



UNIVERSIDADE TECNÓLOGICA FEDERAL DO PARANÁ
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL
MULTICAMPI APUCARANA E LONDRINA

NATÁLIA PIANCA STIER

MODELAGEM ESTATÍSTICA DA ILHA URBANA DE CALOR

LONDRINA

2021

NATÁLIA PIANCA STIER

MODELAGEM ESTATÍSTICA DA ILHA URBANA DE CALOR

STATISTICAL MODELING OF THE URBAN HEAT ISLAND

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Ambiental / multicampi Apucarana e Londrina da Universidade Tecnológica Federal do Paraná, como requisito à obtenção do título de Mestre em Engenharia Ambiental.

Área de Concentração: Engenharia Ambiental

Linha de Pesquisa: Poluição Atmosférica

Orientador(a): Prof(a). Dr(a). Patricia Krecl.

LONDRINA

2021



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite que outros remixem, adaptem e criem a partir do trabalho para fins não comerciais, desde que atribuam o devido crédito e que licenciem as novas criações sob termos idênticos.

Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.



**Ministério da Educação
Universidade Tecnológica Federal do Paraná
Câmpus Londrina**



NATALIA PIANCA STIER

MODELAGEM ESTATÍSTICA DA ILHA URBANA DE CALOR

Trabalho de pesquisa de mestrado apresentado como requisito para obtenção do título de Mestra Em Engenharia Ambiental da Universidade Tecnológica Federal do Paraná (UTFPR). Área de concentração: Engenharia Ambiental.

Data de aprovação: 04 de Março de 2021

Prof.a Patricia Krecl Abad, - Universidade Tecnológica Federal do Paraná

Prof Admir Creso De Lima Targino, Doutorado - Universidade Tecnológica Federal do Paraná

Prof Francisco Jablinski Castelhana, Doutorado - Universidade Estadual do Centro Oeste (Unicentro)

Documento gerado pelo Sistema Acadêmico da UTFPR a partir dos dados da Ata de Defesa em 06/03/2021.

AGRADECIMENTOS

Agradeço a minha professora e orientadora, Prof^a. Dr^a. Patricia Krecl, pelo aprendizado adquirido durante estes anos de estudo, assim como pela paciência, oportunidade e confiança depositadas em mim.

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte financeiro, à EMBRAPA Soja (Empresa Brasileira de Pesquisa Agropecuária), ao Sistema Meteorológico do Paraná (SIMEPAR), ao Prof. Dr. Admir Targino, Gabriel Oukawa, Rodrigo Favaro e Dr. Max Anjos por disponibilizarem os dados meteorológicos utilizados neste estudo.

Agradeço à Deus, meus pais, meu irmão e namorado pelo suporte, compreensão e conselhos nos momentos de desânimo, pela cumplicidade e por respeitarem minha ausência. A minha psicóloga que nunca desistiu de mim e me guiou em cada passo durante essa jornada.

A todos os professores, que estiveram presentes nessa caminhada, transmitindo seus conhecimentos, experiências e incentivos, oferecendo sugestões e soluções para as mais adversas situações.

Agradeço, por fim, aos meus amigos do Laboratory for Urban Air Pollution and Climate e do mestrado, por compartilharem todo o conhecimento e experiências nos momentos de dificuldades, pelo apoio e carinho.

A todos aqueles que, direta ou indiretamente, contribuíram para a realização deste trabalho, meu muito obrigada.

STIER, NATÁLIA PIANCA. **Modelagem estatística da ilha urbana de calor**. 2021. 92 folhas. Dissertação (Mestrado em Engenharia Ambiental) – Universidade Tecnológica Federal do Paraná, Londrina, 2021.

RESUMO

A rápida urbanização produz mudanças significativas na paisagem de uma região devido à substituição de superfícies naturais por materiais impermeáveis e às atividades antrópicas. Tais alterações diminuem a evapotranspiração, aumentam a temperatura da superfície e do ar, interferem na dinâmica atmosférica, formando uma ilha urbana de calor (IUC), que consiste da diferença de temperatura entre a área urbana e rural. A IUC causa impactos meteorológicos, econômicos, sociais, ambientais, biológicos e na saúde humana. Portanto, este estudo caracterizou a formação e o desenvolvimento da IUC em Londrina, região norte do Paraná, a partir de treze pontos de coleta de dados distribuídos em seu tecido urbano no período de 27/08/2018 a 13/12/2018. Inicialmente, calculou-se a intensidade da ilha urbana de calor (IIUC) e posteriormente, selecionou-se as variáveis independentes para aplicar um modelo de regressão linear múltipla (RLM) para modelar a temperatura do ar durante o período de estudo diurno (06h00-18h00) e noturno (18h00 – 06h00). A metodologia *bootstrap* foi aplicada para validar os modelos diurno e noturno, separadamente. Essa abordagem valida um modelo multivariado extraindo um grande número de subamostras e estimando modelos para cada uma delas. Os resultados mostraram que a temperatura do ar média diária variou entre 12,5 °C e 30,5 °C durante o período de estudo. Foi observada a presença de uma IUC, principalmente no centro da cidade e no período noturno, com intensidade média entre 1,1 °C e 3,0 °C, assim como a presença de ilha urbana fria (IUF) durante o período diurno com valores entre -0,3 e 0 °C. O modelo RLM identificou como variáveis preditoras a irradiância solar, umidade relativa e pressão para o dia, assim como, velocidade e direção do vento, umidade relativa e pressão para a noite. A RLM apresentou um valor de R^2 ajustado de 0,76 e 0,60 e RMSE igual a 2,39 °C e 2,38 °C para o dia e para a noite, respectivamente.

Palavra-chave: Ilha urbana de calor; Clima urbano; Modelagem; Temperatura do ar.

STIER, NATÁLIA PIANCA. **Statistical modeling of the urban heat island**. 2021. 92 pages. Dissertation (Master in Environmental Engineering) – Federal University of Technology – Paraná, Londrina, 2021.

ABSTRACT

Rapid urbanization produces significant changes in the landscape of a region due to the replacement of natural surfaces with impermeable materials and human activities. Such changes decrease evapotranspiration, increase surface and air temperature, interfere with atmospheric dynamics, forming an urban heat island (IUC), which consists of the temperature difference between urban and rural areas. The IUC causes meteorological, economic, social, environmental, biological and human health impacts. Therefore, this study characterized the formation and development of the IUC in Londrina, northern Paraná, from thirteen points of data collection distributed in its urban fabric in the period from 27/08/2018 to 12/13/2018. Initially, the intensity of the urban heat island (IIUC) was calculated and later, the candidate variables were selected to apply a multiple linear regression model (RLM) to model the air temperature during the daytime study period (06:00 am- 18h00) and night (18h00 - 06h00). The bootstrap methodology was applied to validate the daytime and nighttime models, separately. This approach validates a multivariate model by extracting a large number of subsamples and estimating models for each one. The results showed that the average daily air temperature varied between 12.5 °C and 30.5 °C during the study period. The presence of an IUC was observed, mainly in the city center and at night, with an average intensity between 1.1 °C and 3.0 °C, as well as the presence of a cold urban island (IUF) during the day with values between -0.3 and 0 °C. The RLM model identified the solar irradiance, relative humidity and pressure for the day as predictive variables, as well as wind speed and direction, relative humidity and pressure for the night. The RLM presented an adjusted R^2 value of 0.76 and 0.60 and RMSE equal to 2.39 °C and 2.38 °C for day and night, respectively.

Keywords: Urban Heat Island; Urban Climate; Modeling; Air Temperature.

LISTA DE FIGURAS

FIGURA 1 - Seção transversal de um modelo idealizado de cidade mostrando a temperatura do ar ao longo da linha A-B.	16
FIGURA 2 - Representação esquemática da estrutura vertical da camada limite urbana (CLU). Camada do dossel urbano (CDU); Camada limite planetária (CLP); Camada limite superficial (CLS); Camada Limite Rural (CLR) e Subcamada de rugosidade (SR). As setas pontilhadas verticais simbolizam a extensão espacial de cada camada. As setas sólidas indicam a direção do fluxo de ar.	18
FIGURA 3 - Mecanismos de formação das ilhas urbanas de calor.	20
FIGURA 4 - Número de publicações listadas na Science Direct e Google Acadêmico sob os termos de pesquisa “Temperatura do ar”, “Ilha de Calor”, “Clima Urbano”, “Brasil” e “Air Temperature”, “Heat Island”, “Urban Climate” e “Brazil”.....	24
FIGURA 5 - Localização do município de Londrina no Estado do Paraná.....	31
FIGURA 6 - Climograma de Londrina para o período de 1989-2019.....	32
FIGURA 7 - Equipamentos de medição. a) HOBO U23-001 e b) Protetor.....	33
FIGURA 8 - Caracterização do entorno das estações meteorológicas e sua localização (ponto vermelho). O raio considerado dos buffers foi de 100m.	34
FIGURA 9 - Fluxograma do método stepwise.....	37
FIGURA 10 - Área de influência ao redor do local de monitoramento IGP mostradas através de um buffer com raio de a) 100 m e b) 600 m.	43
FIGURA 11 - Boxplot de temperatura máxima (vermelho), média (verde) e mínima (azul) diária para todo o período de estudo. Os pontos pretos são as médias. O limite inferior das caixas é o percentil 25 e o superior é o percentil 75. Os bigodes representam os valores mínimos e máximos de temperatura. A linha central da caixa é a mediana.	49
FIGURA 12 - a) Série horária da temperatura média para os dias 31/08 e 01/09 e b) Série horária da IIUC para os dias 31/08 e 01/09.....	50
FIGURA 13 - Ciclo médio diário da temperatura do ar para as 13 estações meteorológicas.....	52
FIGURA 14 - Distribuição espacial da IIUC média horária.	53
FIGURA 15 - Distribuição espacial da IIUC média máxima.....	54

FIGURA 16 - Distribuição espacial da IIUC média mínima.....	55
FIGURA 17 - Ciclo médio diário da IIUC. As linhas verticais correspondem ao período diurno (06h -18h).....	56
FIGURA 18 - Histograma com a velocidade do vento. a) Dados sem a transformação e b) Dados após a transformação. A linha vermelha representa a função de densidade normal.....	60
FIGURA 19 - Rosa dos ventos para o período de estudo.	63
FIGURA 20 - Análise de normalidade dos resíduos dos modelos diurno e noturno. a) Histograma do resíduo do modelo diurno. b) Probabilidade normal para o modelo diurno. c) Histograma do resíduo do modelo noturno. d) Probabilidade normal para o modelo noturno.	69
Figura 21 - Correlação entre os valores de temperatura coletados e modelados para os períodos diurno (a) e noturno (b), quando as observações influentes foram excluídas da análise.....	70

LISTA DE TABELAS

TABELA 1 -Exemplos da transformação de Box-Cox.....	39
TABELA 2 - Correspondência entre os pontos cardeais e subcardeais e seus graus	45
TABELA 3 - Amplitude térmica média diária para o período de 27/08 a 13/12/2018.	51
TABELA 4 - Comparação com estudos de IUC com métricas semelhantes as deste estudo.....	66
TABELA 5 - Métricas de desempenho do bootstrapping para os modelos diurno e noturno com 300 simulações.....	68
TABELA 6 - Equações de regressão linear para os modelos diurno e noturno a partir do bootstrapping com 300 simulações.....	68
TABELA 7 - Diagnósticos considerados para identificar observações influentes e número de amostras identificadas.....	69

