, especially in colder climate zones. However, it is
818 understood that because ASHRAE 169 is applied to the entire world, it would be necessary to establish a much
819 larger number of climate zones to reduce the dispersion in each group. Another point that was clear in the results
820 was the difficulty of ASHRAE 169 in separating wet and dry climates.

821 Zoning criteria can be obtained based on climate data from typical meteorological years (TMYs). However, after
822 identifying these criteria, it is necessary to classify even the locations without TMYs. To conduct this classification,
823 the study proposes an interpolation method via artificial neural networks (ANNs) that proved to be very appropriate
824 for this task. With this method, it was possible to estimate the average annual dry-bulb temperature and relative
825 humidity accurately. This interpolation method via ANN can be applied, for example, to performance data, such as
826 cooling and heating thermal loads. Among the existing databases, only the average annual dry-bulb temperature of
827 ERA5-Land showed accuracy compared to that obtained via ANN. In this context, a positive point of having zoning
828 that considers climate indicators as zoning criteria is the possibility of using good-quality climate databases based
829 on reanalysis, such as ERA5-Land.

830 To get even better results using metamodels, it would be important to have a larger number of weather files
831 used in training. Moreover, it is believed that even with a smaller sample, it would be possible to improve the
832 performances of these metamodels, since there are aspects that can affect the climatic behavior measured in the
833 meteorological station and could be explored in future training, such as bodies of water, vegetation, topography, and
834 land use. Another possibility would be to use other supervised machine learning methods, such as convolutional
835 neural networks, gradient boosting, and support vector machine. However, as the results found in the metamodels
836 presented here were very satisfactory, these other approaches were left aside for developing the study presented in
837 this paper.

838 A climate zoning is generally constructed based on reliable climate data that represents the climate behavior of
839 each location, considering the past. However, climate zoning is established to be used in the present and future.
840 In this sense, when a climate zone has climate indicators as grouping criteria, as climate behavior changes over the
841 years, locations can be easily reclassified. This expresses that the proposed method can adapt to climate changes
842 occurring over the years. Despite this, we believe that the climate zoning method criteria should be completely
843 reformulated if climate change is very significant.

844 **7. Conclusions**

845 The present study aimed to develop a bioclimatic zoning aligned with the hygrothermal and energy performance of
846 Brazilian residential and commercial buildings. Computational simulations were used to determine the performance
847 of these buildings. Several climate databases had their qualities verified through an exploratory data analysis, aiming
848 to select the most reliable databases. Only weather files with no anomalies in their typical meteorological year were
849 simulated. A sensitivity analysis was performed to understand the climate indicators with greater sensitivity to the
850 building performance indicators. Subsequently, three zoning methods were evaluated to establish which should be
851 used as the method for the final proposal, considering the Brazilian context. Three existing climate zoning methods

were compared with this final proposal through contingency analysis, and the zoning performances of these methods were analyzed according to performance indicators of several building typologies. As most Brazilian cities do not have weather files, a final classification was performed using data from good-quality sources that were previously analyzed, resulting in a better spatial resolution. Among these databases are data from three artificial neural networks developed in this study to predict dry-bulb temperature, relative humidity, and heating degree-days using 14 °C as the base temperature. The main conclusions obtained from the results are:

- The TMYx.2007-2021 climate database was the most reliable for computational simulation, outperforming other versions of TMYx and the INMET database.
- The most sensitive climate indicators (DBTmean, RHmean, and HDD14) are usually the same for all typologies. Considering these climate indicators in a classification method establishes a high-performance zoning system.
- DBTmean has a high correlation with the cooling thermal (CgTr) load and the PHsFT. The HDD14 has a high correlation with the thermal load of heating (CgTa) and the PHiFT.
- The annual mean relative humidity (RHmean) showed the highest correlation with moisture-related performance indicators (PHRi30 and PHRs70). This moisture climate indicator needs improvement because of its low correlation values (approximately 60%), although it is still within an acceptable range.
- Developing a zoning method based only on thermal comfort, the total thermal load from heating and cooling places the Amazon and Caatinga biomes, which are very distinct, in the same zone. For this reason, it was important to include building performance indicators related to moisture.
- The performance-based method had better scores because it used the same data for clustering and validation. Climate-based and Decision Tree yield the best results when the validation was performed using climate indicators. Thus, direct consideration of climate is more effective than a performance-based zoning method for climate characterization.
- The final bioclimatic zoning proved to be more accurate than existing climate zoning when validated for four building typologies and two clustering performance metrics.
- To classify Brazilian municipalities without meteorological stations, artificial neural networks of the DBTmean, RHmean, and HDD14 were trained and proved to be very accurate, but ERA5-Land also showed excellent results for the DBTmean.

879 8. Limitations and future works

880 Limitations and possible future work were also observed in the present study, among them:

- The climate zoning method was developed only for Brazilian territory. Nevertheless, other regions around the world that have similar climates to Brazil can classify their locations, and the divisions of zones 1 and 2 must be made via the HDD14 approach.

- The final map considered the climatic classification that would occur precisely at a point in the urban area of each municipality. Therefore, zoning is not suitable for classifying the microclimate. This is a delimitation of the study to facilitate the visualization of the defined climatic zones. For example, Altamira is the largest Brazilian municipality in territorial extension, with 161446 km², and its entire territory is classified according to data from a location within the urban perimeter.
- Because the developed zoning had to be aligned with the current ABNT-NBR 15575, the performance indicators of the building were calculated considering deterministic building occupant behavior according to normative. However, it would be interesting to investigate how different occupants' behavior could impact zoning, especially performance-based zoning.
- Only dry-bulb temperature and relative humidity from existing databases with high spatial resolution were validated, but extending this analysis to other variables that also impact building performance would be interesting.
- The final zoning criterion to characterize dry and humid climates was determined by relative humidity. However, it was observed that this indicator related to humidity could be improved since it presented correlation values close to 0.60, which are much lower than the DBTmean and HDD14, with values close to 1.
- The zoning was developed and validated considering performance data from residential and office buildings with high and low performance. It would be interesting to extend this validation to other typologies, even if what was done is understood as entirely sufficient.
- The continental effect was represented, especially by relative humidity and longitude. This could be explored by considering other approaches to improve the separation of climates according to moisture and thermal amplitude.

905 Acknowledgments

906 This study was supported by the Brazilian governmental agency CNPq ("Conselho Nacional de Desenvolvimento
 907 Científico e Tecnológico") and CAPES ("Coordenação de Aperfeiçoamento de Pessoal de Nível Superior"). The
 908 authors would like to thank the LNCC ("Laboratório Nacional de Computação Científica"), which kindly provided
 909 essential support for performing this research.

910 Dr. Bre performed part of this research during his 0E-BUILDINGS action. This project has received funding
 911 from the European Union's Horizon 2020 research and innovation program under the Marie Skłodowska-Curie grant
 912 agreement N° 101024627.

913 Appendix A. Criteria for selecting weather data files

914 When comparing typical meteorological months with their respective ISD-Lite data, the number of hours with
 915 missing data should not exceed 40% of the 8760 hours. To filter and remove from database locations that have
 916 outliers in dry-bulb temperature, a maximum admissible limit (Equation A.1) and a minimum admissible limit

917 (Equation A.2) were established. It is important to highlight that most existing climate classification methods use
 918 some indicator to represent the behavior of dry-bulb temperature [5]. This is very positive from the point of view
 919 of the thermal performance of buildings because it is the most important variable in understanding the thermal
 920 performance of the building. Some studies show a strong correlation between temperature and the performance of
 921 naturally ventilated and artificially conditioned buildings [8, 55].

$$DBT_{upper} = DBT_{99.9} + \Delta DBT_{99} \quad (A.1)$$

922 where DBT_{upper} is the upper admissible limit for the dry-bulb temperature, $DBT_{99.9}$ is the 99.9 percentile of the
 923 dry-bulb temperature, and ΔDBT_{99} is the 99 percentile of the temperature range of the dry-bulb that occurs in one
 924 hour.

$$DBT_{lower} = DBT_{0.1} + \Delta DBT_1 \quad (A.2)$$

925 where DBT_{lower} is the lower admissible limit for the dry-bulb temperature, $DBT_{0.1}$ is the 0.1 percentile of the
 926 dry-bulb temperature, and ΔDBT_1 is the 1 percentile of the temperature range of the dry-bulb that occurs in one
 927 hour.

928 Equations A.1 and A.2 describe the admissible limits based on the premise that each climate file has less than
 929 9 hours throughout the year containing outliers for maximum or minimum values of dry-bulb temperature. This
 930 represents 0.1% of the 8760 hours in a year. This value was established after analysis of the histograms of the 577
 931 TMYx.2007–2021, through which it was observed that the number of potential outliers for maximum or minimum
 932 values is much lower than 9 occurrences for each. Outliers can also impact the dry-bulb temperature variation
 933 within an hour. Therefore, the hourly variation of the dry-bulb temperature was added to equations A.1 and A.2,
 934 representing 1% of the hours with the greatest positive difference and 1% of the hours with the greatest negative
 935 difference, based on 8760 hours contained in a year.

936 This method of removing outliers also allowed TMYs with very extreme data to be removed from the base. After
 937 this processing, 279 TMYx.2007-2021 were removed, leaving 298 climate files to be used during this study. The
 938 highest upper admissible limit and the lowest lower admissible limit observed in a location were 46 °C and -6.62
 939 °C, respectively. Before processing, TMYx.2007-2021 had a minimum and maximum dry-bulb temperature of -12
 940 °C and 58.4 °C, respectively, which did not represent what occurred in the analyzed locations. According to the
 941 Brazilian Climate Normals for the period 1991–2020, the absolute maximum dry-bulb temperature was 44 °C and
 942 the minimum -10 °C.

943 **Appendix B. Building envelope**

Table B.6: Building envelope used in energy simulation. Adapted from [19].

Component	Property	Residential		Commercial	
		Reference	Target	Reference	Target
External wall	Thermal resistance (m^2K/W)	0.057	1.294	0.25	1.294
	Thermal capacity (kJ/m^2K)	220	30	151	30
	External solar absorptance (0 – 1)	0.6	0.38	0.5	0.38
	Internal solar absorptance (0 – 1)	0.6	0.6	0.3	0.3
Internal wall	Thermal resistance (m^2K/W)	0.057	1.321	0.25	0.277
	Thermal capacity (kJ/m^2K)	220	20	151	167
	External solar absorptance (0 – 1)	0.6	0.6	0.3	0.3
	Internal solar absorptance (0 – 1)	0.6	0.6	0.3	0.3
Roof	Thermal resistance (m^2K/W)	0.27	0.306	0.27	0.306
	Thermal capacity (kJ/m^2K)	231	238	231	238
	External solar absorptance (0 – 1)	0.67	0.35	0.8	0.35
	Internal solar absorptance (0 – 1)	0.6	0.6	0.3	0.3
Floor	Thermal resistance (m^2K/W)	0.057	0.054	0.123	0.123
	Thermal capacity (kJ/m^2K)	220	164	160	160
	External solar absorptance (0 – 1)	0.6	0.6	0.3	0.3
	Internal solar absorptance (0 – 1)	0.6	0.6	0.3	0.3
Internal floor	Thermal resistance (m^2K/W)	-	-	0.057	0.057
	Thermal capacity (kJ/m^2K)	-	-	250	250
	External solar absorptance (0 – 1)	-	-	0.3	0.3
	Internal solar absorptance (0 – 1)	-	-	0.3	0.3
Window	Glass thermal transmittance (W/m^2K)	5.7	2.72	5.7	2.305
	Glass solar heat gain factor (0 – 1)	0.87	0.764	0.82	0.185
	Window to wall ratio	-	-	0.5	0.5
	Window to floor ratio	0.17	0.17	-	-
Geometry	Number of floors	1	1	3	3
	Floor to floor height (m)	2.5	2.5	3	3
	Total conditioned area of floors (m^2)	38.6	38.6	837	837
	Eaves (m)	-	0.5	-	-

944 **References**

- 945 [1] Intergovernmental Panel on Climate Change IPCC. *Climate change 2014: Mitigation of climate change*, vol-
946 ume 3. Cambridge University Press, 2015.
- 947 [2] IEA. *Tracking Clean Energy Progress 2017*. Paris: Organization for Economic Co-operation and Development
948 (OECD), 2017.
- 949 [3] M. Santamouris, C. Cartalis, A. Synnefa, and D. Kolokotsa. On the impact of urban heat island and global
950 warming on the power demand and electricity consumption of buildings—a review. *Energy and Buildings*, 98:119–
951 124, jul 2015. doi: 10.1016/j.enbuild.2014.09.052. URL <https://doi.org/10.1016/j.enbuild.2014.09.052>.

- 952 [4] Jonas Allegrini, Viktor Dorer, and Jan Carmeliet. Influence of the urban microclimate in street canyons on the
953 energy demand for space cooling and heating of buildings. *Energy and Buildings*, 55:823–832, dec 2012. doi:
954 10.1016/j.enbuild.2012.10.013. URL <https://doi.org/10.1016/j.enbuild.2012.10.013>.
- 955 [5] Angélica Walsh, Daniel Cóstola, and Lucila Chebel Labaki. Review of methods for climatic zoning for building
956 energy efficiency programs. *Building and Environment*, 112:337–350, February 2017. doi: 10.1016/j.buildenv.
957 2016.11.046. URL <https://doi.org/10.1016/j.buildenv.2016.11.046>.
- 958 [6] Angélica Walsh, Daniel Cóstola, and Lucila C. Labaki. Comparison of three climatic zoning methodologies for
959 building energy efficiency applications. *Energy and Buildings*, 146:111–121, July 2017. doi: 10.1016/j.enbuild.
960 2017.04.044. URL <https://doi.org/10.1016/j.enbuild.2017.04.044>.
- 961 [7] Angélica Walsh, Daniel Cóstola, and Lucila Chebel Labaki. Performance-based validation of climatic zoning for
962 building energy efficiency applications. *Applied Energy*, 212:416–427, February 2018. doi: 10.1016/j.apenergy.
963 2017.12.044. URL <https://doi.org/10.1016/j.apenergy.2017.12.044>.
- 964 [8] Leonardo Mazzaferro, Rayner M.S. Machado, Ana Paula Melo, and Roberto Lamberts. Do we need building
965 performance data to propose a climatic zoning for building energy efficiency regulations? *Energy and Buildings*,
966 225:110303, October 2020. doi: 10.1016/j.enbuild.2020.110303. URL <https://doi.org/10.1016/j.enbuild.2020.110303>.
- 967 [9] Konstantin Verichev and Manuel Carpio. Climatic zoning for building construction in a temperate climate
968 of chile. *Sustainable Cities and Society*, 40:352–364, July 2018. doi: 10.1016/j.scs.2018.04.020. URL <https://doi.org/10.1016/j.scs.2018.04.020>.
- 969 [10] P.K. Dash, N.C. Gupta, R. Rawat, and P.C. Pant. A novel climate classification criterion based on the perfor-
970 mance of solar photovoltaic technologies. *Solar Energy*, 144:392–398, 2017. ISSN 0038092X. doi: 10.1016/
971 j.solener.2017.01.046. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-85010871800&doi=10.1016%2fj.solener.2017.01.046&partnerID=40&md5=2cd1462f7289e144456f130e6d26ce1d>. cited By 12.
- 972 [11] A. Palla, I. Gnecco, L.G. Lanza, and P. La Barbera. Performance analysis of domestic rainwater harvesting
973 systems under various european climate zones. *Resources, Conservation and Recycling*, 62:71–80, May 2012.
974 doi: 10.1016/j.resconrec.2012.02.006. URL <https://doi.org/10.1016/j.resconrec.2012.02.006>.
- 975 [12] F. Castino, L. Rusca, and G. Solari. Wind climate micro-zoning: a pilot application to liguria region (north
976 western italy). *Journal of Wind Engineering and Industrial Aerodynamics*, 91(11):1353–1375, November 2003.
977 doi: 10.1016/j.jweia.2003.08.004. URL <https://doi.org/10.1016/j.jweia.2003.08.004>.
- 978 [13] Julián Ascencio-Vásquez, Kristijan Brecl, and Marko Topič. Methodology of köppen-geiger-photovoltaic climate
979 classification and implications to worldwide mapping of PV system performance. *Solar Energy*, 191:672–685,
980 October 2019. doi: 10.1016/j.solener.2019.08.072. URL <https://doi.org/10.1016/j.solener.2019.08.072>.
- 981 [14] Fatima Harkouss, Farouk Fardoun, and Pascal Henry Biwole. Passive design optimization of low energy buildings
982 in different climates. *Energy*, 165:591–613, December 2018. doi: 10.1016/j.energy.2018.09.019. URL <https://doi.org/10.1016/j.energy.2018.09.019>.
- 983
- 984

