



Modelação do Clima Urbano da Cidade de Bragança (Portugal): Zonas Climáticas Locais e Intensidade das Ilhas de Calor e Frio.

Johicy Helenn Parra

Dissertação apresentada ao Instituto Politécnico de Bragança e à Universidade Tecnológica Federal do Paraná para obtenção do Grau de Mestre em Tecnologias Ambientais.

Orientada por

João Paulo Pais de Almeida

Artur Jorge de Jesus Gonçalves

Joseane Debora Peruço Theodoro

Bragança

2020

“Dedico este trabalho a pessoa que me ensinou a voar, minha mãe,
Hilda Felicio Parra (*in memoriam*).”

Agradecimentos

Primeiramente agradeço ao IPB e aos professores João Paulo Pais de Almeida e Artur Jorge de Jesus Gonçalves pela oportunidade recebida no programa de Dupla Diplomação e pela autonomia para desenvolver o presente trabalho. Agradeço também a UTFPR e a todos os seus professores pela formação recebida, em especial às professoras Joseane Debora Peruço Theodoro, Tatiane Cristina Dal Bosco, Nazira Hanna Harb e Sueli Tavares de Melo Souza, que foram mais que simplesmente professoras para mim.

Menciono também a minha mãe, Hilda F. Parra (*in Memoriam*), como a maior motivadora para que estudasse em Portugal, ainda sinto ela me apoiando e intercedendo por mim em todos os detalhes. Meus mais sinceros agradecimentos a todos os amigos e familiares que me apoiaram nesse projeto, em especial aos meus irmãos Gisele e Alex Parra, que são os melhores irmãos que eu poderia ter; aos meus cunhados Kauane e Diogo, que são como irmãos para mim; ao grande amigo e namorado Nicholas Prado, que está sempre ao meu lado, a me apoiar e incentivar para “voos” cada vez mais altos; e aos pais dele, Heloísa e Valdenir, que me adotaram como filha. Agradeço ainda aos meus sobrinhos Lívia, Danilo e Sarah Parra, que me alegram e motivam a lutar para tornar o mundo um lugar melhor.

Por fim, agradeço aos amigos do Brasil que mesmo com a distância se mantiveram próximos, em especial à Thais Sartner, Victor Cercasin, Maria Clara e Bruna Conceição. Aos amigos que Bragança me proporcionou durante este ano incrível, citando Elizandra e Thayná por serem como irmãs. Danilo, Yago e a casa 23 por serem a melhor vizinhança que eu poderia ter. E ao Leonardo Furst, por toda colaboração no presente trabalho.

Resumo

No contexto do clima urbano, regiões com tipologias homogêneas de construções expressam semelhanças climáticas, a isso se dá o nome de Zonas Climáticas Locais (ZCL), onde quanto mais urbanizada a zona for, maior será a diferença dos elementos do clima em relação a sua envolvente rural. Um exemplo disso são os efeitos de ilhas de calor e Frio onde as temperaturas das áreas urbanas diferenciam-se em relação aos arredores, dependendo da hora, mês e das características estruturais das superfícies. O presente trabalho tem como objetivo estudar matematicamente tais características, com o intuito de desenvolver modelos de regressão linear explicativos da relação entre a morfologia urbana e as temperaturas da cidade ao longo do ano e identificar as ZCL da cidade de Bragança - Portugal. Para tal trabalho, serão utilizados os dados de temperatura obtidos no período de 2016 a 2019 por uma rede de monitorização meteorológica composta por 23 sensores distribuídos de modo a atender o gradiente do urbano ao rural e os índices de morfologia urbana característicos da envolvente de cada sensor em um raio de 50 m. Com as análises obteve-se 12 regressões lineares explicativas, que expressam as máximas, médias e mínimas temperaturas de cada uma das estações do ano, onde as equações mais explicativas foram as médias do verão e da primavera, estações com menores interferências do clima de ampla escala. Obteve-se também com a análise de *clusters* 22 diferentes modelos de agrupamentos para o método de Ward e 16 para o método k-means, onde o segundo método apresentou melhores resultados para expressar o gradiente urbano - rural. Por fim, com uma análise de probabilidade pode-se identificar a provável distribuição dos sensores em quatro ZCLs (clusters) devido a quantidade de sensores e ao tamanho da cidade.

Palavras-chave: Análise de Clusters, Regressão Linear Múltipla, Ward, K-means.

Abstract

In the context of urban climate, areas with similar buildings and urban structures present comparable weather profiles. Those zones are called Local Climate Zones (LCZs), in which the differences between urban and rural areas increase with more dense urbanization. One instance of this relationship is in the cold and heat islands phenomenon, in which urban temperatures tend to differ from rural ones, varying upon time of day, month and local features. This work aims the mathematical study of those relationships, and seeks to develop models that describes them, using linear regression. The city of Bragança - Portugal will be our subject, and we will be analyzing data taken from 2016 to 2019, from a network of 23 sensors placed in such a way to represent evenly the rural and urban areas, with the help of morphological indexes in a 50 m radius. Of this work, resulted 12 linear regressions, which accounted for maximums, means and minimums temperatures of each of the seasons. The best fitting equations were calculated from the Summer and Spring data, when broad climatic influences are smaller. We also derived, from cluster analysis, 22 grouping models from the Ward method and 16 for the k-means method, which performed better in expressing the urban-rural gradient. Finally, we manage to statistically derive the optimal distribution of sensors in four LCZs, based on the number of sensors and the city's dimensions.

Keywords: Cluster analysis, Multiple Linear Regression, Ward, K-means.

Conteúdo

Lista de Abreviaturas	12
Introdução	1
1 Enquadramento Teórico	6
1.1 Aspectos Gerais do Clima	6
1.1.1 Escalas Climáticas	8
1.1.2 Elementos Climáticos	13
1.1.3 O Clima nas Áreas de Montanhas	15
1.2 O Clima Urbano e as suas Características	17
1.2.1 Morfologia Urbana	19
1.2.2 Zonas Climáticas Locais	21
1.2.3 Ilha De Calor e Ilha De Frio Urbano	23
1.3 Modelação Matemática do Clima Urbano	27
1.3.1 Estatística Multivariada e Intensidade das Ilhas de Calor e de Frio .	28
1.3.2 Análise de <i>Clusters</i>	31
2 Contexto e Tecnologias/Ferramentas	36
2.1 Caracterização da Área de Estudo	36
2.2 Monitorização do Clima Urbano - Temperaturas	38
2.3 Indicadores de morfologia urbana	40
2.3.1 Indicadores Intermediários	45

2.3.2	Indicadores finais	47
2.4	Análise de Dados	51
2.4.1	Temperatura	51
2.4.2	Intensidade dos Efeitos de Ilha de Calor e Ilha de Frio	52
2.5	Análise de Componentes Principais (ACP)	52
2.6	Modelo de Regressão Linear Múltipla	54
2.6.1	Interação entre variáveis preditoras	55
2.6.2	Métodos seleção de variáveis na regressão múltipla	56
2.6.3	Comparação dos modelos de Regressão Linear	57
2.7	Análise de <i>clusters</i>	58
2.7.1	Número ótimo de <i>clusters</i>	59
2.7.2	Métodos de Clusterização	61
3	Resultados e Discussões	62
3.1	Intensidade dos Efeitos de Ilha de Calor e Frio	62
3.2	Análise de Componentes Principais	66
3.3	Modelo de Regressão Linear Múltipla	70
3.4	Análise de <i>clusters</i>	75
3.4.1	Método de Ward	77
3.4.2	Método K-means	79
3.4.3	Agrupamentos por ano	82
4	Conclusões	102
 APÊNDICES		
A	Sobre o Trabalho	A1
A.1	Citação	A1
A.2	Proposta inicial	A1
A.3	Contribuição Científica	A2

B Envolvente dos Sensores **B1**

ANEXO

A Classificação das ZCL por Stewart e Oke (2012) **A1**

Lista de Tabelas

1.1	Escala Horizontal do Clima (Oke, 2002).	9
1.2	Organização das Escalas Temporal e Espacial do Clima	12
2.1	Localização dos Sensores e suas ZCL.	40
2.2	Descrição das Zonas Climáticas Locais	41
2.3	Albedo Médio	50
2.4	Dados de Morfologia Urbana - Sensores	53
2.5	Tabela ANOVA para o modelo de RLM	57
3.1	Modelos de Regressão Linear Múltipla	71
3.2	Parâmetros das Equações Simplificadas	72
3.3	Índices de Morfologia Urbana para as ZCL (K=2)	88
3.4	Índices de Urbana para as ZCL (K=5)	96
3.5	Descrição das novas ZCL.	99

Lista de Figuras

1.1	Divisão vertical da atmosfera urbana divulgada	11
1.2	Componentes biofísicos do Ecossistema Urbano.	18
1.3	Esquema de Classificação das ZCL	23
1.4	Perfil típico de temperatura no Efeitos de Ilha de Calor Urbano (EICU). . .	24
1.5	Geração das EICU.	25
1.6	Ilustração do processo de Aglomeração Hierárquico.	33
1.7	Ilustração do processo de Aglomeração Particional.	34
2.1	Localização da cidade de Bragança.	37
2.2	Gráfico de Temperatura e Pluviosidade de Bragança (2019).	37
2.3	Localização dos Sensores.	39
2.4	Sensores de Temperatura e Humidade relativa:	41
2.5	Diferentes tipologias de construção na envolvente dos sensores.	42
2.6	Exemplo de envolvente dos Sensores	43
2.7	Metodologia de captura de imagens	45
2.8	Imagens tratadas dos pontos com seus respectivos FVC.	46
2.9	Ilustração da Relação H/L	49
2.10	Exemplo de resultado da função <code>summary()</code> para as Regressão Linear Múltipla (RLM)	56
2.11	Conjuntos de dados utilizados para a obtenção dos <i>clusters</i>	59
3.1	Máxima e Mínima Intensidade de EICU	63
3.2	Intensidade de Ilha de Calor nos Pontos	65

3.3	Análise dos Componentes Principais (ACP) das variáveis de morfologia urbana	66
3.4	Contribuição das variáveis e sensores	67
3.5	Gráfico de correlação variável (\cos^2)	68
3.6	Contribuição dimensional	68
3.7	Intensidade de contribuição de cada variável	70
3.8	Novas matrizes de correlação	73
3.9	Teste de Distribuição dos Resíduos	73
3.10	Teste Normalidade dos Resíduos	74
3.11	Teste anova para a comparação dos modelos de RLM	75
3.12	Número ótimo de <i>clusters</i> - Wss	76
3.13	Número ótimo de clusters - Silhueta	76
3.14	Exemplo de resultado para o Método de Ward's	77
3.15	Agrupamentos obtidos com o método de Ward 's com $k=2$	78
3.16	Agrupamentos obtidos com o método de Ward 's com $k=5$	79
3.17	Exemplo de resultado para o Método de K-means	80
3.18	Agrupamentos obtidos com o método K-means ($k=2$)	80
3.19	Agrupamentos obtidos com o método Kmeans ($k=5$)	81
3.20	Agrupamentos por ano, com $k=2$	83
3.21	Agrupamentos mais provável, com $k=2$	84
3.22	Distribuição de temperaturas pelas estações	85
3.23	Distribuição da intensidade do EICU nas estações do ano	86
3.24	Intensidade do EICU entre os pontos Urbanos e Não Urbanos	87
3.25	Índices Morfológicos para as nosvas ZCLs	89
3.26	Agrupamentos por ano, com $k=5$	91
3.27	Agrupamento mais provável com $k=5$	92
3.28	Distribuição de temperaturas pelas estações nas ZCL	93
3.29	Distribuição da intensidade dos EICU e EIFU nas estações do ano	94
3.30	Intensidade do EICU entre as Zonas Climáticas Encontradas	95

3.31	Índices Morfológicos para as novas ZCLs	98
3.32	Exemplos de sensores contidos em cada ZCL	99
3.33	Comparação das classificações das ZCL	101
B.1	Fotografias das Envolventes dos Sensores.	B1
B.2	Fotografias das Envolventes dos Sensores.	B2
B.3	Fotografias das Envolventes dos Sensores.	B3
A.1	Definições resumidas para Zonas Climáticas Locais (1)	A1
A.2	Definições resumidas para zonas climáticas locais (2)	A2
A.3	Definições resumidas para zonas climáticas locais (3)	A3

Lista de Abreviaturas

AC Análise de Clusters. 31–34, 58, 79, 81, 82, 100, 105, A1

ACP Análise dos Componentes Principais. 10, 28, 29, 52, 66, 68

AEM Análise Estatística Multivariada. 28

Aj Área de construção. 45, 47

AM Albedo médio. 45, 50, 52, 66, 87, 95, 103

Ao Área de implantação. 45, 47, 48

Ap Área permeável. 48

CD Coeficiente de Determinação. 57, 58

CDA Coeficiente de Determinação Ajustado. 58

CEU Camada de Estrutura Urbana. 10, 11, 15, 24, 26

CLP Camada Limite Planetária. 10, 11

CLR Camada Limite Rural. 10, 11

CLU Camada Limite Urbana. 10, 11

CM Camada de Mistura. 10

CP Componente Principal. 43, 52, 54, 55, 66, 69, 70

CUrb Clima Urbano. 1, 10, 18–21, 23, 27, 43, 57, 66

EC Escalas Climáticas. 8

EICU Efeitos de Ilha de Calor Urbano. 2, 9, 10, 19, 21–27, 29, 30, 51, 52, 58, 62–64, 66, 69–71, 75, 78–80, 85–87, 93–95, 102–106

EIFU Efeitos de Ilha de Frio Urbano. 2, 26, 52, 58, 62–64, 66, 79, 86, 87, 93, 102, 103

EMA Estações Meteorológicas Automáticas. 35

FVC Fator de Visão do Céu. 11, 20, 21, 24–26, 30, 43, 44, 52, 66–69, 71, 87, 95, 103

HL Relação H/L. 45, 49, 52, 66–69, 87, 88, 95, 96, 103

IC Índice de construção. 45, 48, 52, 66–69, 87, 88, 95–97, 103

ICU Ilha de Calor Urbano. 51, 59

IFU Ilha de Frio Urbano. 29

IV Índice volumétrico. 49, 52, 66–69, 71, 87, 88, 95, 96, 103

NMP Número médio de pisos. 45, 49, 52, 66, 67, 69, 87, 95, 96, 103

OT Percentagem de ocupação do terreno. 45, 48, 52, 66–69, 87, 88, 95, 96, 103

PI Percentagem de área impermeável. 48, 52, 66, 69, 87, 88, 95, 96, 103

PP Percentagem de área permeável. 45, 48

PU Pluma Urbana. 10

RLM Regressão Linear Múltipla. 9, 28–30, 52, 54–58, 69, 70, 75

Sg Superfície global. 45, 46

SR Subcamada de Rugosidade. 10, 11, 15

St Superfície do terreno. 45, 46, 48, 49

V Volume. 47

VE Variabilidade Explicada. 57

VNE Variabilidade Não Explicada. 57, 58

VT Variabilidade Total. 57, 58

WMO World Meteorological Organization. 1, 7

ZCL Zonas Climáticas Locais. 20–22, 30, 34, 35, 38, 64, 81, 88, 90, 92, 99, 100, 104

Introdução

Define-se **clima** como uma descrição estatística das variáveis climáticas relevantes durante um período de tempo (em termos da média e suas variabilidades) (Cavalcanti et al., 2009). Muitos são os fatores que contribuem para a dinâmica particular e complexa do clima em cada localidade, estes fatores são classificados entre **globais** (latitude, movimento de rotação e translação, continentalidade, etc.); **locais** (dinâmica do mar, topografia, distância de lagos, cobertura vegetal, etc.); e **elementos** (temperatura, humidade, velocidade dos ventos, etc.) (Barbirato et al., 2007; Peixoto & Oort, 1992). Para a definição de um clima médio, segundo a *World Meteorological Organization (WMO)* são necessários 30 anos de dados que devem ser atualizados pelo menos a cada 10 anos (Arguez & Vose, 2011). Deve-se ao fato de que clima não ser algo constante, ele se altera ao longo do tempo e essas mudanças são constantemente associadas as atividades antrópicas.

Segundo a Organização das Nações Unidas (ONU), nos últimos dois séculos a população mundial aumentou de 1 para 7 bilhões de habitantes (em 2015), mesmo período em que a fracção populacional que habita os centros urbanos passou de 3% para mais de 50% (UN, 2015). Atualmente a população mundial está em 7,8 bilhões e espera-se que a marca de 11 bilhões seja alcançada até 2100, caso as taxas de crescimento atuais se mantenham (Sormin et al., 2019). Isso implica também no crescimento de aglomerados urbanos, onde as construções estão diretamente relacionadas com o contexto social, cultural e económico de cada sociedade. Onde os materiais e atividades afetam diretamente no clima, de modo a criar padrões particulares que caracterizam o **Clima Urbano (CUrb)**. Todas as cidades apresentam, em baixa ou alta intensidade, alterações no clima devido ao processo de urbanização (Oke et al., 2017). A crescente preocupação com o conforto térmico humano,

economia de energia e mudanças climáticas motivam o estudo de seus efeitos (Hebbert & Jankovic, 2013), no entanto, cada cidade apresenta singularidades que exigem o desenvolvimento de estudos nas mais diversas condições, para a obtenção de informações adequadas aos planejadores urbanos (Gonçalves et al., 2018; Ren et al., 2011).

Em uma mesma cidade ocorrem, no tecido urbano, regiões com padrões diferentes de construção, isso se deve aos modos de uso e ocupação aplicados para cada localidade. Estes padrões podem ser caracterizados por **Zonas Climáticas Locais (ZCL)**, que têm esse nome pelo padrão de zoneamento em escala local das diferentes regiões de uma mesma cidade, a partir das suas características morfologia urbana (Mendonça & Danni-Oliveira, 2007). Stewart e Oke (2012) desenvolveram um padrão de classificação com 17 diferentes classes de ZCL geradas a partir de vários parâmetros, ao se fazer uso dessas classes a complexidade e diversidade do tecido urbano podem ser abordadas com maior propriedade, assim como as variabilidades climáticas apresentadas pelas áreas urbanas (Gonçalves et al., 2018).

Entre os efeitos mais estudados clima urbano está o **Efeito de Ilha de Calor Urbano (EICU)** (Bornstein, 1968; Carvalho, 2020; Gartland, 2008, 2011; Giridharan et al., 2004; Gonçalves et al., 2018; Grimmond & Oke, 1999; Guo et al., 2015; Magee et al., 1999; Memon et al., 2009; Menezes, 2017; Pórolniczak et al., 2017; Rizwan et al., 2008; Van Hove et al., 2015; Vicente-Serrano et al., 2005; Zhou et al., 2013), caracterizado pela tendência de as áreas urbanas apresentarem temperaturas mais elevadas quando comparadas com suas imediações, ocorrido principalmente no período do fim de tarde até ao nascer do dia, quando as estruturas urbanas demoram mais para se resfriar. A intensidade do EICU pode ser obtida através da comparação de dados de temperatura das áreas urbanas com dados dos arredores não urbanizados. Por vezes, no estudo desta intensidade encontra-se valores negativos, que indicam temperaturas menores nas áreas urbanas, em relação às suas imediações, este fenómeno é denominado **Efeitos de Ilha de Frio Urbano (EIFU)** e ocorre geralmente durante as primeiras horas do dia, entre outros motivos, devido ao sombreamento e a baixa incidência de radiação solar causados pelos elementos urbanos (Yang et al., 2016).

A teoria geral do clima lida com muitos parâmetros, fenómenos e processos evolutivos. Ela é alvo de estudos por diversas áreas do conhecimento e pode ser analisada a partir de diferentes métodos (empíricos, estatísticos, computacionais, etc.) (Dymnikov & Filatov, 2012). A modelação estatística baseia-se na análise de dados climáticos, como a temperatura e a humidade, velocidade e direção do vento, entre outros, observados pluri-anualmente, muitos estudos podem ser encontrados com foco neste tipo de modelagem do clima urbano para cidades de grande porte (Bottyán & Unger, 2003; László & Szegedi, 2015; Lee & Oh, 2018; Matsuo & Tanaka, 2014; Szymanowski & Kryza, 2009, 2012; Wicki et al., 2018, 2019), no entanto existem poucos estudos para cidades de pequeno porte.

Objetivo Geral

O presente trabalho tem como objetivo principal a utilização de métodos matemáticos estatísticos para a identificação de padrões do clima urbano da cidade de Bragança (Portugal).

Objetivos Específicos

- Caracterizar os fenómenos de Ilha de Calor Urbano e Ilha de Frio Urbano ao longo do ano, na localização dos sensores meteorológicos.
- Identificação das componentes principais para os índices de morfologia urbana.
- Definição de modelos de regressão linear multivariada explicativo com as componentes principais da morfologia urbana e também os dados de temperatura média máxima e mínima em cada estação (inverno, primavera, verão e outono). Com o intuito de identificar um padrão climático.
- Definição de um modelo de regressão linear múltipla simplificado a partir dos modelos gerais obtidos, o qual apresente uma explicação do clima com uma perda mínima de informação.

- Identificação das Zonas Climáticas Locais a partir dos dados de temperatura, intensidade de ilha de calor e dos índices morfologia urbana utilizando os métodos de K-means e Ward's para o agrupamento de dados.
- Comparação dos modelos de Ward's e K-means para o agrupamento de dados climáticos.
- Análise temporal do comportamento dos *clusters* a partir dos dados de temperatura no período de 2016 a 2019, a fim de identificar as zonas climáticas locais da cidade de Bragança.

Estrutura do trabalho

O presente trabalho está estruturado em quatro capítulos principais: Referencial Teórico, Materiais e Métodos, Resultados/Discussões e Conclusões.

O primeiro capítulo contém o referencial teórico deste trabalho. Neste capítulo são descritos e exemplificados os conceitos gerais do clima e do clima urbano com foco na morfologia urbana e nos efeitos de Ilha de Calor Urbana, Ilha de Frio Urbano e das Zonas Climáticas Locais. Também são apresentados os principais conceitos matemáticos/estatísticos utilizados para a análise de dados do clima urbano.

O segundo capítulo, Materiais e Métodos, contém a caracterização da área de estudo, informações relativas à rede de sensores utilizados para a monitorização meteorológica, descrição dos indicadores de morfologia urbana utilizados e a explicação dos métodos de análise de dados utilizados para o estudo em questão (análise das componentes principais, regressão linear múltipla e análise de *clusters*).

Na etapa dos Resultados e Discussão avaliam-se os resultados obtidos através das análises quantitativas do clima urbano, com foco na descrição das zonas climáticas identificadas, validação das mesmas, e na identificação de modelos de regressão linear múltipla, explicativos do impacto da morfologia urbana na temperatura da cidade de Bragança.

Por fim, no capítulo cinco, apresentam-se as principais conclusões retiradas a partir

do estudo realizado na presente dissertação, bem como a perspectiva dos trabalhos futuros, sendo que alguns deles já se encontram em andamento.

Uma nota que importa ressaltar é a de que, neste trabalho, convencionou-se a utilização de textos em *itálico* para trechos escritos em outros idiomas, **negrito** para destacar palavras importantes, `espaçamento uniforme` para códigos fonte ou comandos utilizados na programação.

Capítulo 1

Enquadramento Teórico

1.1 Aspectos Gerais do Clima

O planeta Terra passa por diferentes níveis de exposição solar ao longo do ano em sua órbita ao redor do sol, de forma simplificada, é assim que são formadas as estações (primavera, verão, outono e inverno), enquanto a inclinação que o eixo da terra tem em relação a sua órbita faz com que alguns dias do ano sejam mais longos que outros Torres2008. Cada estação, em cada localidade, tem as suas características expressas pelos elementos climáticos, principalmente pela temperatura e a precipitação, no entanto estes são regulados por fatores característicos que constituem o clima (Cavalcanti et al., 2009).

Sabe-se que o clima é o resultado de uma dinâmica complexa e particular que segundo Barbirato et al. (2007) tem como componentes os fatores globais, locais e os elementos climáticos. Os **fatores globais** fazem parte da composição terrestre como a latitude, as radiações solares, a esfericidade da terra, os movimentos de rotação e translação, a existência de continentes e de oceanos. Os **fatores locais** são características de cada localidade como a maritimidade, a topografia, a natureza das superfícies subjacentes, a cobertura vegetal, os solos, a distância de lagos e as intervenções antrópicas. E por fim, os **elementos climáticos** que lidam com as propriedades intrínsecas da atmosfera e dão feição para uma certa localidade, entre eles estão as várias instabilidades (temperatura,

humidade, velocidades dos ventos, nebulosidade, precipitação, etc.) e a circulação geral de massas e energia.

No quotidiano, ao se tratar dos fenômenos atmosféricos, confunde-se muito os conceitos de tempo e clima. No presente trabalho é de fundamental importância deixar ambos bem definidos. Por um lado, o tempo refere-se aos estados momentâneos da atmosfera e da evolução diária dos sistemas sinóticos individuais (Ayoade, 2007; Peixoto & Oort, 1992). Assim, o tempo é um conjunto de valores que caracteriza o estado atmosférico em um determinado momento e local. A meteorologia é responsável por entender a dinâmica dos elementos que de forma momentânea atuam em cada localidade (frentes frias e quentes, temperatura, pluviosidade, ciclones, etc) (Steinke, 2016).

Por outro lado, clima é a média dos tempos em um dado local por um longo período e refere-se às características da atmosfera, inferidas continuamente numa determinada área. Ele inclui considerações a respeito da possibilidade de condições extremas e de frequência de ocorrência de determinadas condições. Desta forma, o clima apresenta uma generalização, enquanto o tempo trabalha com eventos específicos (Ayoade, 2007; Peixoto & Oort, 1992; Steinke, 2016). Portanto, clima é a normalização dos estados físicos do ambiente atmosférico (tempo), de modo constante e previsível, característico de certa localidade geográfica, de modo que não há dois climas rigorosamente iguais (Barbirato et al., 2007). A ciência responsável por estudar o clima é a climatologia (Steinke, 2016).

A *World Meteorological Organization (WMO)* coordena as publicações de padrões climáticos globais para o cálculo das condições climáticas normais desde 1901. A recomendação é que cada país membro atualize seus normais climáticos médios dos últimos 30 anos a cada 10 anos, no entanto sabe-se que nem todos os países membros seguem essa orientação. Tais dados mapeiam e atualizam os padrões climáticos de cada localidade, enquanto constroem o clima normal médio. Este, por sua vez, fornece para as partes interessadas e tomadoras de decisão uma métrica, que pode e deve ser levada em consideração para o planejamento urbano a curto e longo prazo (Arguez & Vose, 2011).

1.1.1 Escalas Climáticas

Landsberg (1981) defende a existência de duas **escalas climáticas**, o clima sinóptico governado por padrões de grande escala e os climas locais associados a camada limite da atmosfera, onde o primeiro é determinante em condições com ventos fortes, nebulosidade e precipitação elevadas. Já nas restantes condições o clima local predomina, nas condições chamadas anti-sinópticas ou estacionárias, de ventos fracos e céu limpo. No entanto, sabe-se que os eventos meteorológicos e climáticos podem ocorrer no espaço de poucos metros até globalmente, durante poucos minutos ou até mesmo alterar um clima permanentemente (Gartland, 2011; Hernández Aja et al., 2013; Landsberg, 1981; Menezes, 2017).

Dessa forma, para a análise do clima e de sua dinâmica, dado a complexidade entre seus fatores, tempo e espaço, é de suma relevância a compreensão das escalas climáticas (Andrade, 2005; Marques, 2012; Ribeiro, 1993). Elas dizem respeito à dimensão, ou seja, uma ordem de grandeza de extensão ou duração, segundo a qual os fenômenos climáticos atuam (Mendonça & Danni-Oliveira, 2007), na sequência as escalas espaciais (horizontal e vertical) e temporais do clima serão melhor detalhadas.

Escala Espaciais do Clima

As escalas espaciais do clima são divididas em horizontais (construída pelas distâncias de alcance de cada fenômeno do clima) e verticais (composta pelas camadas que dão características à atmosfera). Segundo Andrade (2005), existem controvérsias na bibliografia a respeito de mudanças climáticas, na qual muitas vezes utiliza-se do termo **microclima** de forma incorreta, para indicar particularidades quaisquer do clima no meio urbano. Sabe-se que os fenômenos atmosféricos são de natureza contínua, no entanto, a categorização terminológica para estes eventos climáticos ocorrem de forma arbitrária. Vários autores apresentam Escalas Climáticas (EC) em seus trabalhos (Andrade, 2005; Oke, 2007; Oke, 2002; Orlanski, 1975; Ribeiro, 1993).

Escala Horizontal: Orlanski (1975) foi um dos primeiros a definir escalas horizontais do clima. Em seu estudo, o horizonte foi subdividido em três classes: microescalas, que ocorrem em questão de metros até 2 quilômetros de distância; mesoescalas - de 2 a 2000 quilômetros; e macroescalas, para eventos com escala maior que 2000 quilômetros. Mais recentemente, Oke tem utilizado em seus trabalhos o padrão da Tabela 1.1 para as escalas horizontais (Oke, 2007; Oke, 2002; Oke et al., 2017):

Tabela 1.1: Escala Horizontal do Clima (Oke, 2002).

Microescala	Escala Local	Mesoescala	Macroescala
de 10^{-2} até 10^3 m	de 10^2 a $5 \cdot 10^4$ m	de 10^4 a $2 \cdot 10^5$ m	de 10^5 a 10^8 m

Cada uma das classes da escala espacial horizontal tem suas particularidades:

Macroescala: esta é a escala característica dos climas de amplas áreas da terra e dos movimentos atmosféricos de larga escala, neste nível estão incluídos fatores globais do clima como a radiação solar, a curvatura da Terra e os seus movimentos de rotação e translação (Ayoade, 2007; Oke, 2007).

Mesoescala: escala característica do clima urbano e dos sistemas climáticos locais severos como os tornados e temporais (Andrade, 2005; Ayoade, 2007). A interação ocorre entre a energia disponível (para o processo de evaporação e de geração de campos de pressão) e as feições do meio terrestre. Esta escala caracteriza o clima em realidades urbanas extensas e apenas uma estação meteorológica não é suficiente para representá-la por completo (Oke, 2007; Ribeiro, 1993).

Escala Local: nela são incluídos os efeitos climáticos locais das características da paisagem, como topografia, mas exclui efeitos de microescala. Nas cidades, isso significa a uniformidade do clima para bairros com tipos semelhantes de desenvolvimento urbano (cobertura, tamanho, espaçamento, edifícios, atividade) (Ayoade, 2007; Oke, 2007).

Microescala: São típicas de microclimas urbanos e são definidas pelas dimensões de elementos individuais: edifícios, árvores, estradas, ruas, pátios, jardins, etc., estendendo-se de menos de um até centenas de metros. Dessa forma a preocupação da microclimatologia está focada no estudo do clima próximo à superfície ou de áreas muito pequenas, e seus

fatores internos (Ayoade, 2007; Oke, 2007; Ribeiro, 1993). Indica-se o cuidado com os elementos de microclima ao se instalar estações meteorológicas, para que as observações climáticas estejam livres de estranhos sinais de microclima e possam caracterizar o clima local de forma mais real. Wanner e Filliger (1989) consideram que os fenômenos urbanos propriamente ditos se restringem ao espaço da microescala para eventos individuais e da mesoescala para áreas metropolitanas (Andrade, 2005).

Escala Vertical do Clima

A Figura 1.1 apresenta as escalas verticais do clima adaptadas dos trabalhos Andrade (2005), Menezes (2017), Oke et al. (2017), Oke (1984) e Ribeiro (1993), nela estão apresentadas as camadas verticais desenvolvidas pela existência das cidades, que subdividem a troposfera em camadas menores. A primeira delas é a **Camada Limite Urbana (CLU)**, que é criada pela **Pluma Urbana (PU)** na direção do vento, a partir da borda limite da cidade, subdividindo a **Camada Limite Planetária (CLP)**. Esta camada é caracterizada por ser a **Camada de Mistura (CM)** do fluxo de ar, onde a rugosidade impacta em diferentes níveis nos regimes de escoamento. Logo acima dos elementos estruturais da cidade (prédios, casas, árvores, etc.) se encontra o limite da **Camada de Estrutura Urbana (CEU)**, que tem características particulares de fluxo de ar e radiação graças a seus elementos. Acima da CEU forma-se uma **Subcamada de Rugosidade (SR)** provocada pela composição urbana que altera diretamente a dinâmica do escoamento do ar e cria uma zona de escoamento turbulento (Collier, 2006). Para além dos limites da cidade a **Camada Limite Rural (CLR)** começa a ser desenvolvida, motivada pelas características físicas do campo aberto, que cresce e aos poucos ganha forma. No mesmo momento, a PU se estende por um trecho posterior à cidade e leva para o campo resquícios dos fluxos de energia e massa característicos da área urbana (Collier, 2006; Oke, 2006; Ribeiro, 1993).

As camadas que mais expressam o impacto do CUrb nas estruturas atmosféricas são a CLU e a CEU. Na primeira delas, a intensa atividade humana, as trocas e transformações verticais de momento, calor e humidade que ocorrem na CLU promovem uma diferença




Figura 1.1: Divisão vertical da atmosfera urbana divulgada
 Fonte: Adaptado de Oke (2006)

essencial entre o clima urbano e o de seus arredores em campos abertos. Esse efeito é denominado canópia urbana (Oke et al., 2006). A CLU é um conceito de escala local ou mesoescala que diz respeito à porção da CLP em que as características são afetadas pela presença de área urbana em seu limite inferior, esta camada é normalmente mais rugosa, mais quente, seco e produz muito mais poluentes atmosféricos que a CLR (Menezes, 2017; Oke, 2002).

No nível dos telhados, processos e fenômenos diferentes ocorrem em comparação ao ocorrido dentro a canópia urbana. Neste nível desenvolve-se a SR, que causa intenso cisalhamento e mistura de vento, no qual o escoamento do ar normalmente é turbulento. Entre os desfiladeiros formados pelas estruturas urbanas, desenvolve-se a CEU, que apresenta condições bem diferentes. Nesta camada os elementos urbanos fornecem abrigo do impacto dos ventos e a troca de radiação é diferenciada pela crescente visão restrita do céu. Em consequência disso, o **Fator de Visão do Céu (FVC)** é importante ao se analisar o clima urbano. Dentro da CEU, o clima é controlado pela combinação única de

propriedades da superfície em um raio de apenas alguns metros formando os microclimas (Oke et al., 2017).