LISTA DE QUADROS

QUADRO 1 - Tipos de IUC.	17
QUADRO 2 - Efeitos ocasionados pela IUC.	21
QUADRO 3 - Métodos para estudar a IUC	26
QUADRO 4 - Tipos de resolução de imagem captada por sensoriamento remoto...29	
QUADRO 5 - Suposições da RLM.	36
QUADRO 6 - Diagnósticos utilizados para análise de observações influentes.....	41
QUADRO 7 - Variáveis inseridas nos modelos	58

SUMÁRIO

1 INTRODUÇÃO	12
1.1 OBJETIVOS.....	14
2 REVISÃO DE LITERATURA	15
2.1 CLIMA URBANO.....	15
2.2 ILHA URBANA DE CALOR.....	16
2.2.1 Definição, tipos e efeitos da ilha urbana de calor.....	16
2.2.2 Desenvolvimento e formação da IUC.....	18
2.2.3. Impactos da IUC.....	20
2.2.4 Vínculo entre IUC, crescimento urbano e mudanças climáticas.....	22
2.3 ESTUDOS DE IUC NO BRASIL.....	22
2.4 MÉTODOS DE ESTUDO DA IUC.....	24
2.4.1 Medição <i>in situ</i>	28
2.4.2 Sensoriamento remoto térmico.....	28
2.4.3 Métodos analíticos.....	29
3 MATERIAL E MÉTODOS	31
3.1 ÁREA DE ESTUDO.....	31
3.2 REDE DE MONITORAMENTO.....	32
3.3 CÁLCULO DA INTENSIDADE DA ILHA URBANA DE CALOR.....	35
3.4 ANÁLISE ESTATÍSTICA.....	35
3.4.1 Regressão Linear Múltipla.....	36
3.4.2 Teste de normalidade e Transformação de potência.....	38
3.4.3 Multicolineariedade.....	39
3.5 VARIÁVEIS INDEPENDENTES.....	42
3.5.1 Uso e ocupação do solo.....	42
3.5.2 Relevo.....	43
3.5.3 População.....	44
3.5.4 Dados meteorológicos.....	44
3.5.5 <i>Normalized difference vegetation index, Normalized difference built-up index e Water index</i>	45
3.5.6 Características dos edifícios e Fator de visão do céu.....	46
3.5.7 Cobertura de nuvens.....	47
3.6 VALIDAÇÃO DO MODELO.....	47

4. RESULTADOS E DISCUSSÃO	49
4.1 TEMPERATURA DO AR.....	49
4.2 DISTRIBUIÇÃO ESPACIAL DA IIUC	52
4.3 SELEÇÃO DAS VARIÁVEIS INDEPENDENTES	57
4.3.1 Teste de Normalidade e Transformação Logarítmica	57
4.3.2 Análise de Multicolinearidade	60
4.3.3 Resultados dos modelos <i>stepwise</i> diurno e noturno.....	61
4.3.4 Validação do modelo	68
5 CONSIDERAÇÕES FINAIS	71
5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS.....	71
REFERÊNCIAS	73
APÊNDICE A – MÉTODO DE INTERPOLAÇÃO POR KRIGAGEM	87
APÊNDICE B- PORCENTAGEM DE OCUPAÇÃO DO SOLO PARA CADA ESTAÇÃO DE MONITORAMENTO	89
APÊNDICE C- RESULTADOS DA MULTICOLINEARIDADE	90
APÊNDICE D- RESULTADOS OBTIDOS COM O MÉTODO <i>BOOTSTRAPPING</i> ..	92

1 INTRODUÇÃO

De acordo com a Organização das Nações Unidas (ONU), 4,2 bilhões de pessoas vivem atualmente em conglomerados urbanos. Estima-se que a população urbana chegará a 68% da população mundial até 2050, correspondendo a um crescimento de 2,5 bilhões de habitantes urbanos de 2018 a 2050 (ONU, 2019). Presume-se também que até 2030, a cobertura urbana irá aumentar em aproximadamente 1,2 milhões de km² (SETO; GUNERALP; HUTYRA, 2012), e que o contingente populacional estará ainda mais vulnerável às mudanças climáticas acarretadas pelas atividades antrópicas (IPCC, 2014).

A expansão das áreas urbanas e a organização da sociedade produzem modificações nas propriedades radiativas, térmicas e aerodinâmicas da superfície, alterando o padrão dinâmico e termodinâmico da baixa atmosfera (OKE, 1987). Também, mudam o uso e cobertura do solo e substituem superfícies naturais por materiais impermeáveis, resultado da ocupação de grandes áreas na cidade e nas periferias para o desenvolvimento industrial, de infraestrutura e edificações (KLEEREKOPER; ESCH; SALCEDO, 2012; RANI *et al.*, 2018). Por tanto, as cidades modificam a estrutura do dossel urbano (HU *et al.*, 2019), que é definido como uma camada com altura média entre o solo e o topo dos edifícios ou das árvores (OKE *et al.*, 2017).

A transformação das paisagens naturais nos centros urbanos, assim como as características locais (percentual de vegetação, quantidade de área urbanizada, corpos d'água, asfalto, prédios e população) e fatores meteorológicos (temperatura, velocidade do vento, precipitação, umidade relativa) (DEILAMI; KAMRUZZAMANB, LIU, 2018) acarretam diversas mudanças no ambiente. Como por exemplo, a diminuição da evapotranspiração, aumento da temperatura da superfície e do ar, a modificação do clima local e a formação de Ilha Urbana de Calor (IUC) (CIARDINI *et al.*, 2019), definida como a diferença de temperatura da superfície entre a área urbana e a rural (OKE, 1982).

O aumento da temperatura urbana está relacionado ao confinamento de radiação solar em estruturas urbanas, escassez de fontes frias (lagos e florestas) e a estagnação do ar (devido às estruturas das cidades e à poluição atmosférica) que não permitem que a radiação de onda longa escape para o espaço (KLEEREKOPER; ESCH; SALCEDO, 2012; SHAKER *et al.*, 2019).

Os residentes urbanos sofrem diretamente com os efeitos ocasionados pela IUC e os percebem por meio de impactos como, o aumento das concentrações de ozônio e material particulado, do uso residencial de água (PANTAVOU *et al.*, 2011), o consumo de energia para resfriamento e diminuição no consumo para aquecimento (SANTAMOURIS, 2014), além de impactos no bem-estar socioeconômico e ambiental (SHAKER *et al.*, 2019). Evidências sustentam que a morbidade e mortalidade de pessoas são exacerbadas em locais impactados pela IUC, uma vez que são forçadas além de suas capacidades adaptativas (GABRIEL; ENDLICHER, 2011; NORTON *et al.*, 2015).

Estudos revelam que não são apenas os grandes centros urbanos que sofrem com os efeitos ocasionados pelo aumento da temperatura, mas também as pequenas e médias cidades, principalmente devido a sua morfologia, a estrutura do ambiente urbano (muitas vezes mal planejado) e as alterações nas paisagens rurais (através da poluição do ar, da água, do solo e do subsolo) (KOPEC, 1970; PINHO; ORGAZ, 2000; CARDOSO; AMORIM, 2017).

Diante desse cenário, são necessários estudos para compreender em que medidas as atividades humanas interferem na dinâmica atmosférica e quais consequências podem ter no clima urbano, visto que os efeitos ambientais da IUC e suas estratégias de mitigação tornaram-se uma questão crucial nos programas de cidades sustentáveis (RIZVI; ALAM, IQBAL, 2019).

1.1 OBJETIVOS

O objetivo geral deste trabalho foi caracterizar a formação e o desenvolvimento da IUC na cidade de Londrina. Os seguintes objetivos específicos foram identificados:

- Determinar e quantificar a distribuição espaço-temporal da temperatura do ar na área de estudo;
- Calcular a intensidade da ilha urbana de calor (IIUC);
- Identificar as variáveis independentes (fatores meteorológicos e características locais, tais como: uso do solo, população, edifícios, declividade, hipsometria) que possam descrever a temperatura do ar;
- Modelar a temperatura do ar a partir da regressão linear múltipla (RLM) utilizando as variáveis independentes e quantificar a sua contribuição.

2 REVISÃO DE LITERATURA

2.1 CLIMA URBANO

O clima é definido como a descrição estatística do sequenciamento do tempo meteorológico numa determinada região durante um longo período. Geralmente são usados os períodos padronizados de 30 anos definidos pela Organização Meteorológica Mundial (IPCC, 2014; WMO, 2019). Já o clima urbano é o clima de uma região que é afetada pela presença de cidades e estruturas da construção civil (OKE *et al.*, 2017).

As cidades estão sujeitas a condições ambientais estressantes que são impulsionadas, em grande parte, pela variabilidade e mudanças climáticas (GIORDANO *et al.*, 2019). A variabilidade climática é definida como variações no estado médio e outros estatísticos do clima em escalas temporais variando entre décadas e milênios; já as mudanças climáticas representam a variação estatisticamente significativa das características do clima que persistem durante um longo período, podendo ser de décadas ou mais (IPCC, 2014).

Os sistemas urbanos cada vez mais densos, complexos e interdependentes, deixam as cidades vulneráveis aos desafios climáticos e ambientais (BAKLANOV *et al.*, 2018; OLIVEIRA, *et al.*, 2020), aumentando os riscos para as pessoas, economia e ecossistemas (IPCC, 2014). À medida que as cidades se desenvolvem, sua exposição aos efeitos causados pelo clima e ao risco de desastres naturais também aumenta (WORLD BANK, 2019), incluindo riscos de estresse térmico, tempestades e precipitações extremas, inundações costeiras e interiores, deslizamento de terra, poluição do ar, secas, escassez de água e aumento do nível do mar (IPCC, 2014; BAKLANOV *et al.*, 2018).

A temperatura do ar nas áreas urbanas é influenciada pela morfologia urbana, arranjos dos edifícios e as emissões de calor antropogênico (TSOKA; TSIKALOUDAKI; THEODOSIOU, 2017). Assim, existe uma preocupação crescente nos últimos anos pelo aumento da temperatura do ar, resultante das mudanças climáticas, especialmente em áreas urbanas de alta densidade e intensas IUC (RAMYAR; ZARGHAMI; BRYANT, 2019).

2.2 ILHA URBANA DE CALOR


2.2.1 Definição, tipos e efeitos da ilha urbana de calor

A urbanização é um dos aspectos mais evidentes das modificações das paisagens naturais e do clima urbano (CAI, 2019), sendo um claro exemplo a formação da IUC que causa um acréscimo na temperatura do ar e da superfície nas áreas urbanas em comparação com a área rural e os subúrbios circundantes (OKE *et al.*, 2017).

A IUC altera o balanço de energia no sistema urbano. Esse sistema é composto pelas características individuais de elementos inseridos na atmosfera (telhados, paredes, estradas, corpos humanos e edifícios) e interações atmosféricas como fluxos advectivos e convectivos (compostos por movimentos horizontais e verticais, respectivamente) (OKE *et al.*, 2017). O fenômeno é designado como ilha pela semelhança entre os padrões isotérmicos da temperatura do ar próxima à superfície e o contorno de uma ilha marítima com o campo mais frio circundante (OKE, 1995).

A Figura 1 ilustra a temperatura do ar medida ao longo de uma trajetória que atravessa a cidade de Londrina, a "ilha" é representada pelo pico no centro da figura, que acompanha o contorno das estruturas urbanas, e é limitada pelas falésias de cada lado que marcam a fronteira urbana e rural (OKE, 1982).

FIGURA 1 - Seção transversal de um modelo idealizado de cidade mostrando a temperatura do ar ao longo da linha A-B.



Fonte: Adaptado de ANJOS *et al.* (2020).

Oke e colaboradores (2017) classificaram as IUC em quatro tipos (Quadro 1) baseado nas diferenças entre as taxas de resfriamento e aquecimento entre a área urbana e rural na superfície, subsuperfície e no ar (Figura 2).