- 987 [15] ABNT. *ABNT NBR 15220-3: Desempenho térmico de edificações – Parte 3: Zoneamento bioclimático brasileiro*
 988 *e diretrizes construtivas para habitações unifamiliares de interesse social.* ASSOCIAÇÃO BRASILEIRA DE
 989 NORMAS TÉCNICAS, Rio de Janeiro, RJ, Brazil, 2005.
- 990 [16] ANSI/ASHRAE. *ANSI/ASHRAE standard 169-2021.* ANSI/ASHRAE, 2021.
- 991 [17] M. Kottek, J. Grieser, C. Beck, B. Rudolf, and F. Rubel. World map of the köppen-geiger climate classifi-
 992 cation updated. *Meteorologische Zeitschrift*, 15(3):259–263, 2006. ISSN 09412948. doi: 10.1127/0941-2948/
 993 2006/0130. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-33745866181&doi=10.1127%2f0941-2948%2f2006%2f0130&partnerID=40&md5=fba1e5c80cd015caf836550b96ecbf06>. cited By 3712.
- 995 [18] M.C. Peel, B.L. Finlayson, and T.A. McMahon. Updated world map of the köppen-geiger climate clas-
 996 sification. *Hydrology and Earth System Sciences*, 11(5):1633–1644, 2007. ISSN 10275606. doi: 10.5194/
 997 hess-11-1633-2007. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-35348859178&doi=10.5194%2fhess-11-1633-2007&partnerID=40&md5=87740ed624b017283a040b54d3553c67>. cited By 3793.
- 999 [19] Facundo Bre, Rayner M. e Silva Machado, Linda K. Lawrie, Drury B. Crawley, and Roberto Lamberts. As-
 1000 sessment of solar radiation data quality in typical meteorological years and its influence on the building per-
 1001 formance simulation. *Energy and Buildings*, 250:111251, November 2021. doi: 10.1016/j.enbuild.2021.111251.
 1002 URL <https://doi.org/10.1016/j.enbuild.2021.111251>.
- 1003 [20] Seyed Mousavi Maleki, H. Hizam, and Chandima Gomes. Estimation of hourly, daily and monthly global solar
 1004 radiation on inclined surfaces: Models re-visited. *Energies*, 10(1):134, January 2017. doi: 10.3390/en10010134.
 1005 URL <https://doi.org/10.3390/en10010134>.
- 1006 [21] Hyun-Jin LEE, Shin-Young KIM, and Chang-Yeol YUN. Comparison of solar radiation models to estimate
 1007 direct normal irradiance for korea. *Energies*, 10(5):594, 4 2017. doi: 10.3390/en10050594. URL <https://doi.org/10.3390/en10050594>.
- 1009 [22] R. Karki, R. Talchhabadel, J. Aalto, and S.K. Baidya. New climatic classification of nepal.
 1010 *Theoretical and Applied Climatology*, 125(3-4):799–808, 2016. ISSN 0177798X. doi: 10.1007/
 1011 s00704-015-1549-0. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84981170168&doi=10.1007%2fs00704-015-1549-0&partnerID=40&md5=7041f54ae9cfcd1f06de111fcf269885>. cited By 24.
- 1013 [23] Bekarys Omarov, Shazim Ali Memon, and Jong Kim. A novel approach to develop climate classification based
 1014 on degree days and building energy performance. *Energy*, 267:126514, March 2023. doi: 10.1016/j.energy.2022.
 1015 126514. URL <https://doi.org/10.1016/j.energy.2022.126514>.
- 1016 [24] Angélica Walsh, Daniel Cóstola, and Lucila Chebel Labaki. Performance-based climatic zoning method for
 1017 building energy efficiency applications using cluster analysis. *Energy*, 255:124477, September 2022. doi: 10.
 1018 1016/j.energy.2022.124477. URL <https://doi.org/10.1016/j.energy.2022.124477>.
- 1019 [25] Mingcai Li, Shanjun Cheng, and Xiaoyi Fang. An efficient performance assessing index for building climatic
 1020 zoning methods based on probability density functions. *Energy and Buildings*, 271:112323, September 2022. doi:
 1021 10.1016/j.enbuild.2022.112323. URL <https://doi.org/10.1016/j.enbuild.2022.112323>.

- 1022 [26] Angélica Walsh, Daniel Cóstola, Jan L.M. Hensen, and Lucila Chebel Labaki. Multi-criterial performance-based
1023 climatic zoning of brazil supported by local experts. *Building and Environment*, 243:110591, September 2023.
1024 doi: 10.1016/j.buildenv.2023.110591. URL <https://doi.org/10.1016/j.buildenv.2023.110591>.
- 1025 [27] Hamed Yassaghi, Patrick L. Gurian, and Simi Hoque. Propagating downscaled future weather file uncertainties
1026 into building energy use. *Applied Energy*, 278:115655, November 2020. doi: 10.1016/j.apenergy.2020.115655.
1027 URL <https://doi.org/10.1016/j.apenergy.2020.115655>.
- 1028 [28] D. B. Crawley and L. K. Lawrie. Climate.OneBuilding.Org, 2020. URL <http://climate.onebuilding.org>.
1029 Accessed June, 2020.
- 1030 [29] Ian Harris, Timothy J. Osborn, Phil Jones, and David Lister. Version 4 of the CRU TS monthly high-resolution
1031 gridded multivariate climate dataset. *Scientific Data*, 7(1), April 2020. doi: 10.1038/s41597-020-0453-3. URL
1032 <https://doi.org/10.1038/s41597-020-0453-3>.
- 1033 [30] Taiping Zhang, William S. Chandler, James M. Hoell, David Westberg, Charles H. Whitlock, and Paul W.
1034 Stackhouse. A global perspective on renewable energy resources: Nasa's prediction of worldwide energy resources
1035 (power) project. In *Proceedings of ISES World Congress 2007 (Vol. I – Vol. V)*, pages 2636–2640. Springer Berlin
1036 Heidelberg, 2008. doi: 10.1007/978-3-540-75997-3_532. URL https://doi.org/10.1007/978-3-540-75997-3_532.
- 1038 [31] NASA-POWER. POWER Docs, 2020. URL <https://power.larc.nasa.gov/docs/>. Accessed January, 2023.
- 1039 [32] Copernicus Climate Change Service. Era5-land monthly averaged data from 2001 to present, 2019. URL
1040 <https://cds.climate.copernicus.eu/doi/10.24381/cds.68d2bb30>.
- 1041 [33] Copernicus Climate Change Service. Era5-land hourly data from 2001 to present, 2019. URL <https://cds.climate.copernicus.eu/doi/10.24381/cds.e2161bac>.
- 1043 [34] National Oceanic and Atmospheric Administration. Global Hourly - Integrated Surface Database (ISD), 2023.
1044 URL <https://www.ncei.noaa.gov/pub/data/noaa/isd-lite/>. Accessed in January, 2023.
- 1045 [35] L.G. Eli, A.F. Krelling, M.S. Olinger, A.P. Melo, and R. Lamberts. Thermal performance of residential building
1046 with mixed-mode and passive cooling strategies: The brazilian context. *Energy and Buildings*, 244:111047,
1047 August 2021. doi: 10.1016/j.enbuild.2021.111047. URL <https://doi.org/10.1016/j.enbuild.2021.111047>.
- 1048 [36] A.F. Krelling, L.G. Eli, M.S. Olinger, R.M.E.S. Machado, A.P. Melo, and R. Lamberts. A thermal performance
1049 standard for residential buildings in warm climates: Lessons learned in brazil. *Energy and Buildings*, 281:
1050 112770, February 2023. doi: 10.1016/j.enbuild.2022.112770. URL <https://doi.org/10.1016/j.enbuild.2022.112770>.
- 1052 [37] ABNT. ABNT NBR 15575: *Edifícios habitacionais - Desempenho*. ASSOCIAÇÃO BRASILEIRA DE NORMAS
1053 TÉCNICAS, Rio de Janeiro, RJ, Brazil, 2021.

- 1054 [38] Maria Andrea Triana, Roberto Lamberts, and Paola Sassi. Characterisation of representative building typologies
 1055 for social housing projects in brazil and its energy performance. *Energy Policy*, 87:524–541, December 2015.
 1056 ISSN 0301-4215. doi: 10.1016/j.enpol.2015.08.041. URL <http://dx.doi.org/10.1016/j.enpol.2015.08.041>.
- 1057 [39] Rayner Maurício e Silva Machado, Matheus Soares Geraldi, Mateus Bavaresco, Marcelo Salles Olinger, Larissa
 1058 Pereira de Souza, Artur Martins Kamimura, Natasha Hansen Gapski, Tiago de Castro Quevedo, Liége Garlet,
 1059 Ana Paula Melo, and Roberto Lamberts. Metamodel to predict annual cooling thermal load for commercial,
 1060 services and public buildings: A country-level approach to support energy efficiency regulation. *Energy and*
 1061 *Buildings*, 301:113690, December 2023. ISSN 0378-7788. doi: 10.1016/j.enbuild.2023.113690. URL <http://dx.doi.org/10.1016/j.enbuild.2023.113690>.
- 1063 [40] INMETRO. *Instrução Normativa Inmetro para a Classificação de Eficiência Energética de Edificações Comer-*
 1064 *ciais, de Serviços e Públícas.* INMETRO, Rio de Janeiro, RJ, Brazil, 2021.
- 1065 [41] Peter J. Rousseeuw. Silhouettes: A graphical aid to the interpretation and validation of cluster analysis.
 1066 *Journal of Computational and Applied Mathematics*, 20:53–65, November 1987. ISSN 0377-0427. doi: 10.1016/
 1067 0377-0427(87)90125-7. URL [http://dx.doi.org/10.1016/0377-0427\(87\)90125-7](http://dx.doi.org/10.1016/0377-0427(87)90125-7).
- 1068 [42] T. Calinski and J. Harabasz. A dendrite method for cluster analysis. *Communications in Statistics - Theory*
 1069 *and Methods*, 3(1):1–27, 1974. ISSN 0361-0926. doi: 10.1080/03610927408827101. URL <http://dx.doi.org/10.1080/03610927408827101>.
- 1071 [43] Maurício Roriz. Zbbr - zoneamento bioclimÁtico do brasil, 2004. URL <https://labeee.ufsc.br/pt-br/downloads/softwares/zbbr>.
- 1073 [44] Gregory E. Tucker, Stephen T. Lancaster, Nicole M. Gasparini, Rafael L. Bras, and Scott M. Rybarczyk.
 1074 An object-oriented framework for distributed hydrologic and geomorphic modeling using triangulated irregular
 1075 networks. *Computers & Geosciences*, 27(8):959–973, October 2001. doi: 10.1016/s0098-3004(00)00134-5. URL
 1076 [https://doi.org/10.1016/s0098-3004\(00\)00134-5](https://doi.org/10.1016/s0098-3004(00)00134-5).
- 1077 [45] Chang Shu, Abhishek Gaur, Liangzhu (Leon) Wang, Michal Bartko, Abdelaziz Laouadi, Lili Ji, and Michael
 1078 Lacasse. Added value of convection permitting climate modelling in urban overheating assessments. *Building*
 1079 *and Environment*, 207:108415, January 2022. ISSN 0360-1323. doi: 10.1016/j.buildenv.2021.108415. URL
 1080 <http://dx.doi.org/10.1016/j.buildenv.2021.108415>.
- 1081 [46] I. Piri, A. Khanamani, S. Shojaei, and H. Fathizad. Determination of the best geostatistical method for climatic
 1082 zoning in iran. *Applied Ecology and Environmental Research*, 15(1):93–103, 2017. ISSN 15891623. doi: 10.15666/
 1083 aeer/1501_093103. URL https://www.scopus.com/inward/record.uri?eid=2-s2.0-85013157633&doi=10.15666%2faeer%2f1501_093103&partnerID=40&md5=655b215853889f0d8c0ca78edebfa3a3. cited By 5.
- 1085 [47] C.A. Alvares, J.L. Stape, P.C. Sentelhas, J.L. De Moraes Gonçalves, and G. Sparovek. Köppen’s climate
 1086 classification map for brazil. *Meteorologische Zeitschrift*, 22(6):711–728, 2013. ISSN 09412948. doi: 10.1127/
 1087 0941-2948/2013/0507. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84897100402&doi=>

- 1088 10.1127%2f0941-2948%2f2013%2f0507&partnerID=40&md5=0f37f18be7e8900bbb829d3ea64aad3b. cited By
1089 2033.
- 1090 [48] P.G. Dixon, M. Allen, S.N. Gosling, D.M. Hondula, V. Ingole, R. Lucas, and J. Vanos. Perspectives on the syn-
1091 optic climate classification and its role in interdisciplinary research. *Geography Compass*, 10(4):147–164, 2016.
1092 ISSN 17498198. doi: 10.1111/gec3.12264. URL <https://www.scopus.com/inward/record.uri?eid=2-s2.0-84962184081&doi=10.1111%2fgec3.12264&partnerID=40&md5=ec6afbde89564732e82e7f8482a60af8>.
1093 cited By 14.
- 1095 [49] Mehmet Bilgili, Arif Ozbek, Alper Yildirim, and Erdogan Simsek. Artificial neural network approach for monthly
1096 air temperature estimations and maps. *Journal of Atmospheric and Solar-Terrestrial Physics*, 242:106000,
1097 January 2023. doi: 10.1016/j.jastp.2022.106000. URL <https://doi.org/10.1016/j.jastp.2022.106000>.
- 1098 [50] Alessandra Souza. Mapas em representação tridimensional. *Confins*, (47), September 2020. doi: 10.4000/confins.
1099 31886. URL <https://doi.org/10.4000/confins.31886>.
- 1100 [51] QGIS Development Team. *QGIS Geographic Information System*. QGIS Association, 2023. URL <https://www.qgis.org>.
- 1102 [52] Brazilian Institute of Geography and Statistics (Instituto Brasileiro de Geografia e Estatística) IBGE.
1103 Continuous cartographic base of brazil (base cartográfica contínua do brasil) 1:1.000.000 – bcim.
1104 http://geoftp.ibge.gov.br/cartas_e_mapas/bases_cartograficas_continuas/bcim/versao2016/shapefile/bcim_2016_shapefiles_21-11-2018.zip. Accessed on: 2023/05/30.
- 1106 [53] Kelvin S. do Prado. Brazilian municipalities. <https://github.com/kelvins/Municipios-Brasileiros>. Accessed on: 2023/05/30.
- 1108 [54] João Ricardo Lourenço. Open-elevation. <https://github.com/Jorl17/open-elevation>. Accessed on:
1109 2023/05/30.
- 1110 [55] Adams Rackes, Ana Paula Melo, and Roberto Lamberts. Naturally comfortable and sustainable: Informed
1111 design guidance and performance labeling for passive commercial buildings in hot climates. *Applied Energy*,
1112 174:256–274, jul 2016. doi: 10.1016/j.apenergy.2016.04.081. URL <https://doi.org/10.1016/j.apenergy.2016.04.081>.

APÊNDICE B – ARTIGO 2 - ANÁLISE DE INCERTEZA

Na sequência é apresentado na íntegra o artigo intitulado "*The impact of climate data uncertainty on bioclimatic zoning for building design*". Esse artigo foi submetido na revista Building and Environment em Julho de 2024.

AUTORIA COMPARTILHADA

Esse documento atesta que todos os coautores do artigo intitulado “*The impact of climate data uncertainty on bioclimatic zoning for building design*” CONCORDAM com o seu uso como parte da tese de doutorado de Rayner Maurício e Silva Machado, orientada pelo professor Roberto Lamberts e coorientada pela professora Ana Paula Melo do Programa de Pós Graduação em Engenharia Civil (PPGEC) da Universidade Federal de Santa Catarina (UFSC).

Autores: Rayner Maurício e Silva Machado, Facundo Bre, Ana Paula Melo, Roberto Lamberts



Facundo Bre

Florianópolis, 16 de Julho de 2024.

¹ The impact of climate data uncertainty on bioclimatic zoning for building design

² Rayner Maurício e Silva Machado^{a,*}, Facundo Bre^b, Ana Paula Melo^a, Roberto Lamberts^a

³ ^a*Laboratory of Energy Efficiency in Buildings (LabEEE), Department of Civil Engineering, Federal University of Santa Catarina
4 (UFSC), Florianópolis, Brazil*

⁵ ^b*Luxembourg Institute of Science and Technology (LIST), Environmental Research and Innovation (ERIN), 5 avenue des
6 Hauts-Fourneaux, L-4362, Esch-sur-Alzette, Luxembourg*

⁷ **Abstract**

⁸ Bioclimatic zoning is a powerful tool for generalizing construction guidelines for buildings aiming to improve their
9 energy performance and thermal comfort, among other features. Reliable and accurate climate data is crucial for
10 developing an effective zoning method. Additionally, other uncertainties, such as microclimates and future climate
11 conditions, can also highly influence the resulting zoning. The present research aims to investigate how uncertainty
12 regarding climate data can influence climate classification, considering the current bioclimatic zoning method for
13 Brazil and exploring the impact of climate database accuracy, microclimates, and future climate behavior. To do this,
14 the accuracy of climate data is assessed by comparing the standard weather data (i.e., recent typical meteorological
15 years) with equivalent data from reanalysis (ERA5-Land) and an artificial neural network model. The Urban Weather
16 Generator software is employed to model the influence of microclimates. This approach is calibrated based on dry-
17 bulb temperature from an urbanized meteorological station using particle swarm optimization and subsequently
18 applied in local climate zones. The climate change analysis is performed considering two emission scenarios (RCP2.6
19 and RCP8.5), three GCM models (HadGEM2, MPI-ESM, and NorESM1), and two RCM models (RegCM and
20 REMO). All Brazilian cities (5570) are analyzed, but a deeper investigation is conducted in 34 representative cities.
21 Errors in high spatial resolution data are less than 0.4 °C for temperature and 2.1% for relative humidity throughout
22 Brazil. The urban microclimate causes a difference of 0.61 °C in annual mean temperature among urban contexts.
23 Regarding climate change, the annual mean temperature tends to increase over time in Brasília, regardless of the
24 emission scenario, ranging from 1.5 °C to 5.4 °C by 2090. The results show that the three sources of uncertainty
25 analyzed can significantly impact the bioclimatic classification of the studied Brazilian cities.

²⁶ **Keywords:** Building performance, Climatic zoning, Uncertainty analysis, Microclimate, Climate change.

²⁷ **1. Introduction**

²⁸ The need for air conditioning represents a substantial portion of the global energy demand of urban buildings [1].
29 Improving the thermal performance of buildings reduces their energy consumption. Consequently, studies must be
30 conducted to establish building design guidelines according to the local climate to maximize the thermal performance
31 of buildings [2, 3]. As buildings exposed to close climatic conditions tend to have similar energy consumption
32 [4, 5], bioclimatic zoning is a powerful tool for generalizing construction guidelines [6]. Hence, to avoid conducting
33 excessive simulations for various locations, a comprehensive understanding of the building's thermal performance can
34 be achieved by simulating it in climate-representative cities according to existing climatic zoning.