Escala Temporal do Clima

Quanto a temporalidade das variações climáticas, a Tabela 1.2 apresenta os padrões médios de tempo do microclima, mesoclima e macroclima, assim como de suas subdivisões para as escalas verticais, horizontais e temporais (Mendonça & Danni-Oliveira, 2007).

Tabela 1.2: Organização das Escalas Temporal e Espacial do Clima

Ordem de Grandeza	Subdivisões	Escalas		
		Horizontal	Vertical	Temporal
Macroclima	Clima Zonal e Regional	> 2.000 km	3 a 12 km	Algumas semanas a vários anos
Mesoclima	Clima Local e Topoclima	2.000 a 10 km	12 km a 100 m	Várias horas a alguns dias
Microclima	Microclima	de metros a 10 km	abaixo de 100m	minutos ao dia

Fonte: Adaptado de Mendonça e Danni-Oliveira (2007)

Em vista disso, é necessário ressaltar que, além do período de existência dos fenômenos climáticos, os períodos de estudo e seus impactos também são relevante no estudo da escala temporal do clima. Em seu trabalho Mendonça e Danni-Oliveira (2007) relatam três principais escalas temporais de estudo do clima: **escala geológica, escala histórica e escala contemporânea.**

A escala geológica mostra abordagens dos fenômenos climáticos que ocorreram no Planeta desde a sua formação. Nela se realiza o estudo dos climas do passado, anteriores a existência humana, em que observa-se variações e mudanças climáticas ocorridas no planeta de algumas centenas a vários milhões de anos no passado. Este estudo é realizado por paleontólogos climáticos por meio de registos naturais que o clima deixa na natureza. Em seguida a escala histórica, que também utiliza do estudo do passado, porém somente do período da história registada pelo homem com a utilização de diversos meios, como cartas, papiros, livros, cartas de navegação, etc. E, por fim, a escala contemporânea que

é a mais utilizada pelos climatólogos, na qual a elaboração de estudos é realizada a partir de uma série de dados meteorológicos com períodos longos, preferencialmente com mais de 30 anos. A análise de tempos, a variabilidade climática de curta duração, as tendências climáticas e o estabelecimento de médias são as abordagens de climatologistas em escala contemporânea. É na escala temporal contemporânea que se estabelece o estudo do clima urbano (Mendonça & Danni-Oliveira, 2007).

1.1.2 Elementos Climáticos

As variáveis meteorológicas atuam como elementos do clima de forma integrada e influenciam-se mutuamente, entre elas estão: temperatura, humidade, radiação, precipitação, ventos, etc. Elas também sofrem influência do meio urbano (Barbirato et al., 2007).

Radiação Solar

A radiação é uma perturbação ondulatória eletromagnética caracterizada por um comprimento de onda (λ) que se propaga à velocidade da luz (Villas Boas et al., 2007). Os processos radiativos atmosféricos envolvem um amplo conjunto de comprimentos e frequências de ondas, sendo cada um deles relacionado com uma determinada energia (Menezes, 2017). As diferentes intensidades de aquecimento solar recebida por cada localidade depende fundamentalmente da inclinação dos raios solares incidentes, ou seja, quanto mais próximo de uma incidência vertical, maior a taxa de aquecimento da superfície. Próximo a linha do equador, em seu ponto mais elevado, os raios são próximos da perpendiculares ao plano terrestre (90°), já nos polos a inclinação é a menor possível (Não ultrapassando os 30°) (Cavalcanti et al., 2009).

Esse parâmetro é apresentado através da intensidade de radiação (potência térmica por unidade de superfície), que é registrada como radiação direta (composta por raios diretos, que não mudam de direção) ou difusa (sem direção determinada, consequência dos fenômenos de reflexão da radiação direta pela presença de gases na atmosfera) (Hernández

Aja et al., 2013). O balanço da radiação tem uma grande influência sobre as mudanças na temperatura do ar, pois a radiação recebida, tanto as ondas de grande comprimento quanto as de pequeno comprimento, atinge as superfícies e as áreas urbanas têm maior captação de radiação líquida (Memon et al., 2009).

Temperatura do Ar

A temperatura é um dos parâmetros mais estudados para as áreas urbanas, em sua maioria é conhecida a evolução anual da temperatura média mensal, as temperaturas máximas e mínimas médias de cada mês, e conseqüentemente a amplitude térmica (diferença entre a média e os extremos), também são estudados os períodos de ocorrência de entre extremos. A partir de tais dados é possível projetar as temperaturas horárias, ao aplicar simples modelos matemáticos. (Hernández Aja et al., 2013).

Humidade Relativa do Ar

A humidade relativa do ar diz respeito a percentagem de vapor da água presente na atmosfera, onde 100% indica o nível máximo de saturação. A partir de tal dado pode-se conhecer a temperatura, visto que a quantidade de vapor de água na atmosfera é variável dependente da temperatura do ar. Com isso, ferramentas como os diagramas psicrométricos são indicados para estudar a evolução das condições do ar nas suas possíveis transformações (Hernández Aja et al., 2013).

Vento

Para os ventos é comum a obtenção de dados de frequência e intensidade média segundo oito orientações (norte (N), sul (S), oeste (O), leste (L), noroeste (NO), nordeste (NE), sudoeste (SO) e sudeste (SE)), a intensidade máxima é um dado opcional para as estações de monitorização. Procura-se fundamentalmente conhecer o comportamento dos dados mensais e nas distintas estações do ano. A quantidade e periodicidade dos dados climáticos necessários em cada caso dependem do uso que estes venham a ter, para os dados de ventos,

consideram-se dados confiáveis os proporcionados por estações meteorológicas que tenham registros há mais de dez anos. A partir destes dados constrói-se o que foi denominado ano meteorológico real, assim como o ano meteorológico típico, composto dos meses reais que mais se aproximam à média de intensidade e direção dos ventos Hernández Aja et al., 2013.

Precipitação

A medição da precipitação (chuva ou neve) é realizada por um aparelho chamado pluviômetro, o qual coleta a precipitação e informa dados de acúmulo de chuva em mm por tempo. Este aparelho é sempre suscetível a erros associados a sua exposição, dado o contexto urbano e o campo de vento variável na CEU e na SR.

1.1.3 O Clima nas Áreas de Montanhas

Estima-se que montanhas ou planaltos ocupem cerca de 20,2% da superfície terrestre da Terra (Barry, 2008), no ano de 2010 cerca de 10% da população mundial habitava estas áreas (Kohler et al., 2010). A definição de área de montanha é feita de várias formas mas essas são geralmente arbitrárias, alguns autores utilizam apenas o parâmetro de altitude, outros utilizam também a declividade (Azevedo et al., 2016), uma generalização usual é a marca de elevações acima de 600 metros em relação seus arredores para essa denominação, no entanto, sabe-se que até mesmo pequenas colinas tem impactes nos climas locais (Barry, 2008). A topografia dessas áreas se deve aos processos tectônicos que elevam ou declinam a superfície da Terra em conjunto com os processos erosivos, que atuam em cada localidade desgastando as superfícies, essa dinâmica é lenta e leva milhares ou milhões de anos para a sua formação (Menezes, 2017).

Áreas de montanhas apresentam elevada especificidade geomorfológica, derivada principalmente dos efeitos altitudinal e de declive, que causam características especiais aos climas montanhosos, entre elas estão desde a variação dos elementos climáticos (temperatura, humidade, pressão, precipitação, etc) em curtas distâncias e as modificações do fluxo

de massa e energia que surgem devido presença física suas estruturas que são barreiras topográficas naturais (Azevedo et al., 2016; Barry, 2008; Greenland, 2005). A variedade de climas nas áreas montanhosas leva à dificuldades na classificação climática, portanto, tais áreas são geralmente excluídas ou agrupadas em uma ampla categoria (Greenland, 2005).

A altitude é o fator que mais condiciona o clima das montanhas, estima-se que a quantidade de radiação recebida na superfície aumenta com a altitude devido a diminuição da camada atmosférica sob o local e a redução do vapor da água e das partículas que ficam mais concentrado na camada mais baixa da atmosfera. O aumento da radiação é exponencial com a altitude e ocorre tanto em céu claro como em céu nublado, sendo acentuadas pelos comprimentos de ondas curtas (Greenland, 2005).

A temperatura geralmente diminui com a altitude, devido ao aquecimento da atmosfera ser realizado principalmente por ondas infravermelhas, e também devido aos fluxos turbulentos de vento que auxiliam no arrefecimento (Greenland, 2005). A taxa de variação da temperatura com a altitude não é constante, mas é indicado na literatura que este acréscimo médio é de aproximadamente $0,65^{\circ}\text{C}$ a cada 100 metros (Azevedo et al., 2016; Gonçalves et al., 2016), ou de 1°C para cada 200 metros de altitude (Barbirato et al., 2007; Barry, 2008). Sabe-se que a temperatura apresentada nas montanhas tem médias anuais mais baixas do que em áreas de vale ou planície. Localidades montanhosas também apresentam extremos de temperatura de inverno, grandes amplitudes térmicas diária e anual, além de alta variabilidade climática anual (Azevedo et al., 2016; Barbirato et al., 2007; Barry, 2008).

Observa-se uma mudança nos padrões de precipitação nas áreas de montanha em relação aos padrões globais devido ao efeito de barreiras que as montanhas causam no fluxos de ar, onde ao ser forçado a altitudes mais elevadas em sua passagem sobre uma montanha, o ar é resfriado e a condensação do vapor de água frequentemente dá origem a formação de precipitação a barlavento (Greenland, 2005). Os ventos em regiões altas também tendem a ser mais fortes e a apresentar padrões ondulatórios (Greenland, 2005). Do mesmo modo, associada à redução da camada atmosférica proporcionada pela altitude,

a pressão atmosférica é também reduzida com a altitude. Regiões de montanhas também estão associadas a condições climáticas extremas de radiação, temperatura, precipitação e velocidade do vento (Azevedo et al., 2016). Sabe-se também que estão entre as regiões mais afetadas pelas mudanças climáticas (Kohler et al., 2010).

O estudo de regiões com relevos acidentados é diferenciado por três motivos: primeiramente, muitas áreas montanhosas estão distantes dos principais centros urbanos. Em segundo lugar, a natureza variada do terreno montanhoso configura diferentes condições climáticas que qualquer estação meteorológica única negligenciaria ao apresentar dados limitados e não representativos. E por fim, em terceiro lugar, estão as sérias dificuldades a serem enfrentadas na elaboração de observações meteorológicas representativas em estações de montanha, devido a inclinação do terreno que exige uma densa rede de estações (Barry, 2008).

1.2 O Clima Urbano e as suas Características

Acredita-se que uma tendência irreversível a urbanização é o desenvolvimento urbano em direção a uma vida em contexto de alta densidade (habitacional e humana) (UN, 2015; Xu et al., 2017). Em um estudo a respeito do crescimento populacional Bettencourt (2020) relata que as cidades modernas tendem a apresentar taxas de crescimento populacional anuais entre cerca de 1 a 4%, salvo exceções, e que as áreas urbanas são caracterizadas por mudanças rápidas e tipicamente exponenciais em muitas variáveis.

Este crescimento das cidades está atrelado diretamente à estruturação do ecossistema urbano, que devido aos seus materiais e atividades, apresentam características muito particulares. Segundo Oke et al. (2017), os ecossistemas urbanos são formados pela população biológica de organismos (vegetação e animais) dispostos em um mesmo espaço, que é composto pela junção da atmosfera, biosfera, hidrosfera, pedosfera e do sistema construído (Figura 1.2). Neste espaço, as construções estão diretamente relacionadas com o contexto social, cultural e económico de cada aglomerado urbano.




Figura 1.2: Componentes biofísicos do Ecosistema Urbano.
 Fonte: Oke et al. (2017)

O ecossistema urbano altera o natural, com isso, os fatores e as dinâmicas que promovem o estabelecimento do clima também são modificados e dão origem ao Clima Urbano (CUrb), que é definido por Andrade (2005) como:

"O resultado das modificações que as superfícies, materiais e as atividades das áreas urbanas provocam nos balanços de energia, massa e movimento".

São complexas as relações entre atmosfera, oceanos e continentes envolvendo processos físicos, químicos e biológicos, que tornam o clima das cidades diferente do clima ao seu redor (Menezes, 2017). Em grande ou pequena intensidade, todas as cidades apresentam os efeitos do CUrb (Oke et al., 2017). Em regime simultâneo, recíproco e independente, muitos são os elementos que se relacionam e compõem a natureza dos fenômenos climáticos (Ribeiro, 1993). Neste contexto, variáveis como temperatura, umidade relativa e regime de ventos são impactadas devido a modificações ocorridas no ambiente e na atmosfera, o que torna em algo físico o CUrb (Ribeiro, 1993). De modo geral, pode-se concluir que o CUrb é considerado antropogênico, ou seja, uma consequência do desenvolvimento humano em áreas urbanas (Zhao et al., 2011).

Cada área do tecido urbano apresenta suas particularidades, dependendo do uso realizado e do padrão de urbanização. Aspectos como as propriedades térmicas de cada material, a rugosidade das superfícies, a altura e largura dos cânions, a existência e a quantidade de áreas verdes, influenciam diretamente na incidência e perda da radiação solar e no fluxo de ar (Oke et al., 2017). Áreas de alta e baixa pressão são criadas a partir do diferente aquecimento dos materiais e acarreta, por fim, em uma circulação das massas de ar diferenciada (Barbirato et al., 2007; Menezes, 2017). Conseqüentemente, pode-se observar um aumento do aquecimento do ambiente e uma crescente demanda por refrigeração, devido ao aumento da temperatura média. Neste contexto, apresenta-se o Efeito de Ilha de Calor Urbano (EICU), onde a área urbana apresenta uma diferença positiva da temperatura em relação aos seus arredores (Oke et al., 2017).

Por causa do incremento de temperatura ocorrido, mesmo com vapor na atmosfera urbana por conta das atividades antropogênicas, a umidade relativa é menor do que em seus arredores, uma vez que o grande número de superfícies impermeabilizadas nessas áreas provoca o maior escoamento das águas pluviais e reduz o índice de evapotranspiração (Barbirato et al., 2007). No entanto, deve-se evitar causas e efeitos únicos, pois para o C_{Urb} existe um conjunto complexo de relações entrelaçadas (Oke et al., 2017).

O estudo do C_{Urb} é motivado, fundamentalmente, pela necessidade de se ter conhecimento suficiente para a tomada de decisões no planejamento urbano, de forma que estas ocorram para melhorar o conforto térmico e a qualidade de vida nas cidades (Mills, 2014). Tais estudos devem levar em consideração as escalas horizontais e verticais do clima, seus elementos, a morfologia urbana e também os fenômenos climáticos que são desenvolvidos a partir desenvolvimento das cidades como as zonas climáticas locais e as ilhas de calor e frio.

1.2.1 Morfologia Urbana

Por meio de obras de construção e expansão urbana, a urbanização altera gradualmente a cobertura do sol e também as condições climáticas urbanas (Grimmond, 2007). Desde

a década de 1950, os climatologistas estudam como a estrutura das cidades afeta as condições climáticas das cidades por meio de levantamentos como: tamanho da cidade, desenho das ruas, a geometria do cânion e a proporção do terreno verde (Kratzer, 1956; Landsberg, 1981; Mills et al., 2010; Oke, 1982). Sabe-se que o clima urbano local pode ser influenciado pela morfologia urbana por meio dos parâmetros morfológicos (Stewart & Oke, 2012). Compreender como a morfologia urbana afeta o Curb é de fundamental importância para traduzir tal conhecimento em práticas de planejamento e arquitetura urbana (Hernández Aja et al., 2013; Xu et al., 2017).

Oke (2006) definiu quatro fatores significativos sobre o Curb que devem ser considerados em seu estudo. Esses fatores, estão relacionados com a morfologia urbana, desempenhando papéis importantes na criação de certos ambientes climáticos (Zhao et al., 2011). O primeiro deles é a **Estrutura Urbana** com as dimensões dos edifícios e os espaços entre eles, larguras, alturas e espaçamentos das ruas. O segundo é a **Cobertura Urbana** com as frações correspondentes de áreas impermeáveis (construídas), permeáveis (com vegetação, solo nu e água). O terceiro aspecto é o **Textura Urbana**, com seus materiais de construção e os materiais naturais. E por fim o quarto aspecto é o **Metabolismo Urbano** com informações relativas ao calor, humidade e poluentes emitidos devido à atividade humana (Oke et al., 2006).

Neste contexto, muitos são os trabalhos publicados a respeito da relação entre a morfologia urbana com o clima urbano (Javanroodi & Nik, 2020; Matzarakis & Mayer, 2009; Monteiro et al., 2018; Wei et al., 2016; Xu et al., 2017; Zhao et al., 2011). O esquema de **Zonas Climáticas Locais (ZCL)**, desenvolvido por Stewart e Oke (2012), representa um esforço para relacionar a morfologia urbana e as condições climáticas. Para definir a ZCL de um local, um conjunto de parâmetros geométricos e de cobertura de superfície são utilizados; estes incluem FVC, fração da superfície do edifício, fração da superfície impermeável, fração da superfície permeável, altura do edifício, rugosidade do terreno, etc. Entre os indicadores de morfologia, os índices de ocupação do terreno (OT), índice volumétrico (IV), percentagem impermeável (PI), percentagem permeável (PP), relação H/L, Fator de Visão do Céu (FVC), etc, são índices amplamente utilizados para modelos

de estrutura urbana, tentando expressar o quanto o terreno está ocupado por construções. O FVC é um dos indicadores mais encontrados em estudos, ele representa a fração de céu disponível a partir de um ponto determinado, esta visão possibilita que ocorram as trocas de calor com a atmosfera terrestre e conseqüentemente o balanço de energia da Terra (Carvalho, 2020). Matzarakis e Matuschek (2011) apresenta que o FVC é um indicador importante para ilhas de calor urbanas. A explicação para isso é que esta variável fornece uma indicação da geometria da rua e densidade de construção na qual um valor, representa uma visão limitada do céu e resulta em maior armazenamento de calor líquido dentro de edifícios e um aumento do EICU (Dirksen et al., 2019).

1.2.2 Zonas Climáticas Locais

Com os diferentes padrões de urbanização construídos no tecido urbano, desenvolve-se também as denominadas Zonas Climáticas Locais (ZCL), que subdividem a cidade em áreas com características morfológicas particulares. Dessa forma, define-se ZCL como regiões de cobertura superficial uniforme, estrutura, material e atividade humana que abrangem uma escala local na direção horizontal (de centenas de metros a vários quilômetros) (Stewart & Oke, 2012). Este conceito tem sido usado como referência espacial para o design de redes meteorológicas urbanas e estudos do CUrb (Alexander & Mills, 2014; Bechtel et al., 2015; Bechtel & Daneke, 2012; Beck et al., 2018; Gonçalves et al., 2018; Leconte et al., 2015; Lee & Oh, 2018; Middel et al., 2014; Perera & Emmanuel, 2018; Siu & Hart, 2013; Van Hove et al., 2015) tendo permitido a análise de diversas condições meteorológicas dentro das áreas urbanas e nas periferias.

Baseados em estudos anteriores, Stewart e Oke (2012) desenvolveram um sistema de classificação das ZCLs com 17 diferentes classes, nas quais cada classe é única em sua combinação de estrutura de superfície, cobertura e atividade humana. Tal classificação se estrutura a partir dos parâmetros de morfologia urbana onde cada classe apresenta uma combinação única em estrutura de superfície (construção / altura e espaçamento das árvores), cobertura (fração permeável), tecido (albedo, admitância térmica) e metabolismo

(fluxo de calor antropogênico) (Stewart et al., 2014). As diferentes classes traduzem as condições urbanas em relação à maneira como elas modificam as variáveis de vento, temperatura e humidade, com variações características ao nível do dossel (Leconte et al., 2015).

As diferentes classes estão organizadas numericamente de 1 a 10 a partir do tipos de estruturas (partindo do ambiente com construções mais robustas para o ambiente com construções menores e mais espaçadas) e alfabeticamente de A a G a partir dos tipos de cobertura do solo (partindo da cobertura vegetal, passando pela construída e indo para o solo nú). A Figura A.1 ilustra as classes e as ordena a partir de suas estruturas e tipo de cobertura do solo Bechtel et al. (2015) e Stewart e Oke (2012), o Anexo A apresenta o detalhamento a respeito de cada uma dessas classes de ZCL explicado por Stewart e Oke (2012). Cada zona possui um regime de temperatura que é mais aparente em superfícies secas, em noites calmas e claras, e em áreas de simples alívio. A classificação detalhada está contida nos. No entanto, é necessário ressaltar que este sistema é genérico, com uma visão reducionista do todo, e por isso não pode capturar as peculiaridades de todos os locais urbanos e rurais (Stewart et al., 2014).

Este sistema de classificação foi projetado com foco na pesquisa dos Efeito de Ilha de Calor Urbano (EICU), pois fornece uma estrutura de pesquisa, padroniza a divulgação de observações de temperatura urbana e também possui outros usos para planeadores das cidades, ecologistas de paisagens e investigadores de mudanças climáticas globais. Para o clima urbano, o auxílio deste sistema está prioritariamente na definição da localização de sensores e estações meteorológicas, com o propósito de identificar zonas onde existe uma maior probabilidade de encontrar efeitos climáticos particulares, como por exemplo o EICU. Se a escala de análise se centrar no clima local, deve-se partir da análise do efeito de porções relevantes do espaço urbano, como as ZCL, de forma a evitar influências microclimáticas e compreender outros fenómenos locais ou de mesoescala que influenciem os resultados da monitorização. Esta classificação pressupõe ainda que espaços agregados numa única classe apresentem interações semelhantes com alguns dos parâmetros meteorológicos (Lee & Oh, 2018; Stewart & Oke, 2012; Stewart et al., 2014).

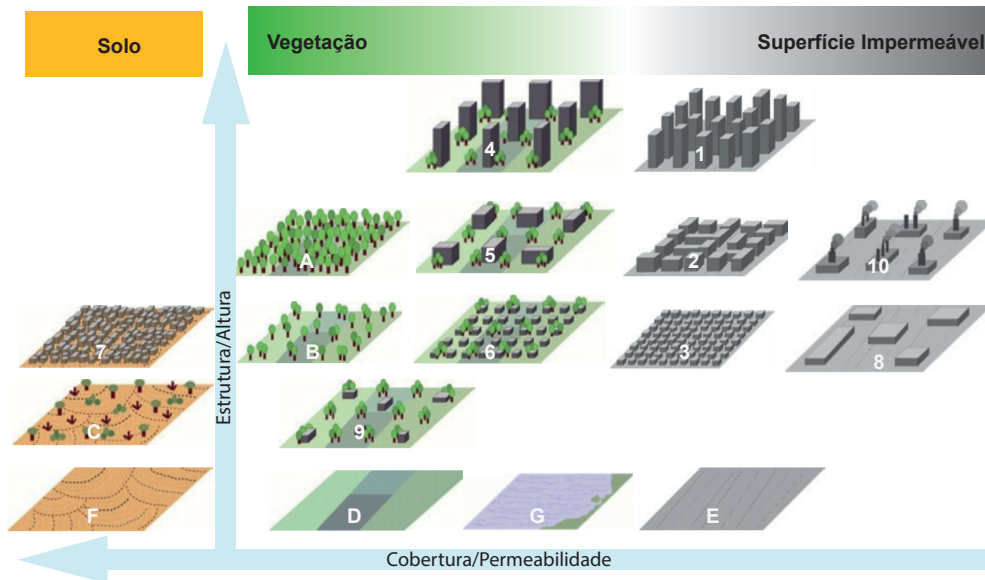


Figura 1.3: Esquema de Classificação das ZCL
 Fonte: Adaptado de Bechtel et al. (2015) e Stewart e Oke (2012)

1.2.3 Ilha De Calor e Ilha De Frio Urbano

Outro fenômeno climático encontrado nas áreas urbanas é o **Efeito de Ilha de Calor Urbano (EICU)**, que é descrito por muitos autores como a tendência da temperatura do ar ser maior nas cidades quando comparada com sua vizinhança (Gartland, 2011; Landsberg, 1981; Oke, 2002; Oke et al., 2017). A Figura 1.4 apresenta o perfil típico de temperatura para uma região urbana, onde o seu pico de temperatura costuma ser encontrado nas áreas mais urbanizadas, a escala característica desse efeito é a mesoescala (Oke, 2002).

O primeiro a identificar tal fenômeno foi Howard (1818), ao estudar o clima da cidade de Londres, Inglaterra. Desde então muitos estudos foram realizados, sendo este atualmente um dos fenômenos mais representativos e estudados do Curb (Bornstein, 1968; Debbage & Shepherd, 2015; Giridharan et al., 2004; Gonçalves et al., 2018; Magee et al., 1999; Memon et al., 2009; Stewart, 2011; Van Hove et al., 2015; Vicente-Serrano et al.,

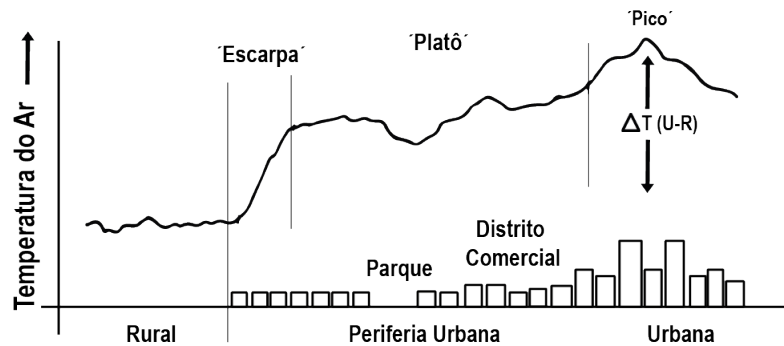


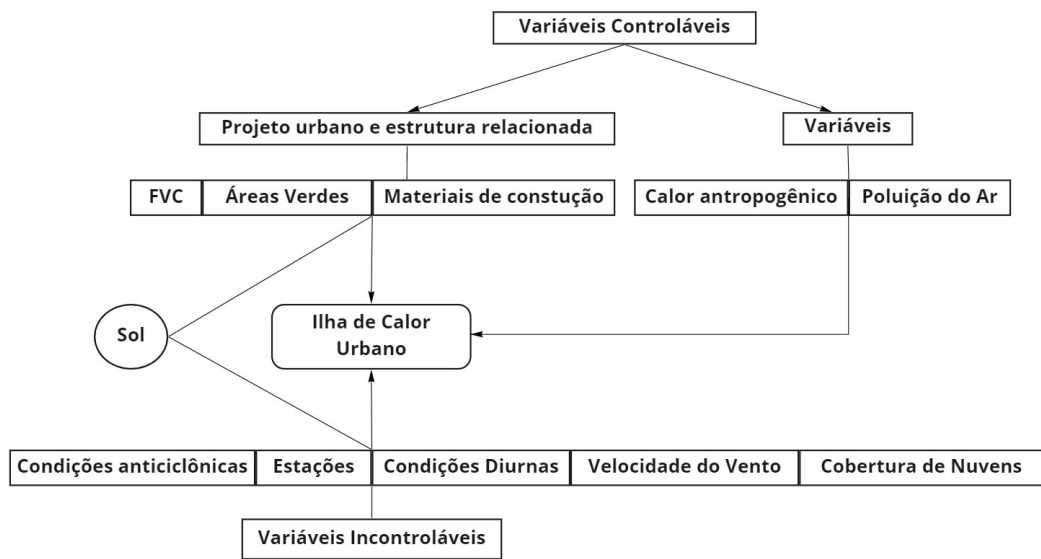
Figura 1.4: Perfil térmico de temperatura no EICU.
 Fonte: Adaptado de Oke (2002).

2005; Zhang et al., 2015).

O EICU é formado em duas diferentes camadas: uma junto à CEU, no nível dos elementos urbanos (topo de edifícios ou solo), chamada **ilha de calor de atmosfera inferior**, a outra ocorre sobreposta à primeira camada e se estende até a atmosfera livre, ela é denominada **ilha de calor de atmosfera superior** (Oke, 1988). A primeira é a mais comumente estudada e tem suas causas diretamente relacionadas a interferência da estrutura urbana no balanço de energia e massa (Menezes, 2017; Oke, 1988), entre seus fatores pode-se citar a geometria urbana (com a formação de canyons), a poluição do ar, a emissão de calor antropogênico, o baixo resfriamento evaporativo, tráfego e metabolismo dos organismos vivos e as características das superfícies (como as características térmicas e de permeabilidade dos materiais de construção) e de cobertura do solo (Gartland, 2011; Maia et al., 2013; Menezes, 2017; Oke, 2002).

O autor Rizwan et al. (2008) esquematiza os fatores de formação da EICU (Figura 1.5) onde pode-se observar a categorização entre fatores **controláveis** e **incontroláveis**, com a subdivisão entre **variáveis de efeito temporário**, como velocidade do ar e cobertura de nuvem, **variáveis de efeito permanente**, como áreas verdes, material de construção e FVC e **variáveis de efeito cíclico**, como radiações solares e fontes de calor antropogênicas (Figura 1.5). O calor gerado e contido em uma área vem de duas principais formas: das radiações solares e do calor antropogênico (a partir de centrais elétricas, automóveis, aparelhos de ar condicionado e outras fontes). O calor antropogênico costuma entrar no

ambiente de forma instantânea e direta. Já as radiações solares aquecem o ambiente diretamente e indiretamente (a partir das estruturas urbanas), transferência de calor e os processos de conservação de energia, como condução, convecção e radiação desempenham seus papéis característicos nesta troca de calor.



miro

Figura 1.5: Geração das EICU.
 Fonte: Adaptado de Rizwan et al. (2008).

As estruturas ao nível do solo naturais ou feitas pelo homem (paredes, telhado, jardins irrigados, espaços verdes não irrigados, áreas pavimentadas, etc.) absorvem e armazenam continuamente essa radiação na forma de energia térmica do sol, no final da tarde, quando o sol começa a se pôr e o ambiente começa a esfriar a energia térmica armazenada nas estruturas é então liberada para o ambiente. O método e a quantidade de calor liberado pelas estruturas urbanas, entretanto, dependem de outros fatores controláveis, como o FVC e os materiais de construção. Em áreas urbanas, materiais de construção maciços são colocados em um espaço muito pequeno que captura alta intensidade de radiação solar. A capacidade de liberação de calor por radiação de onda longa nas cidades é baixa devido à diminuição da visão do céu, o que resulta em alto armazenamento de calor nas

estruturas de edifícios. Assim, acredita-se que os valores de albedo e do FVC são os dois fatores mais importantes na criação de EICU. Também encontra-se na literatura, questões acerca da falta de vegetação que implica em um baixo valor de calor latente e um predomínio da conversão em calor sensível (Rizwan et al., 2008).

A intensidade do EICU pode ser observada ao se analisar as diferenças na temperatura do ar entre as áreas urbanas e rurais. Essas diferenças podem ser atribuídas ao aquecimento (do nascer ao pôr do sol) e resfriamento (do pôr ao nascer do sol) diferenciados em diferentes locais de medição (Oke, 1991; Sakakibara & Owa, 2005). Onde a maior interferência para a intensidade da EICU, ao considerar-se as condições sinópticas, é a nebulosidade e a velocidade do vento. Também por isso, a EICU atinge os valores mais altos sob condições de céu sem nuvens e vento fraco (Gartland, 2011). Outras características citadas por Gartland (2011) para o EICU são: o ar urbano na CEU pode atingir temperaturas de até 6 ° C (10 ° F) mais quente que a temperatura do ar nas áreas rurais, áreas com menos vegetação e maior desenvolvimento urbano tendem a apresentar EICU mais intensas. Os EICU exibem ar mais quente na "Camada Limite"(uma camada de ar até 2000 metros de altura), frequentemente são criadas grandes plumas de ar mais quente sobre as cidades onde inversões de temperatura (temperatura do ar mais frio) causadas por EICU não são incomuns.

Oposto aos EICU apresentam-se, indicados por valores negativos encontrados nos estudos dos EICU, os EIFU, sob os quais a região urbana apresenta temperaturas menores do que o seu arredor (Gonçalves et al., 2018). Esse processo é menos estudado, mas sabe-se que o EIFU, em contraste com a EICU, sempre ocorre durante o dia e com intensidade relativamente fraca (Gartland, 2011; Memon et al., 2009), principalmente durante as primeiras horas do dia, devido ao sombreamento e a baixa incidência de radiação solar causados pelos elementos urbanos. Ao mesmo tempo, essas estruturas afetam a velocidade do vento e estabelecem bases para a EICU (Yang et al., 2016).

Os EICU e EIFU podem apresentar aspetos positivos, entre os casos estão, as cidades com clima frio, em baixas latitudes e com altitudes mais elevadas, nas quais o aquecimento urbano favorece a ocorrência de temperaturas mais confortáveis no inverno. No

entanto, para a maioria das cidades do mundo, os efeitos no verão são vistos como um problema, uma vez que tais efeitos não causam apenas um pouco de desconforto com as suas temperaturas diferenciadas, falta de sombra e papel no aumento poluição do ar, eles também têm efeitos sérios na qualidade de vida do ser humano, são causas de doenças e impactam financeiramente com aumento da necessidade de uso de energia, de construção e manutenção de infraestrutura. Além disso, as construções áridas tecidas nos perímetros urbanos, EICU tendem a ser pouco atraente e pouco saudáveis para a flora e fauna urbanas (Gartland, 2011; Hernández Aja et al., 2013).

O impacto do clima e das variações climáticas na sociedade pode ser positivo (benéfico ou desejável) ou negativo (maléfico ou indesejável), no entanto, costuma-se enfatizar os aspectos climáticos negativos ignorando as oportunidades de o utilizar com recurso. Sabe-se que os efeitos do C_{Urb} ocorrem em pequena ou grande intensidade em todas as áreas urbanas, em climas quentes ou frios. Tal processo já foi amplamente estudado para cidades de grande ou médio porte, ao passo que para as cidades pequenas poucos estudos a respeito estão disponíveis. A singularidade de cada cidade exige o desenvolvimento de estudos em uma ampla gama de condições, fornecendo informações ajustadas para planejadores e formuladores de políticas, promovendo assim um desenho urbano que utilize o clima a favor dos habitantes do local (Gonçalves et al., 2018; Hernández Aja et al., 2013; Ren et al., 2011).