QUADRO 1 - Tipos de IUC.

TIPOS	DEFINIÇÃO
1 - Ilha Urbana de Calor de Subsuperfície (IUC_{Sub})	Diferença entre as temperaturas no solo sob a cidade e aqueles no terreno rural circundante.
2 - Ilha Urbana de Calor de Superfície (IUC_{Sup})	Diferença de temperatura na interface atmosfera - superfície da cidade e equivalente para interface de solo.
3 - Ilha Urbana de Calor da Camada Limite Urbana (IUC_{CLU})	Diferença entre a temperatura do ar e a camada entre o topo da CDU e o topo da camada limite urbana ² (CLU) e em elevações similares na camada limite atmosférica ao redor da região rural.
4 - Ilha Urbana de Calor da Camada Dossel (IUC_{CDU})	Diferença entre a temperatura contida no ar na camada de dossel urbano (CDU), e a camada entre a superfície urbana e o nível do telhado (o exterior da CDU), e corresponde à altura da camada próxima a superfície do campo.

Fonte: Adaptado de OKE *et al.* (2017).


O quarto tipo, IUC_{CDU} , foco do estudo, refere-se ao fenômeno observado em microescala a partir do solo até a altura dos telhados (Figura 2), que reúne toda a complexidade urbana associada ao armazenamento de calor pelos materiais, impermeabilização do solo, diminuição do fator de visão do céu³ (FVC) e redução da velocidade do vento (TEIXEIRA; AMORIM, 2017).

Através da descrição das características da paisagem é possível identificar a relação entre a estrutura urbana e as interações com o clima (AMORIM, 2010). A formação da IUC, depende da heterogeneidade intra-urbana dos componentes físicos e antrópicos, da rugosidade da superfície e a maneira como cada aspecto interage com as forças externas (aquecimento solar, precipitação e o fluxo de ar), resultando na produção de diferentes microclimas (TEIXEIRA; AMORIM, 2017).

²Camada limite interna formada quando a camada limite atmosférica flui pela cidade. É um fenômeno de mesoescala cujas propriedades refletem a natureza da superfície urbana (OKE *et al.*, 2017).

³O fator de visão do céu (FVC) é definido como a proporção entre a quantidade de céu vista de um determinado ponto da superfície e a potencialmente disponível (OKE, 1987).

FIGURA 2 - Representação esquemática da estrutura vertical da camada limite urbana (CLU). Camada do dossel urbano (CDU); Camada limite planetária (CLP); Camada limite superficial (CLS); Camada Limite Rural (CLR) e Subcamada de rugosidade (SR). As setas pontilhadas verticais simbolizam a extensão espacial de cada camada. As setas sólidas indicam a direção do fluxo de ar.



Fonte: Adaptado de GOSLING *et al.* (2017).

2.2.2 Desenvolvimento e formação da IUC

A remoção, substituição ou modificação da paisagem natural por materiais artificiais favorecem a formação de IUC, devido às alterações nas propriedades aerodinâmicas e radiativas da superfície e nas propriedades térmicas e hidráulicas do solo. Também modificam significativamente as características micro (até 100 m) e mesoclimática (100 m – 12 km) da superfície e da camada limite planetária (FERREIRA, 2010; OKE *et al.*, 2017).

Os principais contribuintes para o aumento da temperatura do ar e da superfície (Figura 3) e conseqüentemente para o surgimento da IUC são:

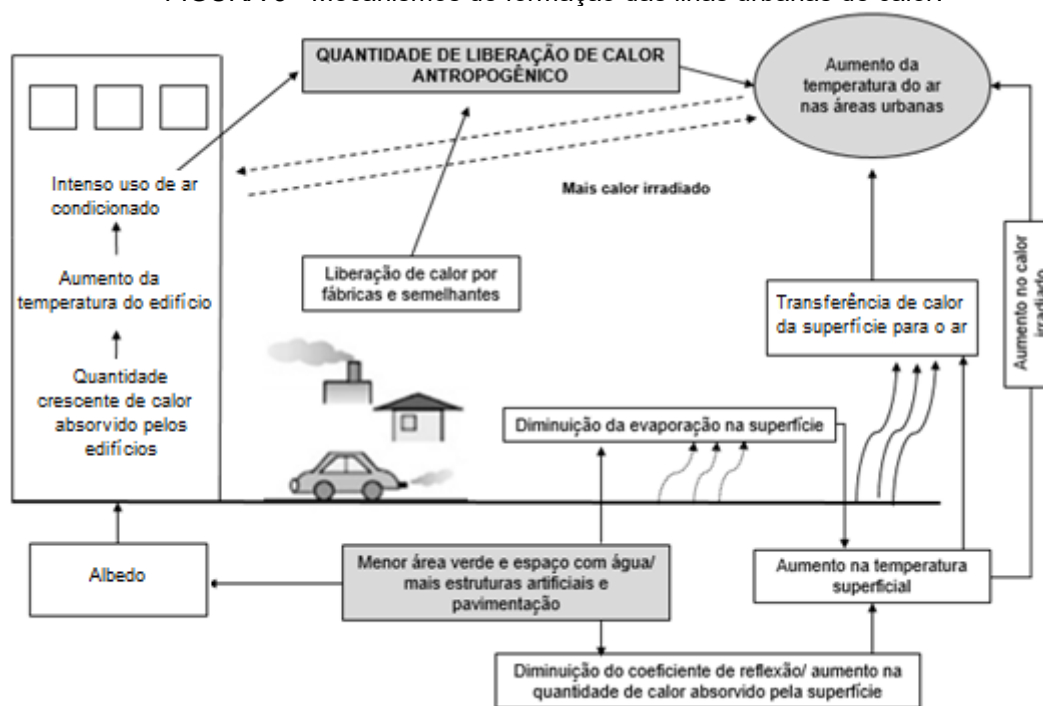
- i) Liberação de calor antropogênico, resultado do consumo de energia elétrica, calor emitido por veículos e atividades metabólicas na área urbana e o uso intensivo de ar condicionado (YAMAMOTO, 2006);
- ii) Diminuição da evapotranspiração devido à redução das áreas verdes (YAMAMOTO, 2006) e aumento de superfícies duras

- (impermeabilização do solo) (MOHAJERANI et. al., 2017), tornando o ambiente mais seco (FENGER; TJELL, 2009, KLEEREKOPER; ESCH; SALCEDO, 2012, IPING *et al.*; 2019);
- iii) Mudança na infraestrutura urbana para suprir necessidades relacionadas ao desenvolvimento econômico, transporte, recursos energéticos, comportamento e cultura que estão atrelados às medidas políticas, sensibilidade e resistência individual às mudanças e capacidade de adaptação (REVI *et al.*, 2014; OKE *et al.*, 2017; IPING *et al.*, 2019);
 - iv) Densa quantidade de edifícios que reduzem a velocidade do vento devido ao atrito (IPING, *et al.*, 2019), além da diminuição do fator de visão do céu, que por sua vez, reduz a perda de calor por ondas longas irradiadas pela superfície urbana (FENGER; TJELL, 2009; IPING *et al.*, 2019);
 - v) Aumento da densidade populacional nas cidades em comparação com a zona rural (MOHAJERANI et. al., 2017);
 - vi) Aumento da poluição do ar nas cidades, com presença de partículas finas que absorvem e reemitem radiação de onda longa para o ambiente (YAMAMOTO, 2006);
 - vii) Condições sinóticas (por exemplo, sistemas de alta pressão, deslocamento de massas de ar, sistemas frontais) e características meteorológicas locais (por exemplo, precipitação, umidade, temperatura, radiação solar) (IPING et al., 2019);
 - viii) Aumento da temperatura superficial e do ar adjacente, retenção de energia no dossel urbano (OKE et al., 2017) e captura por múltiplas reflexões entre edifícios e a superfície da rua (FENGER; TJELL, 2009; KLEEREKOPER; ESCH; SALCEDO, 2012; IPING, *et al.*, 2019) e;
 - ix) Alteração no albedo⁴, que é menor na zona urbana (efeito dos materiais e geometria e de maior área construída), acarretando maior absorção

⁴O albedo é definido como a razão da intensidade de radiação de onda curta refletida por uma superfície (refletância) e a intensidade de radiação de onda curta incidente nessa superfície (OKE *et al.*, 2017). O albedo varia de acordo com a cor e a constituição do corpo refletor.

de calor durante o dia e emissão gradual de energia durante a noite (RIZVI *et al.*, 2019, FENGER; TJELL, 2009).

FIGURA 3 - Mecanismos de formação das ilhas urbanas de calor.



Fonte: Adaptado de YAMAMOTO (2006).

Mudanças no albedo em áreas urbanas são devidas às substituições da cobertura vegetal por pavimentos (SANTAMOURIS, 2014), presença de materiais de construção (por exemplo, tijolos, concreto, aço, asfalto e telhas) com grande capacidade de aquecimento (KLEEREKOPER; ESCH; SALCEDO, 2012) e material da superfície das ruas, que apresentam características hidráulicas, radiativas e térmicas diferentes da cobertura original (GOLDEN; KALOUSH, 2006; GRIMMOND, 2007; MOHAJERANI *et al.*, 2017).

2.2.3 Impactos da IUC

A IUC gera impactos meteorológicos, econômicos, sociais, ambientais, biológicos e na saúde humana (Quadro 2). Esses impactos são maiores nos centros urbanos e mostram uma tendência urbano-rural decrescente, devido a diminuição da urbanização à medida que se aproxima da periferia (LI *et al.*, 2019).

QUADRO 2 - Efeitos ocasionados pela IUC.

TIPOS	EFEITOS	REFERÊNCIAS
Meteorológicos	Aumento de tempestades e precipitação devido a elevada quantidade de calor sensível e ao aumento da camada limite nas áreas urbanas, que criam um campo de baixa pressão e formação de nuvens.	IPING <i>et al.</i> , 2019 LUCENA <i>et al.</i> , 2011
	Aumento na intensidade e duração das ondas de calor	IPING <i>et al.</i> , 2019
Econômico e Social	Diminuição do desempenho, duração e frequência das atividades ao ar livre	IPING <i>et al.</i> , 2019
	Alto consumo de energia, já que para um aumento de 1°C na temperatura do ar, o consumo de energia aumenta 2-4%.	OKE, 1982 IPING <i>et al.</i> , 2019 YANG <i>et al.</i> , 2015 MOHAJERANI <i>et al.</i> , 2017
	Redução da demanda de energia para aquecimento durante o inverno (19%) e aumento do consumo de energia para resfriamento no verão (19%).	SANTAMOURIS, 2014 DUAN, <i>et al.</i> , 2019 LI <i>et al.</i> , 2019
Ambientais	Aumento da poluição pelas emissões de atividades urbanas, combustão em geral, queimadas e redução da cobertura vegetal. Reduzindo a radiação solar incidente (aumento da reflexão causada pela camada de poluição) e aumenta a radiação de onda longa (absorção e remissão).	ICHINOSE <i>et al.</i> , 2008 LI <i>et al.</i> , 2018 WANG <i>et al.</i> , 2018a
	Floração e florescência precoce de plantas e árvores, prolongamento da estação de crescimento e desenvolvimento de algumas aves, destruição de espécies de plantas e alteração nos ecossistemas.	KEIKHOSRAVI, 2019
	Aumento da temperatura que ocasiona alteração na dinâmica do carbono terrestre, mudança da biodiversidade urbana e aumento do uso residual de água.	SANTAMOURIS, 2014 LI; ZHOU, 2019 MEINEKE <i>et al.</i> , 2016
	Influência significativa nas propriedades químicas, concentrações e tempo de vida dos poluentes.	MIKA <i>et al.</i> , 2018
Biológicos e Saúde	Aumento do teor de ozônio no solo, do estresse térmico nos moradores e um significativo aumento no risco de mortalidade e doenças associadas ao calor.	RIZWAN, DENNIS e LU, 2008
	Doenças respiratórias alérgicas, como rinite e asma, associadas ao aumento da poluição.	MIKA <i>et al.</i> , 2018
	A mudança de temperatura e no clima podem ocasionar disseminação de doenças infecciosas e formação de epidemias, pois nos períodos de escassez de água ocorre o aumento de doenças transmitidas pela água.	
	As doenças provocadas pelo calor podem se manifestar de forma leve (queimaduras e edemas), bem como de forma grave ou letal (exaustão e insolação)	LORENZO; LIAÑO, 2017
	Efeitos na saúde mental (suicídio).	PANTAVOU <i>et al.</i> , 2011
	Hipertermia e desidratação.	THOMPSON <i>et al.</i> , 2018
Desconforto térmico e mortalidade.	MIKA <i>et al.</i> , 2018	

Fonte: Autoria própria (2021).