*Corresponding author

Email address: rayner.mauricio@posgrad.ufsc.br (Rayner Maurício e Silva Machado)

When climate zoning adds two locations with different climatic behaviors into one climate zone, it suggests an accuracy issue [7, 5], resulting in less reliable zoning. Thus, it is typical for any climatic zoning method to have dispersion within each climate zone. For instance, if buildings were simulated in all cities of a climate zone, a dispersion in energy consumption for heating or cooling could be seen. When performance indicators are used instead of climate indicators in the development of climatic zoning, the dispersion in energy consumption within each zone may be smaller. However, this approach can group locations with the same energy consumption, even if this occurs for different reasons [8]. Therefore, the dispersion in climate and building performance indicators must be carefully analyzed when developing climate zoning.

Climate zoning can be developed considering a deterministic or probabilistic approach. The first approach assumes that each city is classified into a single climate zone (hard clustering). In the second approach, each location can be in more than one zone, following a probability of occurrence (soft clustering) [9]. The most traditional approach to developing climate zoning is deterministic. It applies a clustering method (e.g., K-means) to climate indicators [7], such as dry-bulb temperature, precipitation, and relative humidity. Reliable and representative climate data are essential to developing climate zoning. For this purpose, data is obtained from meteorological stations. Due to the limited number of meteorological stations, climate data must be interpolated to classify the climate of locations without stations [10]. Another possibility is to use high spatial resolution climate data, such as ERA5, CRU, or POWER [8]. However, the accuracy of these databases would hardly ever be higher than that of calibrated meteorological stations. Thus, classifying the climate of locations without meteorological stations establishes an important source of uncertainty.

Climate zoning can be understood as a model or classification often based on machine learning techniques, such as Decision Tree or K-means [7, 4]. Despite having high accuracy, it is expected to find uncertainties in the predicted values by a model [11, 12]. Thus, climatic zoning (as models) can also present uncertainty about its results. However, when various sources of uncertainty are associated, the final accuracy of the zoning tends to become more uncertain.

Bre et al. [13] analyzed the quality and impact of solar radiation from typical meteorological years (TMYs) on commercial and residential buildings. As solar radiation is often not measured correctly, it is necessary to use mathematical models to obtain this information. The authors concluded that the accuracy of solar radiation data can strongly influence the selection of the typical months that create TMYs. Furthermore, the results showed that using two versions of TMY databases for simulating the building's ideal thermal loads can establish a difference of close to 40% for residential buildings and 10% for commercial buildings.

Omarov et al. [5] investigated the difference between cooling and heating degree days of two TMY databases. The authors concluded the most recent weather data has a higher cooling degree-day and lower heating degree-day than the older version. The results indicate the risk of combining two databases in clustering analysis and suggest the importance of selecting the most suitable one. Therefore, selecting a climate database plays a crucial role that needs to be addressed in climate zoning studies. Using more recent climate databases is more advisable as they consider the unfolding effect of climate change.

Machado et al. [8] recently published a study introducing the development of a bioclimatic zoning method for Brazil. In this study, the authors showed that although the established zoning is deterministic, there is uncertainty about climate data, especially with the selection of the database that should be used in the development of zoning

73 criteria, as well as the database to be used in the climate classification of all Brazilian municipalities. Moreover, the
74 annual mean dry-bulb temperature used in the climate classification of municipalities was obtained through ERA5-
75 Land and showed an RMSE of 0.63 °C when compared to meteorological station data obtained via TMYx.2007-2021.
76 For relative humidity, the authors used data from an artificial neural network with an RMSE of 2.95%, also about
77 TMYx.2007-2021.

78 Another source of uncertainty regarding climate data is microclimate. For instance, urban climates can be
79 affected by the urban heat island and urban cool island phenomena [14, 15]. Urban heat islands (UHIs) occur when
80 the air temperature inside an urban context is higher than observed in rural areas, occurring mainly at night. This
81 phenomenon leads to higher energy consumption for cooling and lower consumption for heating [1]. For urban cool
82 islands (UCIs), the air temperature inside the urban context is lower than in rural perimeter regions, occurring
83 during the day [16]. As temperature is one of the main climate indicators used in climate zoning methods, the urban
84 climate could strongly impact the climate classification.

85 Palme et al. [17] pointed out that the urban heat island effect is not considered in building energy simulation
86 by default. However, this effect can have a significant impact on building energy consumption. Thus, the authors
87 proposed a method for incorporating UHI into building energy simulation to overcome this issue. The Urban Weather
88 Generator (UWG) was used for urban climate modeling, and TRNSYS for building modeling. Simulations were
89 performed in Guayaquil (Ecuador), Lima (Peru), Antofagasta, and Valparaíso (Chile). The results showed a potential
90 increase in energy demand of 15% to 200% when considering the urban heat island effect.

91 The increase in greenhouse gas concentrations accelerates climate change, leading to significant shifts in future
92 climates. For instance, air temperatures are expected to increase considerably around the world. The implications
93 of these changes can be relevant, particularly regarding the building thermal performance [18, 19]. Furthermore,
94 it is important to consider that the establishment of bioclimatic zoning, which depends on the performance of the
95 building, can be influenced. The hypothesis presented here highlights the importance of analyzing how future climatic
96 conditions could affect bioclimatic zoning. Even with notable advances in climate modeling, several uncertainties
97 are still associated with predicting future climate. Complex climate systems, climate variations, and greenhouse gas
98 emissions are among the many factors that contribute to these uncertainties [20, 21]. Despite their limitations, these
99 models are essential for understanding global climate patterns, allowing scientists to predict future climate scenarios
100 and develop effective strategies to mitigate climate change.

101 Triana et al. [22] studied the impact of climate change on Brazilian social housing using future weather files
102 obtained by CCWorldWeatherGen. The authors observed that in 2050, the city of São Paulo could increase its
103 average annual temperature by 2 °C, the average annual relative humidity tends to decrease by 2.4%, and global
104 horizontal radiation could increase by 3.13 kW/m². These climate variations are reflected in an increase in the
105 cooling degree-days and a decrease in the heating degree-days with values close to 0. Although the results were
106 obtained for São Paulo city, other Brazilian cities may also present similar results.

107 Based on the state-of-the-art literature, several studies have been conducted to explore different approaches to
108 establishing a new climate zoning method. However, the assessment of uncertainty related to the climate data
109 is a point that is often overlooked in these analyses. Some studies pointed out this source of uncertainty but
110 without a comprehensive analysis of the topic. Consequently, several open questions arise and lead to the objectives

111 of this study. For example, the uncertainty related to how the accuracy of the employed climate database can
112 influence the final climate classification. Other sources of uncertainties relate to how many bioclimatic zones can
113 exist within the municipal territory or how microclimates affect the climate classification. Another clear source of
114 uncertainty is associated with climate change. To summarize, various potential sources of uncertainty can affect
115 climate classification and should be thoroughly investigated.

116 Therefore, the present study aims to analyze how uncertainty regarding climate data can influence the climate
117 classification of locations by considering the current bioclimatic zoning method for Brazilian territory. The primary
118 novelty of this work is in treating uncertainty comprehensively, as it explores climate database accuracy, detailing
119 whether there are points along the urban and rural microclimates of each municipal territory that could be classified
120 in another climate zone, besides exploring uncertainty regarding future climate behavior. Although a case study for
121 bioclimatic zoning in Brazil is presented here, the study deals with the subject conceptually since the same type of
122 uncertainty analyzed can also influence climate classification considering other climatic zoning methods and regions
123 worldwide.

124 2. Method

125 This section presents the methods used to investigate the impact of uncertainty in the bioclimatic zoning developed
126 for Brazil. Several sources of uncertainty are assessed, such as database accuracy, microclimates, and future climates.

127 2.1. Introduction of Brazilian bioclimatic zoning

128 The bioclimatic zoning method under analysis in this article was recently developed by Machado et al. [8] to
129 replace the method presented in the Brazilian standard ABNT-NBR 15220-3 [23]. The criteria of the method are
130 mainly based on annual dry-bulb temperature (DBTmean) and relative humidity (RHmean), Table 1. The DBTmean
131 established a bioclimatic zoning that is accurate for the thermal and energy performance of commercial and residential
132 buildings. At the same time, the RHmean allows a grouping of locations according to continentality, precipitation
133 level, latent cooling load, and moisture performance of buildings. Both climate indicators can be highly affected by
134 each uncertainty assessed in this work.

135 The zoning method was developed considering a limited number of TMYs, constructed with climate data measured
136 between 2007 and 2021. This limited number of TMYs occurred because the data comes from 577 meteorological
137 stations, of which only 298 were considered suitable for composing the database used to establish climate zoning.
138 However, Brazil has a vast territorial extension, with around 5570 municipalities. Therefore, other databases were
139 used to classify municipalities that did not have valid climate data from a meteorological station. The most accurate
140 results were obtained using ERA5-Land reanalysis data for DBTmean and an artificial neural network (ANN) model
141 for RHmean. With this information, it was possible to classify each Brazilian municipality and develop the map
142 shown in Figure 1.

143 As the number of Brazilian municipalities is remarkably high, part of the method a deeper analysis of some
144 municipalities is performed. The choice of the municipality was established according to what was most interesting
145 when the results were presented. However, these municipalities are previously indicated on the map, so it is possible

Table 1: Criteria of the Brazilian bioclimatic zoning method. Source: Machado et al. [8].

Zones	Description	Criteria 1	Criteria 2
1R	Very cold zone with severe winter	DBTmean <18.8 °C	Note 1
1M	Very cold zone with moderate winter		Criteria 2 of 1R must be false
2R	Cold zone with severe winter	18.8 °C ≤ DBTmean <20.9 °C	Note 2
2M	Cold zone with moderate winter		Criteria 2 of 2R must be false
3A	Mixed and humid zone	20.9 °C ≤ DBTmean <22.9 °C	RHmean >73.2%
3B	Mixed and dry zone		RHmean ≤ 73.2%
4A	Slightly hot and humid zone	22.9 °C ≤ DBTmean <25 °C	RHmean >70.3%
4B	Slightly hot and dry zone		RHmean ≤ 70.3%
5A	Hot and humid zone	25 °C ≤ DBTmean <27 °C	RHmean >68.7%
5B	Hot and dry zone		RHmean ≤ 68.7%
6A	Very hot and humid zone	27 °C ≤ DBTmean	RHmean >66.8%
6B	Very hot and dry zone		RHmean ≤ 66.8%

Note 1: (-30° < Latitude <-27.7° and DBTmean <17 °C) or (Latitude ≤ -30° and DBTmean <18.5 °C)

Note 2: Latitude ≤ -24.2° and Longitude ≤ -50.3°

146 to see a good spatial distribution of these locations that underwent this more in-depth analysis. These municipalities
 147 also have good diversity in their final bioclimatic classification.

148 This classification presented on the map establishes that the coldest bioclimatic zones are in lower latitudes
 149 (further south). Locations further north tend to be warmer. Locations close to the coast and in the Amazon region
 150 are wetter. However, the effect of altitude can promote behavior different from that of surroundings in some locations.
 151 The dry bulb temperature is expected to be lower at higher altitudes than in regions closer to ocean level. Thus, the
 152 altitude effect tends to make the map less homogeneous, but this is understood as a correct detailing of the climatic
 153 particularities present in the Brazilian context.

154 2.2. Assessing the impact of database accuracy

155 The accuracy of the climate database is the first source of uncertainty assessed in this work. To achieve this, it
 156 is considered the climate data measured at meteorological stations that gave rise to the TMYs from 2007 to 2021
 157 as more accurate values regarding real behavior. Therefore, uncertainty in measuring equipment is disregarded as
 158 an analysis considering such a source of uncertainty would be impractical given the data available for such a study.
 159 Based on this premise, two analyses are carried out regarding the accuracy of the databases: (1) a comparison
 160 between dry bulb temperature (ERA5-Land) and relative humidity (ANN) data with data obtained from TMYs, and
 161 (2) a potential error in the final climate classification of municipalities without valid TMY.

162 2.2.1. Uncertainty about the temperature and relative humidity

163 The bioclimatic zoning evaluated in this work has dry-bulb temperature and relative humidity as the main
 164 climatic indicators to classify each municipality. Therefore, the uncertainty in the accuracy of these indicators will
 165 be previously analyzed. The average annual values of both climate indicators (DBTmean and RHmean) are calculated
 166 for this. This calculation occurred for the databases used to develop bioclimatic zoning (ERA5-Land, ANN, and
 167 TMY). Subsequently, differences in TMY are calculated for DBTmean and RHmean. Using QGIS software, these
 168 differences are interpolated via the Inverse Distance Weighted (IDW) interpolation method with 2 as weight and
 169 presented on a map to understand the spatial distribution of this difference.

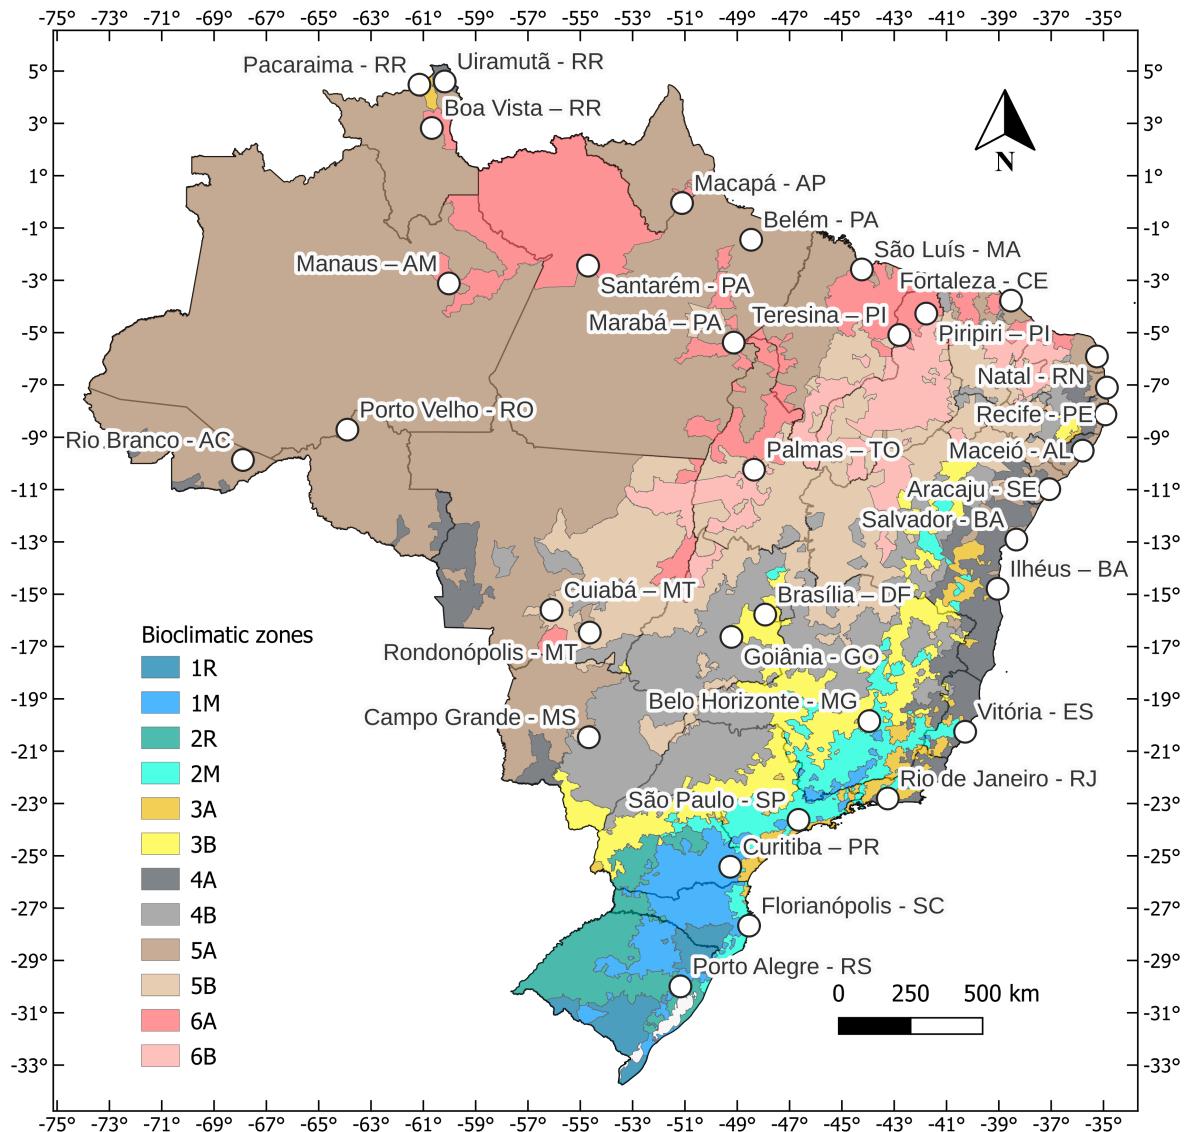


Figure 1: Map of the Brazilian bioclimatic zoning method and cities analyzed in depth.

170 2.2.2. The impact of database accuracy on climate classification

171 This section evaluates how the accuracy of high spatial resolution climate databases may influence municipalities'
 172 final climate classification (5570). For this, the uncertainty presented in the form of RMSE [8] for the annual mean
 173 dry-bulb temperature (ERA5-Land) and relative humidity (ANN) is used as a standard deviation to generate a
 174 random sampling of 10 thousand cases with normal distribution using the Numpy module from Python. For the
 175 annual mean dry-bulb temperature, the RMSE is 0.63 °C; for the annual mean relative humidity, the RMSE is 2.95%.
 176 Each sample of this sampling is classified according to the bioclimatic zoning. Finally, the percentage of the samples
 177 in each bioclimatic zoning is calculated.

178 *2.3. Assessing the impact of local climates and microclimates*

179 Local climates or urban and rural microclimates establish specific climatic behaviors that can considerably differ
180 from each other. For this reason, understanding how this can promote changes in the final climate classification
181 is relevant to be investigated in this work. Depending on the building's location, there may be an urban heat
182 island effect or even a cool island effect. Furthermore, buildings heavily shaded by their surroundings receive less
183 direct solar radiation, directly influencing their thermal balance. When the surrounding area is heavily vegetated
184 or has large bodies of water nearby, these locations may experience a significant increase in local relative humidity.
185 In this context, two tools are useful for microclimate analysis: the Local Climate Zones (LCZs) method and the
186 UWG software. Thus, two analyses are performed in this section about the impact of microclimate in a climate
187 classification: (1) examine the number of climates in each municipality territory using detailed climate data, and (2)
188 consider the microclimate in an urban context using climate modeling and measured data.