1.3 Modelação Matemática do Clima Urbano

A teoria matemática do clima é um ramo da teoria geral do clima, que investiga o comportamento das soluções de modelos climáticos, em escalas de tempo arbitrariamente grandes, através do uso de uma coleção de métodos matemáticos. A teoria geral do clima lida com toda essa evolução do sistema climático, que pode ser considerado de diferentes pontos de vista e estudado por uma variedade de métodos. Entre os exemplos de técnicas que estudam o clima podemos considerar o método empírico, onde padrões são constatados por observação e vivência do observador, e a modelação matemática, que

inclui a modelação estatística usando os dados observados de vários anos e a modelação com base nas leis termo-hidrodinâmicas (Dymnikov & Filatov, 2012).

No presente trabalho recorre-se à modelação estatística para a análise de dados climáticos da temperatura, observados plurianualmente entre os anos de 2016 e 2019, bem como dos aspectos de morfologia urbana.

1.3.1 Estatística Multivariada e Intensidade das Ilhas de Calor e de Frio

Em termos gerais, a **Análise Estatística Multivariada (AEM)** consiste num conjunto de métodos e técnicas estatísticas que permitem a análise simultânea de múltiplas variáveis relativas a um dado indivíduo, ou objeto, que se pretende estudar. A análise simultânea de duas ou mais características de um indivíduo é denominada por análise multivariada (Hair et al., 2010). Entre as várias técnicas de AEM temos a **Análise dos Componentes Principais (ACP)**, ou análise de factores, e a **Regressão Linear Múltipla (RLM)**, que passamos a descrever.

Análise de Componentes Principais

A ACP consiste num método para projetar pontos pertencentes a um espaço multidimensional em pontos de um espaço com menos dimensões, de forma que uma a preservar uma quantidade mínima de informação. O primeiro componente pode ser descrito como a projecção ortogonal em uma dimensão que maximiza a variação dos pontos projetados, removendo essa dimensão e sua variação associada, o segundo componente é a projecção em uma dimensão que minimiza a variação da nova matriz projetada de pontos, e assim sucessivamente, (Edwards & Cavalli-Sforza, 1965).

Esta abordagem estatística pode ser usada para analisar inter-relações entre um grande número de variáveis e explicá-las em termos de suas dimensões subjacentes comuns (factores). O objetivo é o de condensar as informações contidas em várias variáveis originais em um conjunto menor de variáveis (factores) com uma perda mínima de informação (Hair

et al., 2010).

A aplicação da análise de componentes principais a dados climáticos foi feita por diversos autores em vários contextos. Por exemplo, Prado et al. (2016) estudou o comportamento climático da cidade de Uberlândia - MG (Brasil), por meio da análise mensal dos elementos atmosféricos temperatura, humidade relativa do ar, amplitude térmica e precipitação, no período entre 2008 a 2012. No seu estudo, através de uma só componente, o autor conseguiu explicar 70,59% da variação total e se caracterizou por representar meses chuvosos com variação pequena de temperatura.

Regressão Linear Múltipla (RLM)

Um modelo RLM consiste numa função linear em várias variáveis do tipo (Equação 1.1):

$$Y = \beta_1 X_1 + \dots + \beta_n X_n + \beta \quad (1.1)$$

onde Y é a variável quantitativa dependente e X_1, X_2, \dots, X_n são variáveis independentes e explicativas da variável Y . Os coeficientes $\beta, \beta_1, \dots, \beta_n$ são parâmetros que indicam a influência de cada uma das variáveis explicativas do modelo. Note-se que na Equação (1.1) o parâmetro β é designado de termo dependente.

No presente trabalho iremos aplicar as técnicas de ACP e RLM aos dados plurianuais de temperatura recolhidos entre os anos 2016 e 2019, através de 23 sensores distribuídos pela área urbana da cidade de Bragança (21) e pela área contígua à cidade, mas fora da área urbana (2). O objetivo é o de determinar modelos explicativos da intensidade da EICU, que denotaremos por Y_{ICU} , e da Ilha de Frio Urbano (IFU), que será representada pela variável dependente Y_{IFU} . Adicionalmente, usaremos dados atuais relativos a variáveis de morfologia urbana que podem consideradas como potenciais preditoras da estrutura espacial da ICU.

A literatura publicada sobre o assunto é extensa, mostrando alguns modelos desenvolvidos com este objetivo como, por exemplo, nos trabalhos de Bottyán e Unger (2003),

László e Szegedi (2015) e Wicki et al. (2018, 2019). As variáveis utilizadas como preditores climáticos são as mesmas utilizadas na classificação das ZCL (Tipos de Construção ou tipos de Cobertura do Solo, FVC (*Sky View Factor*), Fracção de Superfície Construída, Fracção de Superfície Impermeável, Fracção de Superfície Permeável, Altura e Rugosidade dos Elementos, Classe de Rugosidade do Terreno, Calor Antropogénico Liberado, Albedo Superficial e Absorção Superficial, etc), mas nesse caso podem-se também incluir variáveis meteorológicas como temperatura, humidade, velocidade dos ventos, etc. Descrevem-se a seguir alguns trabalhos que utilizaram esta metodologia para dimensionar a intensidade da ilha de calor urbano em diferentes cidades.

László e Szegedi (2015) elaborou um modelo de RLM com base em parâmetros de superfície tendo como intuito de estrutura espacial do EICU da cidade de Beregszász, Zakarpattia, Ucrânia. O estudo teve como resultado que dois parâmetros apresentam forte impacto na EICU e que a estrutura espacial e a intensidade do EICU podem ser estimadas com uma precisão de $0,4^{\circ}\text{C}$ célcus dentro da área construída da cidade usando nosso modelo de RLM, tal modelo permitem a previsão de carga de calor de espaços menores e partes da cidade.

Já o autor Wicki et al. (2018, 2019) utilizou os fatores que influenciam a EICU noturna que foram avaliados em detalhes e testados usando diferentes resoluções espaciais para a avaliação da EICU da cidade de Basileia, na Suíça. Um modelo de RLM foi desenvolvido com preditores, resultantes de diferentes fontes de dados, para modelar, de forma contínua, a distribuição da temperatura do ar urbano. Os resultados mostram que vários conjuntos de dados podem ser usados para a previsão da distribuição das ilhas de calor com resultados comparáveis, idealmente executados em uma rede de 200 m. Note-se que ambas as cidades têm dimensões e população consideráveis, acima de 50 mil habitantes. Para cidades de pequena dimensão e baixa população, este tipo de estudos é ainda muito escasso. Um dos objetivos do presente trabalho é o de iniciar um estudo mais profundo sobre os fatores que influenciam as ilhas de calor e de frio para cidades de pequena dimensão, como é o caso de Bragança.

1.3.2 Análise de *Clusters*

A metodologia que estudaremos nesta seção é a da análise de *clusters* (Análise de Clusters (AC)). Em tradução literal, a palavra *cluster* significa grupo. Em termos simples, a AC consiste em agrupar dados que apresentem algum tipo de semelhança e descobrir o relacionamento intrínseco que existe entre as variáveis (Valli, 2012). Mais concretamente, esta metodologia permite identificar grupos de pontos em espaços multivariados, estando este dotado de uma medida de distância específica, que são “semelhantes” no sentido de que a medida de distância indicará o grau de proximidade dos pontos entre si, permitindo assim realizar o agrupamento (*clustering*) entre os pontos mais próximos (Caliński & Harabasz, 1974; Edwards & Cavalli-Sforza, 1965; Rao, 1964).

Vários estudos já mostraram aplicações práticas da análise de *clusters* em diversas áreas científicas como, por exemplo, em Economia, com pesquisas de mercado dividindo clientes em grupos homogêneos, na Astronomia com classificações de corpos celestes, na Psiquiatria, para refinar e redefinir as categorias de diagnóstico de doenças, na Bioengenharia, com classificações genéticas, na Climatologia, para classificações climático-ambientais, entre outras (Everitt et al., 2011).

Sendo assim, o objetivo básico da AC é buscar agrupamento naturais de dados (indivíduos, objetos, pessoas, pontos, elementos químicos, espécies biológicas, ou unidades, etc.) que podem representar o todo ou ser uma amostra de uma grupo maior. De forma prática, deseja-se separar os dados em grupos distinguíveis o mais rápido possível sem separar com muita frequência as variedades que devem permanecer juntas (Tukey, 1949). Matematicamente, isso significa que a AC busca determinar grupos de elementos mutuamente exclusivos e semelhantes, onde os elementos pertencentes a um grupo são mais parecidos quanto possível, enquanto indivíduos em grupos diferentes são diferentes (Valli, 2012). Com isso, para este método análises de semelhança (ou diferença) de todo par de indivíduos se torna necessário no processo de análise.

Assim, é dado o nome de AC para o somatório de procedimentos que buscam agrupar dados (Valli, 2012). Com tal análise é determinada uma estrutura interior nos dados a

partir dos grupos (*clusters*) sem que haja nenhuma informação adicional disponível que não seja os valores observados (Fraley & Raftery, 1998). A AC é diferente do problema de análise discriminante, porque na segunda se tem informações adicionais (Fraley & Raftery, 1998).

A possibilidade de erros no agrupamento de dados como as dificuldades de definição precisa dos *clusters* e problemas computacionais ao se buscar agrupamentos ótimos dão origem a muitas abordagens diferentes para análise de *cluster* e, portanto, à aplicação de vários métodos (Caliński & Harabasz, 1974). Entre eles estão:

Métodos de Agrupamento

Técnicas Hierárquicas: A partir do cálculo das distâncias de um indivíduo a outro formam-se grupos, este processo pode ser realizado por **aglomeração** onde todos os grupos começam com um indivíduo e são unidos gradualmente (são exemplos desta técnica: *ex single-link, complete linkage, average linkage, Ward's*) ou por **divisão** nesse caso o processo é iniciado em direção oposta, todos os indivíduos começam em um único grupo e a partir daí é iniciado o processo de divisão de grupos (exemplos de métodos que utilizam tal estratégia: *splinter-average distance, AID automatic interaction detection*), tais técnicas são realizadas até que se chegue a uma quantidade satisfatória de *clusters* (Everitt et al., 2011; Valli, 2012).




Figura 1.6: Ilustração do processo de Aglomeração Hierárquico.

Fonte: Adaptado de Valli (2012).

Técnicas Particionais: tal análise é iniciada definindo centros de grupos arbitrários, e alocamos os indivíduos no grupo mais próximo. Na sequência são calculados novos centros, e indivíduos são permutados a novos grupos, se estiverem mais próximos ao centro. O processo continua até que a estabilidade seja alcançada com um número predeterminado de grupos, uma exemplo de método particional é o método K-means e o método hierárquico particional (Everitt et al., 2011; Valli, 2012). A estrutura de árvore hierárquica ou dendograma são as representações mais comuns para esse tipo de AC, onde a quantidade de *clusters* pode ser maior ou menor dependendo do objetivo pretendido (Figura 1.7).

Por serem os mais comumente utilizados em análises climáticas, no presente trabalho os métodos Ward's e K-means serão utilizados:

Método de Ward

Algoritmo hierárquico de agrupamento no qual a similaridade usada para unir *cluster* é calculada como a soma dos quadrados entre os dois *cluster* associados a todas as variáveis. Este método tem a tendência de resultar em grupos de tamanho aproximadamente igual devido à sua minimização de variações dentro do grupo (Joseph Jr et al., 2009).

Método K-means

Um grupo de algoritmos de *clustering* não hierárquicos que funcionam particionando observações em um número especificado de *clusters* (que deve ser pré estabelecido), em

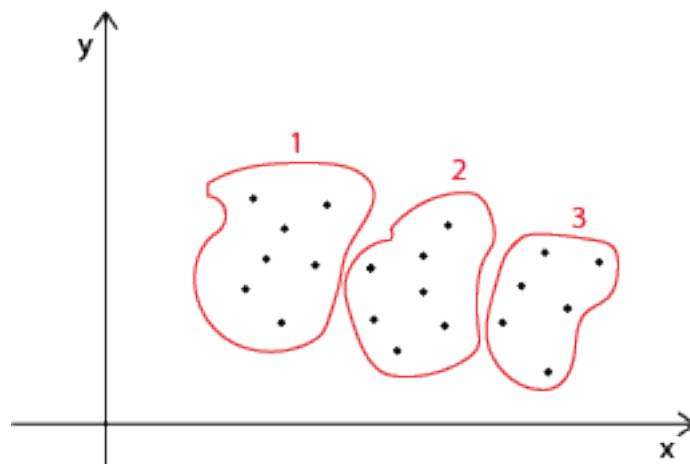


Figura 1.7: Ilustração do processo de Aglomeração Particional.
 Fonte: Adaptado de Valli (2012).

seguida, reiterando iterativamente as observações até que algum objetivo numérico relacionado à distinção de *cluster* seja alcançado (Joseph Jr et al., 2009). Na primeira etapa, determina-se uma partição inicial atribuindo observações aos *cluster*. Não precisando preocupar-se se as atribuições são arbitrárias ou lógicas. O único problema com tarefas ruins é que elas aumentam o tempo de cálculo, o quanto melhor o *clustering* estiver na partição inicial, mais rápido o resultado final será obtido. Depois de definir a partição inicial, pode-se começar a pensar na qualidade do *cluster* (Cleff, 2019).

Análise de *clusters* e Zonas Climáticas Locais

Sendo assim, pode-se afirmar que a AC é uma ferramenta muito útil para identificar padrões climáticos, outros trabalhos já foram desenvolvidos e publicados utilizando do método de análise de *clusters* como ferramenta para diversos tipos de modelos matemática do clima (Guo et al., 2015; Lee & Oh, 2018; Lee et al., 2019; Lee et al., 2009; Matsuo & Tanaka, 2014; Netzel & Stepinski, 2016; Ren et al., 2019; Santos et al., 2019; Unal et al., 2003; Zhou et al., 2013).

Para o presente trabalho o foco será na aplicação da análise de *clusters* para a climatologia em específico para a determinação e delimitação de ZCL (cada zona será um

cluster), onde os dados temperatura são agrupados até encontrar padrões de comportamento em certas áreas da cidade com características climáticas semelhantes (Lee & Oh, 2018; Matsuo & Tanaka, 2014). A seguir alguns trabalhos que realizaram tal processo de modelação matemática:

O estudo de Lee e Oh (2018), foi realizado na cidade de Seul, capital da Coreia do Sul. O trabalho teve como objetivo a classificação de ZCLs baseadas em abordagens estatísticas, com o intuito de fornecer informações relevantes para o planeamento espacial da cidade, com foco na criação de condições térmicas mais agradáveis nos espaços urbanos. Para tal trabalho foram utilizados 246 Estações Meteorológicas Automáticas (EMA) da cidade, as quais forneceram dados de temperatura e humidade de diferentes pontos, as informações dos elementos espaciais urbanos foram selecionadas com base em revisão da literatura. As zonas climáticas urbanas foram identificados por meio de análise de regressão passo a passo entre a temperatura do ar e os elementos espaciais urbanos. Finalmente, as ZCL da área de estudo foram classificadas aplicando análise de agrupamento K-means, e cada característica espacial das ZCLs foi identificada (Lee & Oh, 2018).

O trabalho de Matsuo e Tanaka (2014) teve como área de estudo a cidade de Hiroshima no Japão, o trabalho teve como problemática o fenómeno de ilha de calor que é apresentado principalmente nas áreas urbanas no verão, o objetivo foi esclarecer os padrões de distribuição de temperatura no verão e seus fatores contribuintes na área urbana, com o intuito de fornecer dados relevantes para o planeamento urbano. A classificação de todos os pontos em *clusters* foi realizada com base nos padrões diários de mudança de temperatura e características geográficas para cada cluster utilizando o método de Ward, o qual identificou quatro ZCLs diferentes na cidade (Matsuo & Tanaka, 2014).

Outro objetivo deste trabalho será o de usar uma análise de *clusters* para a definição de zonas climáticas locais da cidade. Na próxima seção apresentamos o conceito de *cluster* e explicamos em que consiste uma análise de *clusters*.

Capítulo 2

Contexto e Tecnologias/Ferramentas

2.1 Caracterização da Área de Estudo

A área de estudo do presente trabalho é a cidade de Bragança, que se localiza no extremo nordeste de Portugal Continental (Figura 2.1), o município é a capital do distrito de Bragança que faz fronteira ao norte e leste com a Espanha, a oeste com o distrito de Vimioso e a sudeste com Vinhais. Até o século vinte o seu crescimento foi compacto, mas a partir daí pode-se observar um crescimento urbano considerável. Nesse contexto, ocorreu uma expansão territorial que levou a cidade a apresentar uma crescente complexidade nas relações cidade-clima (Menezes, 2017). Bragança apresenta variações de até 200 m de altitude em curtas distâncias que compõem a sua diversidade topoclimática. Entre os seus morros e vales estão presentes os rios Fervença e Sabor. O primeiro deles apresenta maior influência urbana, enquanto o segundo tem maior influência rural, devido às localidades por onde passam.

O seu mesoclima tem característica de influência continental com regime tipicamente mediterrâneo, isso se deve à pouca ou nenhuma influência marítima que sofre, por ser margeada por conjuntos de montanhas (Cantábricos a norte e oeste, do planalto Castelhanoleonês de oriente e do Planalto Beirão e do Maciço Central a sul) (Gonçalves et al., 2014; Menezes, 2017).

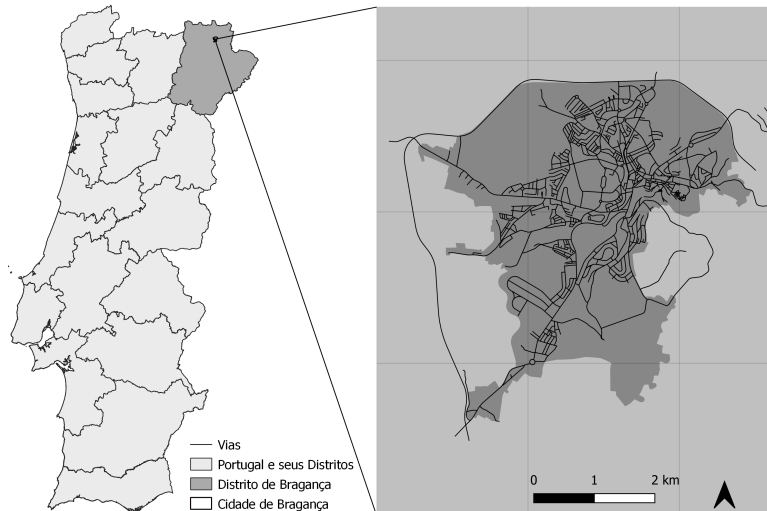


Figura 2.1: Localização da cidade de Bragança.

Segundo a classificação de Köppen-Geiger, o clima da cidade de Bragança encontra-se num contexto Csb, que corresponde a um clima temperado com Inverno chuvoso e verão seco e pouco quente (Geiger, 1936; Köppen & Geiger, 1928), no qual os maiores níveis de precipitação ocorrem no inverno. A Figura 2.2 apresenta a relação entre as médias mensais de temperatura e acumulado precipitação para o ano de 2019 em que é possível perceber claramente que o inverno é frio e húmido e que o verão é ameno e seco.

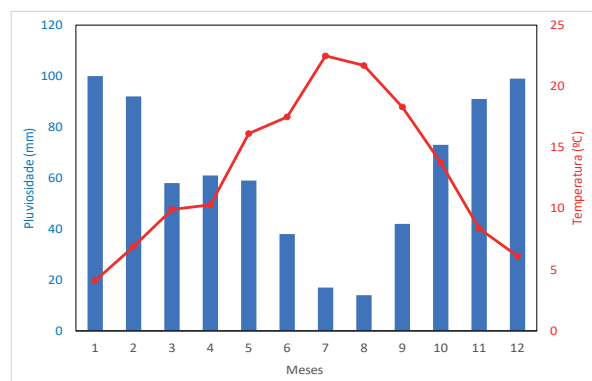


Figura 2.2: Gráfico de Temperatura e Pluviosidade de Bragança (2019).

Fonte: Adaptado de ClimateData (2020).

2.2 Monitorização do Clima Urbano - Temperaturas

Na cidade de Bragança se encontra uma rede de monitorização meteorológica constituída por 23 sensores de temperatura e humidade relativa do ar (Figura 2.3). Essa rede de sensores foi instalada no ano de 2011, com dados consolidados desde 2012, a qual foi objeto de outros estudos sobre várias interfaces do estudo do clima urbano (Carvalho, 2020; Gonçalves et al., 2018; Maia et al., 2013; Menezes, 2017; Menezes et al., 2017).

A instalação dos sensores se deu a partir do conceito de ZCL de Oke (2006), através da qual pode-se identificar seis zonas climáticas, e adicionou-se a categoria referente a espaços verdes urbanos. Buscou-se uma distribuição equilibrada do espaço, em diferentes contextos orográficos, dessa forma, com as ZCL identificadas 3 sensores foram dispostos em cada uma em pontos estratégicos da cidade, exceto os espaços rurais e os espaços verdes urbanos, que ficaram com 4 (Figura 2.4). Posteriormente as localidades em que os sensores foram instalados foram recategorizadas a partir da atualização do conceito de ZCL de (Stewart & Oke, 2012) onde pode-se identificar 7 dentre as 17 ZCL presentes na nova classificação.

Cada um dos pontos de monitorização estão listados na Tabela 2.1, junto aos seus respectivos dados de altitude, latitude e longitude, sendo possível perceber grande variedades de altitudes, com pontos que variam entre 558,1 m e 811,8 m. A ordem dos sensores na tabela vai das ZCL mais urbanizadas (2) até as menos urbanizadas (C) tentando apresentar o gradiente de urbanização identificado em estudos anteriores. Todas os sensores listados estão programadas para a coleta de dados de temperatura, humidade a cada 10 minutos durante todo o dia desde 2012.

Na Tabela ?? pode-se encontrar a descrições de cada ZCL, é necessário ressaltar que os pontos 23 e 20 contidos na ZCL C são os pontos de comparação rural.

Os sensores são do modelo TGP-4500, TinyTag, Gemini Data Loggers, e realizam em conjunto as leituras de humidade relativa do ar e temperatura simultaneamente. Os equipamentos foram instalados a 3 metros de altura do solo em pontos estratégicos da cidade (Figura 2.4 a), dentro de um abrigo feito do material PVC e pintado na cor branca

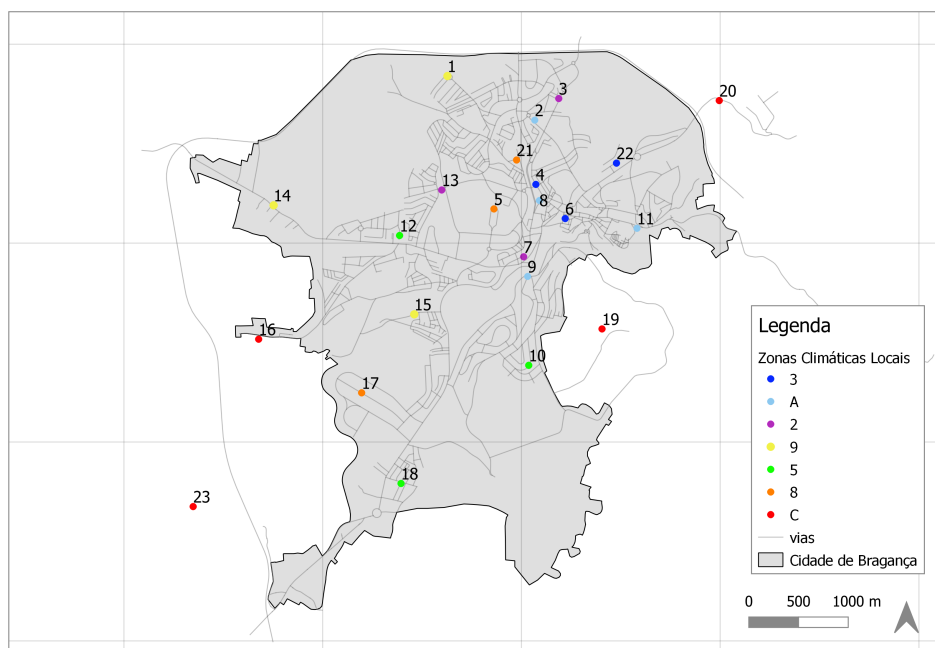


Figura 2.3: Localização dos Sensores.

para minimizar o aquecimento radioativo, na Figura 2.4 b) pode-se ver o sensor sem a proteção.

Estes modelos de sensores são capazes de armazenar até 32.000 leituras de dados de medição de temperatura (entre -25°C e 85°C) e de humidade relativa (entre 0 a 100 %). Os dados são recolhidos e registrados a cada 10 minutos. Também neste intervalo de tempo são gravadas as médias correspondentes, que posteriormente são convertidas em médias horárias. Valores de máximos e mínimos das variáveis também são registados pelos sensores. Todos os dados armazenados são coletados in loco por um integrante da equipe bimestralmente, que os passa para um notebook da instituição, posteriormente os mesmos são compilados e analisados. Eles foram distribuídos ao longo da cidade a fim a atender as diferentes tipologias de construção da cidade, indo das áreas mais arborizadas (Figura 2.5 a.), passando por áreas mais rurais com solo descampado (Figura 2.5 b.), passando por áreas mais habitacionais (Figura 2.5 c.) e chegando as áreas com maior densidade de construções (Figura 2.5 d.). No Apêndice B.1 encontram-se contidos as fotos dos locais

Tabela 2.1: Localização dos Sensores e suas ZCL.

Ponto	ZCL	Altitude	Latitude	Longitude
3	2	651,4	-6,757	41,815
7	2	677,9	-6,762	41,801
13	2	710,2	-6,771	41,807
4	3	670,8	-6,76	41,808
6	3	641,9	-6,757	41,805
22	3	629,8	-6,751	41,809
10	5	720,9	-6,761	41,791
12	5	678,6	-6,777	41,803
18	5	736,8	-6,777	41,781
5	8	712,9	-6,765	41,806
17	8	714,2	-6,782	41,789
21	8	681,6	-6,763	41,81
1	9	679,8	-6,77	41,818
14	9	709,9	-6,792	41,806
15	9	660,7	-6,775	41,796
2	A	644,9	-6,76	41,814
8	A	672,1	-6,76	41,806
9	A	659,7	-6,761	41,799
11	A	664,9	-6,748	41,804
16	C	673,6	-6,794	41,794
19	C	811,8	-6,753	41,795
20	C	558,1	-6,738	41,815
23	C	709,6	-6,803	41,779

Fonte: Adaptado de Menezes (2017).

de instalação de todos os sensores.

2.3 Indicadores de morfologia urbana

O âmbito das análises morfológicas se deram na envolvente dos sensores meteorológicos, onde se procedeu uma análise em escala detalhada dos indicadores de análise da morfologia urbana. Para ser possível relacionar diretamente a morfologia urbana da cidade de Bragança e o microclima, optou-se por definir uma envolvente correspondente a um raio de 50 metros para todos os sensores (Figura 2.6). É de fundamental importância citar, que os dados morfológicos foram obtidos por Carvalho (2020) em sua dissertação e

Tabela 2.2: Descrição das Zonas Climáticas Locais

ZCL	Sensores	Descrição
2	3, 7, 13	Área com edificado moderno de altura média a alta, e elevada densidade com predomínio de superfícies pavimentadas
3	4, 6, 22	Núcleo antigo da cidade, com edifícios de altura média-baixa, elevada densidade, edificado em pedra e tijolo
5	10, 12, 18	Área com média densidade, ruas de habitações de baixa altura em banda ou isoladas
8	5, 17, 21	Área comercial e industrial, densidade média a baixa, com edifícios de grande envergadura com estacionamento pavimentado
9	1, 14, 15	Espaço de transição entre o meio urbano e o rural, casas dispersas com envolvente agrícola e florestal
A	2, 8, 9, 10	os espaços verdes urbanos com cobertura predominante verde com vegetação rasteiras e arbóreas
C	16, 19, 23 e 20	Áreas rurais isoladas nos subúrbios da cidade representativas das características da paisagem local

Fonte: Carvalho (2020)



Figura 2.4: Sensores de Temperatura e Humidade relativa:
a) Altura de instalação b) proteção de PVC c) Sensor.



a) Sensor 11



b) Sensor 23



c) Sensor 10



d) Sensor 7

Figura 2.5: Diferentes tipologias de construção na envolvente dos sensores.

serão aplicados nos modelos matemáticos do presente trabalho.

Para definir e aplicar esse raio foi utilizada a ferramenta *Buffer* do programa (ESRI, 2020), que aplica um perímetro circular na envolvente dos sensores de temperatura de acordo com o raio definido, 50 metros. Sendo assim, os indicadores de morfologia urbana foram expressos em relação a área de superfície de terreno na envolvente dos sensores que ficou de aproximadamente $7830 m^2$.



Figura 2.6: Exemplo de envoltente dos Sensores

Fonte: Carvalho (2020)

Objetivando descrever o espaço urbano da cidade de Bragança numericamente, utilizou-se os indicadores de morfologia urbana. A aplicação dos valores obtidos para os indicadores de morfologia urbana no presente trabalho tem como objetivo identificar as Componente Principal (CP)s do CUrb para a cidade de Bragança, e assim poder elaborar um modelo matemático que o expresse a intensidade do CUrb. Com exceção do FVC (Saga Gis), os cálculos de todos os indicadores foram realizados através do programa de Sistemas de Informações Geográficas ArcMap (ESRI), para ambas as metodologias já citadas. Para esses cálculos, os valores de altura e número de pisos dos edifícios foram agregados, gerando um valor único por zona urbana ou envoltente (Carvalho, 2020).

Fator de Visão do Céu (FVC)

O FVC varia entre 0 e 1, isto é, valores próximos de 1 significam que quase todo o hemisfério é visível, como o caso em feições expostas sem qualquer obstrução (planos e picos), enquanto valores próximos de 0 estão presentes em vales profundos ou regiões urbanizadas com prédios muito altos onde quase nenhum céu é visível (Zakšek et al., 2011). Em geral, a superfície muda sua temperatura mais rapidamente quando uma

grande parte do céu é visível; vários estudos investigaram a correlação entre FVC e ilhas de calor dentro de uma cidade (Dirksen et al., 2019).

Para o cálculo do FVC, os dados foram obtidos por duas metodologias assim como o descrito por Carvalho (2020), a primeira através do uso do ArcMap ESRI (2020) juntamente com o SAGA Gis e a segunda com o processamento de imagens utilizando o Adobe Photoshop CS6. (2020).

Na primeira metodologia obteve-se o FVC a partir de um ficheiro correspondente a rugosidade do terreno calculada através da adição de dois shapes no programa de mapeamento ArcMap ESRI (2020): sendo o primeiro um modelo topográfico tridimensional e o segundo é o um *shape* das edificações com informações sobre suas alturas. No programa SAGA Gis o *shape* foi utilizado, onde aplicou-se a ferramenta de cálculo do FVC, primeiramente para uma matriz de 1x1 metro (escala) e depois calculando a média para todas as subsecções presentes na cidade de Bragança, desconsiderando os telhados. Tal metodologia considerou apenas a massa edificada para o calculo do indicador, dessa forma apenas os pontos que não possuíam vegetação em seu entorno (quatorze pontos) foram considerados (Carvalho, 2020).

A segunda metodologia se baseia no processamento de fotos capturadas a partir da utilização da lente olho de peixe, com a câmera alinhada com uma régua de nível e posicionada para o céu, Figura 2.7. O método foi utilizado para os pontos que possuem vegetação em seu entorno (sete pontos), visto que, o SAGA Gis contabiliza apenas as edificações no seu cálculo de FVC. Uma prática mais precisa pois contabiliza todas as obstruções existentes (vegetação e edificações).

Esta metodologia foi utilizada apenas para o calculo do FVC da envolvente dos sensores. Assim, para se chegar ao valor correto do FVC foi necessário realizar uma contagem de *pixels* nas fotos, onde os *pixels* pretos correspondem as obstruções (vegetação, edifícios e entre outras) e os *pixels* brancos representam o céu, cada pixel é contabilizado e o somatório de ambas as parcelas (pretas e brancas) corresponde ao número total de *pixels* da fotografia, a Figura 2.8 apresenta o resultado do indicador para os pontos arborizados. O cálculo do indicador é então feito através da Equação 2.1:



Figura 2.7: Metodologia de captura de imagens

$$FVC = 1 - \frac{\text{Número de } \textit{pixels} \text{ pretos}}{\text{Número total de } \textit{pixels}} \quad (2.1)$$

2.3.1 Indicadores Intermediários

O cálculo de algumas indicadores intermediários (*Superfície do terreno (St)*, *Superfície global (Sg)*, *Área de implantação (Ao)*, *Área de construção (Aj)*) foram necessários para a obtenção dos indicadores finais (Percentagem de ocupação do terreno (OT), Índice de construção (IC), Número médio de pisos (NMP), glsPI, Percentagem de área permeável (PP), Relação H/L (HL), Albedo médio (AM)), que expressão a morfologia da cidade de Bragança. A ferramenta de área do software de geomática ArcMap ESRI (2020) foi utilizado para a obtenção da *St*. Já os cálculos das *Ao* e *Aj* foram baseados na área de cada edifício presente na cidade. Ao final das análises, obteve-se a altura dos edifícios com a contagem de seus respectivos andares, considerou-se 3 metros de altura para cada andar e, ao final da contagem, acrescentava-se 1 metro para a correção.