2.2.4 Vínculo entre IUC, crescimento urbano e mudanças climáticas

A IUC está intimamente associada ao crescimento urbano pela presença de áreas com alta densidade de edificações (BEK; AZMY; ELKAFRAWY, 2018; DORIGON; AMORIM, 2019) e, por tanto, ao aumento do estresse térmico⁵ sofrido pelos residentes urbanos (ARNFIELD, 2003).

As áreas urbanas e rurais respondem de forma diferente às mudanças climáticas, devido às alterações na temperatura do ar, precipitação, evapotranspiração, nebulosidade, velocidade do vento, na cobertura do solo e liberação de calor antropogênico (HOFFMANN; KRUEGER; SCHLUENZEN, 2012, CHAPMAN *et al.*, 2017). Ao associar mudança climática e crescimento urbano, observa-se o maior aumento na temperatura do ar do que qualquer outro fator considerado isoladamente (ARGUESO *et al.*, 2014).

Em média, a IUC aumenta a temperatura do ar em 2 °C, podendo atingir até 10 °C, dependendo da localização e condições climáticas locais (CHAPMAN *et al.*, 2017; ANJOS *et al.*, 2020). Por exemplo, um estudo realizado em 12 cidades nos EUA mostrou o aumento da temperatura do ar entre 2 °C e 5 °C (LIN *et al.*, 2013); em Sidnei observaram-se variações entre 4 °C e 10 °C (SHARIFI; LEHMANN, 2014), em Barcelona variações entre 2 °C e 7 °C (MARTIN-VIDE *et al.*, 2020) e em Londrina variações entre -2,5 °C e 11 °C (ANJOS *et al.*, 2020).

Em estudos realizados em Berlim, Londres, Milão, Madrid (TRUSILOVA; JUNG; CHURKINA, 2009) e Melbourne (COUTTS *et al.*, 2016), observou-se que as temperaturas nas áreas urbanas existentes sofriam pequena alteração à medida que ocorria a expansão urbana (com variação de 0,08 °C a 0,23 °C). No entanto, o comportamento observado foi o contrário nas novas áreas urbanizadas decorrente da substituição da cobertura do solo, com variação entre 0,20 °C e 0,60 °C.

2.3 ESTUDOS DE IUC NO BRASIL

A IUC é o mais claro e bem documentado exemplo de mudança climática local provocada pela ação antrópica (OKE *et al.*, 2017). Apesar da pesquisa sobre o efeito

⁵ Efeito das condições ambientais às quais o corpo está exposto perturbando as funções termorreguladoras (OKE *et al.*, 2017).


de IUC ter aumentando exponencialmente nas últimas décadas (DEILAMI; KAMRUZZAMAN; LIU, 2018), o conhecimento específico sobre o clima urbano tropical ainda é menor se comparado ao clima temperado (GIRIDHARAN; EMMANUEL, 2018; FONG *et al.*, 2019).

O ambiente tropical naturalmente apresenta situações de estresse térmico (AMORIM; DUBREUIL; CARDOSO, 2015), devido à temperaturas elevadas durante todo o ano (AYOADE, 1996). Esta é uma questão de grande preocupação em muitas cidades, pois a alta IUC intensifica ainda mais o estresse térmico (KOLOKOTRONI; GIRIDHARAN, 2008).

Deste modo, as pesquisas sobre IUC se mostram importantes porque a maior parte da população na zona tropical mora em cidades (GIRIDHARAN; EMMANUEL, 2018; ONU, 2019). No Brasil, 84,7% (178,4 milhões) da população é urbana e 78% mora em áreas tropicais (IBGE, 2019). Quanto ao tamanho das cidades brasileiras, a maioria da população está inserida em cidades de pequeno (até 100 mil habitantes) e médio porte (100-500 mil habitantes) e apresentam papel importante na economia nacional (AMORIM, 2019). Do total de municípios nacionais, 24,4% são de pequeno porte e 46,4% de médio porte (IBGE, 2019).

A revisão bibliográfica de estudos sobre IUC realizados no Brasil nos últimos 11 anos (Figura 4) mostrou que 87% dos trabalhos foram publicados em congressos, eventos e revistas nacionais e 13% no âmbito internacional.

FIGURA 4 - Número de publicações listadas na Science Direct e Google Acadêmico sob os termos de pesquisa “Temperatura do ar”, “Ilha de Calor”, “Clima Urbano”, “Brasil” e “Air Temperature”, “Heat Island”, “Urban Climate” e “Brazil”.



Fonte: Autoria própria (2021).

2.4 MÉTODOS DE ESTUDO DA IUC

Além da modelagem estatística, várias abordagens, incluindo métodos de observação (medição em campo, sensoriamento remoto térmico e modelagem em pequena escala) e simulação (dinâmica dos fluidos computacionais e o balanço energético) foram usadas em estudos anteriores para verificar as causas, formação e consequências da IUC, além das possíveis soluções para mitigar seus impactos (AFLAKI *et al.*, 2017). As simulações vêm tomando destaque nas últimas décadas devido aos recentes avanços nas ferramentas computacionais (MIRZAEI; HAGHIGHAT, 2010).

A modelagem estatística é baseada em dois princípios, o conjunto de variáveis de interesse e a distribuição de probabilidade associada, que deve permitir inferir as propriedades de um dado fenômeno aleatório (HAIR JR *et al.*, 2009). Muitas vezes faz-se necessário determinar fatores em um campo de estudo no qual o método experimental não pode ser aplicado, visto que os fatores que afetam o fenômeno de interesse não permanecem constantes, sendo necessário portanto, a aplicação de um método estatístico (MONTGOMERY; RUNGER, 2016).

A formação da IUC é consequência do acúmulo de fenômenos em diferentes escalas que abordam desde o corpo humano, por exemplo as atividades metabólicas, até ao tamanho da cidade. Desta forma, são necessárias resoluções diferentes para abordar simultaneamente a interação dos fenômenos.

Neste contexto, a modelagem estatística agrupa os resultados encontrados para aplicar um modelo adequado que alcance a finalidade do estudo, minimizando as complexidades e os custos das pesquisas (MIRZAEI, 2015). De acordo com Mirzaei (2015), uma série de modelos foram desenvolvidos pelos pesquisadores para prever e avaliar a eficácia de estratégias mitigadoras relacionadas à diminuição dos efeitos da IUC; esses métodos estão baseados em observações e técnicas computacionais (Quadro 5).

QUADRO 3 - Métodos para estudar a IUC.

(continua)

ABORDAGEM	TIPO	MÉTODO	PRÓS	CONTRAS	REFERÊNCIAS
OBSERVACIONAIS	Medição <i>in situ</i>	Utilização de estações fixas e móveis.	Maior resolução temporal (captura de informações em escala espacial pequena), melhor parametrização dos modelos relacionando temperatura e fatores locais e meteorológicos.	Alto custo. Demora na instalação dos dispositivos de medição. Limite no número de variáveis medidas simultaneamente. Erros de medição e perda de dados.	MIRZAEI; HAGHIGHAT (2010) MIRZAEI (2015)
	Sensoriamento remoto térmico	Uso de plataformas de satélite, aerotransportadas e aeronaves.	Permite monitorar a IUC com uma maior resolução espacial se comparadas as medidas <i>in situ</i> .	Abordagem muito cara e não é possível ter imagens estáveis da superfície urbana. Tempo limitado sobre uma região específica e probabilidade de céu nublado.	WENG (2009) MIRZAEI; HAGHIGHAT (2010) MIRZAEI (2015)
	Pequena escala	A área urbana é substituída por protótipo (Similaridade entre escala real e pequena escala).	Usada para verificar, calibrar e melhorar os modelos matemáticos. Estuda o impacto de um número limitado de variáveis de um edifício em seu ambiente ou sobre uma pequena região da cidade.	Alto custo. Necessidade de ajustes para obter semelhança entre pequena escala e escala real. Consome muito tempo. Apenas partes de uma área urbana podem ser simulada.	MIRZAEI; HAGHIGHAT (2010) MIRZAEI (2015)

QUADRO 3 - Métodos para estudar a IUC.

(conclusão)

ABORDAGEM	TIPO		MÉTODO	PRÓS	CONTRAS	REFERÊNCIAS
SIMULAÇÃO	Balanço de energia	Modelo de dossel urbano	Trocas de energia entre as superfícies e o ar ambiente na CLU.	Os modelos podem ser desenvolvidos em uma, duas ou três dimensões. Fornece precisão aceitável para estudos de consumo de energia em larga escala.	Ausência de campo de velocidade do ar e de banco de dados com geometria tridimensional.	MIRZAEI; HAGHIGHAT (2010) MIRZAEI (2015)
		Balanço energético da Cidade	Trocas de energia no topo do cânion urbano e no telhado.		Sensibilidade às características radiativas da superfície.	MASSON (2000)
	Numérico dinâmico (Simultaneidade de equações dos fluidos no interior das áreas urbanas)	Mesoescala	As interações sobre a camada limite planetária são resolvidas, incluindo estratificação atmosférica e tratamento da camada superficial.	Informações mais precisas sobre a distribuição de IUC dentro e acima dos dosséis dos edifícios que o modelo de dossel urbano.	Problemas computacionais relacionadas à complexidade e alto custo da simulação. Baixa resolução dos dados temporais e espaciais dos fenômenos que ocorrem dentro das cidades, além da diferença entre escalas.	MIRZAEI; HAGHIGHAT (2010) MIRZAEI (2015)
		Microescala	As interações são calculadas na camada superficial.			

Fonte: Autoria própria (2021).

2.4.1 Medição *in situ*

A abordagem com medição *in situ* tem o intuito de avaliar a IUC que ocorre na CLU ou na CLDU por meio de observações da temperatura do ar. Geralmente, a temperatura do ar é monitorado por uma rede de estações meteorológicas fixas instaladas na cidade e no seu entorno ou por estações móveis, constituídas da instalação de sensores em meios de transporte como carros (NORO; BUSATO; LAZZARIN, 2015; QAID *et al.*, 2016; SILVA *et al.*, 2018), van (ULPIANI, 2021) e bicicleta (RODRÍGUEZ *et al.*, 2020a). Os estudos realizados com medição *in situ* permitem analisar se a IUC é afetada por fatores meteorológicos e condições sinóticas (MARTINS, 2013).