189 Stewart and Oke [24] developed a versatile classification method known as LCZ that accurately represents various
190 urban and rural environments. Using the LCZ classification system, environments can be categorized according to
191 their physical and morphological features in a standardized way. Factors like building height, density, vegetation
192 coverage, and surface materials are considered in this classification system. To analyze and compare urban heat
193 island effects in various cities or neighborhoods, one can examine the specific LCZ type of each area. Using this
194 standardized method enables a more accurate analysis of how urbanization affects the local climate, offering valuable
195 insights to develop strategies for mitigating the urban heat island effect and improving urban planning.

196 The UWG [25] is widely employed in urban climate research, providing a user-friendly framework of an urban
197 canopy model (UCM). UWG uses an algorithm that employs four models (rural season, vertical diffusion, urban
198 boundary layer, and urban canopy layer) to generate hourly air temperature and humidity values in urban locations
199 based on rural meteorological data. It is essential to comprehend this information to minimize the urban heat island
200 effect and analyze the consequences of urbanization on urban microclimates. This tool considers various features,
201 such as building height, building plan density, urban surface characteristics, anthropogenic sensible heat, vegetation
202 cover, and more.

203 *2.3.1. Uncertainty about the local climate using high spatial resolution climate data*

204 High spatial resolution data is evaluated to understand its variation within the territory of each Brazilian municip-
205 ipality, allowing to understand how representative each data can be. Ideally, within the territory of a municipality,
206 there would only be one type of bioclimatic zone, which will be explored in this section. Using ERA5-Land data
207 for annual mean dry-bulb temperature and an ANN for relative humidity, 70841 locations are classified according to
208 climate. These locations ate established according to the spatial distribution of ERA5-Land. Only locations within
209 the Brazilian territory are considered. The altitude considered as input in the ANN prediction is obtained using the
210 Global 30 Arc-Second Elevation (GTOPO30) [26], which is a digital elevation model (DEM) with a spatial resolution
211 of approximately 900 meters (30 arc seconds). The last procedure is to select each of the 5570 Brazilian municipalities
212 and calculate the percentage of occurrence where a given municipality has climates of one bioclimatic zone or more.
213 For example, a municipality with 20 points with climate data within its territory may have 30% of these locations
214 in one bioclimatic zone and 70% in another.

Table 2: Minimum and maximum values of UWG inputs used in calibration.

Name	Unit	Variable	Minimum	Maximum
Average Building Height	m	bldHeight	3	10
Urban area vertical to horizontal ratio	-	verToHor	0.5	2
Fraction of HVAC waste heat set to the street	-	h_mix	0	1
Road Albedo	-	albRoad	0.12	0.25
Non-building sensible heat at street level	W/m ²	sensAnth	0	25
Tree Cover	-	treeCover	0.01	0.05
Vegetation Albedo	-	albVeg	0.2	0.3
Roof Albedo	-	albRoof	0.12	0.25
Wall Albedo	-	albWall	0.2	0.8
Sensible heat per occupant	W	sensOcc	81	108
Urban boundary layer height during the day	m	h_ubl1	500	1500
Urban boundary layer height during the night	m	h_ubl2	50	100
Inversion height	m	h_ref	100	200

Table 3: Parameters combinations used in PSO algorithm.

Combination	C1	C2	W
PSO 1	2	2	0.9
PSO 2	0.5	0.5	0.7

2.3.2. The impact of urban microclimate on climate classification

To investigate the uncertainty concerning the urban microclimate, the DBTmean of TMYs inside and outside the urban perimeter is analyzed. These climates are also classified according to the bioclimatic zoning. The TMYs used are the same as those used in developing bioclimatic zoning (TMYx.2007-2021). Satellite imagery is used to assess the land cover and land use attributes surrounding the meteorological stations, including urban areas, vegetation, and bodies of water. One of these cities is selected to undergo a UWG calibration process. LCZ classification information is used to establish a variety of urbanistic variables that have an impact on the local climate. All variables involved in the optimization process are listed in Table 2. By including this data in the calibration process, the urban climate is more accurately represented. The remaining inputs of UWG are presented in Appendix Appendix A.

The optimization algorithm used in the calibration process is the Particle Swarm Optimization (PSO), through the Python pyswarms module [27]. Two combinations of hyperparameters are evaluated, one that explores the sample space more (PSO 1) and another that focuses more on the best results (PSO 2), Table 3. The cognitive component, known as C1, represents how a particle is attracted to its personal best position. Representing the particle's inclination towards the global best position, C2 serves as the social component in the particle swarm optimization algorithm. The inertia weight, denoted by W, determines the impact of a particle's previous velocity on its current velocity. By considering 1000 iterations and 12 particles, 12,000 UWG simulations are conducted for each combination. Furthermore, a sampling of 12 thousand cases is conducted using Sobol Sequence to compete with optimization algorithms.

In the last decade, many studies have discussed the urban heat island, especially analyzing how the urban climate behaves in building energy performance. To achieve this, researchers have used models that calculate urban climate behavior considering a series of urban parameters, as occurs with UWG. Therefore, to assess uncertainty regarding the urban microclimate, a few urban contexts (Appendix Appendix B) are simulated in the UWG and subsequently analyzed based on the calibrated model. These urban contexts are based on the LCZ established by Stewart and

238 Oke [24]. Here, it was decided that dense and open urban contexts with high, medium, and low buildings should
239 be evaluated. Only the open urban context has vegetation, represented by grasses and trees. Anthropogenic heat is
240 also established based on this same study and is fixed according to the buildings' density level. The denser it is, the
241 greater the anthropogenic heat established.

242 *2.4. Assessing the impact of climate changes*

243 Regarding climate change, at this stage, it is essential to understand the techniques used to determine these future
244 climates. The climate models used to predict future conditions vary in scale and complexity. Certain models simulate
245 future climate globally and are called Global Climate Models, General Circulation Models, or Global Circulation
246 Models (GCMs), which consider complex interactions between the atmosphere, oceans, land surface, and ice sheets
247 [21]. Other models have a regional focus, simulating the behavior of specific geographic regions, which is defined as
248 Regional Climate Models (RCMs). RCMs are used as a downscaling method [20]. RCMs use GCMs as boundary
249 conditions, establishing greater spatial and temporal resolution [28]. These models consider different greenhouse gas
250 emissions scenarios, representing possible paths for future socioeconomic development and mitigation efforts [29].
251 Emissions scenarios are described as Representative Concentration Pathways (RCPs), ranging from a substantial
252 increase in emissions (RCP8.5) to a dramatic decrease (RCP2.6), resulting in a range of potential climate futures
253 [20].

254 The simulated future climate may present different behaviors because several models and pollutant emission
255 scenarios exist. In this sense, it is important to understand that the simulated future climate does not express a
256 certainty of what will happen to the climate, but an indication of what could happen in the future can be predicted
257 based on whether the level of environmental impact is increased, reduced, or maintained. Given the impossibility
258 of predicting the future accurately, there is great uncertainty regarding which model and scenario are closest to
259 future climate behavior. For this reason, two analyses are conducted: (1) the behavior of the models and scenarios
260 (modeling) in terms of dry-bulb temperature and relative humidity; and (2) the impact of climate change on the
261 climate classification of Brazilian cities.

262 *2.4.1. Uncertainty about the modeling of future climate*

263 To assess climate change, we are using weather files developed by Bracht et al. [30] for all state capitals in Brazil
264 and the Federal District. These weather files consider two emission scenarios (RCP2.6 and RCP8.5), three GCMs
265 models (HadGEM2, MPI-ESM, and NorESM1), and two RCMs models (RegCM and REMO). The researchers used
266 the same methodology used in Annex 80 to create these files. For each weather file, the annual average dry-bulb
267 temperature and annual average relative humidity. By conducting an exploratory analysis on these data, it will be
268 possible to establish the capitals with the greatest variations in the evaluated climatic indicators. This exploratory
269 analysis considered the climate behavior of three different decades (2010, 2050, and 2090).

270 *2.4.2. Impact of future climate on climate classification*

271 Understanding how a city's climate classification can change over the years is crucial for exploring uncertainty
272 in climate studies. While such analysis can be performed using past climate data, this study focuses on evaluating
273 potential future changes in climate classification. For this analysis, Brasília is selected. It is anticipated that by 2050,

274 a new bioclimatic zoning will be necessary, as the current method may become outdated. However, it is important
275 to assess how climate classification might evolve over three different decades.

276 **3. Results**

277 This section presents and discusses the results regarding the different sources of uncertainty considered, namely:
278 (1) the accuracy of climate databases; (2) the thermal and moisture behavior of rural and urban areas; and (3)
279 climate change projections for the decades of 2010, 2050, and 2090. All analyses conducted in this paper are within
280 the Brazilian context. In particular, a detailed analysis is performed for various selected cities to understand the
281 impact of uncertainties on climate classification. It is worth noting that the baseline climate zoning employed in this
282 research was developed in [8] and briefly introduced in Section 2.1, which focuses on performing bioclimatic zoning
283 for the thermal, moisture, and energy performance of buildings.

284 *3.1. Uncertainties driven by the accuracy of weather data*

285 The first source of uncertainty analyzed in this paper is regarding the accuracy of the climate databases (ERA5-
286 Land and ANN). Although the accuracy of measurements is an important source of uncertainty, it is only possible
287 to perform a proper analysis with information about calibrations and features of equipment. For this reason, the
288 dry-bulb temperature and relative humidity from meteorological stations included in the database TMYx.2007-2021
289 are considered perfectly calibrated. Thus, two analyses are performed: (1) spatial distribution of the error related
290 to climate data; and (2) impact of the uncertainty about the accuracy in the final climate classification using a
291 probabilistic approach.

292 *3.1.1. Uncertainty associated with the temperature and relative humidity*

293 The bioclimatic zoning used in this study considered two main high-resolution spatial datasets (ERA5-Land
294 and ANN) for classifying municipalities. However, when municipalities had measured data from meteorological
295 stations (i.e., TMYx.2007-2021), we used them because of their potential higher accuracy. To understand the error
296 of considering only high-resolution spatial data, a comparison with TMYs is performed. The difference between
297 the high-resolution spatial data and the TMY data is employed as the indicator. These values are subsequently
298 interpolated throughout Brazil. Negative values indicate that TMYs have higher values than the high-resolution
299 spatial data, while positive values indicate that the high-resolution spatial data have higher values than the TMYs.

300 Figure 2 shows the results obtained from this analysis for the DBTmean and RHmean, which are the primary
301 environmental variables involved in the climate zoning method.

302 Regarding the DBTmean, it is possible to observe that a large portion of the Brazilian territory falls within the
303 range of -0.4 °C to 0.1 °C. This indicates that a considerable number of TMYs have higher values than ERA5-Land.
304 Moreover, it can be stated that this is the interval with the smallest possible errors. To provide a general description
305 of this error, it can be said that the mean is -0.13 °C, with a minimum of -2.46 °C, a maximum of 1.95 °C, and
306 a median of -0.11 °C. For the RHmean, it is possible to observe that a large portion of the Brazilian territory falls
307 within the range of -2.1% to 0.5%. To provide a general description of this error, it can be said that the mean is
308 0.32%, with a minimum of -13.75%, a maximum of 8.97%, and a median of 0.29%.

309 It is also possible to observe that the DBTmean of ERA5-Land is higher in regions of high altitude in the southern
 310 region (Rio Grande do Sul and Santa Catarina states) and some country's center regions. On the other hand, in the
 311 Northeast and North of Brazil, the tendency is for the DBTmean of ERA5-Land to be lower than in TMYx.2007-2021.

312 Regarding the RHmean, ERA5-Land overestimates the values in most locations between latitudes -19° and -30°.
 313 This same behavior is observed in the North and Northeast regions. With this analysis, it is possible to identify
 314 where these climate variables (DBTmean and RHmean) need to be improved. However, it is possible to conclude
 315 that the data are robust enough for the entire Brazilian territory, and in most locations, the error is close to 0.

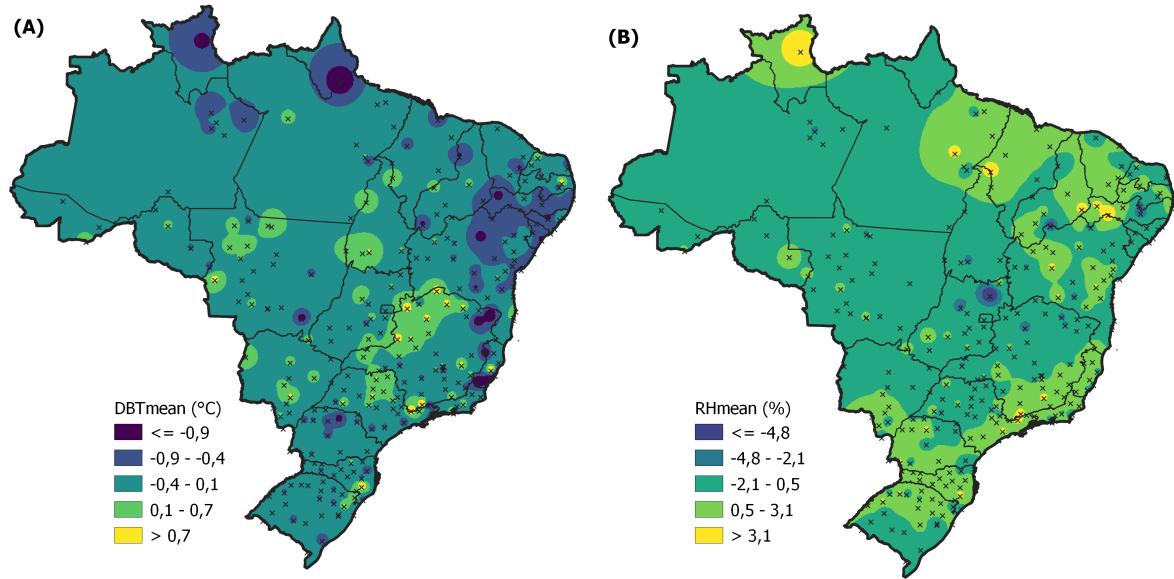


Figure 2: Map of interpolated values for the differences between the high-resolution spatial data (ERA5-Land and ANN) and the TMY data (TMYx.2007-2021): (a) DBTmean and (b) RHmean

316 3.1.2. Impact of geospatial resolution of the weather database

317 To understand how the accuracy of the high-resolution spatial climate dataset can impact the final bioclimatic
 318 classification, a normal distribution sampling of 10,000 cases is performed for each municipality, where the standard
 319 deviation is the same as the RMSE calculated for the ERA5-Land and the ANN model. This approach is statistically
 320 consistent since the RMSE can be understood as the standard deviation of the residual values. Thus, each point
 321 in this sample is classified into a bioclimatic zone, and the relative percentage of the occurrence frequency in each
 322 bioclimatic zone is calculated. For example, Table 4 shows the results for three locations (Santarém, Rondonópolis,
 323 and Piripiri).

324 As the main climatic indicators of the bioclimatic zoning method are characterized by the DBTmean and RHmean,
 325 changes can occur because of uncertainty in one of these indicators or both simultaneously. In the case of Santarém,
 326 which is previously classified in bioclimatic zone 6A, with the inclusion of uncertainty, 57% of the 10 thousand cases
 327 are classified as 6A and 43% as 5A. This change occurred only due to uncertainty in the DBTmean. In Rondonópolis,
 328 the uncertainty analysis indicates that this location can lie in five bioclimatic zones: 4B, 5A, 5B, 6A, or 6B. In this
 329 case, the changes are driven by both the DBTmean and RHmean. In Piripiri, the uncertainty in the RHmean
 330 establishes that it is more likely that this location is in a humid zone (6A) than in a dry zone (6B).

Table 4: Three cities with changes in the bioclimatic zone due to uncertainty in the data accuracy.

Municipality	DBTmean	RHmean	Zone	4B	5A	5B	6A	6B
Santarém	27.1 °C	82%	6A	-	43%	-	57%	-
Rondonópolis	26.3 °C	68%	5B	2%	35%	50%	8%	4%
Piripiri	28.6 °C	68%	6A	-	-	-	66%	34%

Table 5: Percentage according to the number of bioclimatic zones that each Brazilian city can be classified in accuracy analysis.

Number of Zones	1	2	3	4	5	6
Percentage of Total (%)	1.1	22.62	33.9	27.88	13.59	0.92

331 As Table 4 shows, when climate classification is performed probabilistically, the impact of uncertainty regarding
 332 climate indicators establishes that a given location could be classified into one or more bioclimatic zones. To
 333 understand how many bioclimatic zones could potentially exist in each municipality, Table 5 shows an analysis of
 334 the occurrence frequency for each number of zones in terms of occurrence percentages.

335 Only 1.1% of the municipalities presented a unique resulting bioclimatic zone in the 10,000 cases evaluated per
 336 location. For most municipalities (33.9%), the territory can have three different bioclimatic zones. Furthermore,
 337 many municipalities (27.88%) can result in up to four different zones, while 13.59% of municipalities can result in up
 338 to five different zones.

339 Although the employed bioclimatic zoning method classifies the municipality by considering single values for
 340 temperature and humidity, the results indicate that the final climate zoning is highly sensitive to the uncertainty
 341 associated with the geospatial resolution of the weather data source. Furthermore, although this study evaluates a
 342 specific bioclimatic zoning method for Brazil, the results suggest that other climate classification methods might also
 343 be inaccurate when classifying locations.