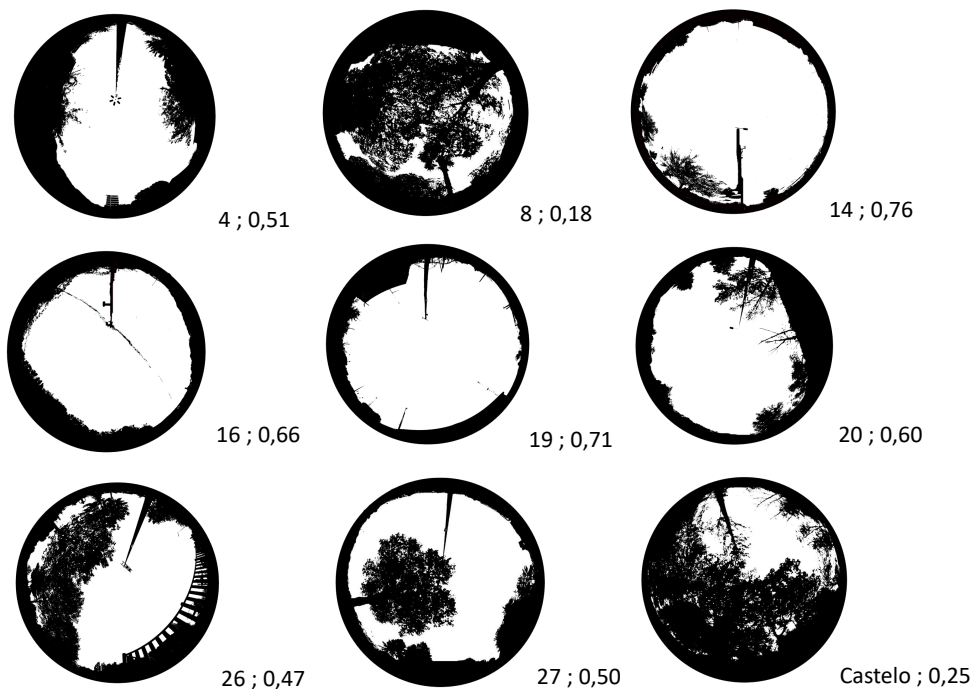


Figura 2.8: Imagens tratadas dos pontos com seus respectivos FVC.
 Fonte: Adaptado de Carvalho (2020)

Superfície do terreno (St)

A St é a área de cada zona existente na cidade em questão (Carvalho, 2020; Lobo et al., 1995).

Superfície global (Sg)

Entende-se como Sg a superfície de um espaço territorial, podendo ser um país, uma cidade, um bairro, etc. Sendo assim, para calcular a Sg foi necessário somar todas as St (Equação 2.2) (Carvalho, 2020; Lobo et al., 1995).

$$Sg = \sum St \quad (2.2)$$

Área de implantação (A_o)

A área de implantação corresponde a área de construção das edificações (casa, prédio, indústria, etc) , ou seja, a área de suas bases. A A_o pode ser calculadas através do somatórios das áreas de implantação de cada edificação (A_i) (Equação 2.3) (Carvalho, 2020; Lobo et al., 1995).

$$A_o = \sum A_i \quad (2.3)$$

Área de construção (A_j)

A área de construção, ou área de cobertura, diz respeito ao total de pisos cobertos por uma edificação. Esta área é calculada a partir da multiplicação do somatório da A_o das edificações pelo somatório do seu Número de Pisos (N_p) (Carvalho, 2020; Lobo et al., 1995).

$$A_j = \sum A_o \times \sum N_p \quad (2.4)$$

Volume Volume (V)

A relação entre a A_o e a altura das edificações expressa o V das mesmas. Sendo assim, o V_{total} das edificações é calculado a partir do somatório das A_o multiplicado pelas alturas (H) das edificações.

$$V_{total} = \sum (A_o \times H) \quad (2.5)$$

2.3.2 Indicadores finais

Com os indicadores intermediários pode-se proceder o cálculo dos indicadores finais.

Percentagem de Ocupação do Terreno (*OT*)

A percentagem de ocupação do terreno, também conhecido como índice de implantação, é calculado através da relação da Ao das edificações e a St (Equação 2.6).

$$OT = \frac{\sum Ao}{\sum St} \times 100 \quad (2.6)$$

Índice de construção (*IC*)

O IC representa a fração do terreno que foi construída, ele é obtido a partir da Equação 2.7.

$$IC = \frac{\sum Aj}{\sum St} \quad (2.7)$$

Percentagem de área permeável (*PP*)

A PP foi gerada a partir de um shape no ArcMap ESRI (2020) no qual os espaços verdes (Área permeável (Ap)) da cidade se encontravam registrados, a base de dados era antiga (2008), por este motivo foi necessária uma atualização dos dados. Tal arquivo possibilitou o cálculo das PP e também das Percentagem de área impermeável (PI). A percentagem de área verde é representada pela fração de Ap pela St 2.8.

$$PP = \frac{\sum Ap}{St} \times 100 \quad (2.8)$$

Percentagem de área impermeável (*PI*)

A percentagem de PI representa a fração construída da cidade, com seus edifícios, ruas, passeios, etc, que ficam dispostos na St . Esta área foi obtida a partir da diferença da PP (Equação 2.9).

$$PI = 100\% - PP \quad (2.9)$$

Índice volumétrico (*Índice volumétrico (IV)*)

O IV expressa uma relação entre os volumes ocupados pelos edifícios e a St . O cálculo é feito a partir da Equação 2.10, onde a somatória dos volumes é dividida pela St .

$$IV = \frac{\sum V}{\sum St} \quad (2.10)$$

Número médio de pisos (NMP)

O NMP expressa a quantidade de pisos expressa a quantidade média de andares que cada edificação apresenta, ele é calculado a partir da Equação 2.11.

$$NMP = \frac{\sum Ai}{\sum Ao} \quad (2.11)$$

Relação H/L (HL)

A relação H/L (HL) expressa a razão entre a altura média dos edifícios (H) e a largura média das ruas (L) assim como a Figura 2.9 mostra (Allegrini et al., 2012; Vallati et al., 2016). Para a aplicação deste indicador, foram utilizados as subsecções das áreas urbanas nos limites das envolventes (50 metros) e um shape das edificações da cidade, onde com o uso do ArcMap ESRI (2020) gerou-se a relação final da média da altura dos edifícios pela média da largura das ruas.




Figura 2.9: Ilustração da Relação H/L
Fonte: Adaptado de Allegrini et al. (2012) e Vallati et al. (2016)

A média da altura dos edifícios, com base nos valores individuais de altura de cada

edificação, foi utilizada para o cálculo da altura (H), e a largura (L) foi obtida através da utilização da ferramenta *Euclidean distance* do ESRI (2020)), pela qual foi possível elaborar uma matriz de distância entre edifícios, através da qual se calcularam os valores médios para o contexto de análise (Carvalho, 2020).

Albedo médio (AM)

Albedo ou refletividade é um indicador que apresenta a percentagem de radiação solar que qualquer superfície reflete em relação a radiação que incidente (Hernández Aja et al., 2013). O albedo também permite conhecer a quantidade de energia calorífica que a superfície é capaz de absorver, ao descontar a energia transmitida da radiação total

Polígonos para cada superfície existente (calçada/passeio, asfalto, gramíneas e floresta) nas envoltentes dos sensores foram criadas com o uso do programa ArcMap ESRI (2020), onde para cada material foi atribuído um valor médio de albedo 2.3.

Tabela 2.3: Albedo Médio

Superfície	Albedo
Solo exposto (seco)	0,300
Gramíneas	0,220
Calçadas/passeio	0,200
Florestas	0,135
Asfalto	0,125

Fonte: Carvalho (2020)

A partir da atribuição dos valores de albedo para as superfícies nas envoltentes dos sensores, calculou-se uma média ponderada para obter um albedo médio para cada envoltentes (Equação 2.12).

$$AM = \frac{\sum Albedo \times AS}{\sum AS} \quad (2.12)$$

2.4 Análise de Dados

2.4.1 Temperatura

Para o presente trabalho, decidiu-se utilizar os dados de temperatura coletados entre o período de janeiro de 2016 e dezembro de 2019, os quais foram compilados e as falhas foram completadas a partir do software *SPSS Statistics* (IBM Corp, 2020), em que os pontos 9 e 16 foram retirados do trabalho devido aos seus dados apresentarem uma percentagem elevada de dados omissos (respectivamente 47% e 35 %), seguindo apenas com sensores com valores abaixo de 18% de dados omissos. No *Microsoft Excel* foram organizados os dados de temperatura a cada 10 minutos, por estações.

Para os estudos da EICU, a correção da altitude se fez necessária para minimizar distorções incorporadas pela complexidade orográfica da cidade de Bragança, uma vez que essa dependência também afeta nos efeitos da Ilha de Calor Urbano (ICU).

A variedade de pontos de monitorização permite calcular um gradiente térmico real, baseado em dois pontos a diferentes alturas e com envolvente semelhante. Os pontos rurais 20 e 23 foram escolhidos para evitar interferências de efeitos urbanos. Baseado nestes pontos, calculou-se um gradiente térmico vertical médio horário para cada mês dos anos em estudo e aplicou-se uma curva polinomial do 5º grau, que serviu de cálculo para o gradiente vertical de temperatura horária. O objetivo da correção foi retirar dos dados o efeito da altitude, nivelada a uma cota média de 680 metros, que é o nível médio de Bragança, a partir da Equação 2.13. Como exemplo, apresenta-se a Figura 10, com o perfil médio horário do gradiente vertical de temperatura de fevereiro de 2016. Fica, portanto, evidenciada a variação diária através deste método, que se apresentou como a melhor alternativa frente aos gradientes adiabáticos. Devido à variedade dos pontos, a normalização da temperatura será realizada a partir da Equação 2.13 (Menezes, 2017).

$$T_{final} = T_{inicial} - [T_{calculado} \times (H - 680)] \quad (2.13)$$

Em que T final é a Temperatura após correção (°C), T inicial é a Temperatura antes da correção (°C), T calculado é o Gradiente vertical de temperatura (°C/m) e H é a Altura do ponto (m). Com os dados obtidos pelos sensores no período de 2016 a 2019 obteve-se as planilhas de média horária, média, máxima e mínima diária.

2.4.2 Intensidade dos Efeitos de Ilha de Calor e Ilha de Frio

Numericamente, a Intensidade do EICU se apresenta como a diferença de temperatura entre um ponto urbano e um rural, sendo que quando a intensidade se apresenta negativa, caracteriza-se o EIFU (Gartland, 2011). Neste contexto, a partir dos dados de temperatura de 2016 a 2019 obteve-se os dados de intensidade de EICU com a diferença da temperatura dos pontos urbanos em relação a média da temperatura dos pontos rurais (20 e 23) (Equação 2.14).

$$I_{(EICU)} = T_{(ponto)} - T_{(rural)} \quad (2.14)$$

Com os dados obtidos pode-se então gerar as planilhas de Intensidade máxima e mínima diária da intensidade de EICU para análises posteriores, e também plotar o gráfico de intensidade de ilha de calor em relação as horas do dia e os meses do ano possibilitando avaliar o efeito da urbanização nos diferente pontos da cidade.

2.5 Análise de Componentes Principais (ACP)

Utiliza-se da análise de componentes principais (ACP) para extrair informações de um conjunto de dados multivariado e expressar essas informações em um novo conjunto chamado de CP, o conjunto de dados inicial contém a variação total dos dados, dessa forma a ACP pretende identificar direções, CP, ao longo das quais a variação dos dados é máxima. Ou seja, a ACP reduz a dimensionalidade dos dados com uma perda mínima de informação (Kassambara, 2017).

Os índices de morfologia urbana (OT, IC, NMP, IV, FVC - ArcMap, FVC - fotos PI, HL AM) compilados na Tabelas 2.4 serão utilizados na ACP com o intuito de obter as componentes principais para um posterior modelo de RLM que possibilite explicar os impactos da morfologia urbana nas temperaturas da cidade de Bragança.

A tabela 2.4 foi computada no *software* estatístico R! (R Core Team, 2020), onde primeiramente as variáveis foram escalonadas a partir da função *scale*, a qual padronizou os dados para que nenhum indicador tenha um peso maior unicamente devido aos seus valores numéricos, nessa análise os pacotes **FactoMineR**, **factoextra** foram necessários (Kassambara & Mundt, 2020; Lê et al., 2008).

O modelo da ACP foi desenvolvido com base no texto *Practical Guide To Principal Component*

Tabela 2.4: Dados de Morfologia Urbana - Sensores

Sensores	ZCL	OT	IC	NMP	IV	FVC-S	FVC-F	AM	PI	H/L
1	9	4,57	0,23	5	0,73	0,99	0,99	0,20	28,21	0,48
2	A	1,94	0,15	8	0,48	0,84	0,47	0,19	32,44	0,61
3	2	32,76	2,38	7	7,28	0,92	0,92	0,12	99,90	3,02
4	3	25,80	0,83	3	2,63	0,82	0,51	0,21	70,18	1,04
5	8	9,54	0,10	1	0,41	0,88	0,88	0,18	84,79	0,21
6	3	34,25	0,87	3	3,31	0,68	0,68	0,18	99,89	0,94
7	2	48,89	2,56	5	5,85	0,64	0,64	0,12	100,00	3,14
8	A	11,65	0,35	3	1,17	0,67	0,18	0,15	38,85	0,56
10	5	21,71	0,43	2	1,52	0,91	0,91	0,17	92,51	1,06
11	A	3,19	0,06	2	0,19	0,83	0,25	0,14	29,66	0,25
12	5	35,16	0,70	2	2,46	0,86	0,86	0,13	97,96	0,86
13	2	22,97	1,60	7	3,68	0,91	0,91	0,16	89,98	1,44
14	9	3,39	0,07	2	0,24	0,92	0,76	0,18	22,10	0,18
15	9	13,02	0,38	3	1,27	0,99	0,99	0,20	48,30	0,44
17	8	36,56	0,85	2	2,97	0,87	0,87	0,16	97,81	0,83
18	5	20,62	0,41	2	1,44	0,85	0,85	0,15	67,17	1,26
19	C	10,85	0,11	1	0,33	0,98	0,71	0,22	10,85	0,16
20	C	8,98	0,09	1	0,36	0,98	0,60	0,19	8,98	0,13
21	8	39,59	0,69	2	2,56	0,89	0,89	0,14	96,11	0,87
22	3	30,41	0,64	2	2,30	0,99	0,99	0,15	96,96	1,75
23	C	0,00	0,00	0	0,00	0,99	0,99	0,22	0,00	0

Fonte: Adaptado de Carvalho (2020)

Methods in R, de Kassambara (2017), que apresenta como método alternativo para determinar o número de CP.

O gráfico *Scree Plot*, que é o gráfico de autovalores (também chamados de valores próprios) ordenados do maior para o menor, onde número de componentes é determinado no ponto além do qual os autovalores restantes são todos relativamente pequenos e de tamanho comparável. Dessa forma, utilizando a função `fviz_eig()` do software R pode-se plotar o *Screeplot* das principais variáveis morfológicas.

A função `PCA()` do pacote (Lê et al., 2008) foi utilizada para extrair resultados relativos as variáveis de saída do PCA. Tal função apresenta uma lista de matrizes contendo todos os resultados para as variáveis ativas: coordenadas, correlação entre variáveis e eixos, cosseno quadrado e contribuições. Com tais dados pode-se obter o gráfico de matriz de correlação entre as variáveis e as dimensões de trabalho. A qualidade de representação também chamada `cos2` (cosseno quadrado, coordenadas quadradas). Com o comando `cos2` pode-se obter os gráficos de intensidade de contribuição de cada variável para cada dimensão de estudo. Por fim, com as mesmas variáveis pode-se obter um *biplot* do universo de estudo, com as variáveis e seus pontos no espaço (Battisti & Smolski, 2020; Kassambara, 2017).

2.6 Modelo de Regressão Linear Múltipla

Para o modelo de RLM utilizou-se das CPs e da hipótese de que os aspectos de morfologia urbana influenciam diretamente no comportamento da temperatura. Dessa forma, gerou-se uma tabela com as CP de cada sensor e as temperaturas máximas, mínimas e máximas de cada uma das estações do ano (inverno, primavera, verão e outono), a mesma foi importada para o *software* R onde utilizou-se da Equação Geral 2.15 para então encontrar a regressão linear relativa a cada estação do ano, onde X_k , são as variáveis preditoras de cada uma das CP (i) em cada ponto, β_k são seus respectivos coeficientes de inclinação e Y_i é a intensidade (máxima, média ou mínima) da temperatura em cada estação, ou seja, as variáveis de resposta que se quer estudar. Os modelos foram obtidos seguindo as metodologias e as orientações de três principais trabalhos (Battisti & Smolski, 2019; Kassambara, 2018; Weisberg, 2005).

$$Y_i = \beta_{0_i} + \beta_{1_i}X_{1_i} + \beta_{2_i}X_{2_i} + \cdots + \beta_{K_i}X_{K_i} + \epsilon_i \quad (2.15)$$

onde:

Y_i = variável de resposta

$i = 1, 2, \dots, n$, número de observações

X_{k_i} = variáveis explicativas

β_{k_i} = parâmetros do modelo

$k = 1, 2, \dots, K$, número de variáveis

ϵ_i = erro aleatório.

A partir da equação geral foi adaptada então para a equação 2.16 que apresenta a sintaxe de regressão múltipla com a seis variáveis preditivas no software R onde os valores de X_k foram atribuídos às CP na ordem : IV, FVC (Fotos), IC, OT, HL e NMP.

$$\text{regressao} = \text{lm}(y \sim x_1 + x_2 + x_3 + x_4 + x_5 + x_6) \quad (2.16)$$

2.6.1 Interação entre variáveis preditoras

Nessa altura, os coeficientes, os erros e os níveis de significância foram obtidos com a função `summary()` do R Core Team (2020), onde deve-se utilizar-se de seus valores para avaliar e interpretar o comportamento de cada modelo, assim como apresentado na sintaxe a baixo (Figura 2.10), onde a coluna *Estimate* apresenta o coeficiente de cada componente, na sequencia apresentam-se seus respectivos erros e por fim os valores para $Pr(> |t|)$.

A partir dos dados obtidos com a função `summary()` pode-se então montar uma tabela com as RLM obtidas com todos os coeficientes estimados, relacionado ao ρ -value geral de cada equação.

Teste de hipótese aos parâmetros do modelo

Uma hipótese nula geralmente afirma que não existe relação entre dois fenômenos. O teste de Teste de Hipótese Nula ou *Null-Test* é uma hipótese que é apresentada sobre determinados fatos estatísticos e cuja falsidade se tenta provar através de um adequado teste de hipóteses. No caso da regressão linear múltipla, tal como acontece na regressão linear simples, a hipótese nula é de que os parâmetros do modelo de regressão, β_{k_i} são nulos. O objetivo do teste de hipótese aos parâmetros será o de rejeitar a hipótese nula.

```

> summary(lm5)

Call:
lm(formula = MedP ~ IV + SVF + IC + OT + HL + NMP, data = Principais_Estacoes)

Residuals:
    Min       1Q   Median       3Q      Max
-0.36388 -0.11796 -0.02031  0.08917  0.40766

Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept) 13.595025   0.207567  65.497 < 2e-16 ***
IV           0.151784   0.131095   1.158 0.266313
SVF          -0.762715   0.219998  -3.467 0.003775 **
IC           -1.437552   0.334652  -4.296 0.000740 ***
OT            0.032831   0.007372   4.453 0.000546 ***
HL            0.497571   0.166218   2.993 0.009676 **
NMP           0.175732   0.034901   5.035 0.000182 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.2241 on 14 degrees of freedom
Multiple R-squared:  0.8616,    Adjusted R-squared:  0.8024
F-statistic: 14.53 on 6 and 14 DF,  p-value: 2.699e-05

```

Figura 2.10: Exemplo de resultado da função `summary()` para as RLM

Probabilidade condicional ρ -value

O ρ -value representa a probabilidade condicional de um valor observado como extremo ou mais extremo no valor de F, aqui tão grande ou maior, do que o valor observado, dado que a hipótese nula seja verdade. Neste contexto, um pequeno valor de ρ fornece evidências contra o teste de hipótese nula. Tradicionalmente utiliza-se em algumas áreas da pesquisa valores ρ significado fixo para analisar ρ -value em estudos aplicados (Weisberg, 2005). Costuma-se adotar um nível de significância fixo de α , ao nível em que é possível dizer que um teste nulo é rejeitado se o valor $\rho < \alpha$. Neste trabalho considerou-se $\alpha = 0,05$.

2.6.2 Métodos seleção de variáveis na regressão múltipla

Para a determinação de modelos simplificados com representatividade semelhante utilizou-se dos métodos `stepwise`, `backward` e `forward` testando cada modelo a partir da sintaxe `regressao=step(lm(y ~ x1+x2+x3), direction = "método"), ostrêsmétodostestamapermanênciadevariáveis`

2.6.3 Comparação dos modelos de Regressão Linear

Yan e Su (2009) afirma que em uma RLM deve-se atender aos seguintes requisitos: apresentar uma distribuição normal, linearidade, independências de autocorrelação, homogeneidade e multicolinearidade. Neste contexto plotou-se os gráficos de distribuição dos resíduos, normalidade dos resíduos e a detecção de valores alavanca e significativos para avaliação dos novos modelos.

Ao final com os modelos iniciais escolhidos e suas respectivas simplificações, necessitava-se de comparações para avaliar qual deles seria o mais explicativo com o mínimo possível de variáveis sem perder consideravelmente o potencial de explicação do comportamento que as componentes morfológicas tem no Curb, mas especificamente na temperatura urbana. Senso assim, realizou-se o teste de análise de variância, ou anova() para comparar se as médias entre os grupos é diferente.

Análise de Variância ou Teste de Comparações Múltiplas

O teste de análise de variância ou anova() usa o teste F para testar estatisticamente a igualdade entre médias. Onde a variância das amostras são decompostas em Variabilidade Total (VT), Variabilidade Explicada (VE) e Variabilidade Não Explicada (VNE) dentro da regressão pela equação 2.17, explicada na Tabela 2.5. Onde p são as constantes e n as observações.

$$VT = VE + VNE \quad (2.17)$$

Tabela 2.5: Tabela ANOVA para o modelo de RLM

Fonte de Variação	Soma dos quadrados	Graus de Liberdade
Regressão (VE)	$VE = \sum_{i=1}^n (\hat{y}_i - \bar{y}_i)^2$	p
Residual (VNE)	$VE = \sum_{i=1}^n (y_i - \hat{y})^2$	$n - (p + 1)$
Total (VT)	$VT = \sum_{i=1}^n (y_i - \bar{y})^2$	$n - 1$

O Coeficiente de Determinação (CD) (R^2) é definido como a proporção de variabilidade da variável dependente que é explicada pela regressão Equação 2.18.

$$R^2 = \frac{VE}{VT} = 1 - \frac{VNE}{VT} \quad (2.18)$$

O CD tem a desvantagem de aumentar sempre que aumenta o número de variáveis da regressão (às vezes artificialmente). Por este motivo, e para penalizar o número de variáveis regressivas que estão incluídas no modelo de regressão, é conveniente usar o Coeficiente de Determinação Ajustado (CDA) pelo número de graus de liberdade (Equação 2.19).

$$R^2_{ajustado} = 1 - \frac{VNE/(n - (p - 1))}{VT/(n - 1)} \quad (2.19)$$

Dessa forma, supondo que o modelo de RLM seja válido, é de interesse determinar quais variáveis X_j (índices de morfologia urbana) são significativas para explicar o variável de resposta Y (temperatura). O teste anova permite por meio de uma tabela contrastar a influência individual da variável X_j analisando o aumento que ocorre na soma dos quadrados explicado por o modelo, introduzindo a variável regressora X_j .

Dessa forma, as regressões completas e as suas simplificações foram comparadas para avaliar se mantinha-se o nível de explicação nas novas equações.

Os modelos de regressão obtidos puderam, através de simplificações climáticas, expressar o impacto das variável morfológica na temperatura, consequentemente explicar matematicamente a intensidades dos EICU e EIFU que ocorre nos centros urbanos graças as características urbanas.

2.7 Análise de *clusters*

A AC foi obtida através de três conjuntos de dados (temperaturas (2016 - 2019), intensidades de EICU (2016 - 2019) e índices de morfologia urbana), para os dados de temperatura gerou-se para análise quatro novos conjuntos de dados (médias horárias, mínimas, médias e máximas diárias) e para a intensidade de EICU gerou-se dois conjuntos de dados (máximas e mínimas diárias) (Figura 2.11).

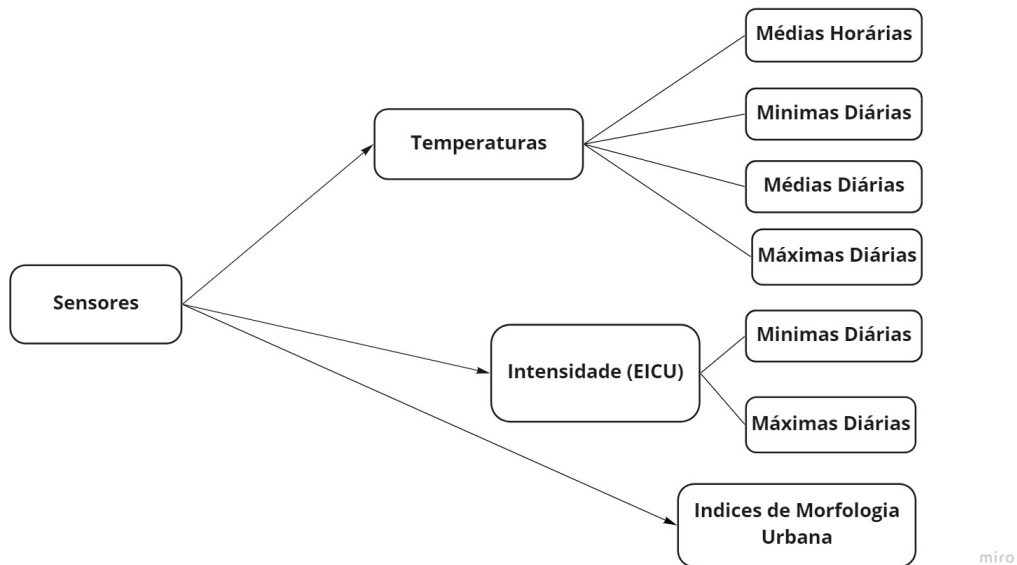


Figura 2.11: Conjuntos de dados utilizados para a obtenção dos *clusters*

2.7.1 Número ótimo de *clusters*

Para todas os conjuntos de dados gerados realizou-se os testes Wss (Within Sum of Square - Soma dos quadrados) e Silhueta (Average silhouette width - Largura média da silhueta) para a indicação das quantidades ótimas de grupos onde identificou-se a quantidade de *clusters* ($k = 1, 2, 3, \dots, K$). Importante ressaltar que o método WSS é mais indicado para avaliar o número ótimo de *clusters* do método K-means, ao passo que os métodos Silhueta e GAP são mais indicados para modelos de clusterização hierárquicos como o método de Ward 's (Kassambara, 2017).

Para as variáveis morfológicas realizou-se o escalonamento com a função $()scale$, porque os índices não têm as mesmas intensidades e seus valores absolutos poderiam interferir no agrupamento, esse procedimento não foi necessário para os dados de temperatura e intensidade de ICU, pois não tem alteração no tipo de variável.

Soma dos quadrados (WSS)

Como o método K-means calcula a distancia das observações até o centro do agrupamento de pertencimento, sendo essa distancia a menor possível, neste contexto, procura-se uma quantidade de agrupamentos em que a soma dos quadrados (Equação 2.20) seja a

menor, assim quanto foi viável. Para detectar o agrupamento com o ótimo número de grupos (k) do conjunto de soluções K , normalmente é utilizado um *Scree plot* para que seja realizada a análise de torção na curva gerada a partir da soma dos quadrados (WSS) (Equação 2.20) ou seu logaritmo ($\log(WSS)$) para todas as soluções de *clusters* (Makles, 2012), neste gráfico o ponto que indica o equilíbrio de maior homogeneidade dentro do *cluster* é a maior diferença entre *clusters*, visualmente é o ponto em que forma-se um "cotovelo" na curva.

$$W = \sum_a (x_0 - \bar{x})^2 \quad (2.20)$$

O comando para a criação de tal gráfico foi o `fviz_nbclust(df, FUNcluster = "WSS")`, o mesmo foi utilizado em todas as séries de dados que seriam agrupados para que a escolha da quantidade de *clusters* fosse justificada.

Largura média da silhueta (Silhueta)

O gráfico da Largura Média das Silhuetas que foi sugerido por Rousseeuw e Kaufman (1990) e implementado no programa (R Core Team, 2020), se baseia na matriz de similaridade, avaliando a coesão dos *clusters* através da proximidade de um ponto a outro de um mesmo *cluster* C_i onde pertence e a proximidade do mesmo ponto aos pontos do *cluster* mais próximo C_j . Este coeficiente varia entre $(-1, 1)$, onde o valor 1 significa que o ponto x_i está mais próximo dos pontos do seu *clusters* do que dos pontos do *clusters* mais próximo e -1 representa o contrário nunes2016breve. Desta forma o gráfico da silhueta é uma forma de avaliar a qualidade de uma solução de *cluster*, permitindo identificar objetos classificados mal e, assim, distinguir *clusters* bem definidos, de forma a otimizar a qualidade da solução de *cluster* everitt2011cluster.

Da mesma forma, o comando para a criação de tal gráfico foi o `fviz_nbclust(df, FUNcluster = "silhouette")`, o mesmo foi utilizado em todas as séries de dados que seriam agrupados para que a escolha da quantidade de *clusters* fosse justificada.

2.7.2 Métodos de Clusterização

Para o processo de clusterização utilizou-se do *software* estatístico R Core Team (2020) e dos pacotes FunCluster, factoextra (Henegar, 2012; Kassambara & Mundt, 2020), tanto para o método de K-means como para o método de Ward's utilizou-se a distancia Euclidiana foi utilizada como a distancia padrão da *clusterização*, assim, plotou-se o agrupamento para o método K-means e a arvore de agrupamentos (dendograma) para o método de Ward's para todos os conjuntos de dados.

com os mesmos métodos de clusterização (Ward's e Kmeans) também realizou-se um estudo de caso temporal, com os dados de média horária de temperatura, para tentar analisar a dinâmica do agrupamento ao longo dos anos de estudo e ao final gerar uma probabilidade de agrupamento de um ponto ser classificado dentro de um grupo ao longo dos anos em um modo geral e por cada método.

Nesse caso, os dados de médias horárias de temperatura foram separados por anos, e os *clusters* foram gerados para os métodos de Ward's e Kmeans para todos os anos, podendo observar a dinâmica dos *clusters* ao longo dos anos e também gerar uma probabilidade de pertencimento de cada ponto a um grupo.

Obteve-se assim os gráficos com 2 e 5 grupos para os métodos de Ward's e Kmeans, todos os resultados obtidos foram compilados em uma planilha separando os agrupamentos obtidos com $k = 2$ e $k = 5$, onde os indivíduos que foram agrupados juntos em cada modelo foram enumerados com o número do *cluster* que ficou. Para as séries com dois grupos analisou-se cada modelo para avaliar onde os sensores mais urbanos (3, 7 e 13) tinha ficado e o número 2 foi atribuído aos indivíduos, o grupo onde os sensores mais não urbanos ficaram foi enumerado como 1. Para os agrupamentos com 5 grupos atribuiu-se valores de 1 a 5 para os grupos sendo 1 o grupo com os sensores mais não urbanos e 5 os sensores mais totalmente urbano, os outro números (2, 3 e 4) foi distribuído de modo a atender o gradiente de urbanização de acordo com o conhecimento das características dos arredores de cada sensor. Essa classificação em alguns modelos foi um pouco difícil de definir. Com as planilhas pode-se por fim montar os mapas de com os agrupamentos no programa QGIS Development Team (2020).

Capítulo 3

Resultados e Discussões

3.1 Intensidade dos Efeitos de Ilha de Calor e Frio

Nas análises iniciais pretendeu-se avaliar a intensidade dos EICU e EIFU nas localidades dos sensores onde com os dados de temperatura em cada ponto pode-se obter os valores para ΔT , que representa a diferença entre a temperatura nos pontos centrais da cidade em relação a média dos pontos da envolvente (20 e 23), resultado que expressa a intensidade dos efeitos de EICU e EIFU. Para investigar melhor quais são as intensidades de tais efeitos nas localidades de cada sensor, obteve-se as máximas e as mínimas diárias (Figura 3.1), onde pode-se observar que o EICU tem impacto em todos as localidades dos sensores, tendo maior intensidade máxima nos sensores: 3, 7, 13, 17, 18 e 19, onde essa diferença pode atingir extremos maiores que 10 graus. Na Figura 3.1 b) pode-se observar as intensidades mínimas diárias, onde é possível de identificar as caixas deslocadas para os valores negativos do eixo Y, resultados que expressam que todos os sensores também apresentam o efeito de EIFU, onde as diferenças de temperatura da cidade em relação a sua envolvente são negativas, podendo chegar a -12°C de diferença, os sensores 2, 3, 4, 11, 13 e 17 apresentam os menores valores.

Em termos da média, os pontos apresentaram de $-0,006^{\circ}\text{C}$ (ponto 15) a $+1,28^{\circ}\text{C}$ (ponto 13) de intensidade do EICU no período estudado (2016 - 2019), este resultado pode ser comparado com o obtido por Alves (2017) onde as médias diárias obtidas no estudo variaram de $0,1$ a $1,2^{\circ}\text{C}$ para a intensidade média do EICU ao longo do dias, em Iporá,

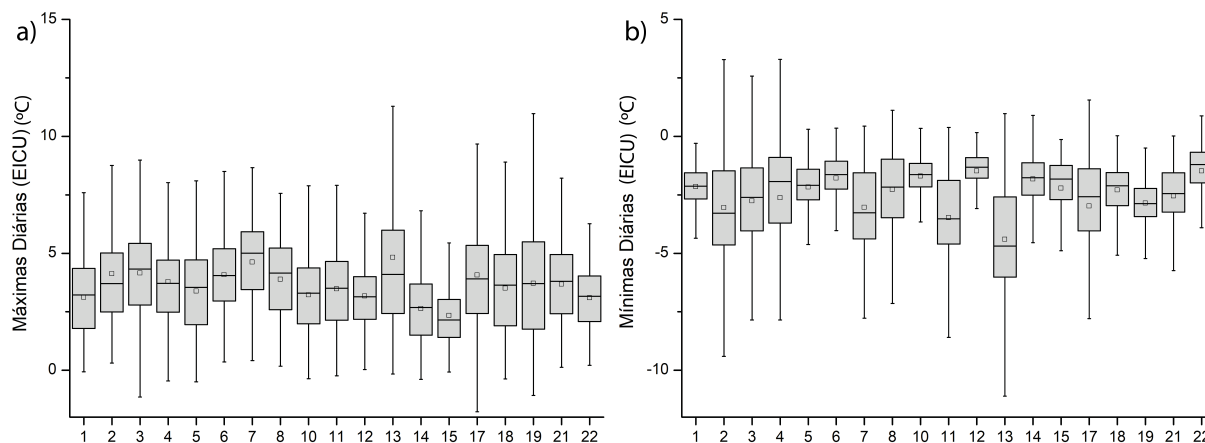


Figura 3.1: Máxima e Mínima Intensidade de EICU

Goiás (Brasil), cidade com tamanho semelhante a Bragança, aproximadamente 32 mil habitantes. Analisando as Figuras 3.1 a) e b) foi possível observar que os extremos podem atingir a diferenças superiores a $+12^{\circ}\text{C}$ e mínimas inferiores que -12°C em ocasiões isoladas e que as intensidades máximas têm maiores variabilidade e intensidades para todos os sensores, resultado indicado pelas caixas com maior dimensão e as abas mais alongadas.