Um benefício do uso de sensores *in situ* é a aproximação entre medição e as condições ambientais oferecendo como resposta o comportamento real do meio (OKE *et al.*, 2017) e a alta resolução temporal (DASH *et al.*, 2002). No entanto, a resolução espacial tem baixa representatividade da região (DASH *et al.*, 2002). Outro desafio observacional é expor no meio urbano os instrumentos de forma adequada levando em conta suas características, posições e segurança (OKE *et al.*, 2017).

2.4.2 Sensoriamento remoto térmico

O sensoriamento remoto é observado como uma técnica para medir a temperatura superficial e identificar padrões de temperatura superficial nas regiões urbanas heterogêneas (SULTANA; SATYANARAYANA, 2018). Aplicado em estudos de clima urbano vem tomando destaque nas últimas décadas, além de possuir alta resolução espacial (MARTINS, 2013; FALLAHI *et al.*, 2018) e permitir utilizar dados no infravermelho termal dentro da janela atmosférica. Após correções dos efeitos atmosféricos e da superfície (emissividade), esses dados podem ser convertidos em temperatura da superfície continental (ESPINOZA, 2017).

A temperatura da superfície terrestre é sensível à presença de vegetação e umidade do solo, portanto, pode ser usada para detectar também, mudanças no uso e cobertura do solo (DASH *et al.*, 2004). Além da medição da temperatura da superfície, o sensoriamento remoto permite determinar outras características

importantes para o estudo da ilha de calor urbana, como coberturas, pavimentos, vegetação, solo exposto, volume de construção por área (GARTLAND, 2010).

As imagens captadas por meio do sensoriamento remoto são oriundas de sensores térmicos a bordo de satélites que fornecem diferentes resoluções espaciais, temporais, radiométricas e espectrais (Quadro 4) (ESPINOZA, 2017) e, dessa forma, permitem medir a temperatura da superfície em escala local, regional ou global (DASH *et al.*, 2002; AMORIM, 2020ab).

QUADRO 4 - Tipos de resolução de imagem captada por sensoriamento remoto.

Tipos de resolução	Definição
Espacial	Está relacionada com a capacidade de cada sensor em detectar os objetos da superfície terrestre. Quanto melhor a resolução espacial, maior o nível de detalhe observado.
Temporal	Definida em função do tempo de revisita do sensor para um mesmo ponto da superfície terrestre. Em sensores orbitais equivale ao intervalo de aquisição das imagens pelo sistema.
Radiométrica	A resolução radiométrica está relacionada ao nível de quantização ou sensibilidade do sensor em detectar pequenas variações radiométricas, ou seja, relaciona-se à capacidade do sensor em “perceber” diferenças nos valores da radiância.
Espectral	Definida pelo número de bandas espectrais de um sensor e pela largura do intervalo de comprimento de onda coberto por cada banda. Quanto maior o número de bandas e menor a largura do intervalo, maior é a resolução espectral de um sensor. Diferentes bandas refletem a superfície de maneira diferente.

Fonte: Adaptado de JENSEN (2000) e OLIVEIRA (2018).

Os sensores podem ser classificados quanto a fonte de energia (passivo ou ativo) ou ao tipo de produto gerado (não-imageadores e imageadores). Os imageadores podem ser divididos em: sistema de quadro (exemplo: RBV), de varredura (exemplo: MSS e HRV) ou fotográfico (CCD e CMOS) (SPRING, 2006).

O sensoriamento remoto combinado com dados *in situ* podem ser utilizados para diagnosticar a origem da IUC e identificar as suas principais causas (MARGALHO, 2019).

2.4.3 Métodos analíticos

Existem vários métodos que permitem avaliar a relação entre a IIUC e diferentes variáveis como vegetação, área construída, população, vias, precipitação e umidade relativa do ar, edifícios, uso e ocupação do solo. Segundo a revisão de

Deilami, Kamruzzaman e Liu (2018), o principal método aplicado é a regressão de mínimos quadrados ordinários em conjunto com o indicador estatístico de correlação de Pearson (r) (68% dos estudos). Também são usadas análise comparativa (por exemplo, comparando a tendência da IUC e a mudança na cobertura do solo) (33%), modelos não-paramétricos (4%) e regressão geograficamente ponderada (4%).

Em conclusão da revisão bibliográfica sobre modelagem estatística de IUC, observou-se uma variedade de métodos com base nas variáveis de interesse (por exemplo, a temperatura do ar e de superfície) e nos modelos empregados. A comparação dos resultados de modelagem de IUC de diferentes estudos deve ser feita com cuidado pelas diferenças entre as variáveis independentes⁶ escolhidas, o método utilizado, e a resolução temporal utilizada na análise.

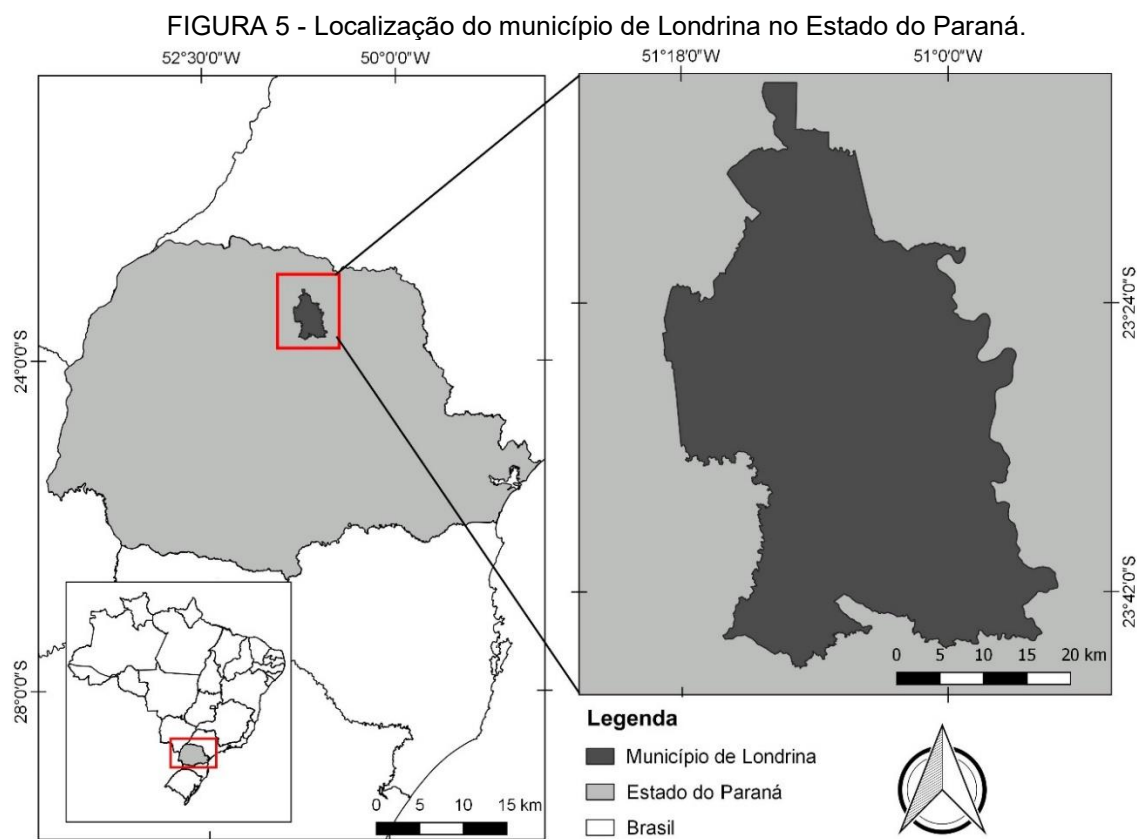
⁶ Variáveis que representam uma grandeza que está sendo manipulada em um experimento, que condicionam a variação da variável dependente (HAIR JR *et al.*, 2009; AMORIN, 2020).

3 MATERIAL E MÉTODOS

O estudo foi realizado de acordo com as seguintes etapas: i) análise e processamento de dados de medições de temperatura do ar para calcular a IIUC; ii) seleção e tratamento das variáveis independentes que descrevem a temperatura do ar; iii) aplicação do modelo estatístico para identificação da correlação entre as variáveis estudadas e por fim, iv) validação do modelo.

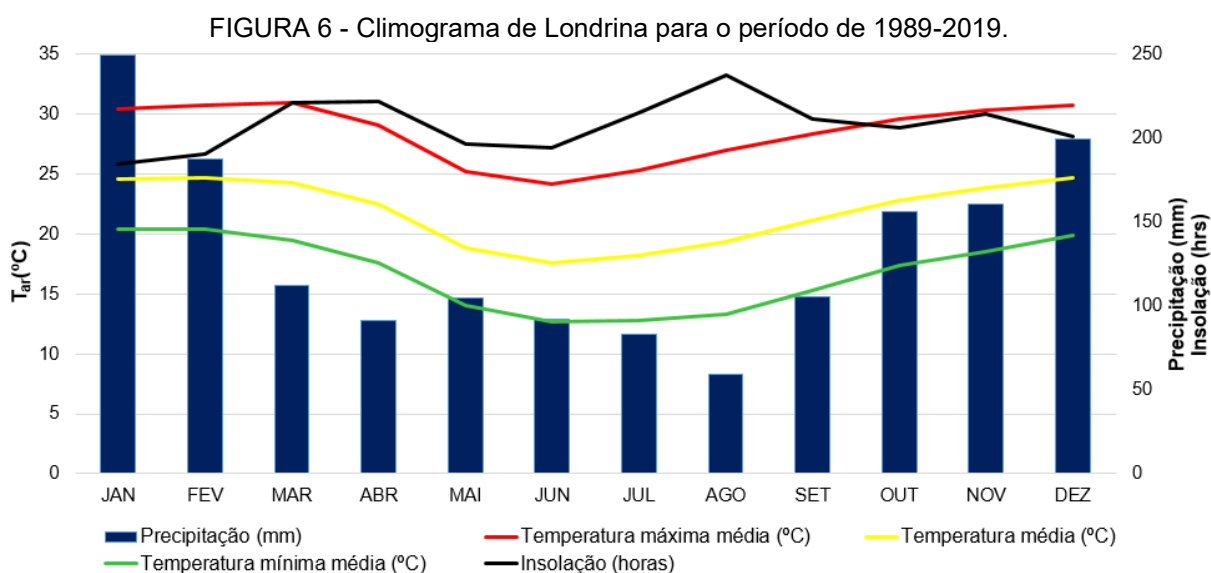
3.1 ÁREA DE ESTUDO

Londrina é um município com 563.943 habitantes (IBGE, 2019) localizada no norte do estado do Paraná, sul do Brasil (latitude $23^{\circ} 17' 34''$ sul, longitude $51^{\circ} 10' 24''$ oeste) (Figura 5). O relevo é suave com altitudes variando entre 520 e 610 m acima do nível do mar, orientadas na direção noroeste-sudeste seguindo a bacia hidrográfica de Cambé, Limoeiro, Cafezal e Três Bocas e no sentido oeste-leste a bacia do Jacutinga e Lindóia (ANA, 2010) e baixa declividade (10%).



Fonte: Autoria própria (2021).

A cidade possui um clima subtropical úmido, com verões quentes e sem estação seca definida (Cfa na classificação de Köppen-Geiger). De acordo com as estatísticas climatológicas no período de 1989-2019, Londrina apresenta temperatura média anual de 21,6 °C e precipitação média acumulada anual de 1583 mm, ocorrendo durante todo o ano, sendo mais intensa no verão (dezembro a fevereiro). Em média, no inverno (junho a agosto), a temperatura varia entre 12,3 °C e 26,6 °C, enquanto que no verão (dezembro a fevereiro) varia entre 19,5 °C e 30,3 °C (Figura 6). A insolação é maior durante o inverno (valor médio de 206 hrs por mês) devido a menor cobertura de nuvens, influenciado pelos sistemas de alta pressão.