344 3.2. Impact of microclimates

345 Due to the existence of microclimates, climate indicators can vary spatially depending on the location. For
 346 instance, rural areas exhibit lower temperatures and higher relative humidity than urban areas during hot seasons.
 347 To evaluate the impact of these microclimates on climate zoning, two analyses are performed: (1) Uncertainty
 348 analysis and climate classification of high-resolution spatial data within each municipal territory, considering both
 349 rural and urban areas, using ERA5-Land and ANN data. (2) Analysis of the impact of urban microclimates on
 350 climate classification using TMYs from meteorological stations, specifically TMYx.2007-2021. Additionally, urban
 351 weather data is calibrated for one city using the UWG software, the PSO algorithm, and sampling via the Sobol
 352 sequence.

353 3.2.1. Uncertainty about the local climate using high spatial resolution climate data

354 Various geospatial factors, such as altitude and latitude can significantly influence the dry bulb temperature. To
 355 analyze this, Figure 3 presents the DBTmean data from the ERA5-Land database for 5570 Brazilian municipalities.
 356 The x-axis represents the DBTmean, the y-axis represents altitude, and the colors indicate the latitude bands. The
 357 results show that as latitude decreases, the dry-bulb temperature also decreases. Additionally, it can be observed
 358 that as altitude increases, the temperature mostly decreases.

Because of the small size of each city, the effect of latitude on climate zoning is not significant within the territory domain. On the other hand, the altitude effect within the municipal territory can strongly influence the climatic behavior of dry-bulb temperature. This greater focus on dry-bulb temperature occurs because most climate zones consider this indicator in some way, making it one of the most important indicators to be considered.

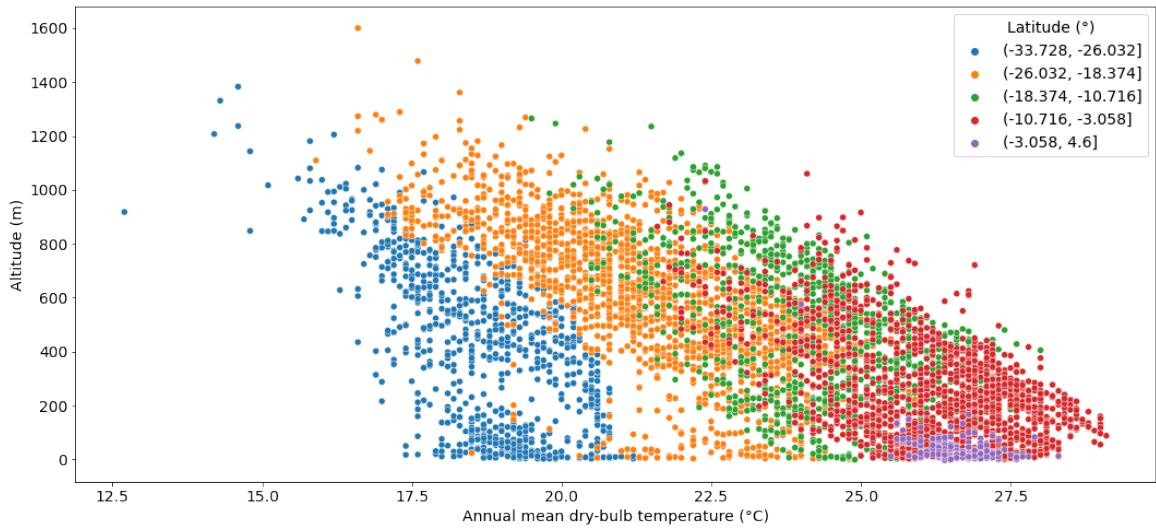


Figure 3: Correlations between annual mean dry-bulb temperature, altitude, and latitude.

The climate classification established by Machado et al. [8] assumes that a single point within the municipality classifies all its territory. Therefore, possible variations in altitude in urban or rural areas are not considered. To understand how these variations could impact climate classification, the DBTmean is observed using ERA5-Land, where only the data in each of the municipalities is selected. Figure 4a shows a histogram with the temperature difference observed in the DBTmean of the ERA5-Land data within each municipal territory. Only municipalities with more than one location with data are considered here. The standard deviations for the DBTmean occurring in the municipality territories are observed in Figure 4b.

The results indicate that the DBTmean difference within a municipal territory can reach 8.66 °C, with an average of 0.68 °C. Values equal to 0 are disregarded; otherwise, a higher frequency would be observed at an amplitude equal to 0, since some municipalities only had a single temperature data available within their territory. For the standard deviation, the average is 0.30 °C, where the highest values reach 2.34 °C. Although the difference is mostly less than 1 °C, this is enough to change the climate classification depending on the point considered. It is important to highlight that 70841 points are identified within Brazilian territory with valid data obtained through the ERA5-Land.

As the RHmean is obtained using an ANN model in Machado et al. [8], a new prediction is performed for the same 70841 ERA5-Land points. The altitude used in the input of the ANN model is obtained from the GTOPO30 digital elevation model [26]. Other inputs for the ANN model include latitude, longitude, dry-bulb temperature, interpolated values of relative humidity and global horizontal radiation. These interpolated values are obtained using the IDW method [31], and the climate indicators are derived from the TMYx.2007-2021 database.

To understand how differences in DBTmean values can influence the final climate classification, each point with valid data is classified and grouped according to its municipal territory. Table 6 shows that most cities (67.44%)

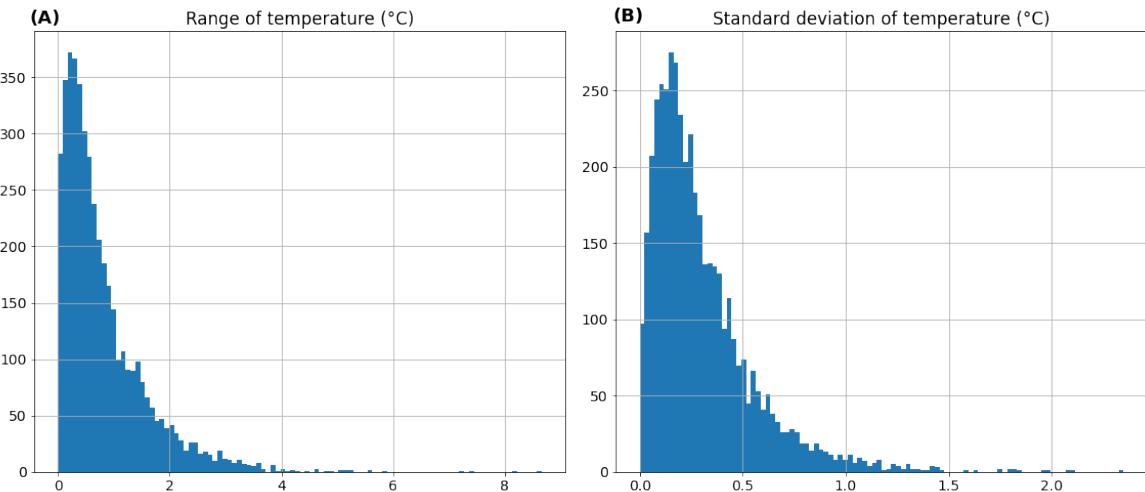


Figure 4: Histograms of difference in maximum and minimum annual mean dry-bulb temperature observed in the territory of each Brazilian city: (a) range; and (b) standard deviation.

Table 6: Percentage according to the number of bioclimatic zones found in the territory of each Brazilian city.

Number of Zones	1	2	3	4	5	6
Percentage of Total (%)	67.44	27.48	4.62	0.38	0.06	0.02

383 have only one type of climate zone within their territory, which is highly desirable for developing national standards.
 384 However, many municipalities (27.48%) have two climatic zones within their territory, which may be influenced by
 385 their location, e.g., in transition regions between two climate zones.

386 The results indicate the occurrence of several zones within the same municipal territory, so the effect of altitude is
 387 investigated since it may strongly influence thermal behavior. In this context, it is observed that two municipalities
 388 have the most significant variation regarding the DBTmean: Uiramutã with 8.14 °C and Pacaraima with 5.86 °C.
 389 These variations occur mainly because of differences in altitude within the municipality of 1765 m and 1135 m,
 390 respectively.

391 As these two municipalities have a population of approximately 14 thousand inhabitants each, it is interesting to
 392 investigate what happens in relevant municipalities, such as the state capitals. In this context, four state capitals
 393 are analyzed in Table 7.

394 The results show capitals with great uncertainty in the regional climate classification, as they have points in their
 395 territory classified in different bioclimatic zones. Cuiabá and Palmas are the capitals where the difference in altitude
 396 is the greatest, with 565 m and 415 m, respectively. Analyzing the classification of each ERA5-Land data within the
 397 territories of these municipalities, it is observed that Cuiabá and Palmas have three distinct bioclimatic zones. In
 398 comparison, Boa Vista and Teresina are classified into two distinct bioclimatic zones. The uncertainty percentages
 399 show that regional representation is relatively well established in Cuiabá (82% of points as 5B) and Boa Vista (77%
 400 of points as 6A). In Teresina, almost half of the points (45% of points as 6B) are classified in a zone different from
 401 that observed for a point in the urban perimeter of the municipality (6A). The case of Palmas is the most sensitive
 402 about this uncertainty in regional representation, as the highest percentage of points (64%) classify the climate as
 403 zone 5B and only 24% of points as zone 6B.

Table 7: Four cities with changes in the bioclimatic zone due to uncertainty in the local climate analysis.

Municipality	Altitude Diff.	DBTmean Diff.	Zone	4B	5A	5B	6A	6B
Cuiabá	565 m	2.34 °C	5B	9%	9%	82%	-	-
Boa Vista	98 m	1.26 °C	6A	-	23%	-	77%	-
Teresina	139 m	0.55 °C	6A	-	-	-	55%	45%
Palmas	415 m	2.39 °C	6B	-	-	64%	12%	24%

404 Establishing an accurate map in all regions of the municipal territory considering altitude is possible. However,
 405 this would make the map less homogeneous, as the areas tend to be more fragmented due to altitude. Moreover,
 406 the climate classification of each region would become more reliable. Thus, there is a contradiction between the
 407 simplicity of the climate zoning map (resolution) and its accuracy.

408 *3.2.2. Impact of urban microclimate on the climate classification*

409 When the TMYs of several Brazilian cities, employed in bioclimatic zoning in [8], are analyzed in detail, it is
 410 observed that some cities can have different climate classifications depending on the meteorological station considered.

411 Figure 5 analyzes the DBTmean values for three Brazilian cities (Manaus, Ilhéus, and Marabá) in the TMYx.2007-
 412 2021 database, representing each climate zone with a different color. It is observed that depending on the chosen
 413 weather station, the DBTmean can cause the city to be classified into different climate zones. This occurs mainly
 414 because the temperatures of these cities are around the transition limits of 25 °C and 27 °C in the classification
 415 method. In Manaus, two stations classify this city as Zone 6 and one station classifies as Zone 5. Marabá-PA can
 416 also be classified as Zone 6 or Zone 5. In the case of Ilhéus-BA, the climate can be classified as Zone 5 or Zone 4.

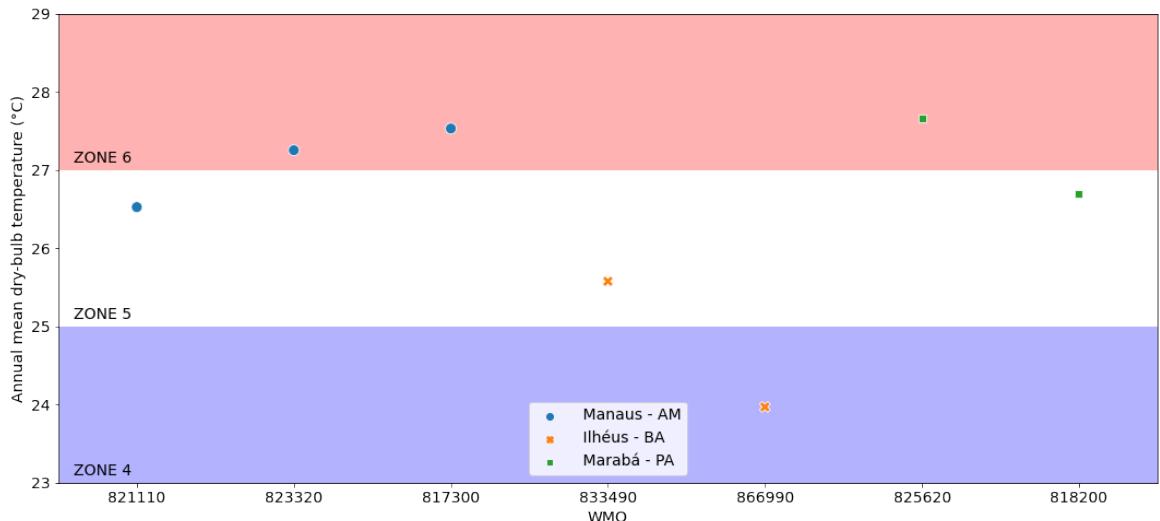


Figure 5: Changes in the climate classification of three cities due to dry-bulb temperature observed in different meteorological stations.

417 Figure 6 shows the locations of the meteorological stations for the three cities analyzed to understand better the
 418 reasons that can drive the different classifications. The results suggest that the characteristics of the surrounding
 419 conditions at the meteorological station influence the climatic behavior recorded by the meteorological station.
 420 Therefore, when there are several meteorological stations in the same city, the ideal is to classify the municipality

according to the climate zone that appears most frequently. The correct climate classification of the municipality becomes doubtful when two or more bioclimatic zones appear more frequently within a city. Here, using reanalysis data and ANN can be an excellent solution to classify the city into a bioclimatic zone. Another solution is to analyze the surrounding meteorological stations and establish, using some objective criteria, which meteorological station is most qualified to represent the climate of that city.

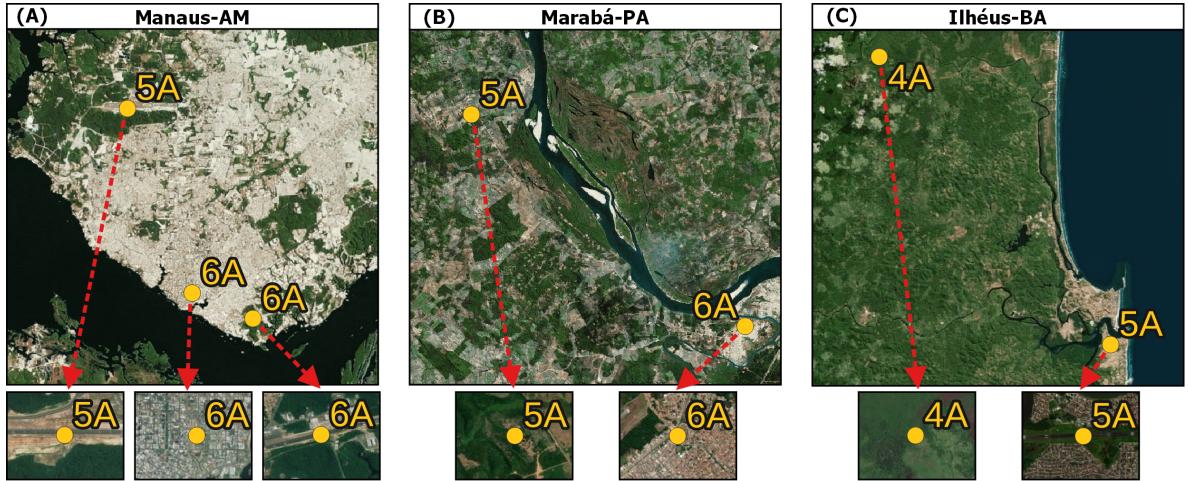


Figure 6: Satellite images of the meteorological stations in three cities: (a) Manaus-AM; (b) Marabá-PA; and (c) Ilhéus-BA.

The analyzed cities have humid climates with high precipitation levels throughout the year and have rivers or seas in the surroundings. Because of this, all the cities are classified with the letter "A". On the other hand, in Manaus, two meteorological stations are classified as 6A (one is at an airport) and one as 5A (also at an airport). The point highlighted here is that the stations closer to more urbanized regions have higher temperatures (Zone 6) than those at the airport a little further away from the city (Zone 5). This shows that the microclimate established by the surroundings may influence the thermal behavior of these meteorological stations. The same behavior occurs in Marabá-PA and Ilhéus-BA, where the meteorological station of an urbanized area has a warmer climate than stations in a rural area.

Buildings are commonly placed within the urban perimeter, where the climatic behavior differs from adjacent rural areas. A phenomenon called Urban Heat Island explains this particular climate behavior in cities. In cities, the annual mean temperature tends to be higher due to the difficulty of losing heat at night. This phenomenon reduces thermal amplitude in urban areas. Therefore, a conventional meteorological station cannot establish climate behavior in an urban context, suggesting that microclimates and climate classifications within urban spaces differ from those observed in meteorological stations.

To assess different urban contexts, the UWG software is adopted for climate modeling, and the model is calibrated based on optimization using the PSO algorithm [27]. Certain UWG parameters are fixed based on satellite images processed with QGIS software (see Appendix A). This study is applied to Ilhéus-BA, where a rural meteorological station and a more urbanized one are located.

In the optimization process, two configurations of hyperparameters are tested: one that explores a wide range of combinations (PSO 1) and another that focuses on the best results (PSO 2). A sampling using the Sobol Sequence

is also implemented to compare with the previous calibration. Figure 7 shows the histogram of the mean annual dry-bulb temperature RMSE for the rural meteorological station compared to the more urbanized station. The PSO 1 algorithm exhibits a wide RMSE range, with values comparable to those obtained by the Sobol Sequence. Notably, the PSO 2 configuration yields the best results. This indicates that while PSO 1 explores a broader range of the sample space without focusing on optimal cases, PSO 2 specifically targets the best outcomes. Despite the varied methodologies, the optimal results are similar across all three approaches (1.1851 °C for PSO 1, 1.1836 °C for PSO 2, and 1.1848 °C for Sobol Sequence). Among all simulations, the optimal case is produced by PSO 2, with an RMSE of 1.1836 °C, classifying the more urbanized station as Local Climate Zone 6 (LCZ6).