Neste mesmo contexto, com as médias horárias da intensidade do EICU pode-se plotar o gráfico da intensidade do efeito de EICU em relação as horas do dia e aos meses do ano (Figura 3.2), onde os efeitos EICU e EIFU de cada ponto urbano puderam ser apresentados individualmente, expondo seu comportamento. Também foi plotado um gráfico para a média das intensidades de todos os pontos urbanos com o intuito de ter um ponto de comparação, ressalva-se que os pontos urbanos 9 e 16 foram excluídos do trabalho por apresentarem uma percentagem elevada de dados omissos.

Muller et al. (2013) afirma que para uma adequada monitorização meteorológica de modo a representar a variabilidade espacial e temporal do clima em cidades ou regiões inteiras, visando fornecer os detalhes suficientes para a pesquisa do clima urbano e aplicações de tomada de decisão. Neste contexto, analisando os resultados de todos os sensores em relação ao das médias é possível confirmar que valores únicos de temperatura para uma cidade omitem individualidades climáticas de pontos específicos, onde aspectos microclimáticos influenciam para que o clima no ponto seja diferenciado,

como por exemplo os pontos 7, 8 e 13 que apresentam EICU e EIFU muito mais intensos que o gráfico da média, com as cores vermelha e azul mais intensas.

A análise apresentada na figura 3.2 já foi realizada para a cidade de Bragança - Portugal, considerando médias das ZCL (Gonçalves et al., 2018; Menezes, 2017), nestes estudos as intensidade médias para as horas do dia foram de 3 a 4°C para o EICU. No presente estudo, para a mesma cidade pode-se encontrar diferenças médias horárias de até +3,084°C para o EICU e até -3.092°C para o efeito de EIFU, ambos os extremos foram encontrados no sensor 13 um dos localizados na região mais urbanizada da cidade. Na Figura 3.2 também pode-se observar que o EICU expressa-se em maior intensidade nos meses de verão (Julho, Agosto e Setembro) e durante a noite, quando as superfícies levam mais tempo para se resfriar do que as áreas rurais dos arredores, os mesmos meses mas durante o dia, o EIFU ocorre em maior intensidade, quando as superfícies levam mais tempo para aquecer devido ao diferente aquecimento que as superfícies e materiais apresentam. Menezes (2017) relaciona tal padrão pela característica da cidade de apresentar estabilidades atmosféricas nos meses de verão, facto que favorece o surgimento dos EICU e EIFU. Contrário a isso, os meses entre outubro e fevereiro que compreendem o outono e o inverno apresentam as maiores pluviosidades, fenômeno que ameniza as intensidades do EICU, momento em que o clima de ampla escala (sinóptico) prevalece em relação aos efeitos de escala micro e local, onde as individualidades dos sensores são menores. Como previsto por Landsberg (1981) os climas de ampla escala prevalecem em condições de vento forte nebulosidade e grande precipitação, ao passo que os climas de microclima e de escala local prevalecem em condições anti-sinópticas de céu limpo e ventos fracos.

Segundo (Oke, 2002) os picos geralmente do EICU ocorrem de três a cinco horas após o pôr do sol, mas às vezes atrasam. O momento do pico depende das propriedades dos materiais urbanos, onde madeira e solo seco tendem a liberar o calor mais rapidamente, ao passo que o concreto em si libera mais lentamente, atrasando os horários da intensidade do efeitos (Gartland, 2008). Analisando essa questão, os pontos 2, 3, 4, 7, 8, 13 e 21, que estão localizados na região mais densamente urbanizada da cidade, localidade que apresenta mais concretos em seus materiais, apresentam os picos em horários atrasados, podendo chegar até pouco antes do amanhecer, entre as 5 e 6 da manhã.

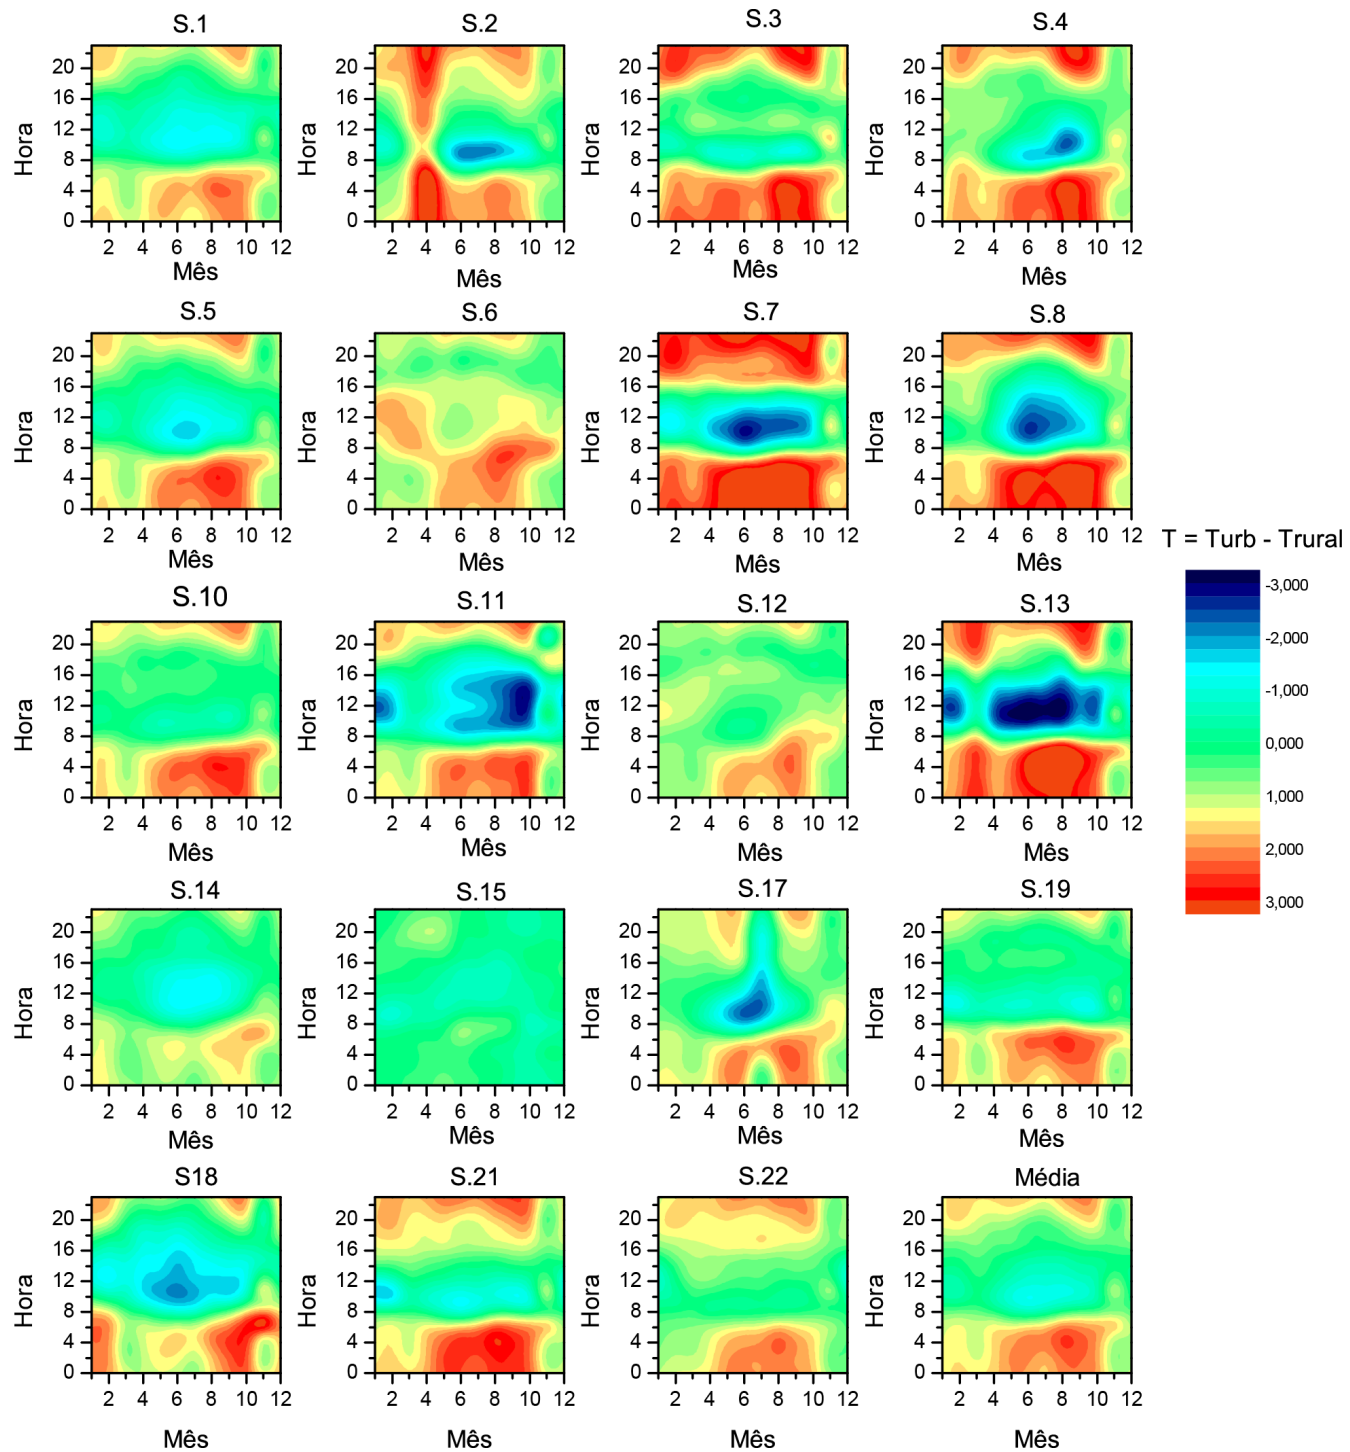


Figura 3.2: Intensidade de Ilha de Calor nos Pontos

3.2 Análise de Componentes Principais

Segundo Hyvärinen (2015) o método de ACP é uma ferramenta que fornece uma redução de dimensão para variáveis explicativas baseando-se em análises lineares de dados multivariados. Compreendendo que cada sensor apresenta intensidades diferenciadas do EICU e EIFU, pretendeu-se com a ACP dos índices de morfologia urbana, compreender quais são os indicadores mais explicativos do CUrb para posteriormente desenvolver uma equação explicativa do clima com as CP. Os índices analisados foram: OT, IC, NMP, IV, FVC - SIG, FVC - Fotos, AM, PI e HL.

Primeiramente na ACP obteve-se o *Scree plot* (Figura 3.3) o qual apresenta a percentagem de representação variável das componentes em relação as componentes que estão numeradas de 1 a 9 na ordem: OT, IC, NMP, IV, FVC - SIG, FVC - Fotos, AM, PI e HL. É possível identificar que as duas primeiras expressam mais de 75% da morfologia urbana, mas que são necessários mais de quatro variáveis para ter mais de 90% dos aspectos de morfologia urbana sejam explicados.




Figura 3.3: ACP das variáveis de morfologia urbana

Na Figura 3.4 a contribuição variável é explicada, onde as linhas vermelhas tracejadas representam a contribuição média desejada, ou seja, se a contribuição das variáveis

fosse uniforme, o valor esperado seria igual a $1 / \text{comprimento}$ (variáveis) onde uma variável com contribuição maior do que o corte pode ser considerada importante para a componente. Dentro das dimensões de estudo, as variáveis (índices de morfologia urbana) e os indivíduos (os sensores) realizam as suas contribuições percentuais, ao analisar as três primeiras dimensões pode-se inferir que as variáveis mais importantes para o modelo são: IV, FVC - Fotos IC, OT, HL e o NMP, e que os sensores mais importantes são os: 7, 3, 21, 8, 2, 10 e 17, considerando os índices de morfologia urbana.




Figura 3.4: Contribuição das variáveis e sensores

A Figura 3.5 apresenta o gráfico de intensidade de contribuição das variáveis e dos sensores, onde os fatores são chamados \cos^2 (cosseno quadrado, coordenadas quadradas), tal indicador é utilizado para indicar a qualidade de representação. Onde um \cos^2 alto indica uma boa representação da variável na componente principal, neste caso, quanto mais próxima uma variável estiver do círculo de correlações ou quanto mais vermelho for o sensor, melhor será sua representação no mapa de fatores (e mais importante será a interpretação desses componentes) (Kassambara, 2017). Já as variáveis que estão fechadas no centro do gráfico, ou os sensores com cores mais frias, são componentes menos importantes ou representativas.




Figura 3.5: Gráfico de correlação variável (cos2)

Com a Figura 3.6 pode-se destacar quais variáveis contribuem mais em cada dimensão, onde é possível identificar que na primeira dimensão os índices HL, IV, IC e OT são as mais representativas e para a segunda dimensão apenas o FVC apresenta uma contribuição forte para o modelo.

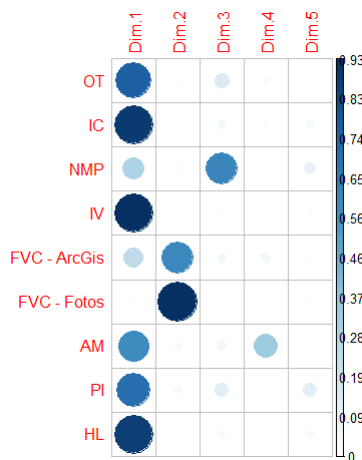


Figura 3.6: Contribuição dimensional

Para finalizar a ACP, realizou-se a matriz gráfica com as correlações das variáveis (Figura 3.7), onde pode-se avaliar quais dos índices morfológicos estão mais correlacionados, sabendo que quando duas variáveis apresentam valores entre $0.7e0.89$ é classificada como fortemente correlacionadas e que variáveis com correlações entre $0.9e1$ são variáveis com correlação classificada como muito forte, inversamente a isso, variáveis com

valores negativos de correlação indicam uma relação inversamente proporcional. Dessa forma, foi possível identificar que as variáveis IV e IC apresentam uma correlação muito forte e que as variáveis IC - HL, IV - HL apresentam correlação forte, tal resultado era de se esperar pois as formulas a partir das quais esses índices foram obtidos variam apenas um parâmetro ou outro, e todos os parâmetros estão relacionados às construções do terreno.

Em seu trabalho Carvalho (2020) identifica que os índices OT, IC, IV, NMP, NMP, PI e HL apresentaram as maiores correlações com a intensidade do EICU, mas que essa correlação muda ao longo das estações do ano. Tendo isso em mente, junto as análises apresentadas na presente secção pode-se definir que as componentes principais para o modelo de regressão linear que será realizado a seguir são as variáveis IV, FVC - Fotos, IC, OT e NMP, as seis variáveis expressam cerca de 98% dos aspectos da morfologia urbana, valor muito mais alto do que os 84,5% obtidos para variáveis explicativas no trabalho de Bottyán e Unger (2003) para o desenvolvimento dos modelos de regressão explicativas da EICU da cidade de Szeged (Hungria). Dessa forma é possível que nas seis CP existe uma expressão muito significativa nos aspectos de morfologia para o desenvolvimento dos modelos de RLM, no entanto, espera-se que para o modelo simplificado algumas dessas sejam excluídas pois existem correlações altas entre as mesmas e no modelo simplificado pretende-se utilizar uma quantidade mínima de indicadores explicativos.

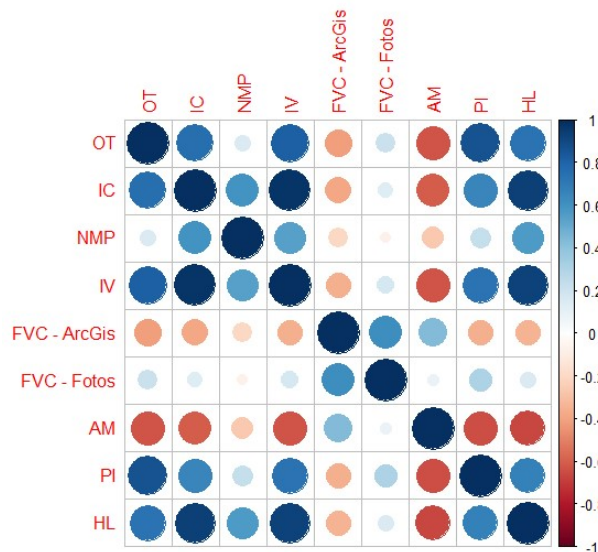


Figura 3.7: Intensidade de contribuição de cada variável

3.3 Modelo de Regressão Linear Múltipla

Com as CP dos índices de morfologia urbana obtidos, objetivou-se desenvolver modelos de RLM explicativos da relação entre os índices (variáveis independentes) e as temperaturas (variáveis dependentes) máximas, médias e mínimas de cada estação do ano (inverno, primavera, verão e outono) no modelo da Equação 2.16 apresentada por Weisberg (2005). Similar ao trabalho atual, Salvati et al. (2019) utilizou três índices de morfologia urbana e as intensidades do EICU para desenvolver seus modelos de RLM.

Como Salvati et al. (2019) ressalva, uma das implicações mais relevantes da análise de RLM é o facto de identificar que a relação entre a morfologia urbana e a intensidade do EICU varia ao longo do ano, este trabalho corrobora a ideia da utilização das equações obtidas para a identificação da variação ocorridas nas temperaturas. A Tabela 3.1 apresenta as doze equações encontradas e seus respectivos testes *p-value*, onde quanto mais próximo de zero o valor de *p*, maiores são as evidências contra o teste de hipótese nula. Neste contexto as melhores regressões obtidas foram com as temperaturas médias do verão e da primavera. Estes resultados podem ser explicados pelo facto de que nestas estações do ano existem menores interferências climáticas

Tabela 3.1: Modelos de Regressão Linear Múltipla

Regressão	<i>p - value</i>
Inverno	
$Y_{Min} = 0,163X_1 - 2,533X_2 - 1,439X_3 - 0,005X_4 + 1,858X_5 - 0,291X_6 - 6,099$	0,2756
$Y_{Med} = 0,065X_1 - 0,389X_2 + 0,001X_3 + 0,011X_4 - 0,043X_5 + 0,043X_6 + 6,060$	0,0878
$Y_{Max} = 0,837X_1 - 1,772X_2 - 3,802X_3 + 0,118X_4 - 0,594X_5 + 0,709X_6 + 25,154$	0,0240
Primavera	
$Y_{Min} = -0,249X_1 - 1,033X_2 + 2,837X_3 - 0,010X_4 - 0,126X_5 - 0,413X_6 - 3,019$	0,0334
$Y_{Med} = 0,152X_1 - 0,763X_2 - 1,438X_3 + 0,033X_4 + 0,498X_5 + 0,176X_6 + 13,595$	0,0001
$Y_{Max} = -0,832X_1 + 2,546X_2 + 1,064X_3 + 0,118X_4 - 0,264X_5 + 0,337X_6 + 35,633$	0,0170
Verão	
$Y_{Min} = -1,940X_1 - 0,640X_2 + 2,790X_3 + 0,089X_4 + 0,632X_5 + 0,062X_6 + 2,603$	0,5032
$Y_{Med} = 0,108X_1 - 0,295X_2 - 0,885X_3 + 0,029X_4 + 0,414X_5 + 0,088X_6 + 21,377$	0,0014
$Y_{Max} = 0,377X_1 + 1,786X_2 - 0,588X_3 + 0,063X_4 - 0,796X_5 + 0,132X_6 + 37,255$	0,0305
Outono	
$Y_{Min} = 0,227X_1 - 1,304X_2 + 0,390X_3 - 0,018X_4 + 1,065X_5 - 0,863X_6 - 3,860$	0,1978
$Y_{Med} = 0,133X_1 - 0,462X_2 - 0,459X_3 + 0,013X_4 + 0,181X_5 + 0,029X_6 + 10,389$	0,1158
$Y_{Max} = 0,756X_1 + 0,575X_2 - 2,144X_3 + 0,096X_4 - 0,724X_5 + 0,252X_6 + 30,653$	0,1185

1

como a pluviosidade e o ventos fortes, ao mesmo tempo que estes meses apresentam temperaturas elevadas que favorecem o EICU.

As regressões multilíneas devem atender algumas suposições para as suas validações (distribuição normal, linearidade, independência de autocorrelação, homogeneidade e multicolinearidade), os testes de valores significativos, distribuição e normalidade dos resíduos foram realizados com as doze equações e comprovaram as observações realizadas com os dados de *p-value* para os testes de hipótese nula, onde as distribuições dos indivíduos apresentaram-se inadequadas na maioria das equações, como foram escolhidas seis componentes principais, algumas delas ainda estavam com correlações altas, as reduções das equações são necessárias para deixar melhor explicativas possíveis com o mínimos de variáveis.

Seguiu-se assim, apenas com as equações $Y_{T(med)}$ da Primavera e do Verão, as quais foram melhoradas, retirando os componentes principais que apresentaram valores muito altos para os testes *p-value* individuais (IV para as duas equações e FVC para o verão). Obtendo assim as novas regressões (Equações 3.1 e 3.2), as quais apresentaram valores para o *p-value* <0,05 para as a primavera e o verão respectivamente, com

todas as variáveis individuais com $p\text{-value} < 7.2\%$ que foi o melhor resultado obtido para a equação do verão, por mais que indique-se deixar apenas variáveis com $p\text{-value} < 5\%$ (Weisberg, 2005).

$$Y = -0.725X_{(FVC)} - 1.144X_{(IC)} + 0.037X_{(OT)} + 0.519X_{(HL)} + 0.182X_{(NMP)} + 13.558 \quad (3.1)$$

$$Y = -0.671X_{(IC)} + 0.031X_{(OT)} + 0.413X_{(HL)} + 0.098X_{(NMP)} + 21.154 \quad (3.2)$$

A Tabela 3.2 apresenta um resumo dos resultados dos testes aos parâmetros dos dois modelos de regressão simplificados. Nesta tabela é possível de observar os valores do erro padrão, os graus de liberdade, o R^2 , o R^2 ajustados, a significância do teste F e o p-value, bem abaixo do valor crítico 0,05. Com estes resultados, podemos concluir que as equações simplificadas são estatisticamente válidas.

Tabela 3.2: Parâmetros das Equações Simplificadas

	Primavera	Verão
Erro padrão	0,2267	0,2958
graus de liberdade	15	16
R^2	0,8484	0,7255
R^2 ajustado	0,7979	0,6568
Significância F	16,79 (5 de 15)	10,57 (4 de 16)
p-Value	0,00001	0,00021

A Figura 3.8 apresenta as correlações das variáveis utilizadas para as novas regressões da primavera e as temperaturas médias do verão e da primavera, onde pode-se identificar que as correlações dos índices de morfologia com as temperaturas estão abaixo de 0,6.

A Figura 3.9 a apresenta os gráficos de distribuição dos resíduos para as equações da primavera (a) e do verão (b)

No mesmo contexto, a Figura 3.10 apresenta os gráficos de normalidade dos resíduos

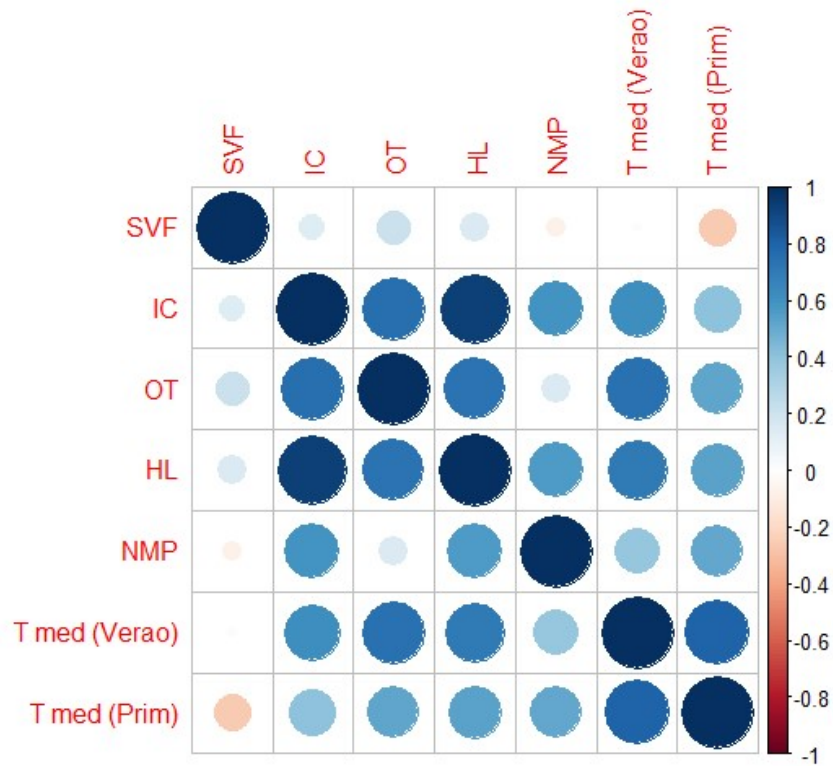


Figura 3.8: Novas matrizes de correlação




Figura 3.9: Teste de Distribuição dos Resíduos

para as equações da primavera (a) e do verão (b), onde os valores devem estar distribuídos de forma normal e linear, o mais próximos possível da linha tracejada (que representa as regressões) e os valores enumerados são denominados *outliers*, eles representam casos que apresentaram valores atípico, se diferenciando substancialmente da maioria dos dados. A figura a) apresenta distribuição correlacionada dos indivíduos, um

tanto não normais, já a Figura 3.10 b) apresenta uma distribuição melhor dos indivíduos, com melhores resultados quanto a independência, normalidade e homogeneidades visuais. Os *outliers* com desvios > 2 foram os sensores 2 e 5 para a equação 3.1 e o sensor 6 para a equação do 3.2.

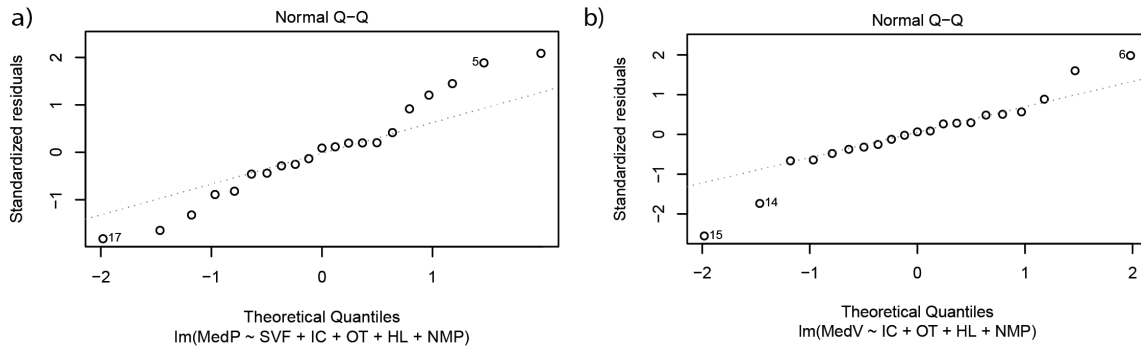


Figura 3.10: Teste Normalidade dos Resíduos

Por fim, realizou-se a comparação dos modelos através do teste anova() entre as equações iniciais (3.1) e as simplificadas (Equações 3.1 e 3.2) indica que não existem indícios para rejeitar a hipótese nula de igualdade de qualidade dos modelos Figura 3.11. Dessa forma, os modelos são semelhantes, portanto é devido escolher os modelos mais simples, pelo princípio da parcimônia.

```

> anova(lm5, lm51)
Analysis of Variance Table

Model 1: MedP ~ IV + SVF + IC + OT + HL + NMP
Model 2: MedP ~ SVF + IC + OT + HL + NMP
  Res.Df    RSS Df Sum of Sq    F Pr(>F)
1     14 0.70328
2     15 0.77062 -1 -0.067341 1.3405 0.2663
> anova(lm8, lm81)
Analysis of Variance Table

Model 1: MedV ~ IV + SVF + IC + OT + HL + NMP
Model 2: MedV ~ IC + OT + HL + NMP
  Res.Df    RSS Df Sum of Sq    F Pr(>F)
1     14 1.2897
2     16 1.4003 -2  -0.1106 0.6003 0.5622

```

Figura 3.11: Teste anova para a comparação dos modelos de RLM

Fonte: R Core Team (2020)

Dessa forma, pode-se concluir foi possível encontrar 12 RLM explicativas da relação entre as temperaturas e a morfologia urbana e duas RLM explicativas simplificadas para o comportamento da temperatura média na cidade de Bragança nas estações do verão e primavera, estações do ano em que o comportamento climático foi mais simples de prever. Corroborando a hipótese de que tal relação pode ser explicada matematicamente.

Os trabalhos realizados por Bottyán e Unger (2003) e László e Szegedi (2015) apresentam também bons resultados para a metodologia utilizada, mas tendo como variável dependente especificamente as intensidades de EICU, indica-se então uma nova abordagem que pode ser aplicada a cidade de Bragança, que pode utilizar os indicadores morfológicos especificamente para prever a intensidade de EICU e diferente do realizado com a temperatura das estações.

3.4 Análise de *clusters*

Com todas as séries de dados compiladas realizou-se a análise do número ótimo de *clusters* primeiramente pelo método WSS, neste método a melhor quantidade de *clusters* se dá no ponto em que a inclinação da curva apresenta um "cotovelo", ou seja, uma

alteração brusca de ângulo. O método de WSS foi inconclusivo para indicar a quantidade ótima de grupos em todas as séries de dados. A Figura 3.12 apresenta um exemplo de gráfico obtido para a análise WSS, com os dados de temperatura média horária.




Figura 3.12: Número ótimo de *clusters* - Wss

Na sequência os mesmos dados foram processados pelo método da "Silhueta", onde o ponto mais alto das curvas apresenta o número ótimo de clusters. Tal metodologia indicou a quantidade de dois *clusters* como a quantidade ótima de grupos para a maioria dos dados, exceto para os dados de médias diárias de temperatura, que o teste apresentou a necessidade de cinco *clusters* no ponto mais alto da curva (Figura 3.13). Com isso padronizou-se agrupamentos de 2 e 5 *clusters* para todas as séries de dados.




Figura 3.13: Número ótimo de clusters - Silhueta

Unal et al. (2003) ressalva que cada método de agrupamento tem seus pontos fortes

e que compreender o desempenho de cada um nas análises a que se quer realizar é fundamental para a obtenção de uma boa clusterização. Devido a isso, após uma longa pesquisa bibliográfica a respeito da clusterização de dados climáticos para a obtenção de agrupamento de zonas climáticas, observou-se que os métodos de Ward's e K-means são os mais utilizados, como nos trabalhos de Hidalgo e Jouglá (2018), Hidalgo et al. (2014), Iyigun et al. (2013), Rhee et al. (2008), Unal et al. (2003) e Yufeng Luo et al. (2010).

3.4.1 Método de Ward

Com o método de de Ward obteve-se os dendogramas com dois e cinco grupos (Figura 3.14) para todas as séries de dados. Estes agrupamentos foram organizados em tabela para posterior análise.

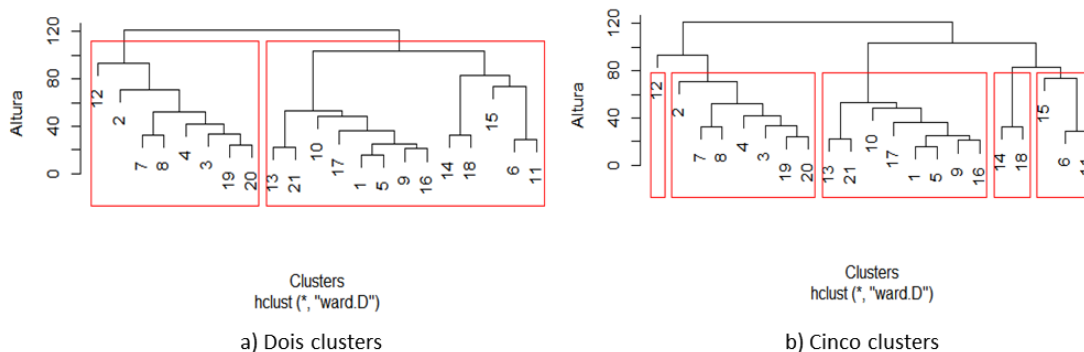


Figura 3.14: Exemplo de resultado para o Método de Ward's

A figura 3.15 apresenta o mapeamento geográfico realizado no QGIS Development Team (2020) plotando os agrupamentos dos sensores obtidos pelo método de Ward's ($k=2$), relacionando o arruamento da cidade e o seu limite administrativo. Onde pode-se observar que por mais que o agrupamento ótimo indicado pelos testes seja o de dois grupos, os modelos apresentaram certa confusão entre áreas urbanas e as não urbanas. Os melhores agrupamentos obtidos com o método de Ward's ($k = 2$) ficam os dados de temperaturas máximas e médias diárias, o agrupamento de médias horárias acabou por classificar inadequadamente um ponto rural principal. O agrupamento mais confuso

foi o obtido com os dados de Intensidade Máxima do EICU, ao qual foi atribuído a um grupo uma grande quantidade de sensores e o segundo ficou com apenas dois sensores que não tem nenhuma característica muito particular para justificar o agrupamento, no entanto, para este modelo os sensores 20 e 23 (principais rurais) não existiam para gerar um agrupamento mais adequado do rural, o que pode é uma limitação deste agrupamento.