Fonte: Autoria própria (2021). Base de dados INMET (2020).

3.2 REDE DE MONITORAMENTO

A temperatura do ar foi medida na cidade de Londrina em 13 locais, sendo dois locais permanentes (EMBRAPA - EMB e SIMEPAR - SIM) e 11 instalados em uma rede dedicada a esse estudo (rede LONDRINET). Detalhes das características dos locais de amostragem são apresentados no Apêndice A.

Nas estações instaladas para esse estudo, a temperatura do ar e a umidade relativa foram monitoradas com 11 sensores com *dataloggers* integrados (HOBO U23-001, Onset Computer Corporation, EUA), operando a uma frequência de amostragem de 10 minutos, com precisão de $\pm 0,21$ °C na faixa de 0 a + 50 °C. Os sensores foram

instalados em postes de luz a 3 m acima do solo e alojados em protetores para evitar a interferência da radiação solar e vento (Figura 7).



Fonte: Imagens do Google (2021).

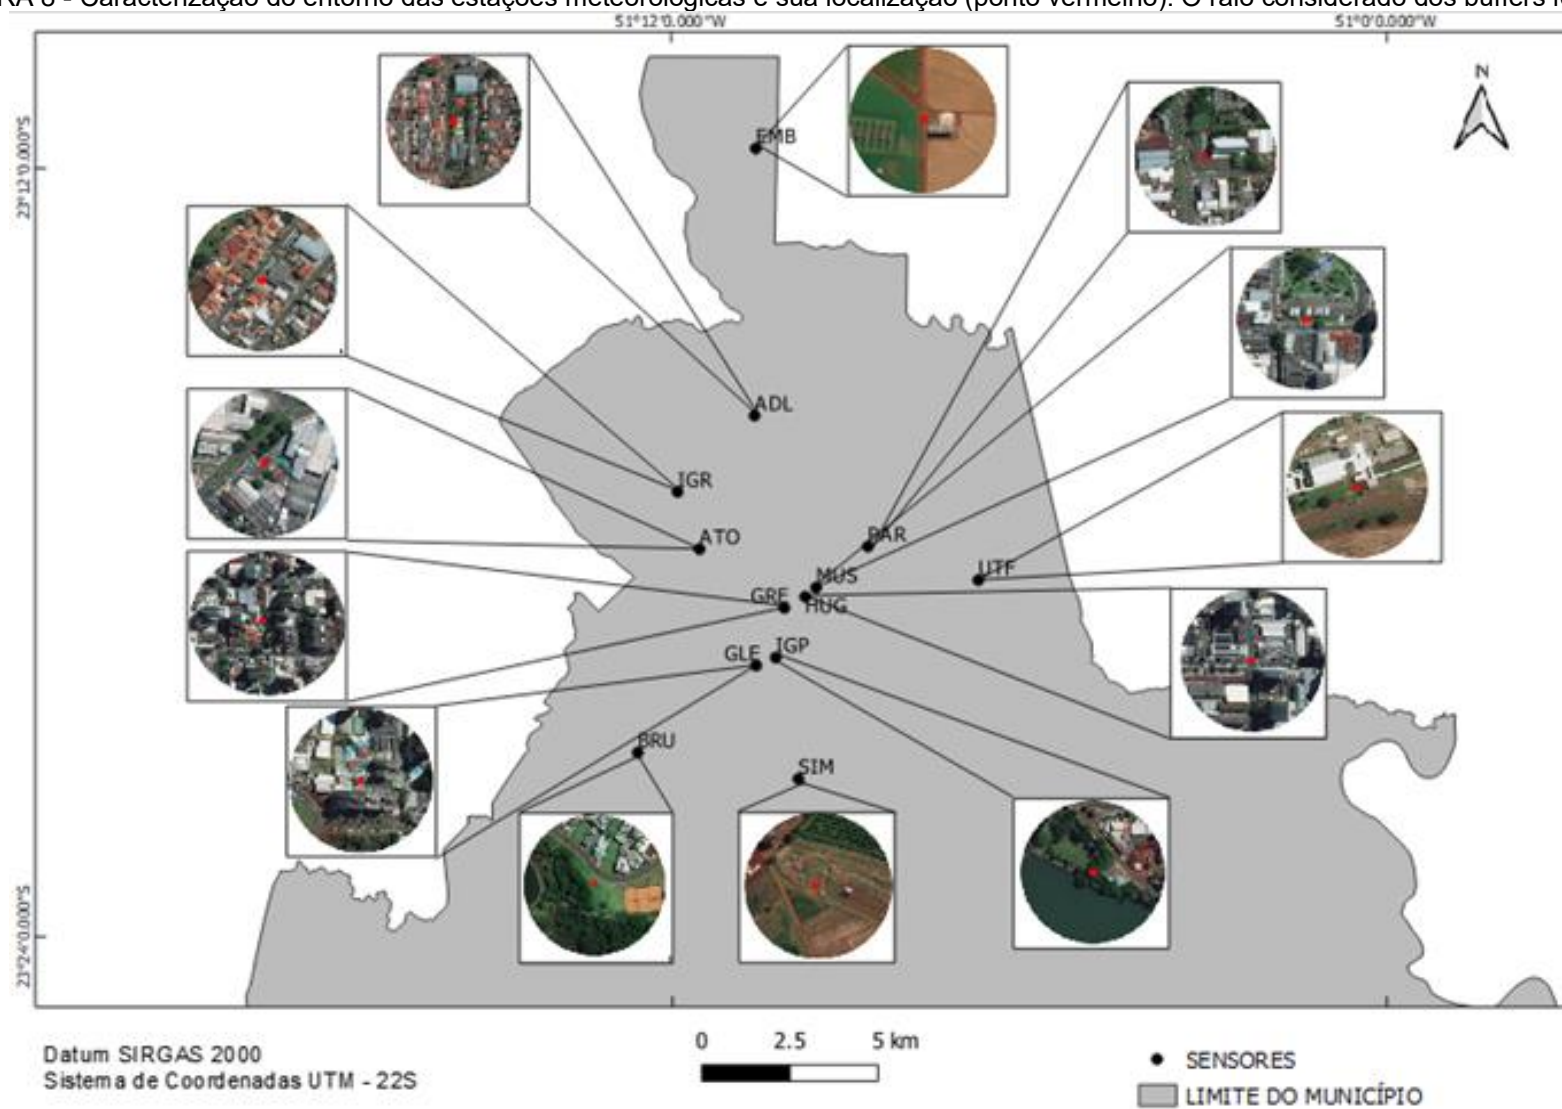
Para garantir a reproduzibilidade dos dados, os sensores foram comparados entre 2 e 4 dias com um sensor de referência em cada local de amostragem. Todos os sensores apresentaram coeficientes angulares entre 0,98 e 1, intercepto de y entre -0,05 e 0,40 °C e r de 0,99.

Na estação da EMBRAPA, a temperatura do ar e a umidade relativa foram monitoradas com um sensor de temperatura do ar com *datalogger* integrado (HOBO S-THB-M002, Onset Computer Corporation, EUA), operando a uma frequência de amostragem de 5 minutos, com precisão de $\pm 0,21$ °C na faixa de 0 a + 50 °C. Os sensores foram instalados a 1,5 metros acima do solo e alojados em abrigos meteorológicos para evitar a interferência da radiação solar e vento.

O SIM e a EMB forneceram dados de suas estações meteorológicas permanentes, com resoluções temporais de 15 e 5 minutos, respectivamente. Com o intuito de favorecer a comparação, os dados das treze estações foram colocados na mesma base temporal (médias horárias e diárias). A campanha de monitoramento ocorreu entre 27 de agosto a 13 de dezembro de 2018.

A escolha dos pontos de medição foi baseada nas características dos locais (Figura 8), visando abranger diferentes ocupações do solo e também garantir a segurança dos sensores.

FIGURA 8 - Caracterização do entorno das estações meteorológicas e sua localização (ponto vermelho). O raio considerado dos buffers foi de 100m.



Fonte: Autoria própria (2021).

3.3 CÁLCULO DA INTENSIDADE DA ILHA URBANA DE CALOR

A IIUC, definida como a diferença da temperatura do ar entre o centro urbano e uma estação de referência de arredores rurais, foi calculada como:

$$IIUC = T_{arU} - T_{arR} \quad \text{Equação (1),}$$

em que:

T_{arU} é a temperatura do ar na estação urbana;

T_{arR} é a temperatura do ar na estação de referência.

A estação BRU foi escolhida como referência por estar próxima de uma área com vegetação densa, corpos hídricos, nenhuma verticalização e apresentar menores temperaturas do ar mínimas e médias diárias durante o período de estudo (ver os resultados na seção 5.1).

A IIUC foi calculada para cada estação aplicando a Equação 1, a partir da média dos valores médios diários da temperatura máxima, mínima e média durante o período de estudo. Para representar a distribuição espacial da temperatura do ar e da IIUC na área de estudo, foi empregado o método geoestatístico de interpolação por krigagem, utilizando o software QGis. A krigagem produz a melhor estimativa linear que busca o valor de erro e resíduo igual a 0 e minimiza a variância dos erros (para mais detalhes ver Apêndice A) (ISAAKS; SRIVASTAVA, 1989).

3.4 ANÁLISE ESTATÍSTICA

A modelagem estatística da temperatura do ar (variável dependente⁷) foi realizada em três etapas: 1) seleção das variáveis independentes para a construção do modelo; 2) cálculo de r , normalidade, linearidade e homoscedasticidade para avaliar a relação entre cada variável independente com a temperatura do ar, e 3) aplicar a RLM para determinar o nível de interação entre as variáveis independentes e a temperatura do ar.

⁷ Variável que representa o fenômeno a ser explicado. É o resultado, consequência ou resposta a algo que foi manipulado (variável independente) (HAIR JR *et al.*, 2009; AMORIN, 2020).

3.4.1 Regressão Linear Múltipla

O método da RLM é uma técnica estatística que descreve o nível de interação entre as variáveis independentes e a variável dependente (HAIR JR *et al.*, 2009). Seja k o número de variáveis independentes e assumindo que $k > 2$, o modelo de regressão pode ser representado pela seguinte Equação (2):

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon Y \quad \text{Equação (2),}$$

em que:

Y é a variável dependente;

X_k as variáveis independentes;

β_k os coeficientes de regressão;

ε o erro aleatório.

Para aplicar a RLM, diferentes suposições devem ser levadas em consideração (Quadro 5):

QUADRO 5 - Suposições da RLM.

SUPOSIÇÕES	CONDIÇÕES
Tamanho da amostra	A razão mínima entre as variáveis independentes e a dependente deve ser de 5:1;
	A razão desejável deve ser entre 15 e 20 observações;
	E no caso do emprego do procedimento de <i>stepwise</i> (exemplo do estudo), o nível recomendado é de 50 observações.
Linearidade	Neste caso, trata-se da relação linear entre as variáveis independentes e a dependente. Relações não-lineares não são representadas no modelo, sendo necessário ações corretivas (por exemplo, transformação dos dados, inclusão direta de relações não-lineares no modelo e métodos especializados).
Homoscedasticidade	É desejável igualdade de variância entre as variáveis. O diagnóstico é feito com gráficos de resíduos ou dispersão como resultado do teste de variância. Os pontos devem estar distribuídos próximo ao 0.
Normalidade	As variáveis devem apresentar distribuição normal. Geralmente o diagnóstico é feito por histograma e teste de normalidade.
Multicolinearidade	Recomenda-se ter diversas variáveis independentes altamente correlacionadas com a variável dependente, mas com pouca correlação entre elas próprias. O diagnóstico é feito por meio de gráficos de dispersão e correlação bivariada, acima de 0,7.