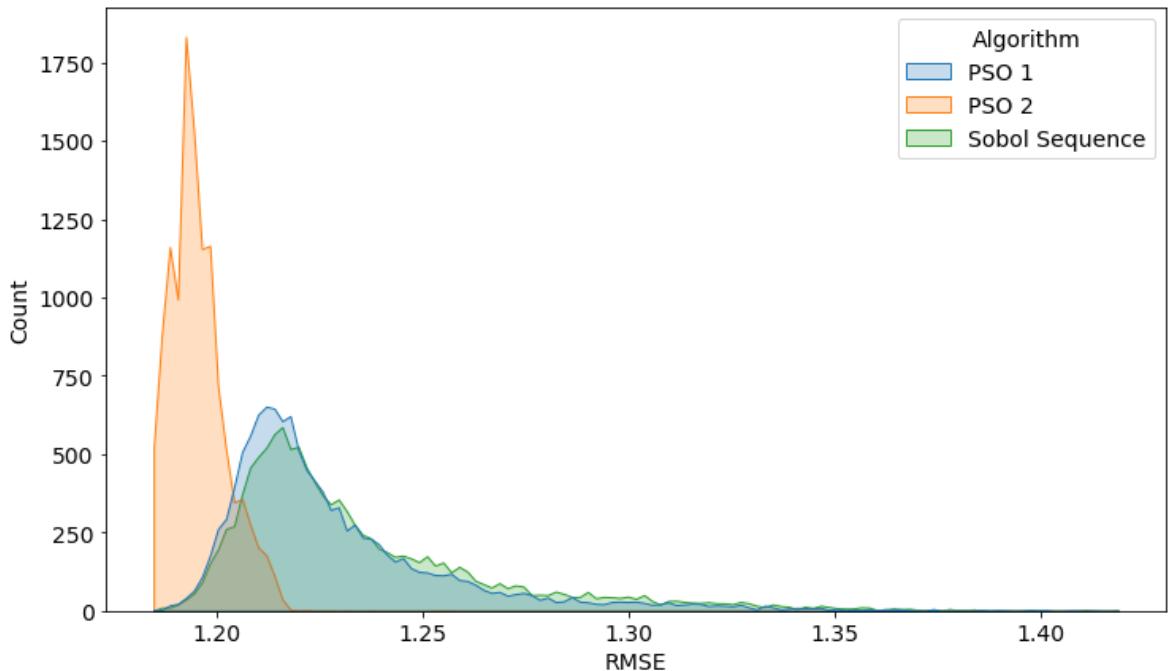


Figure 7: Histograms of RMSE of annual mean dry-bulb temperature of PSO and Sobol Sequence.

Figure 8 illustrates the hourly mean dry-bulb temperature and relative humidity results for the calibration month across the three scenarios (Rural, UWG, and Urban). These results demonstrate that the UWG model effectively transforms the rural climate data into urban climate data. The agreement between the urban data and the UWG outputs is notable for the dry-bulb temperature. However, the relative humidity results could be more satisfactory. This discrepancy may be attributed to the proximity of the urban station to the sea, in contrast to the more inland rural station. The actual context of the meteorological station is likely more complex than the UWG algorithm can capture, leading to inaccuracies in modeling relative humidity throughout the day.

Despite these challenges, the urban station is successfully characterized as LCZ6 through calibration. Consequently, the input parameters are adjusted for other Local Climate Zones (LCZ1 - LCZ5), and further simulations are conducted using UWG, as detailed in Appendix B.

Figure 9 shows the dry-bulb temperature and relative humidity obtained from the weather file to better understand the hygrothermal behavior of these LCZs. "Maximum" represents the average of daily maximums, "Minimum" represents the average of daily minimums, and "Mean" represents the annual mean of each evaluated climate variable.

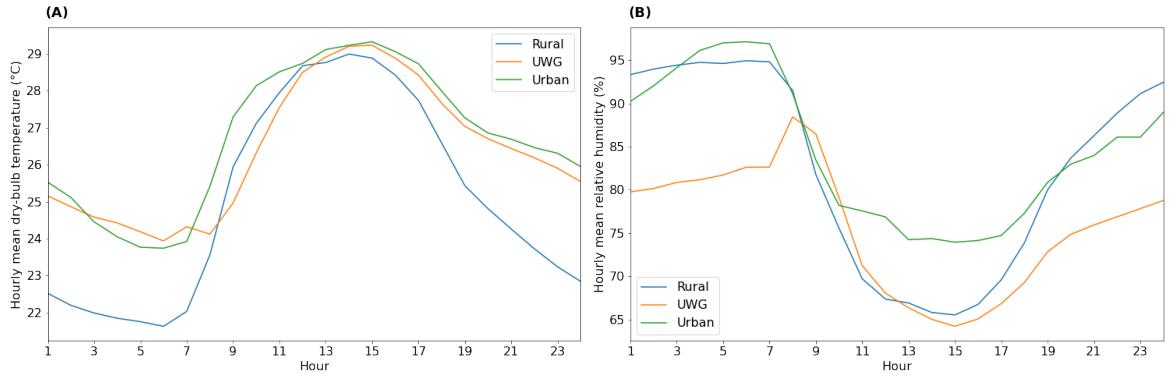


Figure 8: Comparison of hourly mean values of December of 2018 considering UWG simulation, rural and urbanized meteorological stations: (a) dry-bulb temperature and (b) relative humidity.

The results indicate that higher temperatures are observed in denser urban environments. This trend is consistent across all temperature metrics (maximum, mean, and minimum). The highest differences reach 0.61 °C for the mean temperature, 0.49 °C for the minimum temperature, and 0.24 °C for the maximum temperature. Conversely, relative humidity is higher in less dense urban environments. A significant decrease is observed for relative humidity, averaging approximately 2.80%. For the maximum relative humidity, the reduction is close to 1.99%.

Regarding the bioclimatic zone, the base weather file establishes that Ilhéus-BA is in bioclimatic Zone 4A. However, the classification shifts to zone 5A in the simulated urban results. This indicates that uncertainty in the urban context can cause the city to be classified in a different zone from that indicated by the meteorological station.

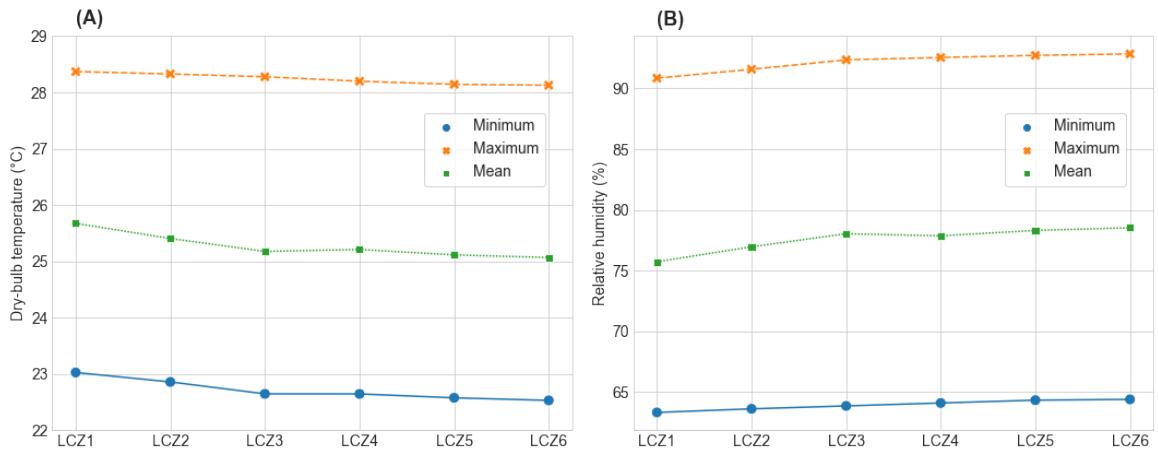


Figure 9: Maximum, minimum, and mean values according to six Local Climate Zones: (a) dry-bulb temperature and (b) relative humidity.

3.3. Influence of climate change

Researchers have made significant efforts to address potential future climates by developing and applying various models and scenarios, resulting in numerical simulations that require high computational resources. Although it is currently possible to access the results of these simulations, knowing which model and scenario is most appropriate

479 for estimating future climates is a matter of considerable uncertainty. Furthermore, climate classification is expected
480 to change as the climate is also likely to change. In this context, this section evaluates (1) the uncertainty regarding
481 models and scenarios considering the major Brazilian cities (state capitals); and (2) the impact of climate change on
482 the bioclimatic classification of those cities.

483 *3.3.1. Uncertainty about the modeling of future climate*

484 Climate zoning is usually generated using past climate data. Although uncertainties can be associated with
485 this data, it is still possible to perform a numerical validation of the climate database. However, climate zoning is
486 designed to be used in the present and the future, where the behavior of climates is very uncertain. Currently, several
487 models are available to predict future climates, representing potential climate changes over the years. In this section,
488 the uncertainty associated with some of these models (HadGEM2 + RegCM, MPI-ESM + RegCM, NorESM1 +
489 RegCM, HadGEM2 + REMO, MPI-ESM + REMO, NorESM1 + REMO) [30] for high and low emission scenarios
490 (RCP 2.6 and RCP 8.5) in the 2010s, 2050s, and 2090s is investigated, considering the two main weather variables
491 of the climate classification method, i.e., DBTmean and RHmean. Figures 10 and 11 show the results obtained for
492 this analysis in all the state capitals selected.

493 The results show that for the low emission scenario (RCP 2.6), the future DBTmean (2050 and 2090) will be
494 higher than in 2010 in almost all models and capitals; see Figure 10a. It is worth noting that the temperature in
495 2050 can be higher than in 2090 depending on the model considered. However, the boxes of these two decades have
496 similar dispersions and almost equivalent results. For this scenario, the capitals have an averaged dispersion of 1.21
497 °C, considering the three decades analyzed. Porto Alegre-RS is the capital with the lowest temperature dispersion
498 of 0.77 °C, while Boa Vista-RR has the highest dispersion of 2.22 °C.

499 For the high emission scenario (RCP 8.5), the dispersion in temperature does not overlap between the three
500 decades; see Figure 10b. It is evident that with the increase in emissions, the temperature will also increase,
501 especially over time, since the 2090s has much higher values than in the past and the same occurs for the 2050s.
502 Although there is no overlap, there is a great dispersion between models. Furthermore, this dispersion increases over
503 time; i.e., the 2090s is higher than the 2050s, and the 2050s is higher than 2010. For this scenario, the average of
504 the capitals had a dispersion of 4.8 °C considering the three decades analyzed; Florianópolis-SC is the capital with
505 the lowest dispersion in temperature, with 3.08 °C; and Manaus-AM is the capital with the highest dispersion, with
506 7.97 °C.

507 Figure 11a shows the results for the low-emission scenario, i.e., RCP 2.6. There is a great overlap in the mean
508 annual relative humidity of the models between the decades analyzed. In many cases, the overlap practically makes
509 the boxes of the three decades equivalent, as occurs in Recife-PE, São Luís-MA, and Vitória-ES, among others.
510 Inverse behaviors are also observed, for example, in Palmas-TO many models indicate that in the 2050s it will be
511 drier than the 2090s, while in Boa Vista-RR there is an indication that in the 2090s it will be drier than the 2050s.
512 For this scenario, the average of the capitals has a dispersion of 3.92% considering the three decades analyzed; Recife-
513 PE is the capital with the lowest dispersion in relative humidity, with 1.33%; Boa Vista-RR is the capital with the
514 highest dispersion, with 10%.

515 Regarding the high-emissions scenario (RCP 8.5), the dispersion in relative humidity shows an overlap between
516 the three decades; see Figure 11b. However, the general trend is that in the 2090s, the relative humidity will be

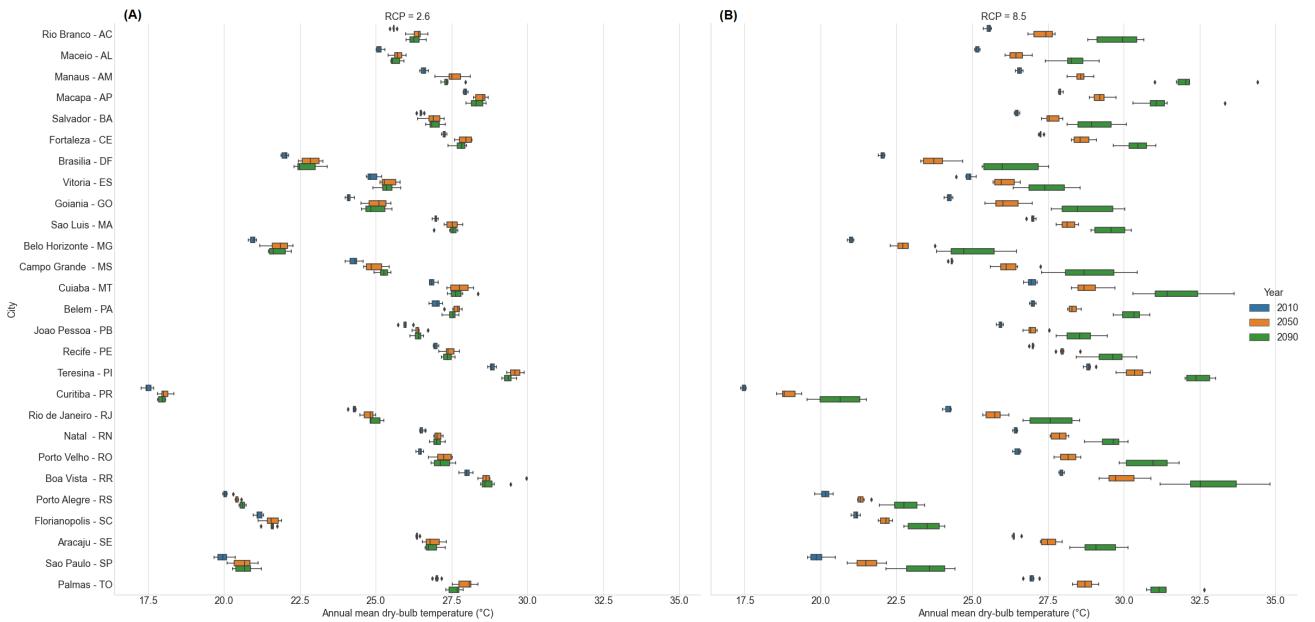


Figure 10: DBTmean under different emission scenarios: (a) low-emission scenario and (b) high-emission scenario.

lower than in the 2050s. Similarly to the case of predicted future temperatures, the dispersion between the models increases over time for the relative humidity. Despite this, it is also possible to observe capitals with very overlapping boxes, almost equivalent, having low dispersion, such as João Pessoa-PA, São Luís-MA, and Vitória-ES. For this high-emissions scenario, the average of the capitals has a dispersion of 9.2% considering the three decades analyzed; Salvador-BA is the capital with the lowest dispersion in relative humidity (1.33%); Manaus-AM is the capital with the highest dispersion (28.5%).

3.3.2. Impact of climate change on climate classification

In the previous section, it is possible to observe significant differences between the future climate scenarios and models. However, the analysis was performed to have an overall magnitude of uncertainties (i.e., for all models). In this section, the results of all models are analyzed in detail for the city of Brasília to understand the impact of climate change on the resulting climate zoning. Brasília was selected because it is one of the most important cities in Brazil since it is the federal capital. Furthermore, this city has a good representativeness of Brazilian climates, with an intermediate behavior, allowing us to better appreciate the potential climate changes.

Independent of the scenario and model considered, the DBTmean is around 22 °C in the 2010s; see Figure 12. For the other years, the mean annual temperature in the high-emissions scenario (RCP 8.5) establishes much higher temperatures than the low-emissions scenario (RCP 2.6). For RCP 8.5, temperatures also increase over the years, which is not very noticeable for RCP 2.6, depending on the model considered. The model with the highest temperature in the 2050s and 2090s is HadGEM2 with REMO, followed by HadGEM2 with RegCM. Therefore, an analysis of how climate zoning can be affected by this model that presents the highest temperature (HadGEM2 with REMO) is performed to understand better.

Figure 13 shows the climate classifications in different decades, and the results for the annual mean dry-bulb

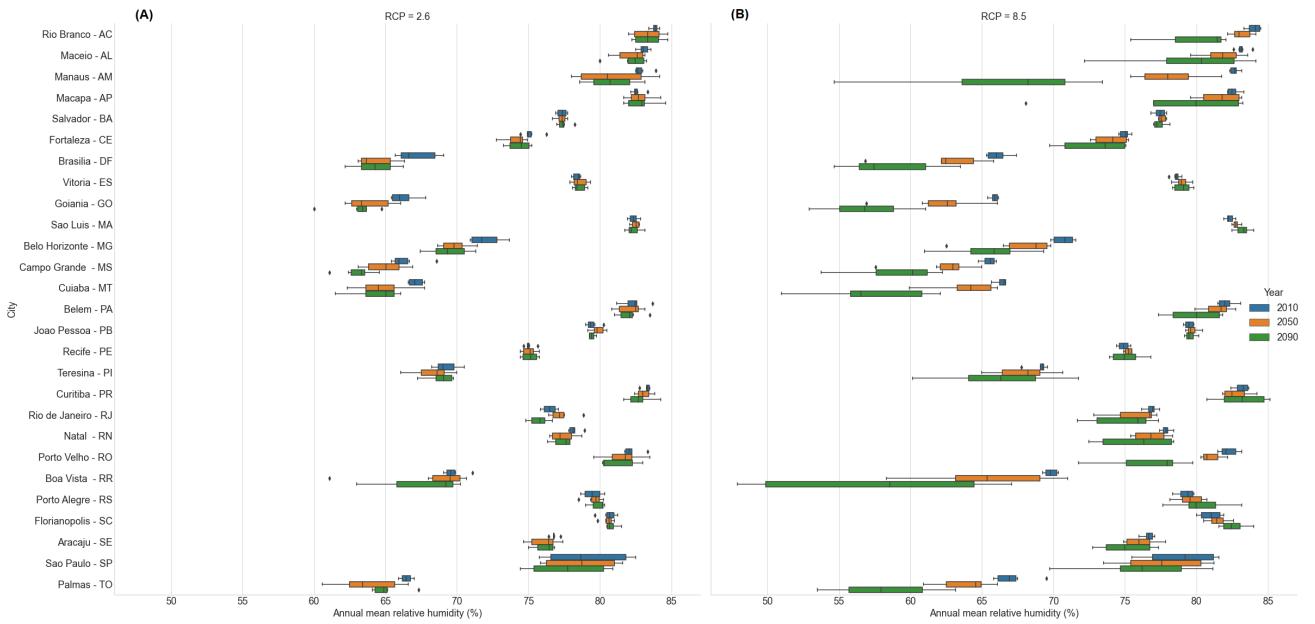


Figure 11: RHmean under different emission scenarios: (a) low-emission scenario and (b) high-emission scenario.

temperature and annual mean relative humidity. These results indicate that if the Representative Concentration Pathway is high, Brasília will increase its temperature and decrease its relative humidity in the future. The annual mean dry-bulb temperature resulting for the 2010s is 22.1°C , which could rise to 27.5°C in the 2090s. Consequently, the city's climate classification is altered. Brasília is classified as 3B (mixed and dry climate) in the 2010s, moving to 4B (slightly hot and dry) in the 2050s, and changing to 6B (very hot and dry) in the 2090s. These results show that climate change strongly impacts the climate classification of the evaluated city. However, similar behavior could also be observed in many other cities worldwide.