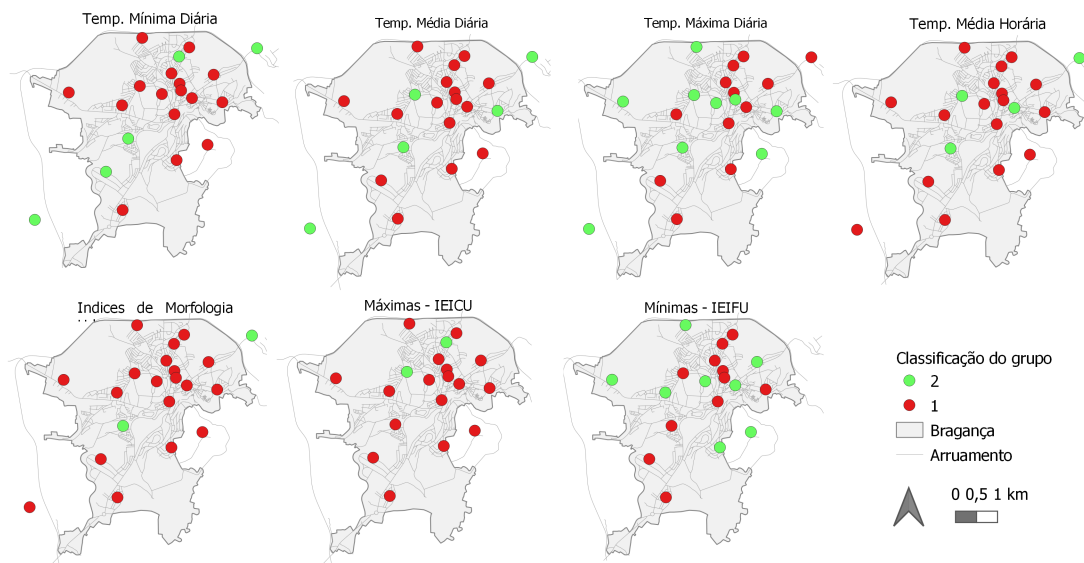


Figura 3.15: Agrupamentos obtidos com o método de Ward 's com $k=2$

Já a Figura 3.16 apresenta a distribuição dos *clusters* para o método de Ward 's com $K = 5$ para todas as séries de dados. Onde por vezes o agrupamento não é bom, pois apresenta indivíduos únicos pertencentes à grupos isolados. No entanto, com cinco grupos pode-se obter uma melhor distribuição de grupos para áreas com diferentes tipologias de construção, não apenas atendendo a grupos "urbanos" ou "não urbanos". O melhor agrupamento encontrado com este método foi o obtido com os índices de morfologia urbana seguindo pelo agrupamento dos dados de média diárias. Novamente o agrupamento mais confuso foi o agrupamento com os dados de EICU máximas.

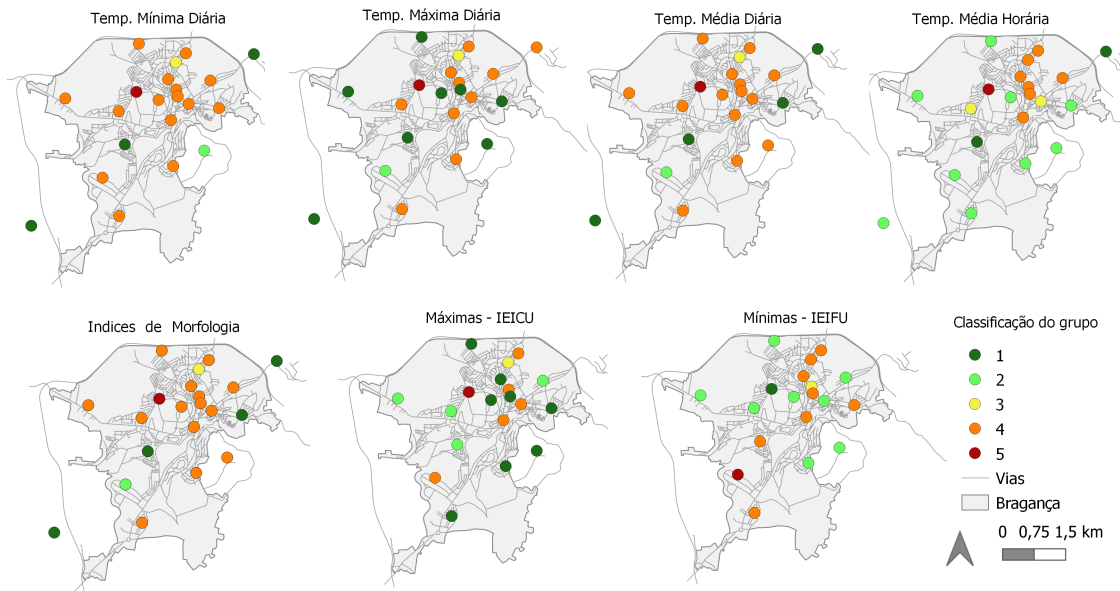


Figura 3.16: Agrupamentos obtidos com o método de Ward 's com $k=5$

3.4.2 Método K-means

Com o método K-means para a AC gerou-se agrupamentos semelhantes aos apresentados na Figura 3.17 que apresenta os agrupamentos obtidos para as médias horárias de temperaturas. Para o método K-means a função ggplot2, utilizada para gerar os agrupamentos no método apresentaram erros na compilação, caso que impossibilitou a obtenção dos modelos para três séries de dados, as máximas, médias e mínimas diárias das temperaturas. Com isso obteve-se apenas os modelos para as outras séries de dados (dados morfológicos, médias horárias das temperaturas, máximas e Mínimas de EICU), reforçando que as mínimas EICU se tratam de valores negativos o que consubstancia uma condição de EIFU).



Figura 3.17: Exemplo de resultado para o Método de K-means

Na Figura 3.18 pode-se então observar os agrupamentos obtidos com o método Kmeans para $k = 2$, onde novamente o agrupamento dos dados de máxima EICU foram os que se apresentaram confusos, quase todos os sensores ficaram em um grupo e apenas um sensor ficou agrupado no segundo grupo. Os agrupamentos obtidos com os índices de morfologia e com as médias horárias foram os melhores agrupamentos, distinguindo bem os sensores nos grupos 1 e 2, onde 1 pode ser classificado como "urbano" e 2 como "não urbano".

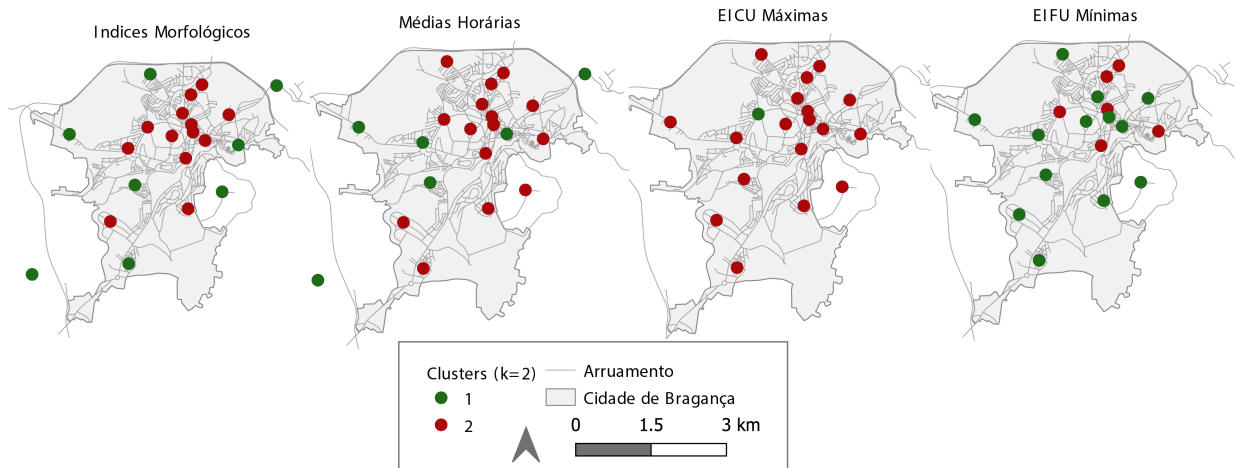


Figura 3.18: Agrupamentos obtidos com o método K-means ($k=2$)

Para $k=5$ obteve-se a figura 3.19, com a distribuição dos sensores em 5 grupos pelo método K-means. Novamente, a distribuição com cinco *clusters* apresentou-se não tão boa por apresentar indivíduos sozinhos em alguns grupos, no entanto essa

quantidade de grupos assumiu melhor a distribuição em ZCL, por apresentar melhor a distribuição de sensores entre áreas com distribuição morfológica/climática semelhante. Novamente destaca-se os agrupamentos com os dados de temperatura média horária e os dados de índices morfológicos.

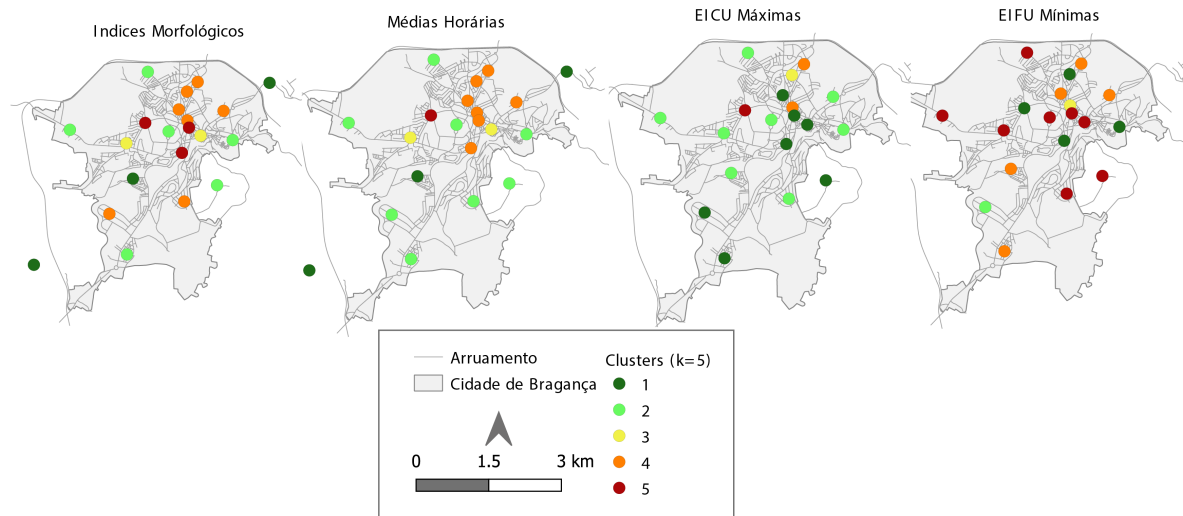


Figura 3.19: Agrupamentos obtidos com o método Kmeans ($k=5$)

Em relação as relação aos métodos de clusterização utilizados, escolheu-se os métodos k-means e Ward por serem os mais utilizados para o agrupamento de dados (Hidalgo & Jouglá, 2018; Hidalgo et al., 2014; Iyigun et al., 2013; Rhee et al., 2008; Unal et al., 2003; Yufeng Luo et al., 2010), outros foram testados brevemente nas análises preliminares dos dados mas decidiu-se seguir com estes. No entanto o método K-means apresentou problemas para na análise dos dados de médias, máximas e mínimas diárias, nesse contexto o método de Ward pode ser considerado melhor, por conseguir ter resultados com vários tipos de séries de dados. No entanto, levando em consideração as médias horárias e os índices de morfologia urbana, o método k-means apresentou resultados mais coerentes, contemplando melhor a distribuição dos sensores em *clusters* relacionados ao gradiente de urbanização presente na cidade, comprovando a hipótese de que o método de AC pode ser utilizado para a definição de ZCL.

No entanto, sabe-se que existem limitações na classificação realizada por ambos

os métodos uma vez que utilizou-se de dados dos período completo de 2016 a 2019 e que ao longo das estações muitas características climáticas podem interferir na temperatura. (Hidalgo & Jouglá, 2018; Hidalgo et al., 2014) ao utilizar o método K-means propõem a utilização de filtros climáticos para a separação dos dados por dias típicos de cada estação do anos, e também a utilização de outros tipos de dados como temperatura máxima, temperatura mínima, médias diárias de umidade, específica, precipitação e vento, todos em um único modelo.

Também questiona-se sobre o aplainamento dos dados realizado ao corrigir as temperatura pela altitude, (Unal et al., 2003) utilizando o método de Ward's aos dados de temperatura máxima, média, mínima e precipitação, encontrou um agrupamento característico para os sensores de maior altitude, o que também indica que a utilização de um modelo tridimensional considerando a altitude de cada ponto traria agrupamentos melhores para os métodos de AC.

3.4.3 Agrupamentos por ano

Agrupamento com $k = 2$

Por fim, pretendeu-se então pela análise de dados de médias horárias de temperatura separados por ano, avaliar a dinâmica dos *clusters* ao longo dos anos onde em primeiro lugar avaliou-se os agrupamentos para $k= 2$, nos métodos de K-means e Ward (Figura 3.20). O método de Ward apresentou uma classificação de má qualidade para os anos de 2017, 2018 e 2019, anos em que os sensores não foram classificados em dois grupos de modo a atender as classes "Urbano" e "Não Urbano". Já o método de K-means apresentou agrupamentos mais adequados, por obter uma agregação mais clara entre as classes citadas anteriormente. Na figura também pode-se observar as probabilidades de pertencimento ao grupo "Urbano" indo de 0 para totalmente Improvável para 1 Totalmente Provável, Nesse contexto novamente o método de Ward se apresentou muito confuso com os pontos mais ao centro da cidades, considerado como os mais urbanos, os quais foram classificados com a cor verde clara (0,2 -0,4) indicando uma probabilidade baixa de ser um ponto urbano, no entanto esses pontos estão na região mais altamente urbanizada da cidade.

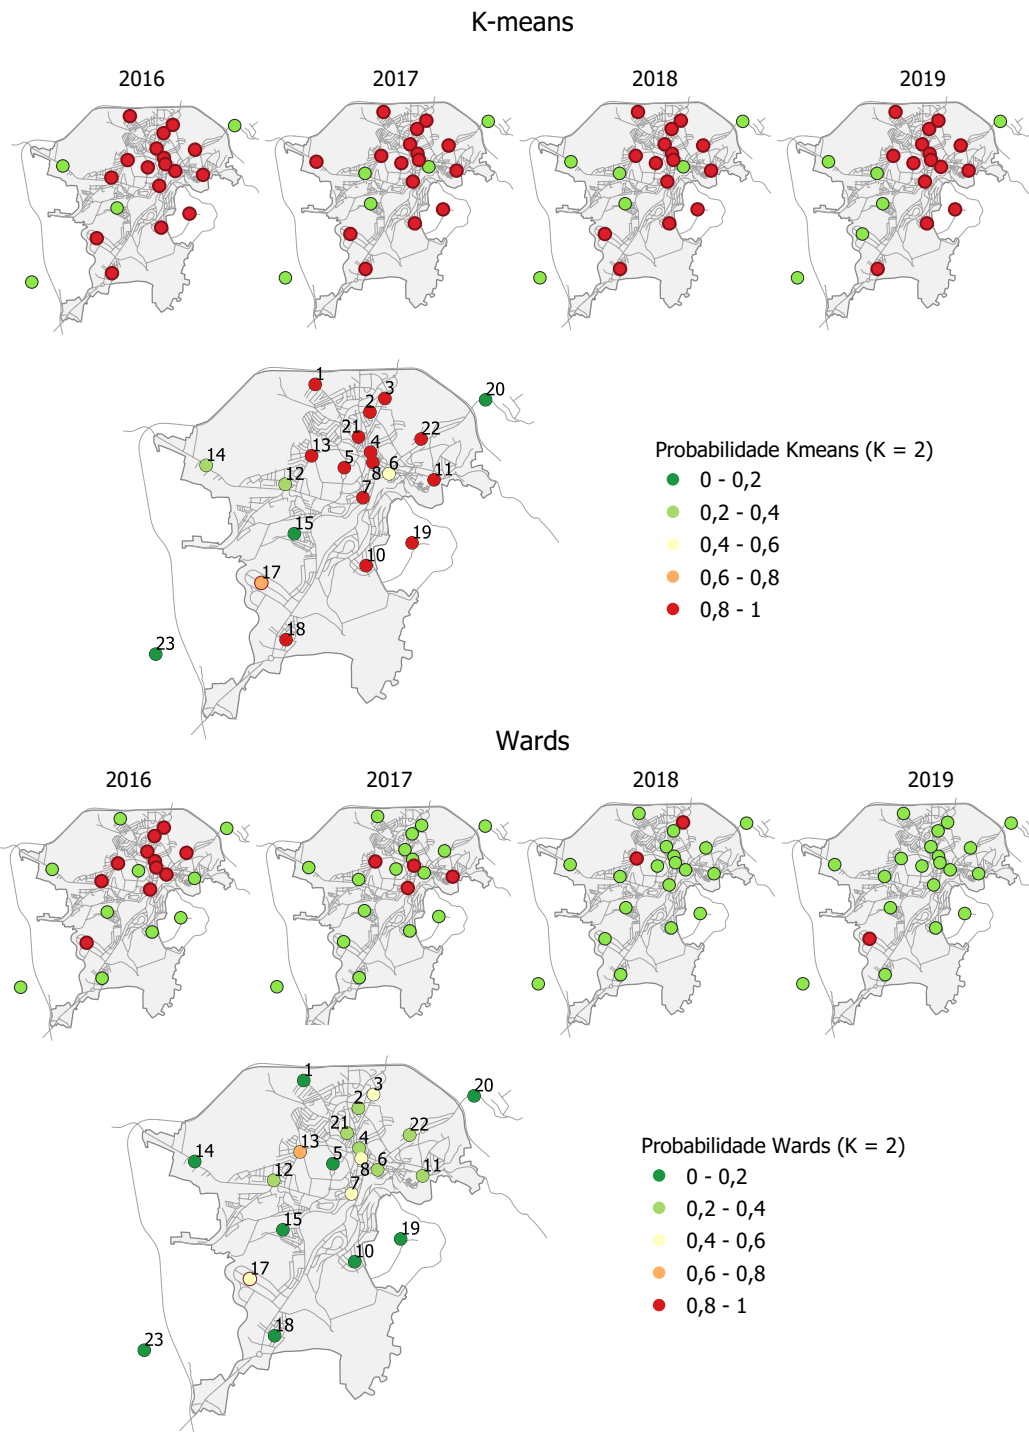


Figura 3.20: Agrupamentos por ano, com $k=2$

O método K-means se apresentou mais coerente com uma distribuição melhor entre

pontos do centro da cidade, os quais apareceram com a cor vermelha, indicando uma probabilidade alta de serem pontos urbano, inversamente a isso, os pontos menos urbanos da cidade apareceram com a cor verde, exceto o ponto 19 que é externo a zona urbana mas ficou classificado como urbano. O ponto 19 apresenta uma particularidade, ele fica próximo a uma torre de telecomunicações que contém um sistema de climatização que libera calor para o exterior, dessa forma as temperaturas do sensor sofrem interferências. Na sequência, utilizou-se todos os agrupamentos anuais com $k = 2$ para se gerar uma probabilidade global de agrupamento, novamente de 0 a 1, onde 1 indica a maior probabilidade de um ponto ser classificado como urbano (Figura 3.21 a)), para obter a classificação geral em dois grupos utilizou-se das probabilidades de 0 - 0,5 para a classe "Não Urbano" (verde) e de 0,5 - 1 para a classe "Urbano" (vermelho) obtendo assim a figura 3.21 b). Os sensores 5, 6, 14, 15, 20, 23 foram classificados como "Não Urbano" e os sensores 1, 2, 3, 4, 7, 8, 10, 11, 12, 13, 17, 18, 19, 21, 22 "Urbano", importante ressaltar que os pontos, 1, 5, 18, 10, 19 ficaram com probabilidade entre 0,4 e 0,6 o que pode indicar que foram pontos difíceis de agrupar nessas duas classes.

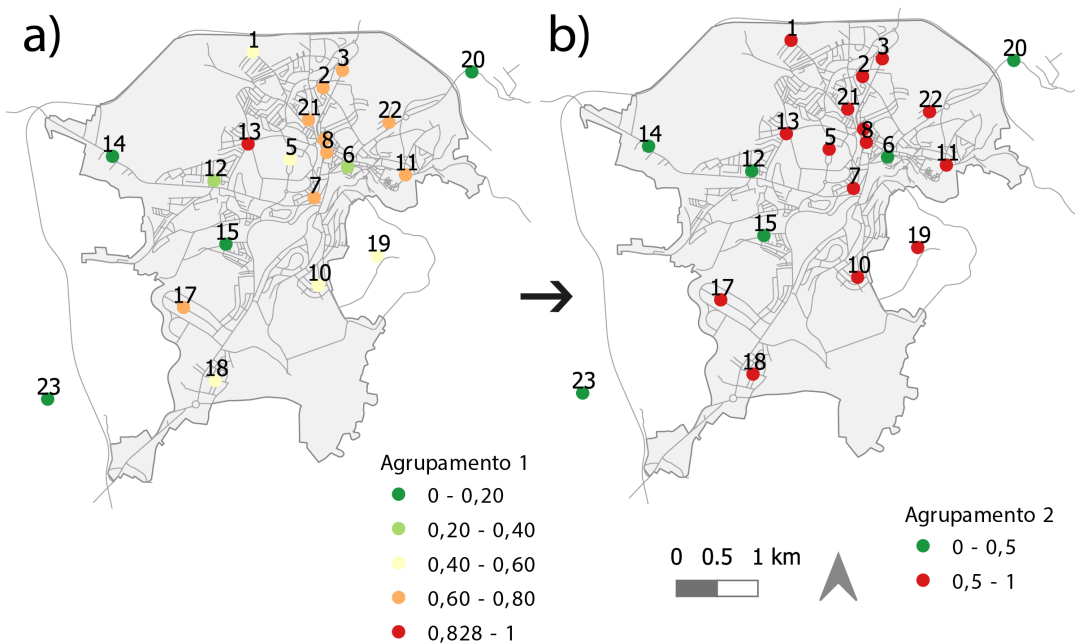


Figura 3.21: Agrupamentos mais provável, com $k=2$

Com os pontos classificados entre as duas classes foram investigadas os padrões de temperatura e EICU. A figura 3.22 apresenta o comportamento da temperatura em relação as estações do ano para os dois agrupamentos, no *boxplot* as caixas apresentam o comportamentos médio na estação do ano, ao passo que seus hastes representam as máximas e mínimas. As temperaturas do verão são as maiores e as do inverno as menores, oque era de se esperar pois são padrões naturais destas estações do ano, a diferença entre os grupos é pequena (cerca de 2 graus) para as máximas e as mínimas temperaturas, no entanto essa análise é difícil de realizar pois para tais gráficos utilizou-se todas as temperaturas obtidas no período apenas com o filtro das estações, e sabe-se que ao longo dos dias a temperatura apresenta uma certa amplitude.

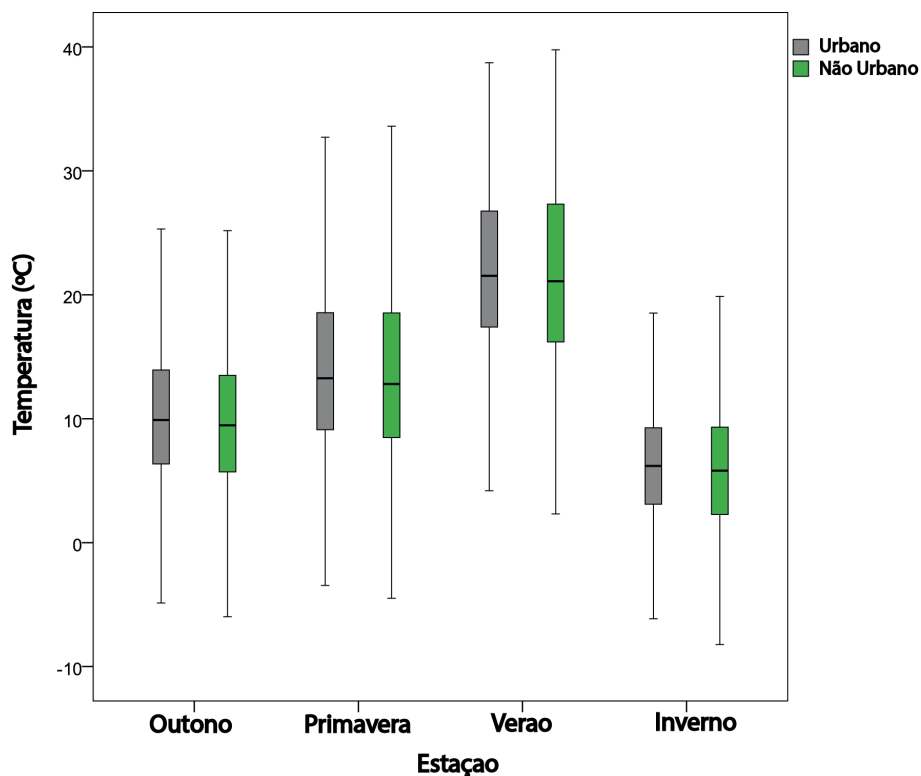


Figura 3.22: Distribuição de temperaturas pelas estações

Pensando em a diferença de temperatura entre os grupos nas estações obteve se a Figura 3.23 que apresenta o comportamento da intensidade do EICU dos dois agrupamentos em relação aos sensores 20 e 23 (rurais). Neste gráfico pose-se observar que a intensidade do EICU é maior para o grupo urbano para todas as estações. No verão o comportamento

médio do grupo Urbano tem intensidade de EICU cerca de dois graus acima do comportamento do grupo Não Urbano, as máximas expressam que as intensidades de EICU são maiores para os sensores localizados em área urbana com valores de até $+6^{\circ}\text{C}$ no verão, ao mesmo tempo que as mínimas também mostram que o EICU ocorrem em maior intensidade nos sensores urbanos em todas as estações do ano com diferenças de temperatura de até $-3,5^{\circ}\text{C}$. O verão apresenta as maiores intensidade de EICU e EIFU para os dois grupos mas as temperaturas que podem atingir são consideravelmente, comprovando a hipótese de que o agrupamento 1 deve ser classificado como Urbano e que o agrupamento 0 como Não urbanos.




Figura 3.23: Distribuição da intensidade do EICU nas estações do ano

Com a diferença da temperatura entre os dois grupos foi possível obter a Intensidade da EICU relacionada à diferença de urbanização entre os dois grupos, a Figura 3.24 apresenta essa diferença de temperatura em relação aos meses do ano e as horas do dia. Em tal gráfico é possível identificar que o efeito de EICU começa a aparecer

ao fim do dia tendo seu pico na madrugada, antes do sol nascer, tendo sua maior intensidade ($\approx +3^\circ$) entre os meses de julho e agosto, período em que o verão ocorre. Estes meses também são os de maior intensidade para a EIFU ($\approx -2^\circ$), que tem ocorrência comum nas primeiras horas de sol e pode se estender até meio da tarde em menor intensidade. Tal resultado comprova o previsto por Gartland (2011) para as diferenças de temperatura entre áreas urbanas e não urbanas.




Figura 3.24: Intensidade do EICU entre os pontos Urbanos e Não Urbanos

Com os pontos urbanos e não urbanos definidos pode-se analisar também as características médias da morfologia de cada *cluster*, a tabela 3.3 apresenta os índices de morfologia médios para os grupos "Urbano" e "Não Urbano", em tal tabela é possível identificar uma diferença clara entre os indicadores para os dois grupos, onde o agrupamento "Não Urbano" apresenta valores consideravelmente menores dos índices diretamente relacionados às construções OT, IC, NMP, IV, PI e HL ao passo que apresentam um FVC e um AM maiores do que a classe "Urbano".

No entanto, os valores médios não são completamente representativos da morfologia para os grupos, pensando nisso também realizou-se o *Boxplot* mostrando o comportamento geral dos índices para os indivíduos dos dois grupos (Figura 3.25). As caixas alongadas

Tabela 3.3: Índices de Mofologia Urbana para as ZCL (K=2)

Índices	OT	IC	NMP	IV	FVC_S	FVC_F	AM	PI	HL
Urbano	21,40	0,76	3,52	2,24	0,87	0,73	0,16	69,03	1,11
$\sigma_{Urbanos}$	14,37	0,80	2,36	2,07	0,10	0,26	0,03	32,01	0,92
Não Urbano	15,80	0,35	1,74	1,27	0,90	0,81	0,18	46,21	0,43
$\sigma_{N\tilde{a}oUrbanos}$	15,32	0,37	1,07	1,35	0,12	0,16	0,03	43,97	0,40

nos índices OT e PI, indicam que mesmo com os agrupamentos homogêneos existe uma grande variabilidade da tipologias de construções nas localidades de cada sensor. podendo ir de 0 a 35 o índice de ocupação do terreno com a mediana em 10 para o grupo Não Urbano, e de 0,2 a 48,0 com mediana em 22,0 para o grupo Urbano. Para a OT os índices dos sensores variam de 0% a 100% impermeabilizado, com mediana em 25%, para o grupo Não Urbano, e de 5 a 95% para o grupo Urbano, no entanto a mediana está em 80%, indicando uma maior impermeabilização geral dos sensores no grupo. Os IC, IV e HL apresentaram uma variabilidade menor, indicando uma tendência do grupo Urbano apresentar valores dos indicadores relacionados as construção serem maiores do que os Não urbanos. Tal variabilidade indica que os agrupamentos não são totalmente homogêneos em construção o que é indicado por Stewart e Oke (2012) para caracterizar as ZCL, dessa forma, por mais que 2 grupos seja o ótimo indicado para o processamento de dados pela Análise de *Clusters* indicado pelos métodos WSS e Silhueta, esse agrupamento climatologicamente não é o mais adequando para agrupar as ZCL.

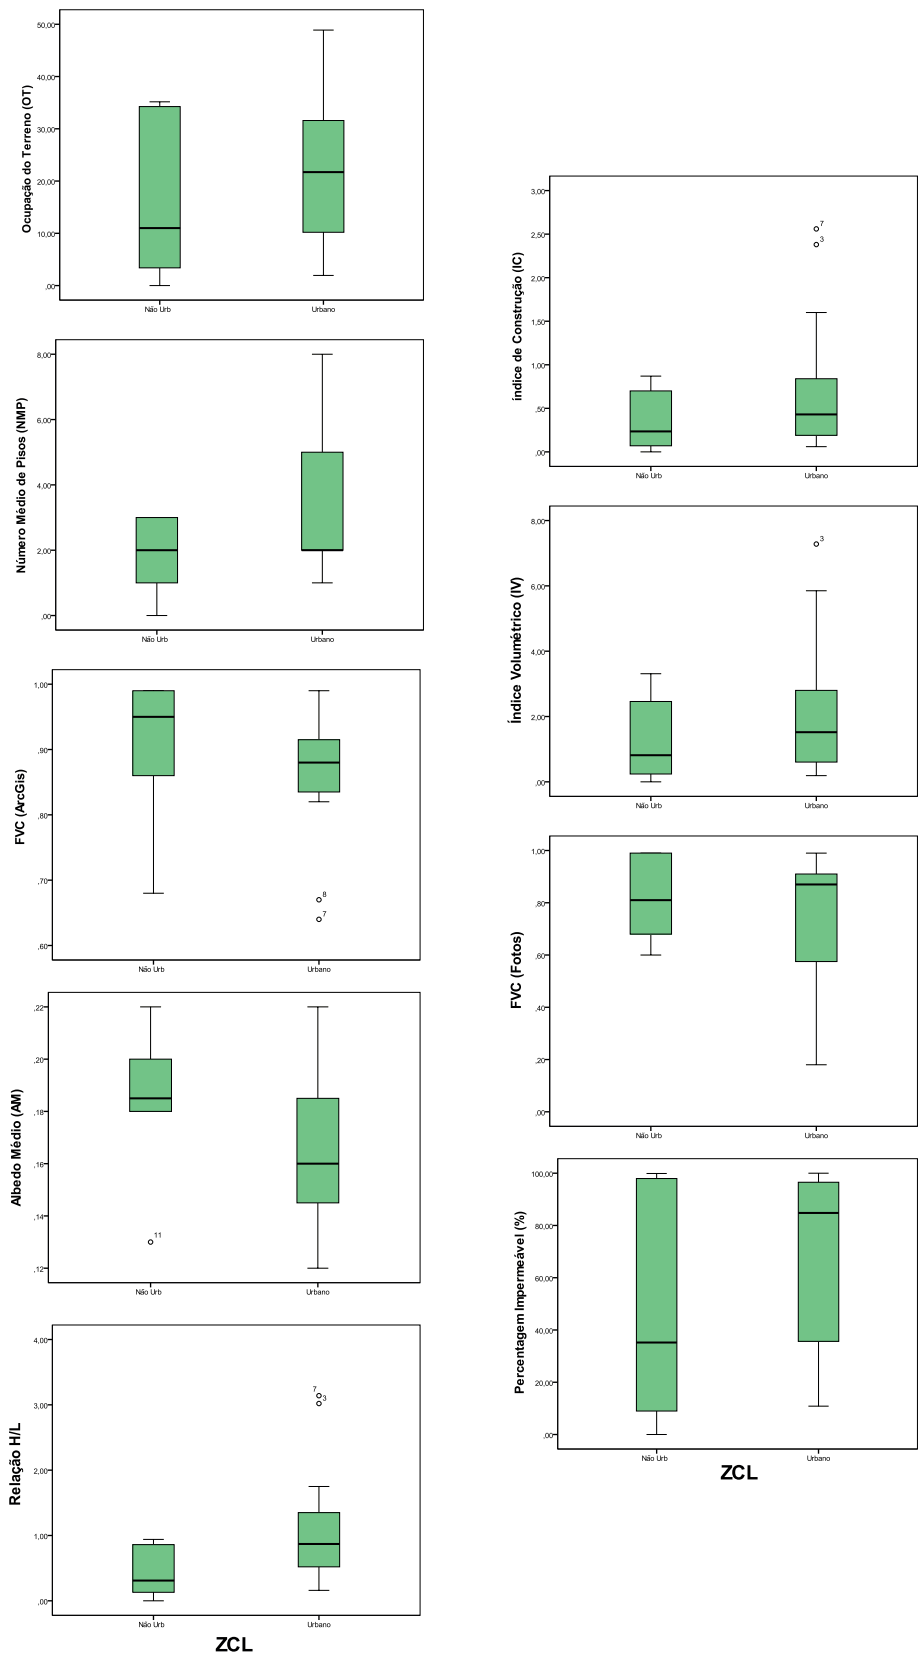


Figura 3.25: Índices Morfológicos para as novas ZCLs

Agrupamento com $K = 5$

No mesmo contexto, a Figura 3.26 apresenta os agrupamentos por ano (2016 - 2019) para o método de Ward 's e Kmeans, mas com cinco grupos. Ambos os métodos apresentaram uma distribuição boa para os sensores, contemplando o gradiente de urbano para não urbano de uma forma adequada, com os indivíduos mais ao centro da cidade com coloração vermelha e os mais afastados com coloração verde. Poucos indivíduos ficaram isolados em um único grupo em alguns modelos, no entanto, a quantidade de *clusters* $k = 5$ ainda não pareceu completamente adequada para a quantidade de sensores estudada, o tamanho e o nível de urbanização da cidade *clusters*. Com as notas de 1 a 5 atribuídas aos indivíduos em cada grupo, obteve-se uma nota média de cada sensor em relação aos agrupamentos anuais. Essa nota foi utilizada para obter as faixas de probabilidade de agrupamento para cada sensor em relação a cada método (Ward 's ou K-means), onde de 0 - 0,20 (grupo 1), 0,20 - 0,40 (grupo 2), 0,40 - 0,60 (grupo 3), 0,60 - 0,80 (grupo 4) e de 0,80 - 1 (grupo 5) (Figura 3.26). Pouco se diferenciou entre as classificações médias de cada método, destacando-se apenas os sensores, 17, 10, 11 5 e 3, no entanto, todos eles mudaram apenas um nível nos agrupamentos, indo para um grupo de intermédia urbanização, mas com pouca diferença do grupo de pertencimento no outro método de relação, dessa forma, tanto o método de Ward 's como o método Kmeans se mostraram adequados para a classificação das ZCL da cidade.