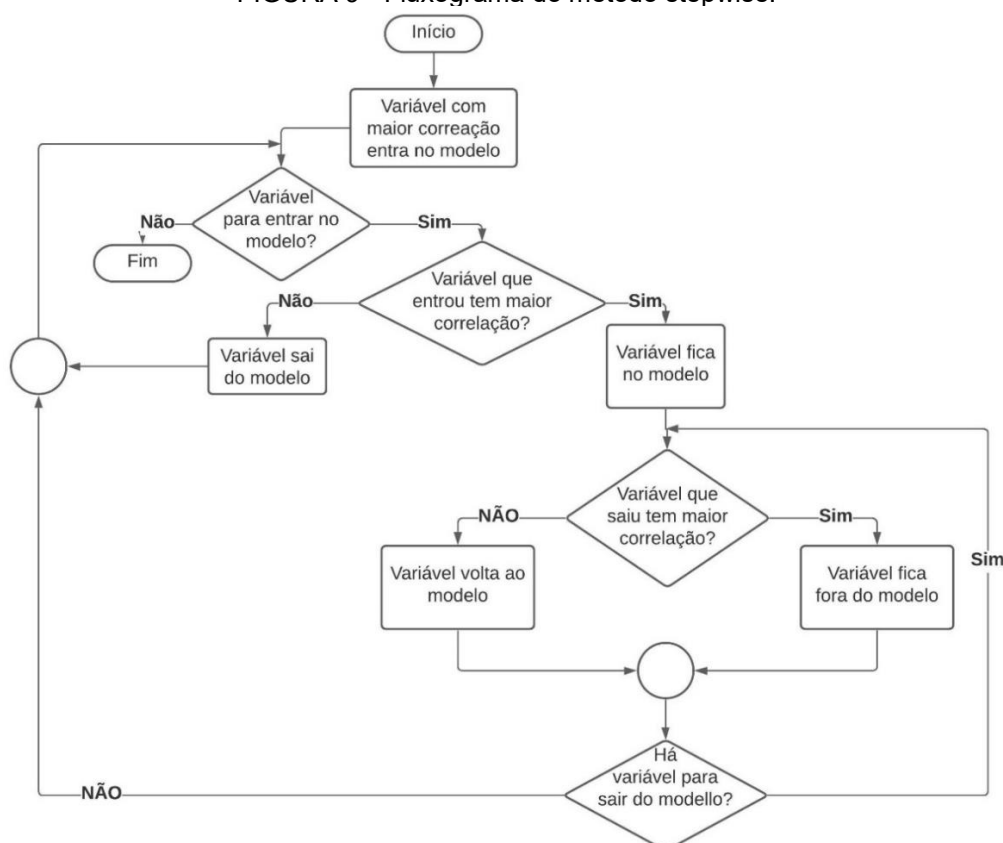
Fonte: Adaptado de KRECL *et al.* (2014).

No conjunto de variáveis independentes, pode haver variáveis que pouco influenciam o conjunto de variáveis dependentes. O método *stepwise* é um método de regressão para seleção de variáveis que adiciona progressivamente novas variáveis ao modelo, iniciando com maior correlação com a resposta e incorpora mecanismo de eliminação de variáveis (HAIR JR *et al.*, 2009).

É feito de forma iterativa, adicionando e removendo variáveis, a partir de critério de seleção tais como, teste F, coeficiente de correlação linear múltipla ou erro quadrático total (HOCKING, 1976). Nesse estudo, o critério de seleção foi o coeficiente ajustado de determinação (R^2 ajustado $>0,01$).

Inicialmente, a variável com maior contribuição para o modelo é adicionada, e posteriormente, as variáveis com contribuição incremental sobre as variáveis já presentes na equação (HAIR JR. *et al.*, 2009). A Figura 9 apresenta um fluxograma que descreve o método *stepwise*.

FIGURA 9 - Fluxograma do método *stepwise*.



Fonte: ALVES, LOTUFO, LOPES (2013).

As variáveis independentes aplicadas ao modelo podem ser métricas (numéricas/quantitativas) e/ou não-métricas (categóricas/qualitativas). As variáveis métricas são utilizadas quando indivíduos diferem em quantia ou grau em relação a um atributo em particular, ou seja, refletem quantidade.

As variáveis categóricas descrevem diferenças em tipo ou natureza, indicando a presença ou ausência de uma característica ou propriedade (HAIR JR *et al.*, 2009). Podem ser representadas por variáveis dicotômicas que apresentam acontecimento ou não de um evento e se convencionou denotar cada observação i como $y_i = 1$ se o evento ocorrer, e $y_i = 0$ se o evento não ocorrer (BRAGANÇA, 1977). Qualquer variável não-métrica com L categorias podem ser representada por $L-1$ variáveis dicotômicas.

3.4.2 Teste de normalidade e Transformação de potência

A análise exploratória dos dados foi realizada com estatística descritiva. Os testes de normalidade Anderson – Darling foi utilizado para verificar se a distribuição de probabilidade associada a um conjunto de dados pode ser aproximada pela distribuição normal. As hipóteses testadas ao aplicar esse teste consistem da hipótese nula (H_0) e alternativa (H_1) determinadas como:

H_0 : A amostra segue uma distribuição normal a um p-valor $\geq 0,05$.

H_1 : A amostra não segue uma distribuição normal a um p-valor $\leq 0,05$.

As variáveis independentes numéricas que rejeitaram a hipótese nula, foram transformadas utilizando transformação de potência; dessa forma, a variável fica mais adequada para descrever a relação. A transformação de potência, também conhecida como Transformação de Box-Cox, consiste em determinar um valor de λ tal que os dados transformados se aproximem de uma distribuição normal.

Box e Cox (1964) introduziram uma família de transformações de modo que o valores transformados são uma função monotônica das observações ao longo de um intervalo admissível, sendo aplicável apenas para variáveis com valores positivos (Equação 3):

$$Y_i(\lambda) = \begin{cases} \ln(y), & \text{se } \lambda=0 \\ \frac{y_i^\lambda - 1}{\lambda}, & \text{se } \lambda \neq 0 \end{cases} \quad \text{Equação (3),}$$

em que:

λ é um valor real

No procedimento Box-Cox, λ é considerado como um parâmetro adicional e desconhecido no modelo e é estimado por meio dos métodos de inferência estatística como o de máxima-verosimilhança e o método Bayesiano (SIQUEIRA, 1983). Exemplos típicos da transformação de Box-Cox, e seu correspondente significado para valores de λ , podem ser observados na Tabela 1.

TABELA 1 -Exemplos da transformação de Box-Cox.

Valores de Lambda	Transformação Recomendada	
	Equação	Nome
$\lambda = 2$	$y(\lambda) = y^2$	Quadrática
$\lambda = 1$	$y(\lambda) = y$	Não há transformação
$\lambda = 0,5$	$y(\lambda) = \sqrt{y}$	Raiz quadrada
$\lambda = 0$	$y(\lambda) = \ln y$	Logarítmica
$\lambda = -0,5$	$y(\lambda) = \frac{1}{\sqrt{y}}$	Inverso da raiz quadrada
$\lambda = -1$	$y(\lambda) = \frac{1}{y}$	Inversa
$\lambda = -2$	$y(\lambda) = \frac{1}{y^2}$	Inverso da quadrática

Fonte: Adaptado de MINITAB (2020) e MATHWORKS (2020).

3.4.3 Multicolineariedade

Para quantificar a dependência linear entre as variáveis independentes, analisou-se a matriz de correlação a partir dos valores apresentados por r , no qual o valor limite ($r \geq \pm 0,6$) foi escolhido baseado em Krecl *et al.* (2014).

As variáveis independentes que apresentaram maiores correlações entre si e menor correlação com a variável dependente foram excluídas do conjunto de variáveis independentes. Desta forma, foram estimados os valores de r entre todas as variáveis independentes numéricas, assim como entre as variáveis independentes e a variável dependente.

Após selecionar as variáveis independentes, estas foram avaliadas quanto ao cumprimento das suposições exigidas pelo modelo de RLM. Para a escolha das

melhores variáveis dentro de um conjunto de variáveis foi aplicado o método de busca sequencial, por meio da estimação de *stepwise*.

O total de 18423 dados diurnos (06h00 às 18h00) e 15589 dados noturnos (18h01 às 05h59) das variáveis independentes foram utilizados para rodar o modelo. Os dados são referentes aos diagnosticados nos diferentes *buffers* de cada estação, calculando-se os valores médios horários.

A área total de cada variável independente foi calculada para diferentes tamanhos de *buffers* (100 m a 600 m), com uma variação a cada 100 m, obtendo-se 6 *buffers* para cada estação. O tamanho dos *buffers* foi escolhido com base em estudos de IUC (por exemplo, SHI; KATZSCHNER; NG, 2018; FOISSARD; DUBREUIL; QUÉNOL, 2019) e para evitar a sobreposição de dados e o aumento do risco de correlação espacial devido à distância entre as estações meteorológicas.

O processo de regressão foi iniciado a partir de um modelo linear, o qual utilizou um critério de inclusão de variáveis independentes no decorrer das etapas por meio do R^2 ajustado. O coeficiente pode variar entre 0 e 1 e quanto maior seu valor, melhor a previsão da variável dependente. Num segundo momento de execução do modelo, foi incluído um efeito não linear que permite interações na forma de um modelo bilinear, que consiste da porção de grau único de liberdade da interação correspondente aos efeitos lineares das variáveis independentes (VENTER; MXWELL, 2000).

Os resíduos ou valores residuais podem ser entendidos como a diferença entre os valores observados e modelados para a variável dependente, e sua análise auxilia no diagnóstico para identificar problemas na técnica de estimação. O valor médio dos resíduos é zero quando os resíduos são aleatórios (HAIR JR *et al.*, 2009).

Para verificar se ocorreram violações de suposição do modelo de RLM devido aos efeitos ocasionados pela combinação de todas as variáveis independentes com relação a variável dependente, os valores residuais foram explorados quanto a normalidade (histograma), linearidade, homocedasticidade (resíduos estudentizados x valores ajustados) e independência dos termos de erro (HAIR JR *et al.*, 2009). A correlação temporal foi explorada por meio de análise de autocorrelação.

Finalmente, para aferir se há alguma alteração de forma substancial em alguma propriedade do modelo ajustado, foram analisadas as observações influentes

através dos seguintes diagnósticos: alavancagem, distância de cook's, razão de covariância, DFFIT e DFBETAS (Quadro 6).

QUADRO 6 - Diagnósticos utilizados para análise de observações influentes.

Tipo	Definição	Fórmula	Observações
Alavancagem (A)	Medida da influência de uma dada observação em uma regressão devido à sua localização no espaço das entradas	$A = 2 \frac{p}{n}$ n: número de observações p: número de parâmetros no modelo.	
Distância de cook's	Mudança em escala nos valores ajustados, sendo essencial para identificar <i>outliers</i> nas observações para as variáveis independentes.		
Razão de covariância (RV)	Determinada pelo grau no qual o observador impacta o erro padrão dos coeficientes de regressão.	$RV = (1 + 3) \frac{p}{n}$ em que: p: número de coeficientes de regressão n: número de observações.	Os valores de covariância quando maiores ou menores que RV indicam pontos influentes
DFFITS	Demonstra a influência de cada observação nos valores de resposta ajustados.	$DFFITS = 2 \sqrt{\frac{p}{n}}$	Os valores de DFFITS com um valor absoluto maior do que duas vezes a raiz quadrada de p/n podem ser influentes.
DFBETAS	Indica se essa observação causa um aumento ou diminuição na estimativa do coeficiente de regressão. O valor absoluto indica a magnitude da diferença em relação ao desvio padrão estimado do coeficiente de regressão.	$DFBETAS = \frac{3}{\sqrt{n}}$	Um valor DFBETAS maior que a razão de três pela raiz quadrada de nem valor absoluto indica que a observação tem uma grande influência no coeficiente correspondente.