Figure 14 shows the results for the low-emissions scenario (RCP 2.6). In the 2050s and 2090s, The mean annual dry-bulb temperature increased by $1.3\text{-}1.5^{\circ}\text{C}$, while the RHmean decreased by $3.2\text{-}3.8\%$. Although the differences between the 2050s and 2090s are smaller for this scenario, climate change is still modifying a region classified as 3B into 4B. Thus, even in an optimistic emission scenario (low-emissions), global warming will significantly impact Brasília. Additionally, comparing the data from the low- and high-emissions scenarios, differences in temperatures can be observed: 0.9°C in the 2050s and 4.1°C in the 2090s.

4. Discussions

Climatic zoning is a useful tool for generalizing bioclimatic strategies and normative parameters, grouping locations with buildings that potentially exhibit similar performance. Even though the protocol used to construct climate zoning is reliable and conducted in the best possible manner, there will always be uncertainties associated with past, present, and future climate data. To explore the impact of this uncertainty, the present study evaluated various sources of uncertainty and their respective impacts on the climate classification of many Brazilian locations.

Different weather stations within the same city can present different classifications, and various points within the municipal territory can also be classified differently. This is especially due to altitude, which significantly affects

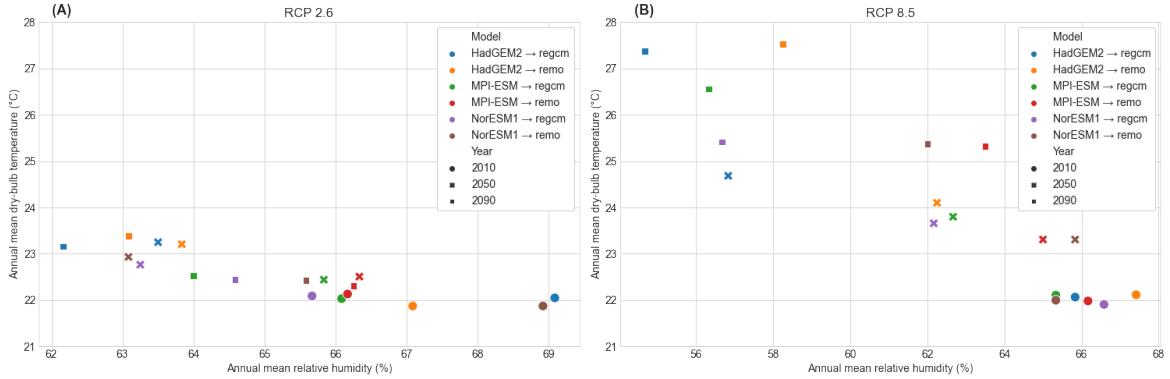


Figure 12: DBTmean and RHmean for Brasília, considering several models and decades: (a) low-emission scenario and (b) high-emission scenario.

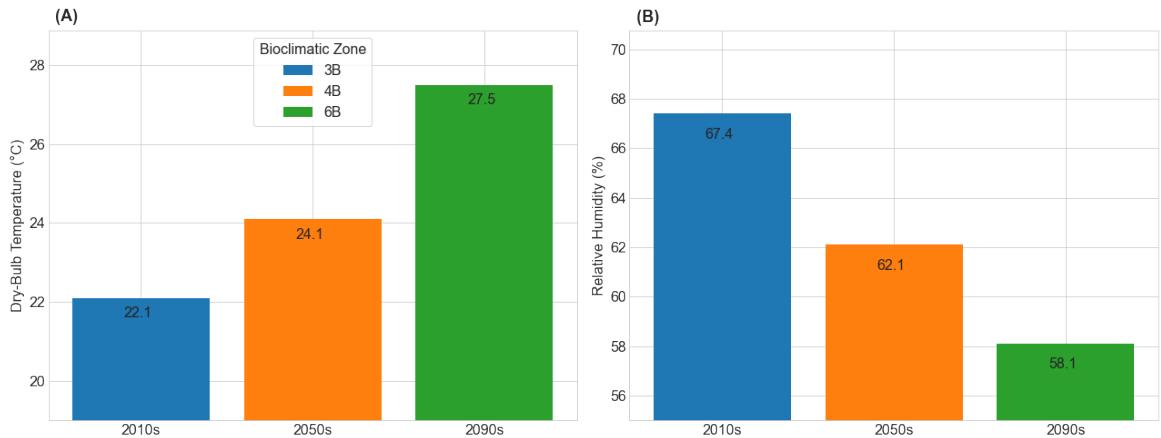


Figure 13: Climate classification of Brasília considering climate change with RCP 8.5: (a) DBTmean and (b) RHmean.

air temperature. Most municipalities had only one classification, but a significant number had two or more climate zones. Choosing a single classification for the entire city is the approach commonly used in the literature, but it is necessary to select data that is highly representative. However, a more detailed approach would involve different climate classifications depending on the specific location of the building analyzed.

Climate data itself has inherent uncertainties. These uncertainties can arise from the accuracy of the equipment, the accuracy of the interpolation method, or the model used to estimate climate data. The present study observed that when uncertainty is factored into the database, most locations could fall into three distinct zones. This probabilistic zoning approach allows us to understand that, although a location may be classified in a specific bioclimatic zone, the data may be inaccurate, leading to a completely different classification.

Although most zoning methods are deterministic, it would be beneficial to adopt a probabilistic approach. This would be particularly useful in differentiating locations within the same climatic zone that exhibit slightly different climatic behaviors. While uncertainty has been assessed for a specific bioclimatic zoning method, other climate zoning methods are also susceptible to these and other sources of uncertainty. Therefore, deterministic climate zoning is unlikely to be perfectly accurate in its final climate classification.

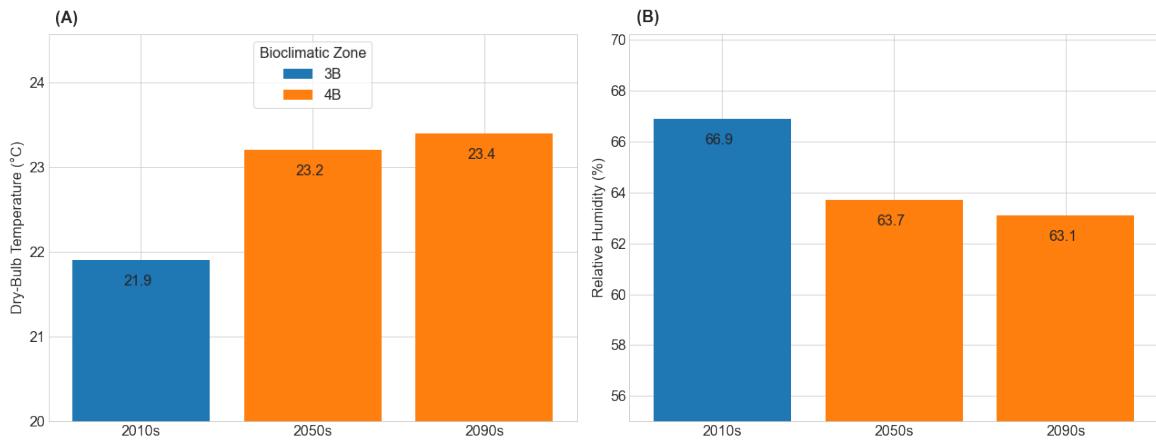


Figure 14: Climate classification of Brasília considering climate change with RCP 2.6: (a) DBTmean and (b) RHmean.

The bioclimatic zoning explored in this study is aimed at buildings, most of which are located in cities. In urban environments, climatic phenomena, such as the urban heat island effect occur. The analysis revealed a notable increase in air temperature and a decrease in relative humidity in urban areas. This is decisive for the classification of the bioclimatic zone, particularly when considering the urban heat island effect. However, no significant difference was found between the urban climatic contexts evaluated.

Future climate represents the final source of uncertainty assessed in this study. There is a clear trend towards a decrease in relative humidity and an increase in air temperature. While it is possible to use future weather data to create bioclimatic zoning or classify a location, the uncertainty of future climate data makes this approach less reliable. Therefore, we recommend to update climate zoning with past climate data whenever necessary, e.g., every 10-15 years.

5. Conclusions

This study assessed the uncertainty associated with climate data and its impact on the climate classification of a bioclimatic zoning method within the Brazilian context. Three main sources of uncertainty were evaluated: (1) the accuracy of the climate database; (2) urban and rural microclimates; and (3) future climate models and scenarios. The accuracy and uncertainty of the database were assessed by considering the errors in ERA5-Land and ANN in comparison to TMYx.2007-2021. The influence of urban microclimates was explored through calibrations using optimization algorithms and microclimate modeling with UWG software. Additionally, the rural climate was evaluated using data from ERA5-Land and an artificial neural network model. Regarding climate change, three GCM models (HadGEM2, MPI-ESM, and NorESM1) and two RCM models (RegCM and REMO) were evaluated using two emission scenarios (RCP2.6 and RCP 8.5) for the decades 2010s, 2050s, and 2090s.

From the results and analyses performed in this work, the following main conclusions can be drawn:

- The comparative analysis between high spatial resolution data (ERA5-Land and ANN) and meteorological station data (TMYx.2007-2021) revealed that, in a large part of the Brazilian territory, high spatial resolution

596 data present errors smaller than 0.4 °C for the average annual dry-bulb temperature and less than 2.1% for
597 the average annual relative humidity.

- 598 • High-resolution data showed slightly larger errors in certain regions, such as the south and northeast of the
599 country, which highlights the need for improvements in those locations. However, it is possible to state that
600 the data are sufficiently robust for the entire Brazilian territory, and in most places, the error is close to zero.
- 601 • To classify the climate of each municipality, when considering uncertainty in temperature and humidity data, it
602 was found that only 1.1% of municipalities have only one bioclimatic zone, while 33.9% have three bioclimatic
603 zones. This suggests that uncertainty in climate data may lead to bioclimatic classifications that differ from
604 those previously established.
- 605 • Many municipalities have more than one climate zone within their territory, which is influenced especially
606 by altitude. Altitude can cause variations in temperature within the same municipality of up to 8.66 °C.
607 This suggests that altitude is critical for accurate and realistic climate classification of each evaluated pixel.
608 Furthermore, it was observed that latitude also has a strong impact on temperatures observed throughout the
609 Brazilian territory.
- 610 • When analyzing the TMYs, it was observed that the climate classification can vary depending on the me-
611 teorological station considered, leading to different climate zones for the same city. This occurred mainly
612 when temperatures were close to the transitions of 25 °C and 27 °C. Furthermore, the characteristics of the
613 surroundings close to the station can influence the climatic behavior of the meteorological station.
- 614 • As for the UHI, the results suggest that uncertainty about the urban context can lead to the classification of
615 a city (Ilhéus-BA) in a zone different from that observed at the rural meteorological station, with a difference
616 of 0.61 °C in the average annual temperature observed between urban contexts.
- 617 • Regarding climate change, analysis of models for low (RCP 2.6) and high (RCP 8.5) scenarios shows that
618 temperature and relative humidity in capital cities vary considerably depending on the model. In the low-
619 emission scenario, temperature and relative humidity tend to be more stable over time. In the high-emission
620 scenario, the temperature increases, and the relative humidity decreases over time, with a large dispersion
621 between the models.
- 622 • As for the climate changes observed in Brasília, independent of the emission scenario, the average annual tem-
623 perature increases over time, while relative humidity decreases. In the high emission scenario, the temperature
624 could increase by up to 5.4 °C by 2090, changing the city's climate classification from 3B (mixed and dry
625 climate) to 6B (very hot and dry). In the low emission scenario, the temperature will increase by up to 1.5 °C
626 by 2090, changing the climate classification to 4B (slightly hot and dry).

627 Acknowledgments

628 This study was supported by the Brazilian governmental agency CNPq ("Conselho Nacional de Desenvolvimento
629 Científico e Tecnológico") and CAPES ("Coordenação de Aperfeiçoamento de Pessoal de Nível Superior"). The

630 authors would like to thank the LNCC ("Laboratório Nacional de Computação Científica"), which kindly provided
631 essential support for performing this research.

632 For supporting this research, Dr. Bre thanks the REGEN project. This project has received funding from the
633 European Union's Horizon Europe research and innovation programme under grant agreement N° 101123325.

634 **Appendix A. Urban microclimate modeling fixed in calibration**

635 In the modeling process, some UWG inputs are considered as fixed. Some are fixed after satellite images to be
636 processed in QGIS software, such as bldDensity, charLength, grasscover, rurVegCover, and h_obs. Google's Street
637 View helped identify many residential buildings in the region analyzed, making it possible to establish an entrance
638 to the bld. The other entries are established within what is common or even default in the UWG program.

Table A.8: Inputs of UWG fixed in calibration.

Name	Unit	Variable	Value
Urban area building plan density	-	bldDensity	0.31
Dimension of a square of the whole neighborhood	m	charLength	1000
Road pavement thickness	m	dRoad	0.5
Road pavement conductivity	W/m K	kRoad	1
Road volumetric heat capacity	J/m ³ K	cRoad	1600000
Climate Zone	-	zone	1A
Fraction of the urban ground covered in grass	-	grasscover	0.44
The month in which vegetation starts	month	vegStart	1
The month in which vegetation stops	month	vegEnd	12
Fraction of the heat absorbed by grass that is latent	-	latGrss	0.4
Fraction of the heat absorbed by trees that is latent	-	latTree	0.6
Fraction of the rural ground covered by vegetation	-	rurVegCover	0.95
Traffic schedule	-	SchTraffic	Default of Version 5.3.4
Building stock	-	bld	MidRiseApartment/New
Latent heat fraction from occupant	-	LatFOcc	0.3
Radiant heat fraction from occupant	-	RadFOcc	0.2
Radiant heat fraction from equipment	-	RadFEquip	0.5
Radiant heat fraction from light	-	RadFLight	0.7
Temperature height	m	h_temp	2
Wind height	m	h_wind	10
Circulation coefficient	-	c_circ	1.2
Exchange coefficient	-	c_exch	1
Max day threshold	W/m ²	maxDay	150
Max night threshold	W/m ²	maxNight	20
Min wind speed	m/s	windMin	0.01
Rural average obstacle height	m	h_obs	0.1

639 **Appendix B. Calibrated urban context and local climate zones analyzed**

640 Once the calibration process, which involved fine-tuning various urban parameters, is completed, the following
641 combination of UWG inputs is arrived at (Table B.9). The optimization algorithm selected these inputs because they
642 produce results that most closely match the actual measurements. However, it is important to note that these inputs
643 may not be a perfect representation of reality, as uncertainties and limitations still exist in the modeling process.
644 Thus, the calibrated combination serves as the best approximation currently available.

Table B.9: Inputs of UWG established after calibration.

Name	Unit	Variable	Value
Average Building Height	m	bldHeight	9.81
Urban area vertical to horizontal ratio	-	verToHor	1.35
Fraction of HVAC waste heat set to the street	-	h_mix	0.96
Road Albedo	-	albRoad	0.13
Non-building sensible heat at street level	W/m ²	sensAnth	23
Tree Cover	-	treeCover	0.03
Vegetation Albedo	-	albVeg	0.21
Roof Albedo	-	albRoof	0.16
Wall Albedo	-	albWall	0.55
Sensible heat per occupant	W	sensOcc	88
Urban boundary layer height during the day	m	h_ubl1	603
Urban boundary layer height during the night	m	h_ubl2	83
Inversion height	m	h_ref	143

645 The calibrated model is identified as an LCZ 6, and based on these results, the other Local Climate Zones (LCZs
 646 1-5) are modeled, as seen in the table B.10. The entries are presented in the same way as they are in the UWG input
 647 file. The Tables A.8 and B.9 above describe what each means. However, as *bldDensity* is fixed in the calibration
 648 process, it is important to highlight that it refers to building horizontal density considering the urban area.

Table B.10: Local Climate Zones analyzed in urban microclimate modeling using UWG.