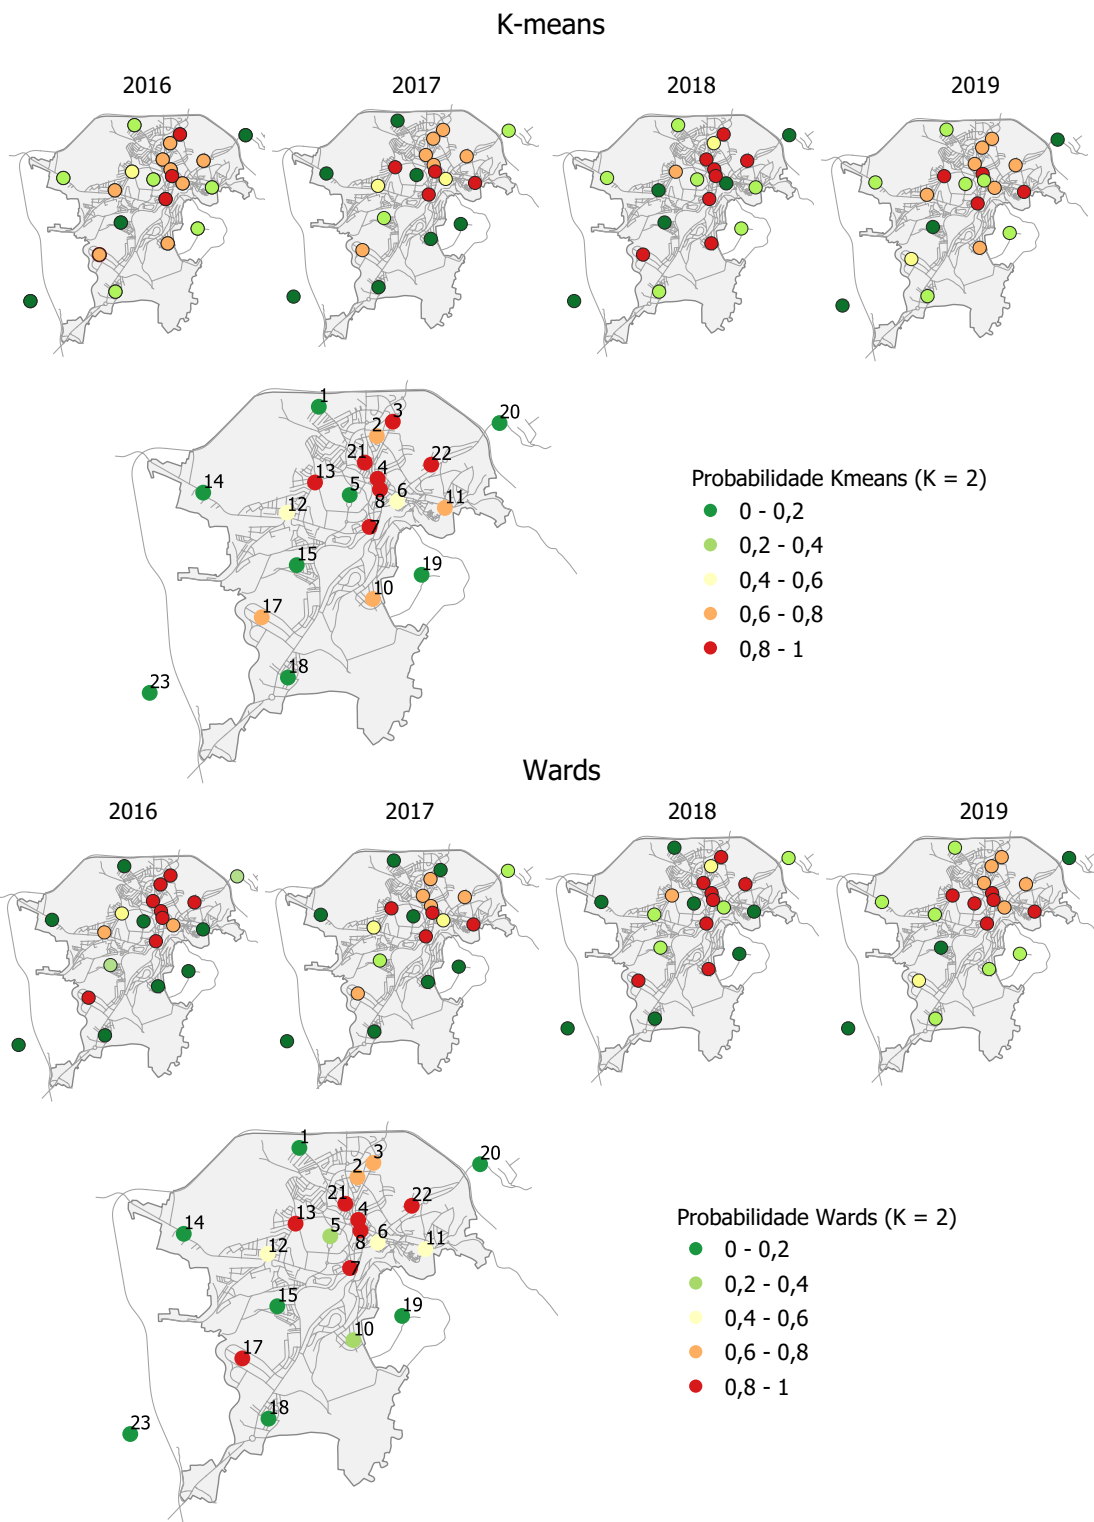


Figura 3.26: Agrupamentos por ano, com k=5

A Figura 3.27 a) apresenta a classificação geral de agrupamento em relação a todos os modelos e anos, no entanto essa distribuição proporcional entre os grupos deixou o sensor 5 isolado no grupo 2 e o grupo 3 com apenas três sensores. Optou-se então pela distribuição proporcional indicada pelo *software* QGIS Development Team (2020), que realocou o sensor 5 para o grupo 3 e o sensor 13 para o grupo 4 (Figura 3.27 b)), gerando assim um novo agrupamento onde os sensores 1, 14, 15, 18, 19, 20, 23 ficaram no Grupo 1 - Verde, os sensores 5, 6, 10 e 11 no Grupo 2 - Amarelo, os sensores 2, 3, 13, 17 no Grupo 3 - Laranja e os sensores 4, 7, 8, 21 e 22 no Grupo 4 - Vermelho, este agrupamento foi atribuído as ZCL da cidade de Bragança, dessa forma, distante do previsto no trabalho de (Carvalho, 2020) que utilizou sete zonas climáticas a partir do método de (Stewart & Oke, 2012) para classificar os climas locais da cidade de Bragança - Portugal, apenas quatro zonas foram classificadas matematicamente a partir do método de análise de *clusters* para os dados de temperatura média horárias.

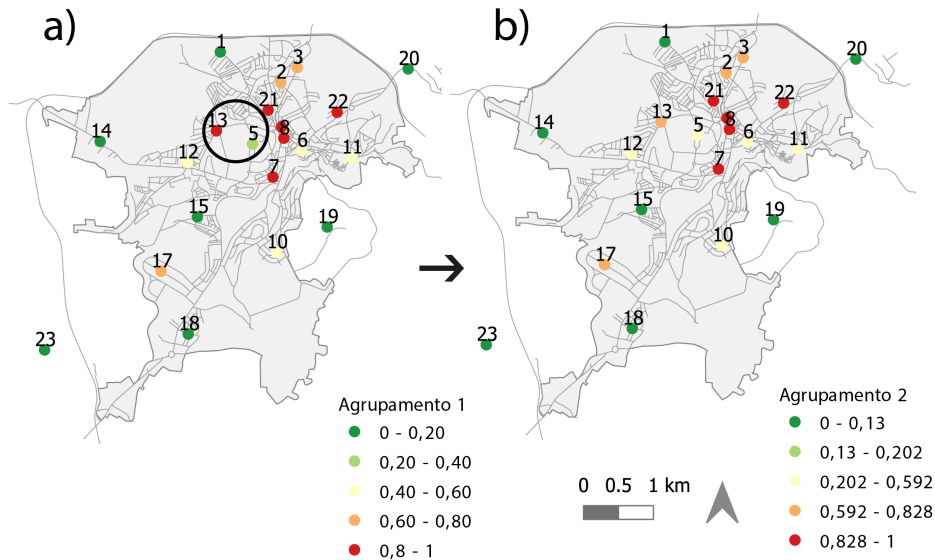


Figura 3.27: Agrupamento mais provável com $k=5$

Da mesma forma, objetivando analisar o comportamento da temperatura nos grupos identificados para as novas ZCLs, plotou-se o *boxplot* da distribuição de temperatura para os quatro grupos de sensores em relação as estações do ano (Figura 3.28), onde é possível visualizar nas caixas o comportamento de 50% dos dados, os extremos representam

as máximas/mínimas e o corte representa a mediana da temperaturas de cada grupo nas estações (outono, primavera, verão e no inverno). Neste quadro identificou-se poucas diferenças entre os agrupamentos, ficando claro apenas as diferenças das temperaturas nas estações do ano.




Figura 3.28: Distribuição de temperaturas pelas estações nas ZCL

Com isso, também foi plotado o *Boxplot* da Figura 3.29 com a diferença de temperatura de cada grupo em relação aos sensores rurais (20 e 23), onde a intensidade segue a ordem 1, 2, 4, 3, sendo o grupo 3 o mais afetado pelas intensidades máximas e mínimas do EICU, novamente vale ressaltar que quando essas intensidades são negativas o EIFU é identificado. Sendo assim, pode-se caracterizar tal grupo como o mais afetado pela relação entre a urbanização e as temperaturas, sendo essas as localidades que precisam de mais atenção dos planeadores urbanos com o intuito de minimizar a ilha de calor urbana existente, de modo a melhorar a qualidade de vida dos habitantes da localidade pois são os sensores que apresentam máximas e mínimas mais elevadas. No entanto, o grupo 4 apresenta intensidade dos EICU e EIFU tão acentuadas quanto

o grupo 3 na maioria dos dados, pode-se observar isso com as caixas de tamanhos semelhantes principalmente no verão onde os efeitos são mais acentuados. Dessa forma, as temperaturas indicam que as localidades dos sensores contidas nos grupos 3 e 4 dever ser melhor estudadas por apresentarem maior diferenciais de temperatura.




Figura 3.29: Distribuição da intensidade dos EICU e EIFU nas estações do ano

Com as diferenças de temperatura entre os *clusters* 2, 3 e 4 em relação ao grupo 1, pode-se identificar o gradiente de intensidade do EICU entre os sensores dos grupos 2, 3 e 4. Onde o grupo 2 caracterizado por sensores com localidades mais habitacionais com construções menores e espaçadas apresenta a menor intensidade do efeito, ao passo que os grupos 3 e 4 apresentam as maiores intensidades. Comprovando assim que são zonas, apresentam características climáticas diferentes em relação a morfologia e temperatura. Diferente do interpretado na figura anterior, na figura 3.30 mostra que a maior diferença de temperatura geral entre os grupos em relação as aos meses do ano e as horas do dia é o grupo 4.




Figura 3.30: Intensidade do EICU entre as Zonas Climáticas Encontradas

Também foi possível identificar os índices morfológicos médios de cada *cluster*, onde é possível observar um gradiente de características, passando pelo grupo 1 que apresenta os menores números para os índices relacionados às construções OT, IC, NMP, IV, PI e HL, o que indica que a localização apresenta construções pequenas e espaçadas ou mesmo apresenta apenas vegetação, características de áreas de campo ao arborizado. Para o grupo 2 a PI foi a maior, ao passo que a OT, IC, NMP, IV, HL foram os segundo menores, o que indica que são localidades com grande área de construções que as construções são menores e espaçadas, características de localidades habitacionais. Por fim os grupos três e quatro apresentam os maiores valores OT, IC, NMP, IV, PI e HL e os menores valores de AM e FVC ambos apresentam características de áreas densamente urbanizadas ...

Novamente é importante ressaltar que os valores médios não representam completamente o comportamento dos sensores contido nos agrupamentos, dessa forma os *boxplots* da

Tabela 3.4: Índices de Urbana para as ZCL (K=5)

Índices	OT	IC	NMP	IV	FVC_S	FVC_F	AM	PI	HL
1	14,20	0,33	2,21	1,20	0,92	0,84	0,19	43,63	0,43
σ_1	14,61	0,34	1,57	1,25	0,12	0,16	0,03	40,71	0,36
2	13,18	0,22	1,58	0,78	0,89	0,72	0,17	57,00	0,59
σ_2	7,85	0,18	0,53	0,65	0,06	0,27	0,03	35,40	0,53
3	23,56	1,25	6,14	3,60	0,89	0,79	0,16	80,03	1,48
σ_3	15,51	0,96	2,58	2,81	0,04	0,22	0,03	32,01	1,09
4	31,27	1,01	3,06	2,90	0,80	0,64	0,15	80,42	1,47
σ_4	14,10	0,88	1,37	1,75	0,15	0,32	0,03	26,15	1,03

Figura 3.31 apresentam o comportamento geral dos índices nos sensores agrupados em cada grupo, com as máximas, mínimas, medianas e o comportamento médio, onde 50% dos valores estão contidos nas caixas.

Quanto a OT o grupo 1 é o menos ocupado (com mínima de 0%, mediana de 22% e máxima em 35%), seguido pelo 2 e pelo 3 que apresentam comportamento semelhante nos quartis 1 e 3 (respectivamente com 10 e 32%), por fim o grupo 4 apresenta a mínima de 12, mediana de 30 e máxima de 48, sendo este o cluster localizado nos pontos com terreno mais urbanizado da cidade. Para o índice NMP a disposição ficou um pouco diferente, os grupos 1 e 2 apresentaram medianas iguais a 2, no entanto o grupo 2 apresentam pouca variabilidade entre a maioria dos sensores com a caixa igual a mediana, os pontos 5 e 6 ficaram como os representando dos valores máximos (2) e mínimos (1). O grupo 3 apresentou a maior variabilidade de dados mas a mediana e as máximas foram as maiores (7 e 8).

Para os índices IC e IV, a ordem de mínimas, medianas e máximas seguiu na ordem 1, 2 e 3, com um padrão crescente de valores, o grupo 4 no entanto, apresentou os valores menos variados e medianas menores que o grupo 3 indicando que a ocupação da localidade desses sensores é menor. A PI em relação ficou muito próxima de 100% para a maioria dos sensores agrupados nos sensores 2, 3 e 4, tendo o terceiro grupo a maior variação de valores. O grupo 1 apresentou a mediana iguala a apenas 20%, indicando que o terreno tem mais solos, gramados e menos construções. Por fim no índice HL pode-se constatar que a altura das construções seguem a ordem 1, 2, 4 e 3, tendo o grupo 3 as construções mais altas nas maioria dos dados. Dessa forma,

relacionando ao obtido no índice IC chega-se a conclusão de que o grupo 4 é o mais densamente urbanizado mas com construções de menor porte, ao passo que o grupo 3 também tem um grande nível de construções mas as construções são mais altas e espaçadas.

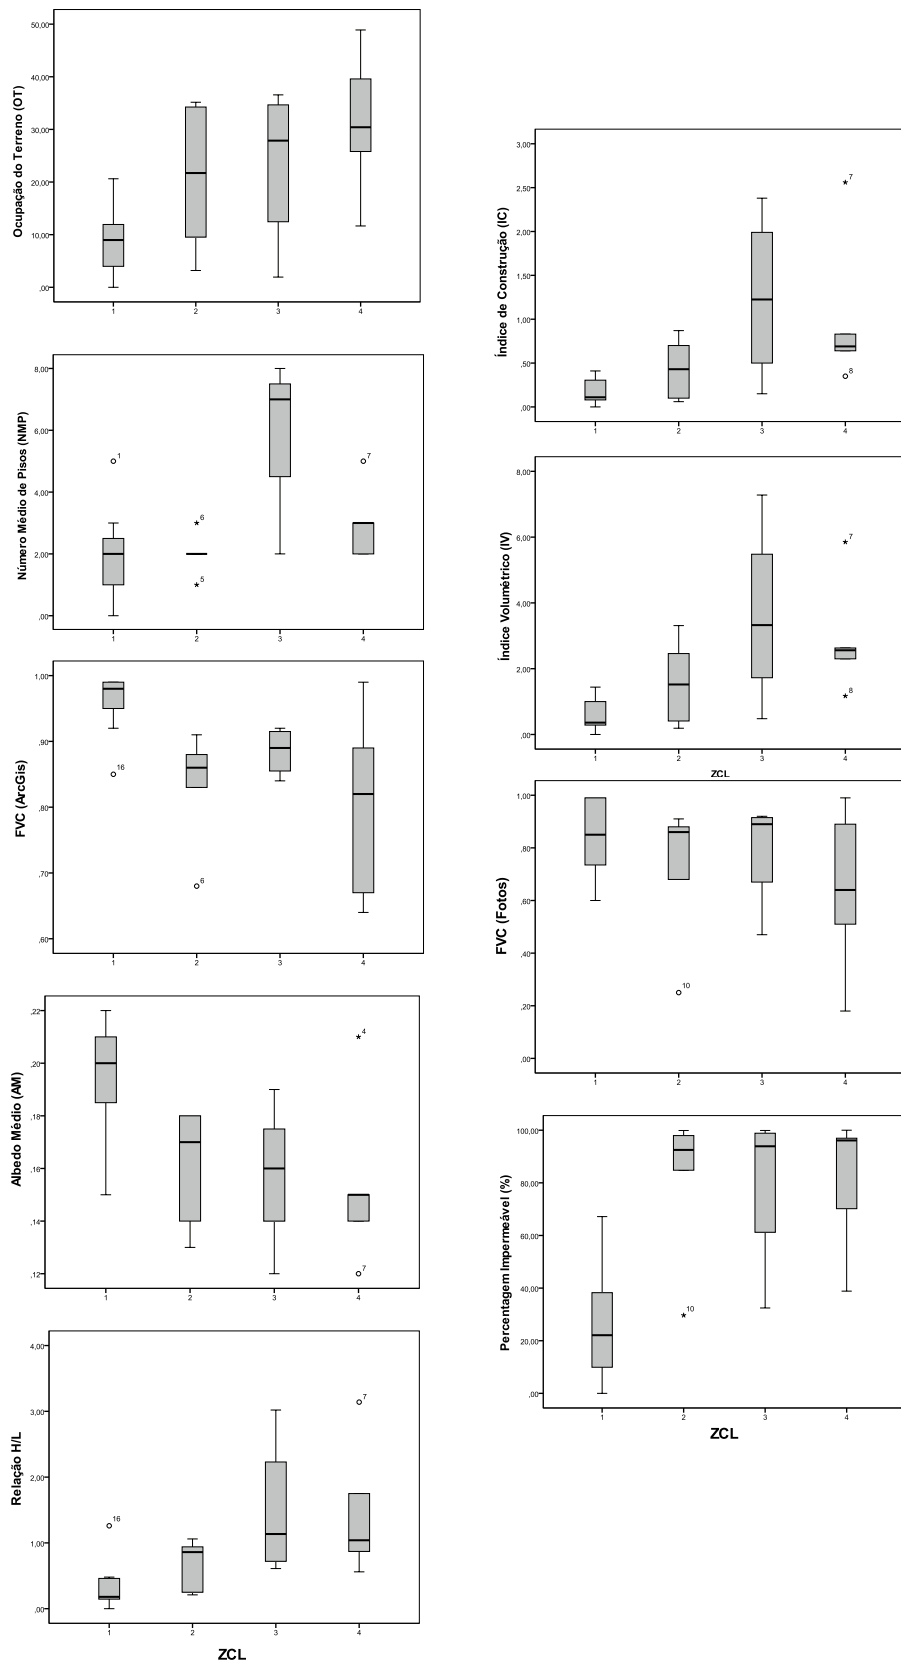


Figura 3.31: Índices Morfológicos para as novas ZCLs

Stewart e Oke (2012) explica que as ZCL são regiões de cobertura uniforme de superfície, estrutura, material e atividade humana nas cidades, esta uniformidade se estendem por centenas de metros a vários quilômetros em escala horizontal. Analisando novamente a classificação proposta por estes pesquisadores, e tendo em vista os índices de morfologia urbana de cada grupo, pode-se enquadrar os cluster nas ZCL descritas na Tabela 3.5. Em complemento, a Figura 3.32 apresenta fotos com o intuito de exemplificar o explicado na tabela 3.5, com sensores característicos de cada agrupamento.

Tabela 3.5: Descrição das novas ZCL.

Cluster	ZCL	Definição
1	C	Áreas rurais isoladas nos subúrbios da cidade representativas das características da paisagem local.
2	5	área com média densidade, ruas de habitações de baixa altura em banda ou isoladas.
3	2 ou 4	Área com edificado moderno de altura média a alta, e elevada densidade com predomínio de superfícies pavimentadas ou arranjo entre prédios altos, espaçados com terreno permeável e plantas ao redor.
4	3	Núcleo antigo da cidade, com edifícios de altura média-baixa, elevada densidade, edificado em pedra e tijolo.

Fonte: Adaptado de Stewart e Oke (2012)



ZCL 1 - Sensor 14



ZCL 2 - Sensor 5



ZCL 3 - Sensor 3



ZCL 4 - Sensor 8

Figura 3.32: Exemplos de sensores contidos em cada ZCL

A fim de comparar as novas classificações obtidas com as ZCL estudadas por (Carvalho, 2020), desenvolveu-se a figura 3.33 que relaciona as classificações apresentadas com o nível de urbanização que elas representam através das cores, onde o verde apresenta os sensores localizado nas áreas identificadas como Não Urbano e o Laranja apresenta o identificado como localizado nas localidades urbanas. As variações intermediárias de cor variam com a quantidade de grupos em cada classificação, a primeira tem as 7 classes do estudo anterior, a coluna do meio contem as duas classes encontradas para a AC com $k=2$ e a coluna mais a direita apresenta as classes obtidas com a classificação AC com $k=5$.

Assim, pode-se identificar que os grupos classificados como "C" e "9" por Carvalho (2020) tendem ficar agrupados juntos, o novo grupo então caracteriza-se como as zonas mais afastadas da cidade, com solo exposto e/ou vegetação natural, com construções pequenas ou inexistentes.

Os grupos classificados como "A" e "8" no estudo anterior foram os de mais difícil classificação pelos algoritmos, eles ficaram todos como "Urbanizados" na classificação com $k=2$ e variaram entre as classes 2, 3 e 4 na classificação com $k = 5$, dessa forma em ambos os agrupamentos identificou-se que esses sensores não estão localizados em envolventes de áreas urbanas. No entanto, a classe A corresponde a localidades com vegetação arbórea, a vegetação arbórea da cidade de Bragança compõem-se principalmente de árvores caducas e pinheiros, quando essas áreas arborizadas estão localizadas em regiões urbanizadas, no inverno devido a perda das folhas a condição climática apresentada se aproxima a encontrada em localidades próximas mas sem árvores, devido grande entrada de luz que passa a ocorrer, ampliando o aquecimento do local.

Por fim, os grupos contidos nas ZCL 2 e 3 ficaram também os sensores das classes mais urbanizadas 3 e 4. Com algumas confusões a serem analisadas. No agrupamento com $k=2$, os sensores 6 e 12 foram classificados como não urbanos e os sensores 1 e 19 como Urbanos mesmo esses sensores estando localizados em localidade no arredor da cidade, novamente ressalva que o sensor 19 está localizado em um ponto que um sistema de climatização que altera as temperaturas locais, isso interfere de certa forma nas temperaturas do verão. Também ressalva-se que a classificação em dois grupos identifica poucos padrões de temperaturas. Para o agrupamento com cinco *cluster*

os grupos 2, 3 e 5 ficaram um pouco misturadas quando relacionados a classe anterior, isso pode dizer que a classificação anterior não foi tão de áreas com morfologia tão homogêneas e também que alguns indivíduos deviam estar na margem dos grupos, mas de modo geral os grupos 2 e 3 ficaram nas classes mais urbanizadas na nova classificação. Dessa forma os *cluster* podem se identificados como coerentes, mas estudos mais detalhados devem ser realizados de modo a identificar dados e métodos que promovam agrupamentos melhores.




Figura 3.33: Comparação das classificações das ZCL

Capítulo 4

Conclusões

Quatro áreas de análise compuseram o presente trabalho, a primeira delas consistiu na análise do comportamento dos Efeito de Ilha de Calor e Frio Urbanos para as envolventes dos sensores a partir da análise das diferenças de temperaturas nos pontos de estudo da cidade. Nesta análise pode-se identificar os EICU e EIFU ocorrem em menor ou maior intensidade em todos as localidades dos sensores de dentro da cidade de Bragança, a intensidade dos efeitos depende fundamentalmente do nível de urbanização de cada ponto. Também foi possível identificar os padrões destes efeitos ao longo dos meses do ano, mais expressivos nos meses contidos entre a primavera e o verão onde as condições sol e brisas leves permitem que as características dos climas locais e até mesmo de microclima prevaleçam em detrimento dos climas de ampla escala que tendem a se sobrepor nos meses de outono e inverno. Da mesma forma foi possível identificar que o EICU surge após o por do sol, quando as superfícies urbanas se resfriam em velocidades muito diferentes das rurais, trazendo temperaturas mais altas para as áreas urbanas durante a noite, o inverso ocorre com o EIFU que se apresenta com temperaturas mais baixas da cidade em relação a envolvente devido a demora que se tem para aquecer as superfícies urbanas em comparação ao aquecimento que o sol realiza nas áreas não urbanas, efeito relacionada aos tamanhos dos edifícios que atrasam o aquecimento das áreas centrais nas primeiras horas do dia.

Com relação a intensidade de EICU e EIFU nas localidades dos sensores pode-se identificar que os sensores 2, 3, 4, 7, 8, 11, 13, 18 e 21 apresentam os efeitos

mais expressivos, sendo que as maiores diferenças de temperatura em relação a envolvente rural foram atribuídas aos sensores 3 e 7, com máximas e mínimas ultrapassando os $\pm 3^{\circ}\text{C}$, com horário de pico para a EICU próximos ao nascer do sol, nas primeiras horas do dia, indicando que os materiais de construção destas envolventes são materiais com perda lenta de calor específico, como rocha e concreto. Também pode-se concluir que os sensores menos afetados pelos mesmos efeitos são os sensores 14 e 15 onde as máximas e mínimas intensidades ficaram em entre $\pm 1^{\circ}\text{C}$. De modo geral, tal análise, possibilitou concluir que cada localidade apresenta diferentes intensidade dos efeitos de EICU e EIFU relacionados ao nível de urbanização de cada sensor, com isso ressalva-se a importância de uma rede de monitorização grande que atenda diferentes tipologias de construção e também a importância do cuidado criterioso na escolha das localidades de instalação dos sensores para que estes não expressem apenas efeitos adversos relacionados a algum fator específico do clima em sua microescala.

A segunda análise do trabalho consistiu na utilização da metodologia de Análise de Componentes Principais aplicada aos índices de morfologia urbana (OT, IC, NMP, IV, FVC - ArcMap, FVC- Fotos PI, HL AM), nessa análise pretendeu-se identificar quais destes índices são componentes principais que podem ser utilizadas para a explicação da urbanização. Nesse contexto pode-se concluir que os índices principais foram: o IV, FVC, OT, HL e NMP, que juntos expressam 98% dos aspectos morfológicos. No entanto, considerou-se que esse foi um grande número de variáveis explicativas e que, por serem muito correlacionados os três últimos índices, algum desses deveria ser provavelmente ser retirado no desenvolvimento das regressões lineares simplificadas.

Na sequência, a terceira análise utilizou dos componentes principais e das temperaturas máximas, médias e mínimas em cada estação do ano para o desenvolvimento de 12 regressões lineares explicativas da relação que a urbanização tem na intensidade do EICU, onde foi possível identificar que seis componentes explicativas foram muito para o desenvolvimento de boas regressões lineares, isso se deve principalmente pela alta correlação entre os índices IV, IC e NMP. Dessa forma, seguiu-se apenas as duas melhores regressões lineares encontradas que estão relacionadas com as temperaturas médias do verão e da primavera, procurando encontrar uma equação simplificada tão explicativa quanto as primeiras. Pode-se concluir com tal análise que os índices de morfologia podem

ser utilizados junto a métodos matemáticos para a modelação do comportamento das temperaturas e também da intensidade do efeito de EICU, no entanto deve-se considerar que efeitos sinópticos como ventos fortes e chuva atrapalham essa previsão. Nesse contexto, mais elementos do clima como a precipitação, os ventos, a altitude e outros deveriam ser analisados. Para condições de céu limpo e brisas leves essa previsão é mais confiável e possível de se realizar tendo em vista apenas os aspectos de urbanização como foi feito no presente trabalho, devido a isso, os melhores equações obtidas foram as da primavera e do verão.

Por fim, o último eixo de trabalho foi a Análise de *Clusters* com vista a validação das Zonas Climáticas Locais existentes na cidade de Bragança, pelos métodos K-means e Ward, com dois e cinco agrupamentos. Os dados utilizados foram os de temperaturas médias horárias, as médias, mínimas e máximas diárias, intensidade máxima e mínima do efeito de ilha de calor urbano e também os todos os índices de morfologia urbana. Em relação as séries de dados utilizadas para os agrupamentos, os resultados mais coerentes foram obtidos com as médias e mínimas diárias de temperaturas no método de Ward e os obtidos com os médias horárias e os índices de morfologia urbana para o método K-means. Quanto aos métodos pode-se concluir que ambas as abordagens de classificação de Tipo de Clima Local propostas são uma boa prática a ser desenvolvida quando a identificação de ZCL, pois tanto o método de Wards como o k-means apresentaram resultados coerentes em relação ao gradiente urbano-rural, mas conclui-se que os agrupamentos podem ser melhorados ao utilizar filtrados para dias de céu limpo e ausência de ventos fortes em conjunto de mais elementos climáticos como a humidade, precipitação, velocidade do vento, radiação, etc.

Quanto a quantidade de agrupamentos, dois grupos foi o indicado como ótimo pelos métodos estatísticos de previsão para o agrupamento dos dados em questão, no entanto essa quantidade de agrupamentos se mostrou insuficiente para agrupar os sensores em zonas climáticas, apenas expressando a relação Urbano - Não Urbano nos melhores modelos, indicando uma possível necessidade de mais sensores distribuídos na cidade ou uma necessidade de melhoria na qualidade dos dados, retirando dados de dias que sofreram mais interferências sinópticas. Para cinco *clusters* o gradiente de tipologias de construção foi contemplado na maioria dos modelos, no entanto, com frequência

obteve-se grupos contendo um único sensor, o que indica que cinco é uma quantidade acima do que o necessário para o agrupamento adequado dos dados. Dessa forma, conclui-se que devido ao porte e a tipologia de construções existente na cidade de Bragança, quatro Zonas Climáticas homogêneas seria o número ideal.

A última análise de série AC realizada objetivou avaliar o comportamento médio dos agrupamentos dos sensores ao longo dos anos, gerando assim probabilidades de pertencimento para os dois métodos. Para dois *clusters*, os grupos obtidos pelo método de Ward's foram ruins, atribuindo quase todos os indivíduos a uma única classe e poucos para a outra ao passo que o método de Ward's teve uma distribuição boa entre os sensores urbanos e não urbanos. Para cinco *clusters*, ambos os métodos se comportaram bem, deixando poucas vezes algum indivíduo sozinho. No entanto na probabilidade global concluiu-se definitivamente que quatro *clusters* seria o ideal para as ZCLs, identificando os sensores presentes em cada grupo, e o gradiente das temperaturas, intensidades de EICU e índices morfológicos encontradas em cada agrupamento, comprovando assim a existência de um gradiente de urbanização.

Tendo em vista as conclusões obtidas nos quatro tópicos de estudo, pode-se concluir que os métodos matemáticos/estatísticos podem e devem ser utilizados como ferramentas para a modelação do clima nas cidades, promovendo uma compreensão numérica dos fenômenos desenvolvidos no clima urbano de modo a apresentar subsídios técnico-científicos para os planejadores tomarem decisões acertadas no que diz respeito a projeto urbanísticos com o foco numa melhor qualidade de vida nas cidades. No entanto, ressalva-se que é necessário aprofundar o estudo do presente trabalho com foco em ampliar os elementos climáticos contidos nos modelos e também torná-lo tridimensional, considerando as altitudes de cada sensor, dessa forma os modelos terão um poder de previsão melhor, tanto para os *clusters* como para a intensidade do EICU.

Trabalhos Futuros

No seguimento dos resultados dos trabalhos apresentados, pretende-se futuramente proceder uma Análise Extensiva de (2012-2020) para os dados de temperatura e humidade dos mesmos sensores, retirando os dados com interferência de chuva e pluviosidade

de modo a encontrar agrupamentos com menor interferência do clima de ampla escala.

Outra linha de investigação que se pretende realizar no futuro consiste no desenvolvimento de modelos tridimensionais que levem outras variáveis em consideração como a altitude, os ventos, a precipitação e humidade. Assim como a simplificação dos mesmos de modo a encontrar modelos com explicações boas do clima com um mínimo possível de variáveis.

Quando os *clusters* estivessem bem definidos, com todas as variáveis, também seria possível obter modelos de regressão relacionados aos agrupamentos, buscando entender a intensidade de EICU dentro dos agrupamentos de morfologia semelhante.

Bibliografia

- Adobe Photoshop CS6. (2020). CA: Peachpit Press. Berkeley. <https://www.adobe.com/pt/products/photoshop.html>
- Alexander, P. J. & Mills, G. (2014). Local climate classification and Dublin's urban heat island. *Atmosphere*, 5(4), 755–774.
- Allegrini, J., Dorer, V. & Carmeliet, J. (2012). Influence of the urban microclimate in street canyons on the energy demand for space cooling and heating of buildings [Cool Roofs, Cool Pavements, Cool Cities, and Cool World]. *Energy and Buildings*, 55, 823 –832.
- Alves, E. D. L. (2017). Ilha de calor urbana em cidade de pequeno porte e a influência de variáveis geourbanas. *Revista Brasileira de Climatologia*, 20.
- Andrade, H. (2005). O Clima Urbano - Natureza, escalas de análise e aplicabilidade. *Finisterra*, 40(80), 67–91.
- Arguez, A. & Vose, R. S. (2011). The definition of the standard WMO climate normal: The key to deriving alternative climate normals. *Bulletin of the American Meteorological Society*, 92(6), 699–704.
- Ayoade, J. O. (2007). *Introdução à Climatologia para os Trópicos*. 11^a edição (11^a ed.).
- Azevedo, J., Cadavez, V., Arrobas, M. & Pires, J. Sustentabilidade da montanha portuguesa: realidades. Em: *Instituto Politécnico de Bragança*. Instituto Politécnico de Bragança, 2016. Cap. 1, pp. 9–38.
- Barbirato, G. M., de Souza, L. C. L. & Torres, S. C. (2007). *Clima e cidade: a abordagem climática como subsídio para estudos urbanos*. edUFAL.
- Barry, R. G. (2008). *Mountain Weather and Climate* (Third). Cambridge University Press.

- Battisti, I. D. E. & Smolski, F. M. d. S. (2019). *Software R: Análise estatística de dados utilizando um programa livre*. Faith.
- Battisti, I. D. E. & Smolski, F. M. d. S. (2020). Software R: curso avançado. <https://smolski.github.io/livroavancado/>
- Bechtel, B., Alexander, P. J., Böhner, J., Ching, J., Conrad, O., Feddema, J., Mills, G., See, L. & Stewart, I. (2015). Mapping local climate zones for a worldwide database of the form and function of cities. *ISPRS International Journal of Geo-Information*, 4(1), 199–219.
- Bechtel, B. & Daneke, C. (2012). Classification of local climate zones based on multiple earth observation data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 5(4), 1191–1202.
- Beck, C., Straub, A., Breitner, S., Cyrus, J., Philipp, A., Rathmann, J., Schneider, A., Wolf, K. & Jacobeit, J. (2018). Air temperature characteristics of local climate zones in the Augsburg urban area (Bavaria, southern Germany) under varying synoptic conditions. *Urban Climate*, 25, 152–166. <http://www.sciencedirect.com/science/article/pii/S2212095518301196>
- Bettencourt, L. M. (2020). Urban growth and the emergent statistics of cities. *Science advances*, 6(34), eaat8812.
- Bornstein, R. D. (1968). Observations of the urban heat island effect in New York City. *Journal of Applied Meteorology*, 7(4), 575–582.
- Bottyán, Z. & Unger, J. (2003). A multiple linear statistical model for estimating the mean maximum urban heat island. *Theoretical and applied climatology*, 75(3-4), 233–243.
- Caliński, T. & Harabasz, J. (1974). A dendrite method for cluster analysis. *Communications in Statistics-theory and Methods*, 3(1), 1–27.
- Carvalho, B. B. (2020). *Análise do clima urbano da cidade de Bragança e a sua relação com as variáveis de morfologia urbana (2016-2019)* (tese de doutoramento N.º 1). Instituto Politécnico de Bragança.

- Cavalcanti, I. F. d. A., Ferreira, N. J., Silva, M. G. A. J. d. & Dias, M. A. F. d. S. (2009). *Tempo e clima no Brasil*. Oficina de Textos.
- Cleff, T. (2019). *Applied Statistics and Multivariate Data Analysis for Business and Economics*.
- ClimateData. (2020). Bragança Temperaturas e Precipitações. *Climate Data ORG*. <https://pt.climate-data.org/europa/portugal/braganca/braganca-141/>
- Collier, C. G. (2006). The impact of urban areas on weather. *Quarterly Journal of the Royal Meteorological Society: A journal of the atmospheric sciences, applied meteorology and physical oceanography*, 132(614), 1–25.
- Debbage, N. & Shepherd, J. M. (2015). The urban heat island effect and city contiguity. *Computers, Environment and Urban Systems*, 54, 181–194.
- Dirksen, M., Ronda, R., Theeuwes, N. & Pagani, G. (2019). Sky view factor calculations and its application in urban heat island studies. *Urban Climate*, 30, 100498.
- Dymnikov, V. P. & Filatov, A. N. (2012). *Mathematics of climate modeling*. Springer Science & Business Media.
- Edwards, A. W. & Cavalli-Sforza, L. L. (1965). A method for cluster analysis. *Biometrics*, 362–375.
- ESRI. (2020). *ArcGIS Desktop: Release 10*. CA: Instituto de Pesquisa de Sistemas Ambientais. <https://www.arcgis.com/>
- Everitt, B., Landau, S., Leese, M. & Stah, D. (2011). *Cluster analysis*.
- Fraley, C. & Raftery, A. E. (1998). How many clusters? Which clustering method? Answers via model-based cluster analysis. *The computer journal*, 41(8), 578–588.
- Gartland, L. M. (2008). *Heat islands: understanding and mitigating heat in urban areas*. Routledge.
- Gartland, L. M. (2011). *Ilhas de calor: como mitigar zonas de calor em áreas urbanas*. Oficina de Textos.
- Geiger, R. (1936). Classificação climática de Köppen- Geiger, 1–7.

- Giridharan, R., Ganesan, S. & Lau, S. (2004). Daytime urban heat island effect in high-rise and high-density residential developments in Hong Kong. *Energy and buildings*, 36(6), 525–534.
- Gonçalves, A., Ribeiro, A., Maia, F & Feliciano, M. (2014). Análise do Clima Urbano de Bragança. *Instituto Politécnico de Bragança, Bragança*.
- Gonçalves, A., Ornellas, G., Castro Ribeiro, A., Maia, F., Rocha, A. & Feliciano, M. (2018). Urban Cold and Heat Island in the City of Bragança (Portugal). *Climate*, 6(3), 70.
- Gonçalves, D., Figueiredo, T. d., Ribeiro, A. C. & Leite, S. (2016). A geografia e o clima das montanhas ibéricas.
- Greenland, D. (2005). Mountain Climates. Em J. E. Oliver (Ed.), *Encyclopedia of World Climatology* (pp. 517–523). Springer Netherlands.
- Grimmond, C. & Oke, T. R. (1999). Heat storage in urban areas: Local-scale observations and evaluation of a simple model. *Journal of applied meteorology*, 38(7), 922–940.
- Grimmond, S. U. (2007). Urbanization and global environmental change: local effects of urban warming. *Geographical Journal*, 173(1), 83–88.
- Guo, G., Wu, Z., Xiao, R., Chen, Y., Liu, X. & Zhang, X. (2015). Impacts of urban biophysical composition on land surface temperature in urban heat island clusters. *Landscape and Urban Planning*, 135, 1–10.
- Hair, J., Black, B, Babin, B & Anderson, R. (2010). *Multivariate Data Analysis 6th* Pearson Prentice Hall. *Upper Saddle River, NJ*.
- Hebbert, M. & Jankovic, V. (2013). Cities and climate change: the precedents and why they matter. *Urban Studies*, 50(7), 1332–1347.
- Henegar, C. (2012). *FunCluster: Functional Profiling of Microarray Expression Data* [R package version 1.09]. <https://CRAN.R-project.org/package=FunCluster>
- Hernández Aja, A., Fariña Tojo, J., Gálvez Huerta, M. Á., Fernández Áñez, V., Gonçalves, A., Ribeiro, A. & Feliciano, M. (2013). Manual de desenho bioclimático urbano. Manual de orientações para a elaboração de normas urbanísticas.

- Hidalgo, J. & Jouglu, R. (2018). On the use of local weather types classification to improve climate understanding: An application on the urban climate of Toulouse. *PLoS one*, 13(12), e0208138.
- Hidalgo, J., Masson, V. & Baehr, C. (2014). From daily climatic scenarios to hourly atmospheric forcing fields to force Soil-Vegetation-Atmosphere transfer models. *Frontiers in Environmental Science*, 2, 40.
- Howard, L. (1818). *The climate of London* (Vol. 1). W. Phillips, sold also by J.; A. Arch.
- Hyvärinen, A. Chapter 3 - A unified probabilistic model for independent and principal component analysis (E. Bingham, S. Kaski, J. Laaksonen & J. Lampinen, Eds.). Em: *Advances in Independent Component Analysis and Learning Machines* (E. Bingham, S. Kaski, J. Laaksonen & J. Lampinen, Eds.). Ed. por Bingham, E., Kaski, S., Laaksonen, J. & Lampinen, J. Academic Press, 2015, pp. 75 –82. ISBN: 978-0-12-802806-3.
- IBM Corp. (2020). *BM SPSS Statistics for Windows, Version 27.0*. IBM Corp. Armonk, NY. <https://www.R-project.org/>
- Iyigun, C., Türkeş, M., Batmaz, bibinitperiodI., Yozgatligil, C., Purutçuoğlu, V., Koç, E. K. & Öztürk, M. Z. (2013). Clustering current climate regions of Turkey by using a multivariate statistical method. *Theoretical and applied climatology*, 114(1-2), 95–106.
- Javanroodi, K. & Nik, V. M. (2020). Urban Climate Interactions between extreme climate and urban morphology : Investigating the evolution of extreme wind speeds from mesoscale to microscale. *Urban Climate*, 31(May 2019), 100544.
- Joseph Jr, F, William, C, Barry, J. B. & Rolph, E. A. (2009). *Multivariate Data Analysis-7th*. Pearson Education Limited.
- Kassambara, A. (2017). Practical guide to principal component methods in R (Multivariate analysis)(Volume 2).
- Kassambara, A. (2018). *Machine Learning Essentials: Practical Guide in R*. sthda.

- Kassambara, A. & Mundt, F. (2020). *factoextra: Extract and Visualize the Results of Multivariate Data Analyses* [R package version 1.0.7]. <https://CRAN.R-project.org/package=factoextra>
- Kohler, T., Giger, M., Hurni, H., Ott, C., Wiesmann, U., von Dach, S. W. & Maselli, D. (2010). Mountains and Climate Change: A Global Concern. *Mountain Research and Development*, 30(1), 53–55.
- Köppen, W & Geiger, R. (1928). *Klimate der Erde*. Gotha: Verlag Justus Perthes. *Wall-map 150cmx200cm*.
- Kratzer, A. (1956). *Das stadtklima* (Vol. 90). F. Vieweg.
- Landsberg, H. E. (1981). *The urban climate*. Academic press.
- László, E. & Szegedi, S. (2015). A multivariate linear regression model of mean maximum urban heat island: a case study of wicki2019quantification Beregszász (Berehove), Ukraine. *Időjárás/Quarterly Journal Of The Hungarian Meteorological Service*, 119(3), 409–423.
- Lê, S., Josse, J. & Husson, F. (2008). FactoMineR: A Package for Multivariate Analysis. *Journal of Statistical Software*, 25(1), 1–18.
- Leconte, F., Bouyer, J., Claverie, R. & Pétrissans, M. (2015). Using Local Climate Zone scheme for UHI assessment: Evaluation of the method using mobile measurements [Special Issue: Climate adaptation in cities]. *Building and Environment*, 83, 39–49. <http://www.sciencedirect.com/science/article/pii/S0360132314001413>
- Lee, D. & Oh, K. (2018). Classifying urban climate zones (UCZs) based on statistical analyses. *Urban Climate*, 24, 503–516. <http://www.sciencedirect.com/science/article/pii/S2212095517300524>
- Lee, D., Oh, K. & Jung, S. (2019). Classifying Urban Climate Zones (UCZs) Based on Spatial Statistical Analyses. *Sustainability*, 11(7), 1915.
- Lee, W. S., Kim, K. T., Park, H., Jung, S. G., You, J. H., Oh, J. H. & Yoon, Y. C. Effects of spatial characteristics on the Urban thermal environment in Changwon, Korea. Em: *Proceeding of the 7th International Conference on Urban Climate, Yokohama, Japan*. 2009.

- Lobo, M. C., Pardal, S, Correia, P & Lobo, M. S. (1995). Normas Urbanísticas-Princípios e Conceitos Fundamentais (2^a ed.). 2^a edição, 1.
- Magee, N, Curtis, J & Wendler, G. (1999). The urban heat island effect at Fairbanks, Alaska. *Theoretical and applied climatology*, 64(1-2), 39–47.
- Maia, F., Gonçalves, A., Rocha, A, Ribeiro, A. & Feliciano, M. Avaliação da Ilha de calor de Bragança. Em: 10^a Conferência Nacional do Ambiente/XII Congresso Nacional do Ambiente. 3. Universidade de Aveiro. 2013, 704–709.
- Makles, A. (2012). Stata tip 110: How to get the optimal k-means cluster solution. *The Stata Journal*, 12(2), 347–351.
- Marques, D. M. G. (2012). *Contributo da climatologia para a sustentabilidade urbana: o caso da Figueira da Foz* (Tese). Universidade de Coimbra.
- Matsuo, K. & Tanaka, T. (2014). Urban Environmental Climate Maps for Urban Planning Considering Urban Heat Island Mitigation in Hiroshima. *Journal of Heat Island Institute International Vol, 9, 2*.
- Matzarakis, A. & Matuschek, O. (2011). Sky view factor as a parameter in applied climatology rapid estimation by the SkyHelios model. *Meteorologische Zeitschrift*, 20(1), 39–45.
- Matzarakis, A. & Mayer, H. Dependence of urban climate on urban morphology. Em: 5th Japanese-German meeting on urban climatology. Citeseer. 2009, 277–282.
- Memon, R. A., Leung, D. Y. & Liu, C.-H. (2009). An investigation of urban heat island intensity (UHII) as an indicator of urban heating. *Atmospheric Research*, 94(3), 491–500.
- Mendonça, F. & Danni-Oliveira, I. M. (2007). *Climatologia: noções básicas e climas do Brasil*. Oficina de Textos.
- Menezes, G. d. O. (2017). *Análise do clima urbano da cidade de Bragança (2012-2016): estudo da ilha de calor* (Dissertação). Instituto Politécnico de Bragança. Bragança, Portugal.
- Menezes, G. d. O., Gonçalves, A., Ribeiro, A. C., Feliciano, M. & Bineli, A. R. (2017). Análise do efeito de ilha de calor urbano na cidade de Bragança.

- Middel, A., Häb, K., Brazel, A. J., Martin, C. A. & Guhathakurta, S. (2014). Impact of urban form and design on mid-afternoon microclimate in Phoenix Local Climate Zones. *Landscape and Urban Planning*, 122, 16 –28.
- Mills, G., Cleugh, H., Emmanuel, R., Endlicher, W., Erell, E., McGranahan, G., Ng, E., Nickson, A., Rosenthal, J. & Steemer, K. (2010). Climate Information for Improved Planning and Management of Mega Cities (Needs Perspective) [World Climate Conference - 3]. *Procedia Environmental Sciences*, 1, 228 –246.
- Mills, G. (2014). Urban climatology: History, status and prospects. *Urban Climate*, 10, 479–489. <http://www.sciencedirect.com/science/article/pii/S2212095514000443>
- Measurement and modelling of the urban atmosphere in the present and the past
- Monteiro, V. S. et al. (2018). Zonas Climáticas Locais e a relação com a morfologia urbana. Estudo de caso: Campinas/SP.
- Muller, C. L., Chapman, L., Grimmond, C., Young, D. T. & Cai, X. (2013). Sensors and the city: a review of urban meteorological networks. *International Journal of Climatology*, 33(7), 1585–1600.
- Netzel, P. & Stepinski, T. (2016). On using a clustering approach for global climate classification. *Journal of Climate*, 29(9), 3387–3401.
- Oke, P. R., OKE, T., Oke, T. & Oke, T. (2006). Towards better scientific communication in urban climate. *Theoretical and Applied Climatology*, 84(1-3), 179–190.
- Oke, T. R. (1988). The urban energy balance. *Progress in Physical geography*, 12(4), 471–508.
- Oke, T. R. (2006). Initial guidance to obtain representative meteorological observations at urban sites (World Meteorological Organization). (81), 1–51.
- Oke, T. R. Siting and Exposure of Meteorological Instruments at Urban Sites (C. Borrego & A.-L. Norman, Eds.). Em: *Em Air Pollution Modeling and Its Application XVII* (C. Borrego & A.-L. Norman, Eds.). Ed. por Borrego, C. & Norman, A.-L. Boston, MA: Springer US, 2007, 615–631. ISBN: 978-0-387-68854-1.
- Oke, T. R. (1982). The energetic basis of the urban heat island. *Quarterly Journal of the Royal Meteorological Society*, 108(455), 1–24.

- Oke, T. R. Climate of cities. Em: *Climate in Human Perspective*. Springer, 1991, pp. 61–75.
- Oke, T. R. (2002). *Boundary layer climates*. Routledge.
- Oke, T. R., Mills, G., Christen, A. & Voogt, J. A. (2017). *Urban Climates*. Cambridge University Press.
- Oke, T. (1984). Methods in urban climatology. *Applied Climatology*, 14, 19–29.
- Orlanski, I. (1975). A rational subdivision of scales for atmospheric processes. *Bulletin of the American Meteorological Society*, 527–530.
- Peixoto, J. P. & Oort, A. H. (1992). Physics of climate.
- Perera, N. & Emmanuel, R. (2018). A “Local Climate Zone” based approach to urban planning in Colombo, Sri Lanka [ICUC9: The 9th International Conference on Urban Climate]. *Urban Climate*, 23, 188 –203. <http://www.sciencedirect.com/science/article/pii/S2212095516300566>
- Póhrolniczak, M., Kolendowicz, L., Majkowska, A. & Czernecki, B. (2017). The influence of atmospheric circulation on the intensity of urban heat island and urban cold island in Poznań, Poland. *Theoretical and Applied Climatology*, 127(3-4), 611–625.
- Prado, B. Q. d. M., Fernandes, H. R., Araña, T. G., Laia, G. A. & Biase, N. A. G. (2016). Avaliação de variáveis climatológicas da cidade de Uberlândia (MG) por meio da análise de componentes principais. *Engenharia Sanitaria e Ambiental*, 21, 407 –413. http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-41522016000200407&nrm=iso
- QGIS Development Team. (2020). *QGIS Geographic Information System*. Open Source Geospatial Foundation Project. <http://www.qgis.org/>
- R Core Team. (2020). *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria. <https://www.R-project.org/>
- Rao, C. R. (1964). The use and interpretation of principal component analysis in applied research. *Sankhyā: The Indian Journal of Statistics, Series A*, 329–358.

- Ren, C., Cai, M., Li, X., Zhang, L., Wang, R., Xu, Y. & Ng, E. (2019). Assessment of Local Climate Zone Classification Maps of Cities in China and Feasible Refinements. *Scientific reports*, *9*(1), 1–11.
- Ren, C., Ng, E. Y.-y. & Katzschner, L. (2011). Urban climatic map studies: a review. *International journal of climatology*, *31*(15), 2213–2233.
- Rhee, J., Im, J., Carbone, G. J. & Jensen, J. R. (2008). Delineation of climate regions using in-situ and remotely-sensed data for the Carolinas. *Remote Sensing of Environment*, *112*(6), 3099–3111.
- Ribeiro, A. G. (1993). As escalas do clima. *Boletim de Geografia Teorética*, *23*(45-46), 288–294.
- Rizwan, A. M., Dennis, L. Y. & Liu, C. (2008). A review on the generation, determination and mitigation of Urban Heat Island. *Journal of Environmental Sciences*, *20*(1), 120–128.
- Rousseeuw, P. J. & Kaufman, L. (1990). Finding groups in data. *Hoboken: Wiley Online Library*, *1*.
- Sakakibara, Y. & Owa, K. (2005). Urban–rural temperature differences in coastal cities: Influence of rural sites. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, *25*(6), 811–820.
- Salvati, A., Monti, P., Coch Roura, H. & Cecere, C. (2019). Climatic performance of urban textures: Analysis tools for a Mediterranean urban context. *Energy and Buildings*, *185*, 162–179.
- Santos, C. A. G., Brasil Neto, R. M., da Silva, R. M. & Costa, S. G. F. (2019). Cluster analysis applied to spatiotemporal variability of monthly precipitation over Paraíba state using tropical rainfall measuring mission (TRMM) data. *Remote Sensing*, *11*(6), 637.
- Siu, L. W. & Hart, M. A. (2013). Quantifying urban heat island intensity in Hong Kong SAR, China. *Environmental Monitoring and Assessment*, *185*(5), 4383–4398.

- Sormin, M. K. Z., Sihombing, P., Amalia, A., Wanto, A., Hartama, D. & Chan, D. M. Predictions of World Population Life Expectancy Using Cyclical Order Weight/-Bias. Em: *Journal of Physics: Conference Series*. 1255. (1). IOP Publishing. 2019, 012017.
- Steinke, E. T. (2016). *Climatologia fácil* (first). Oficina de Textos.
- Stewart, I. D. & Oke, T. R. (2012). Local Climate Zones for Urban Temperature Studies. *Bulletin of the American Meteorological Society*, 93(12), 1879–1900.
- Stewart, I. D. (2011). A systematic review and scientific critique of methodology in modern urban heat island literature. *International Journal of Climatology*, 31(2), 200–217.
- Stewart, I. D., Oke, T. R. & Krayenhoff, E. S. (2014). Evaluation of the ‘local climate zone’ scheme using temperature observations and model simulations. 34(June 2013), 1062–1080.
- Szymanowski, M. & Kryza, M. (2009). GIS-based techniques for urban heat island spatialization. *Climate Research*, 38(2), 171–187.
- Szymanowski, M. & Kryza, M. (2012). Local regression models for spatial interpolation of urban heat island—an example from Wrocław, SW Poland. *Theoretical and applied climatology*, 108(1-2), 53–71.
- Tukey, J. W. (1949). Comparing individual means in the analysis of variance. *Biometrics*, 99–114.
- UN, U. N. (2015). World population prospects: The 2015 revision. *United Nations Econ Soc Aff*, 33(2), 1–66.
- Unal, Y., Kindap, T. & Karaca, M. (2003). Redefining the climate zones of Turkey using cluster analysis. *International Journal of Climatology: A Journal of the Royal Meteorological Society*, 23(9), 1045–1055.
- Vallati, A., Grignaffini, S., Romagna, M., Mauri, L. & Colucci, C. (2016). Influence of Street Canyon’s Microclimate on the Energy Demand for Space Cooling and Heating of Buildings [ATI 2016 - 71st Conference of the Italian Thermal Machines Engineering Association]. *Energy Procedia*, 101, 941–947.
- Valli, M. (2012). Análise de Cluster. *Augusto Guzzo Revista Acadêmica*, (4), 77–87.

- Van Hove, L., Jacobs, C., Heusinkveld, B., Elbers, J., Van Driel, B. & Holtslag, A. (2015). Temporal and spatial variability of urban heat island and thermal comfort within the Rotterdam agglomeration [Special Issue: Climate adaptation in cities]. *Building and Environment*, 83, 91–103. <http://www.sciencedirect.com/science/article/pii/S0360132314002881>
- Vicente-Serrano, S. M., Cuadrat-Prats, J. M. & Saz-Sánchez, M. A. (2005). Spatial patterns of the urban heat island in Zaragoza (Spain). *Climate Research*, 30(1), 61–69.
- Villas Boas, N., Doca, R. H. & Biscuola, G. J. (2007). *Tópicos de física, 2: termologia, ondulatória e óptica*. (19^a ed.).
- Wanner, H. & Filliger, P. (1989). Orographic Influence On Urban Climate. *Weather and Climate*, 9(1), 22–28.
- Wei, R., Song, D., Hien, N. & Martin, M. (2016). Impact of Urban Morphology Parameters on Microclimate. *Procedia Engineering*, 169, 142–149.
- Weisberg, S. (2005). *Applied linear regression* (3th). John Wiley & Sons.
- Wicki, A., Parlow, E. & Feigenwinter, C. (2018). Evaluation and modeling of urban heat island intensity in Basel, Switzerland. *Climate*, 6(3), 55.
- Wicki, A., Parlow, E. & Feigenwinter, C. Quantification of Urban Heat Island Distribution Using Multiple Linear Regression Models in Basel/Switzerland. Em: *Geophysical Research Abstracts*. 21. 2019.
- Xu, Y., Ren, C., Ma, P., Ho, J., Wang, W., Lau, K. K.-l., Lin, H. & Ng, E. (2017). Urban morphology detection and computation for urban climate research. *Landscape and Urban Planning*, 167(May), 212–224.
- Yan, X. & Su, X. (2009). Linear regression analysis: theory and computing.
- Yang, X., Li, Y., Luo, Z. & Chan, P. W. (2016). The urban cool island phenomenon in a high-rise high-density city and its mechanisms. *International Journal of Climatology*, 37(2), 890–904.

- Yufeng Luo, Yunlu Jiang, Khan, S., Shizhang Peng, Yuehua Feng & Bin Han. Analysis of urban heat island effect using k-means clustering. Em: *The 2nd International Conference on Information Science and Engineering*. 2010, 3543–3546.
- Zakšek, K., Oštir, K. & Kokalj, Ž. (2011). Sky-view factor as a relief visualization technique. *Remote sensing*, 3(2), 398–415.
- Zhang, W., Jiang, J. & Zhu, Y. (2015). Change in urban wetlands and their cold island effects in response to rapid urbanization. *Chinese geographical science*, 25(4), 462–471.
- Zhao, C., Fu, G., Liu, X. & Fu, F. (2011). Urban planning indicators, morphology and climate indicators: A case study for a north-south transect of Beijing, China. *Building and Environment*, 46(5), 1174 –1183.
- Zhou, B., Rybski, D. & Kropp, J. P. (2013). On the statistics of urban heat island intensity. *Geophysical research letters*, 40(20), 5486–5491.

Apêndice A

Sobre o Trabalho

A.1 Citação

Parra, J. H. (2020). Modelação Matemática do clima urbano da cidade de Bragança (Portugal): Zonas Climáticas Locais e Intensidade das Ilhas de Calor e de Frio. (Dissertação de mestrado, Instituto Politécnico de Bragança, Bragança, Portugal).

A.2 Proposta inicial

A proposta inicial do trabalho previa a modelação matemática do clima urbano utilizando a metodologia de Análise de *Clusters* para o agrupamento dos dados de temperatura e humidade, obtidos a cada 10 minutos pelos sensores no período de 2016 e 2019, de modo a identificar as zonas climáticas locais da cidade de Bragança. Também pretendia utilizar dos índices de morfologia urbana para encontrar um modelo de Regressão Linear Múltipla que expresse a relação desses índices com a intensidade do efeito de ilha de calor e frio urbano. Como as variáveis temperatura e humidade são muito relacionadas, utilizou-se apenas dos dados de temperatura e suas variações (máximas, mínimas, médias, intensidade de EICU) para realizar a AC, também identificou-se que a quantidade de dados gerados a cada 10 minutos era muito grande para os modelos, dessa forma, utilizou-se de médias horárias. Para as regressões lineares a mudança de planos se deu na identificação de que uma única regressão seria difícil de explicar a relação dos índices na temperatura

ao longo do ano, dessa forma 12 modelos foram gerados de modo a identificar o comportamento máximo, médio e mínimo, nas quatro estações do ano.

A.3 Contribuição Científica

Apresentação do trabalho "Mathematical modelling of Local Climate Zones in the city of Bragança, Portugal" escrito por Johicy Parra, João Paulo Pais de Almeida, Artur Jorge de Jesus Gonçalves e Joseane Debora Peruço Theodoro no evento Encontro de Jovens Investigadores (EJI) que se realizou no dia 05 de Dezembro de 2019, no Instituto Politécnico de Bragança.

Apresentação do trabalho "Modelação matemática das Zonas Climáticas Locais da cidade de Bragança, Portugal" escrito por Johicy Parra, João Paulo Pais de Almeida, Artur Jorge de Jesus Gonçalves e Joseane Debora Peruço Theodoro no evento Conferência Internacional de Sustentabilidade na Gestão Ambiental (SGA'20) que se realizou nos dias dias 24 e 25 de junho de 2020, na plataforma Zoom.

Bolsa de investigação durante o período de julho a outubro de 2020 atribuída pela Fundação para a Ciência e a Tecnologia (FCT) no Edital Verão com Ciência.

Apêndice B

Envolvente dos Sensores



Sensor 1.



Sensor 2.



Sensor 3.



Sensor 4.



Sensor 5.



Sensor 6.



Sensor 7.



Sensor 8.



Sensor 9.

Figura B.1: Fotografias das Envolturas dos Sensores.



Sensor 10.



Sensor 11.



Sensor 12.



Sensor 13.



Sensor 14.



Sensor 15.



Sensor 16.



Sensor 17.



Sensor 18.



Sensor 19.



Sensor 20.



Sensor 21.

Figura B.2: Fotografias das Envolturas dos Sensores.



Sensor 22.



Sensor 23.

Figura B.3: Fotografias das Envoltentes dos Sensores.

Anexo A

Classificação das ZCL por Stewart e Oke (2012)




Figura A.1: Definições resumidas para Zonas Climáticas Locais (1)
Fonte: Adaptado de Bechtel et al. (2015) e Stewart e Oke (2012)

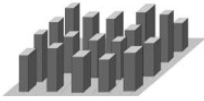
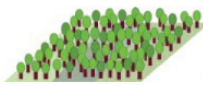



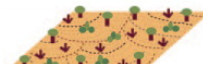


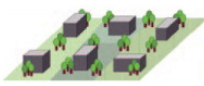

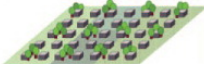

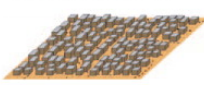




Built types	Definition	Land cover types	Definition
 <p>1. Compact high-rise</p>	Dense mix of tall buildings to tens of stories. Few or no trees. Land cover mostly paved. Concrete, steel, stone, and glass construction materials.	 <p>A. Dense trees</p>	Heavily wooded landscape of deciduous and/or evergreen trees. Land cover mostly pervious (low plants). Zone function is natural forest, tree cultivation, or urban park.
 <p>2. Compact midrise</p>	Dense mix of midrise buildings (3–9 stories). Few or no trees. Land cover mostly paved. Stone, brick, tile, and concrete construction materials.	 <p>B. Scattered trees</p>	Lightly wooded landscape of deciduous and/or evergreen trees. Land cover mostly pervious (low plants). Zone function is natural forest, tree cultivation, or urban park.
 <p>3. Compact low-rise</p>	Dense mix of low-rise buildings (1–3 stories). Few or no trees. Land cover mostly paved. Stone, brick, tile, and concrete construction materials.	 <p>C. Bush, scrub</p>	Open arrangement of bushes, shrubs, and short, woody trees. Land cover mostly pervious (bare soil or sand). Zone function is natural scrubland or agriculture.
 <p>4. Open high-rise</p>	Open arrangement of tall buildings to tens of stories. Abundance of pervious land cover (low plants, scattered trees). Concrete, steel, stone, and glass construction materials.	 <p>D. Low plants</p>	Featureless landscape of grass or herbaceous plants/crops. Few or no trees. Zone function is natural grassland, agriculture, or urban park.
 <p>5. Open midrise</p>	Open arrangement of midrise buildings (3–9 stories). Abundance of pervious land cover (low plants, scattered trees). Concrete, steel, stone, and glass construction materials.	 <p>E. Bare rock or paved</p>	Featureless landscape of rock or paved cover. Few or no trees or plants. Zone function is natural desert (rock) or urban transportation.
 <p>6. Open low-rise</p>	Open arrangement of low-rise buildings (1–3 stories). Abundance of pervious land cover (low plants, scattered trees). Wood, brick, stone, tile, and concrete construction materials.	 <p>F. Bare soil or sand</p>	Featureless landscape of soil or sand cover. Few or no trees or plants. Zone function is natural desert or agriculture.
 <p>7. Lightweight low-rise</p>	Dense mix of single-story buildings. Few or no trees. Land cover mostly hard-packed. Lightweight construction materials (e.g., wood, thatch, corrugated metal).	 <p>G. Water</p>	Large, open water bodies such as seas and lakes, or small bodies such as rivers, reservoirs, and lagoons.
 <p>8. Large low-rise</p>	Open arrangement of large low-rise buildings (1–3 stories). Few or no trees. Land cover mostly paved. Steel, concrete, metal, and stone construction materials.	VARIABLE LAND COVER PROPERTIES	
 <p>9. Sparsely built</p>	Sparse arrangement of small or medium-sized buildings in a natural setting. Abundance of pervious land cover (low plants, scattered trees).	<p><i>b. bare trees</i></p>	Leafless deciduous trees (e.g., winter). Increased sky view factor. Reduced albedo.
 <p>10. Heavy industry</p>	Low-rise and midrise industrial structures (towers, tanks, stacks). Few or no trees. Land cover mostly paved or hard-packed. Metal, steel, and concrete construction materials.	<p><i>s. snow cover</i></p>	Snow cover >10 cm in depth. Low admittance. High albedo.
		<p><i>d. dry ground</i></p>	Parched soil. Low admittance. Large Bowen ratio. Increased albedo.
		<p><i>w. wet ground</i></p>	Waterlogged soil. High admittance. Small Bowen ratio. Reduced albedo.

Figura A.2: Definições resumidas para zonas climáticas locais (2)

Fonte: Stewart e Oke (2012)

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>Sparsely 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

Figura A.3: Definições resumidas para zonas climáticas locais (3)

Fonte: Stewart e Oke (2012)