Name	bldHeight	bldDensity	verToHor	grasscover	treeCover	sensAnth
LCZ1	30	0.60	7.20	0.00	0.00	70
LCZ2	15	0.60	3.60	0.00	0.00	70
LCZ3	3	0.60	0.72	0.00	0.00	70
LCZ4	30	0.31	2.40	0.44	0.03	23
LCZ5	15	0.31	1.90	0.44	0.03	23
LCZ6	9.81	0.31	1.35	0.44	0.03	23

649 References

- 650 [1] M. Santamouris, C. Cartalis, A. Synnefa, and D. Kolokotsa. On the impact of urban heat island and global
 651 warming on the power demand and electricity consumption of buildings—a review. *Energy and Buildings*, 98:119–
 652 124, jul 2015. doi: 10.1016/j.enbuild.2014.09.052. URL <https://doi.org/10.1016/j.enbuild.2014.09.052>.
- 653 [2] Maria Andrea Triana, Rayner Mauricio e Silva Machado, Artur Martins Kamimura, Matheus Körbes Bracht,
 654 Ana Paula Melo, and Roberto Lamberts. Energy efficiency strategies for brazilian social housing considering
 655 a life cycle perspective: Optimisation between thermal autonomy, energy consumption and costs. *Energy and*
 656 *Buildings*, 295:113254, September 2023. ISSN 0378-7788. doi: 10.1016/j.enbuild.2023.113254. URL <http://dx.doi.org/10.1016/j.enbuild.2023.113254>.
- 658 [3] A.F. Krelling, L.G. Eli, M.S. Olinger, R.M.E.S. Machado, A.P. Melo, and R. Lamberts. A thermal performance
 659 standard for residential buildings in warm climates: Lessons learned in brazil. *Energy and Buildings*, 281:112770,
 660 February 2023. ISSN 0378-7788. doi: 10.1016/j.enbuild.2022.112770. URL <http://dx.doi.org/10.1016/j.enbuild.2022.112770>.

- 662 [4] Angélica Walsh, Daniel Cóstola, Jan L.M. Hensen, and Lucila Chebel Labaki. Multi-criterial performance-based
663 climatic zoning of brazil supported by local experts. *Building and Environment*, 243:110591, September 2023.
664 ISSN 0360-1323. doi: 10.1016/j.buildenv.2023.110591. URL <http://dx.doi.org/10.1016/j.buildenv.2023.110591>.
- 666 [5] Bekarys Omarov, Shazim Ali Memon, and Jong Kim. A novel approach to develop climate classification based
667 on degree days and building energy performance. *Energy*, 267:126514, March 2023. doi: 10.1016/j.energy.2022.126514.
668 URL <https://doi.org/10.1016/j.energy.2022.126514>.
- 669 [6] Angélica Walsh, Daniel Cóstola, and Lucila Chebel Labaki. Review of methods for climatic zoning for building
670 energy efficiency programs. *Building and Environment*, 112:337–350, February 2017. ISSN 0360-1323. doi:
671 10.1016/j.buildenv.2016.11.046. URL <http://dx.doi.org/10.1016/j.buildenv.2016.11.046>.
- 672 [7] Leonardo Mazzaferro, Rayner M.S. Machado, Ana Paula Melo, and Roberto Lamberts. Do we need building
673 performance data to propose a climatic zoning for building energy efficiency regulations? *Energy and Buildings*,
674 225:110303, October 2020. ISSN 0378-7788. doi: 10.1016/j.enbuild.2020.110303. URL <http://dx.doi.org/10.1016/j.enbuild.2020.110303>.
- 676 [8] Rayner Maurício e Silva Machado, Facundo Bre, Leonardo Mazzaferro, Ana Paula Melo, and Roberto Lamberts.
677 Bioclimatic zoning for building performance using tailored clustering method and high-resolution climate data.
678 *Energy and Buildings*, 311:114157, May 2024. ISSN 0378-7788. doi: 10.1016/j.enbuild.2024.114157. URL
679 <http://dx.doi.org/10.1016/j.enbuild.2024.114157>.
- 680 [9] Hongzong Li and Jun Wang. From soft clustering to hard clustering: A collaborative annealing fuzzy c -means
681 algorithm. *IEEE Transactions on Fuzzy Systems*, 32(3):1181–1194, March 2024. ISSN 1941-0034. doi: 10.1109/
682 tfuzz.2023.3319663. URL <http://dx.doi.org/10.1109/TFUZZ.2023.3319663>.
- 683 [10] Mingcai Li, Shanjun Cheng, and Xiaoyi Fang. An efficient performance assessing index for building climatic
684 zoning methods based on probability density functions. *Energy and Buildings*, 271:112323, September 2022. doi:
685 10.1016/j.enbuild.2022.112323. URL <https://doi.org/10.1016/j.enbuild.2022.112323>.
- 686 [11] Rayner Maurício e Silva Machado, Matheus Soares Geraldi, Mateus Bavaresco, Marcelo Salles Olinger, Larissa
687 Pereira de Souza, Artur Martins Kamimura, Natasha Hansen Gapski, Tiago de Castro Quevedo, Liége Garlet,
688 Ana Paula Melo, and Roberto Lamberts. Metamodel to predict annual cooling thermal load for commercial,
689 services and public buildings: A country-level approach to support energy efficiency regulation. *Energy and*
690 *Buildings*, 301:113690, December 2023. ISSN 0378-7788. doi: 10.1016/j.enbuild.2023.113690. URL <http://dx.doi.org/10.1016/j.enbuild.2023.113690>.
- 692 [12] Marcelo Salles Olinger, Ana Paula Melo, and Roberto Lamberts. Developing a surrogate model for naturally
693 ventilated cellular offices in brazil. *Building and Environment*, 233:110075, April 2023. ISSN 0360-1323. doi:
694 10.1016/j.buildenv.2023.110075. URL <http://dx.doi.org/10.1016/j.buildenv.2023.110075>.

- 695 [13] Facundo Bre, Rayner M. e Silva Machado, Linda K. Lawrie, Drury B. Crawley, and Roberto Lamberts. Assessment
696 of solar radiation data quality in typical meteorological years and its influence on the building per-
697 formance simulation. *Energy and Buildings*, 250:111251, November 2021. doi: 10.1016/j.enbuild.2021.111251.
698 URL <https://doi.org/10.1016/j.enbuild.2021.111251>.
- 699 [14] Ahmed Memon RIZWAN, Leung Y.C. DENNIS, and Chunho LIU. A review on the generation, determination
700 and mitigation of urban heat island. *Journal of Environmental Sciences*, 20(1):120–128, jan 2008. doi: 10.1016/
701 s1001-0742(08)60019-4. URL [https://doi.org/10.1016/s1001-0742\(08\)60019-4](https://doi.org/10.1016/s1001-0742(08)60019-4).
- 702 [15] Shuangping Duan, Zhiwen Luo, Xinyan Yang, and Yuguo Li. The impact of building operations on urban
703 heat/cool islands under urban densification: A comparison between naturally-ventilated and air-conditioned
704 buildings. *Applied Energy*, 235:129–138, feb 2019. doi: 10.1016/j.apenergy.2018.10.108. URL <https://doi.org/10.1016/j.apenergy.2018.10.108>.
- 706 [16] Xinyan YANG, Yuguo LI, Zhiwen LUO, and Pak Wai CHAN. The urban cool island phenomenon in a high-rise
707 high-density city and its mechanisms. *International Journal of Climatology*, 37(2):890–904, may 2016. doi:
708 10.1002/joc.4747. URL <https://doi.org/10.1002/joc.4747>.
- 709 [17] M. Palme, L. Inostroza, G. Villacreses, Andrea Lobato-Cordero, and C. Carrasco. From urban climate to energy
710 consumption. enhancing building performance simulation by including the urban heat island effect. *Energy*
711 and *Buildings*, 145:107–120, jun 2017. doi: 10.1016/j.enbuild.2017.03.069. URL <https://doi.org/10.1016/j.enbuild.2017.03.069>.
- 713 [18] Fathin Haji Ismail, Mehdi Shahrestani, Maria Vahdati, Philippa Boyd, and Sohrab Donyavi. Climate change
714 and the energy performance of buildings in the future – a case study for prefabricated buildings in the uk.
715 *Journal of Building Engineering*, 39:102285, July 2021. ISSN 2352-7102. doi: 10.1016/j.jobe.2021.102285. URL
716 <http://dx.doi.org/10.1016/j.jobe.2021.102285>.
- 717 [19] Debaditya Chakraborty, Arifat Alam, Saptarshi Chaudhuri, Hakan Başaoglu, Tulio Sulbaran, and Sandeep
718 Langar. Scenario-based prediction of climate change impacts on building cooling energy consumption with
719 explainable artificial intelligence. *Applied Energy*, 291:116807, June 2021. ISSN 0306-2619. doi: 10.1016/j.apenergy.2021.116807. URL <http://dx.doi.org/10.1016/j.apenergy.2021.116807>.
- 721 [20] Jiwei Zou, Henry Lu, Chang Shu, Lili Ji, Abhishek Gaur, and Liangzhu (Leon) Wang. Multiscale numerical
722 assessment of urban overheating under climate projections: A review. *Urban Climate*, 49:101551, May 2023.
723 ISSN 2212-0955. doi: 10.1016/j.uclim.2023.101551. URL <http://dx.doi.org/10.1016/j.uclim.2023.101551>.
- 724 [21] Vahid M. Nik. Making energy simulation easier for future climate – synthesizing typical and extreme weather
725 data sets out of regional climate models (rcms). *Applied Energy*, 177:204–226, September 2016. ISSN 0306-2619.
726 doi: 10.1016/j.apenergy.2016.05.107. URL <http://dx.doi.org/10.1016/j.apenergy.2016.05.107>.
- 727 [22] Maria Andrea Triana, Roberto Lamberts, and Paola Sassi. Should we consider climate change for brazilian social
728 housing? assessment of energy efficiency adaptation measures. *Energy and Buildings*, 158:1379–1392, January

- 729 2018. ISSN 0378-7788. doi: 10.1016/j.enbuild.2017.11.003. URL <http://dx.doi.org/10.1016/j.enbuild.2017.11.003>.
- 730
- 731 [23] ABNT. *ABNT NBR 15220-3: Desempenho térmico de edificações – Parte 3: Zoneamento bioclimático brasileiro e diretrizes construtivas para habitações unifamiliares de interesse social.* ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, Rio de Janeiro, RJ, Brazil, 2005.
- 732
- 733
- 734 [24] I. D. Stewart and T. R. Oke. Local climate zones for urban temperature studies. *Bulletin of the American Meteorological Society*, 93(12):1879–1900, December 2012. ISSN 1520-0477. doi: 10.1175/bams-d-11-00019.1. URL <http://dx.doi.org/10.1175/BAMS-D-11-00019.1>.
- 735
- 736
- 737 [25] Bruno Bueno, Aiko Nakano, and Leslie Norford. Urban weather generator: a method to predict neighborhood-specific urban temperatures for use in building energy simulations. In *Proceedings of the Ninth International Conference on Urban Climate (ICUC9) jointly with 12 Symposium on the Urban Environment*, 2015.
- 738
- 739
- 740 [26] WebGIS. Worldwide - GTOPO30 Format - U.S. Geological Survey (USGS), 2009. URL http://www.webgis.com/terr_world.html. Accessed June, 2024.
- 741
- 742 [27] Lester James V. Miranda. PySwarms, a research-toolkit for Particle Swarm Optimization in Python. *Journal of Open Source Software*, 3, 2018. doi: 10.21105/joss.00433. URL <https://doi.org/10.21105/joss.00433>.
- 743
- 744 [28] Soroush Samareh Abolhassani, Mahmood Mastani Joybari, Mirata Hosseini, Mojtaba Parsaee, and Ursula Eicker. A systematic methodological framework to study climate change impacts on heating and cooling demands of buildings. *Journal of Building Engineering*, 63:105428, January 2023. ISSN 2352-7102. doi: 10.1016/j.jobe.2022.105428. URL <http://dx.doi.org/10.1016/j.jobe.2022.105428>.
- 745
- 746
- 747
- 748 [29] Keivan Bamdad, Michael E. Cholette, Sara Omrani, and John Bell. Future energy-optimised buildings — addressing the impact of climate change on buildings. *Energy and Buildings*, 231:110610, January 2021. ISSN 0378-7788. doi: 10.1016/j.enbuild.2020.110610. URL <http://dx.doi.org/10.1016/j.enbuild.2020.110610>.
- 749
- 750
- 751 [30] Matheus K. Bracht, Marcelo S. Olinger, Amanda F. Krelling, André R. Gonçalves, Ana Paula Melo, and Roberto Lamberts. Multiple regional climate model projections to assess building thermal performance in brazil: Understanding the uncertainty. *Journal of Building Engineering*, 88:109248, July 2024. ISSN 2352-7102. doi: 10.1016/j.jobe.2024.109248. URL <http://dx.doi.org/10.1016/j.jobe.2024.109248>.
- 752
- 753
- 754
- 755 [31] QGIS Development Team. *QGIS Geographic Information System.* QGIS Association, 2023. URL <https://www.qgis.org>.
- 756

Anexos

ANEXO A – ZONAS CLIMÁTICAS LOCAIS

TABLE 3. Values of geometric and surface cover properties for local climate zones. All properties are unitless except height of roughness elements (m).

Local climate zone (LCZ)	Sky view factor ^a	Aspect ratio ^b	Building surface fraction ^c	Impervious surface fraction ^d	Pervious surface fraction ^e	Height of roughness elements ^f	Terrain roughness class ^g
LCZ 1 <i>Compact high-rise</i>	0.2–0.4	> 2	40–60	40–60	< 10	> 25	8
LCZ 2 <i>Compact midrise</i>	0.3–0.6	0.75–2	40–70	30–50	< 20	10–25	6–7
LCZ 3 <i>Compact low-rise</i>	0.2–0.6	0.75–1.5	40–70	20–50	< 30	3–10	6
LCZ 4 <i>Open high-rise</i>	0.5–0.7	0.75–1.25	20–40	30–40	30–40	> 25	7–8
LCZ 5 <i>Open midrise</i>	0.5–0.8	0.3–0.75	20–40	30–50	20–40	10–25	5–6
LCZ 6 <i>Open low-rise</i>	0.6–0.9	0.3–0.75	20–40	20–50	30–60	3–10	5–6
LCZ 7 <i>Lightweight low-rise</i>	0.2–0.5	1–2	60–90	< 20	< 30	2–4	4–5
LCZ 8 <i>Large low-rise</i>	> 0.7	0.1–0.3	30–50	40–50	< 20	3–10	5
LCZ 9 <i>Sparingly built</i>	> 0.8	0.1–0.25	10–20	< 20	60–80	3–10	5–6
LCZ 10 <i>Heavy industry</i>	0.6–0.9	0.2–0.5	20–30	20–40	40–50	5–15	5–6
LCZ A <i>Dense trees</i>	< 0.4	> 1	< 10	< 10	> 90	3–30	8
LCZ B <i>Scattered trees</i>	0.5–0.8	0.25–0.75	< 10	< 10	> 90	3–15	5–6
LCZ C <i>Bush, scrub</i>	0.7–0.9	0.25–1.0	< 10	< 10	> 90	< 2	4–5
LCZ D <i>Low plants</i>	> 0.9	< 0.1	< 10	< 10	> 90	< 1	3–4
LCZ E <i>Bare rock or paved</i>	> 0.9	< 0.1	< 10	> 90	< 10	< 0.25	1–2
LCZ F <i>Bare soil or sand</i>	> 0.9	< 0.1	< 10	< 10	> 90	< 0.25	1–2
LCZ G <i>Water</i>	> 0.9	< 0.1	< 10	< 10	> 90	–	1

^a Ratio of the amount of sky hemisphere visible from ground level to that of an unobstructed hemisphere

^b Mean height-to-width ratio of street canyons (LCZs 1–7), building spacing (LCZs 8–10), and tree spacing (LCZs A–G)

^c Ratio of building plan area to total plan area (%)

^d Ratio of impervious plan area (paved, rock) to total plan area (%)

^e Ratio of pervious plan area (bare soil, vegetation, water) to total plan area (%)

^f Geometric average of building heights (LCZs 1–10) and tree/plant heights (LCZs A–F) (m)

^g Davenport et al.'s (2000) classification of effective terrain roughness (z_0) for city and country landscapes. See Table 5 for class descriptions

TABLE 4. Values of thermal, radiative, and metabolic properties for local climate zones. All values are representative of the local scale.

Local climate zone (LCZ)	Surface admittance ^a	Surface albedo ^b	Anthropogenic heat output ^c
LCZ 1 <i>Compact high-rise</i>	1,500–1,800	0.10–0.20	50–300
LCZ 2 <i>Compact midrise</i>	1,500–2,200	0.10–0.20	<75
LCZ 3 <i>Compact low-rise</i>	1,200–1,800	0.10–0.20	<75
LCZ 4 <i>Open high-rise</i>	1,400–1,800	0.12–0.25	<50
LCZ 5 <i>Open midrise</i>	1,400–2,000	0.12–0.25	<25
LCZ 6 <i>Open low-rise</i>	1,200–1,800	0.12–0.25	<25
LCZ 7 <i>Lightweight low-rise</i>	800–1,500	0.15–0.35	<35
LCZ 8 <i>Large low-rise</i>	1,200–1,800	0.15–0.25	<50
LCZ 9 <i>Sparingly built</i>	1,000–1,800	0.12–0.25	<10
LCZ 10 <i>Heavy industry</i>	1,000–2,500	0.12–0.20	>300
LCZ A <i>Dense trees</i>	unknown	0.10–0.20	0
LCZ B <i>Scattered trees</i>	1,000–1,800	0.15–0.25	0
LCZ C <i>Bush, scrub</i>	700–1,500	0.15–0.30	0
LCZ D <i>Low plants</i>	1,200–1,600	0.15–0.25	0
LCZ E <i>Bare rock or paved</i>	1,200–2,500	0.15–0.30	0
LCZ F <i>Bare soil or sand</i>	600–1,400	0.20–0.35	0
LCZ G	1,500	0.02–0.10	0
Water			

^a Ability of surface to accept or release heat ($\text{J m}^{-2} \text{s}^{-1/2} \text{K}^{-1}$). Varies with soil wetness and material density. Few estimates of local-scale admittance exist in the literature; values given here are therefore subjective and should be used cautiously. Note that the “surface” in LCZ A is undefined and its admittance unknown.

^b Ratio of the amount of solar radiation reflected by a surface to the amount received by it. Varies with surface color, wetness, and roughness.

^c Mean annual heat flux density (W m^{-2}) from fuel combustion and human activity (transportation, space cooling/heating, industrial processing, human metabolism). Varies significantly with latitude, season, and population density.

Fonte: Adaptado de Stewart e Oke (2012).