Fonte: Adaptado de CHEN (2012).

Por fim, foi analisado o peso dos coeficientes de regressão permitindo comparar a influência que cada variável exerce sobre o modelo de regressão (HAIR JR *et al.*, 2009).

3.5 VARIÁVEIS INDEPENDENTES

O estudo analisou as seguintes variáveis independentes: uso e ocupação de solo (vegetação, corpo d'água, asfalto, telhado e solo exposto), população (número total de indivíduos e densidade populacional), relevo (declividade e hipsometria), características dos edifícios (altura média pela área do *buffer*), dados meteorológicos horários (velocidade e direção do vento, irradiância solar, umidade relativa e precipitação), fator de visão do céu (valores entre 0 e 1), camada de nuvens, Normalized difference vegetation index (NDVI) (valores entre -1 e 1), Normalized difference built-up index (NDBI) (valores entre -1 e 1) e Water index (NDWI) (valores entre -1 e 1).

3.5.1 Uso e ocupação do solo

O uso e ocupação do solo foram obtidos do satélite CBERS4A, com imagens pancromáticas (banda 0) e multiespectrais (bandas, 1, 2, 3 e 4) e resolução espacial de 2 m e 8 m, respectivamente. Como o satélite começou a operar em 20/12/2019, não foi possível obter imagens para o período de estudo. Portanto, foram escolhidas as imagens de 20/12/2019 a 31/01/2020, totalizando cinco imagens capturadas, que eram as mais próximas dos meses analisados no estudo.

As imagens foram escolhidas em períodos quando o ângulo zenital do sol está próximo de 90° (perto do solstício de verão no hemisfério sul) para reduzir as sombras geradas por grandes edifícios. Outro critério de seleção das imagens de satélite foi a menor porcentagem de cobertura de nuvens para não afetar o processamento e qualidade do produto final (WANG *et al.*, 2018b).


O entorno das estações de medições e a região de estudo foi caracterizado através da classificação *Semi-automatic Classification Plugin* (SCP), desenvolvida por Congedo (2016). O SPC é um *plugin* do QGIS com classificação semiautomática de imagens de sensoriamento remoto, que permite uma rápida criação de áreas de treinamento ou regiões de interesse (ROI) que consiste de regiões definidas pelo operador onde o processamento estará totalmente concentrado, ou seja, é a predefinição das áreas que deverão ser classificadas. As categorias analisadas foram: telhado, vegetação, asfalto, solo exposto e água.

No caso de discrepâncias entre a classificação SCP e a real característica do tipo de cobertura do solo, foi feito um refinamento manual das classes correspondentes, selecionando áreas de categorias conhecidas de cobertura do solo, utilizando imagens do *Google Earth*.

Após a obtenção das classes foram feitos cálculos de porcentagem para os respectivos tamanhos de *buffers*, assim como, para cada estação de monitoramento.

Quanto maior o raio do buffer, maior a quantidade de classes de solos abordadas (Figura 10), assim como seu percentual (mais detalhes são apresentados no Apêndice B). Dessa forma, foram analisadas diferentes contribuições para a IIUC para o mesmo ponto de coleta.

FIGURA 10 - Área de influência ao redor do local de monitoramento IGP mostradas através de um buffer com raio de a) 100 m e b) 600 m.



Fonte: Autoria própria (2021).

3.5.2 Relevô

Além do uso e ocupação do solo, o relevo também pode influenciar a distribuição espacial da temperatura do ar (DORIGON; AMORIM, 2019). Portanto, foram gerados dados de hipsometria⁸ e declividade usando a imagem de radar do Sistema de Informação Geográfica de Londrina (SIGLON - 2015), obtida com um modelo digital de elevação⁹ (MDE).

⁸ Consiste em um método de representar a elevação de um terreno por meio de um sistema de graduação de cores.

⁹ É aplicado um modelo matemático sobre os dados de levantamentos planialtimétricos (conjunto de coordenadas x, y, z) e a partir deste conjunto, faz-se uma interpolação da superfície contínua por meio de uma rede triangular irregular (dados vetoriais), que irá representar a altitude do terreno.

A partir da imagem de radar foi gerado o Modelo Numérico do Terreno (MNT), através do Sistema de Informação Geográfica (SIG), e o MNT foi reclassificado em 10 classes com altitudes variando entre 350 e 880 m, permitindo dessa forma estimar as altitudes pertencentes a área de estudo. Por fim, foi calculada a altitude média da elevação do terreno para cada *buffer* e estação de monitoramento.

Quanto a declividade, foram utilizadas 6 categorias de declividade conforme estabelecidos pela EMBRAPA (1999), sendo elas: plano (0-3%), suave ondulado (3-8%), ondulado (8-20%), forte ondulado (20-45%), montanhoso (45-75%) e escarpado (superior a 75%). Após aplicar esses limites de declividade para a área de estudo, foi determinada a porcentagem de cada categoria para cada *buffer* e estação de monitoramento.

3.5.3 População

A distribuição da população humana foi mapeada usando o software geoestatístico *Qgis*, a partir dos dados do Censo de 2010 disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Posteriormente, foi calculada a densidade populacional (hab m^{-2}) e o total de habitantes para cada estação de amostragem e *buffer*.

3.5.4 Dados meteorológicos

Para estudar a influência das variáveis meteorológicas sobre as variações da temperatura do ar, foram usados valores horários médios de velocidade e direção do vento, irradiância solar e umidade relativa, e valores horários acumulados de precipitação, com base nos dados coletados pela EMBRAPA.

A direção do vento varia entre 0 e 360°, e foi transformada em variável categórica com os seguintes pontos cardeais e subcardeais: Norte, Nordeste, Leste, Sudeste, Sul, Sudoeste, Oeste e Noroeste (Tabela 2).

TABELA 2 - Correspondência entre os pontos cardeais e subcardeais e seus graus.

PONTOS CARDEAIS E SUBCARDEAIS	INTERVALO (°)
Norte (N)	337,5 ≤ DV < 22,5
Nordeste (NE)	22,5 ≤ DV < 67,5
Leste (L)	67,5 ≤ DV < 112,5
Sudeste (SE)	112,5 ≤ DV < 157,5
Sul (S)	157,5 ≤ DV < 202,5
Sudoeste (SO)	02,5 ≤ DV < 247,5
Oeste (O)	247,5 ≤ DV < 292,5
Noroeste (NO)	292,5 ≤ DV < 337,5

Fonte: Autoria própria (2021).

A precipitação acumulada por hora foi classificada nas seguintes categorias (MANOBS, 2013): chuva leve (< 2,5 mm h⁻¹), chuva moderada (2,5 ≤ PA < 10 mm h⁻¹), chuva forte (10 ≤ PA < 50 mm h⁻¹) e tempestade (PA > 50 mm h⁻¹).

3.5.5 *Normalized difference vegetation index, Normalized difference built-up index e Water index*

Os índices NDVI, NDBI e NDWI foram obtidos com imagens multiespectrais do satélite Landsat 8 (bandas 5, 6, e 7) com resolução espacial de 30 m. As imagens são referentes ao período de estudo, sendo que o satélite cobre a superfície da Terra a cada 16 dias. A taxa de reflexão (valores de 0 a 1) das faixas espectrais absorvidas pelas diferentes bandas é associada a diferentes características do solo.

O NDVI é um indicador importante da biomassa vegetal de uma determinada área (GROVER; SINGH, 2016), e separa a vegetação verde do brilho do solo usando dados do satélite Landsat (SILLEAIS *et al.*, 2006). É expresso pela razão entre a diferença das refletividades do infravermelho próximo e do vermelho, pela soma das mesmas (Equação 3):

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad \text{Equação (3),}$$

em que:

NIR é o fluxo radiante no infravermelho próximo,

RED é o fluxo radiante na banda do vermelho.

O NDVI pode variar de -1 à 1, sendo os valores negativos correspondentes a superfícies não vegetadas, valores próximos a 1 a áreas com grande biomassa de vegetação e valores próximos a 0 a áreas com pouca vegetação.

O NDBI indica o *layout* urbano que ilustra a área construída a partir de imagens de satélite. Para o cálculo de NDBI foram utilizadas as bandas do infravermelho próximo e do infravermelho médio (Equação 4):

$$\text{NDBI} = \frac{\text{MIR} - \text{NIR}}{\text{MIR} + \text{NIR}} \quad \text{Equação (4),}$$

em que MIR é o fluxo radiante no infravermelho médio.

O resultado da razão das bandas do NIR e MIR produz uma imagem com valores de -1 à 1, onde os maiores valores representem os pixels contidos em áreas construídas e os valores negativos representem pixels contidos em áreas não construídas (MIRCHOOI; SADEGHI; DARVISHAN, 2020).

O NDWI usa bandas multiespectrais para identificar corpos d'água em várias regiões (LIU; YAO; WANG, 2016) e está diretamente associado ao conteúdo de água das folhas (MIRCHOOI; SADEGHI; DARVISHAN, 2020). Este índice é calculado a partir dos fluxos radiantes do infravermelho próximo e o infravermelho médio, segundo a Equação 5:

$$\text{NDWI} = \frac{\text{MIR} - \text{NIR}}{\text{NIR} + \text{MIR}} \quad \text{Equação (5).}$$

Por se tratar de um índice normalizado, assim como o NDVI e o NDBI, os valores de NDWI variam entre -1 e 1, sendo os valores mais próximos de 1 indicadores de maior umidade da vegetação e os valores negativos vegetação seca.

4.5.6 Características dos edifícios e Fator de visão do céu

Os edifícios foram identificados quanto à altura com um software SIG, baseado no *shapefile* elaborado pelo Instituto de Pesquisa e Planejamento de

Londrina (IPPUL) e foi calculada a altura média para cada *buffer* e estação de monitoramento.

Os FVC utilizados foram calculados por Anjos *et al.* (2020), a partir do banco de dados de edificações – 3D gerado pelo IPPUL e do site do OpenStreetMap aplicando a metodologia de Gal e Unger (2014) para cada estação de estudo.

3.5.7 Cobertura de nuvens

A cobertura da primeira camada de nuvens observada no aeroporto de Londrina foi extraída das mensagens METAR (código para informe meteorológico regular de aeródromo), disponíveis no site da Iowa Environmental Mesonet (<https://mesonet.agron.iastate.edu/request/download.phtml>). Utilizou-se o Manual de Códigos da Organização Meteorológica Mundial (WMO, 2017) para interpretar as informações contidas nos dados.

3.6 VALIDAÇÃO DO MODELO

A metodologia *bootstrap* foi aplicada para validar os modelos diurno e noturno, separadamente. Essa abordagem valida um modelo multivariado extraíndo um grande número de sub-amostras e estimando modelos para cada uma delas. Em seguida, as estimativas de todas as sub-amostras são combinadas, fornecendo os melhores coeficientes estimados e a sua variabilidade esperada (HAIR JR *et al.*, 2009). Diferente de outros métodos (*K-fold*, *holdout*, LOOCV – em inglês, *leave-one-out cross validation* e *Jackknife*), a avaliação da ocorrência de coeficientes estimados estatisticamente diferentes de zero não se baseia em suposições estatísticas, já que examina os valores reais a partir de repetidas amostras.

Seguindo a metodologia proposta por Krecl *et al.* (2014), os modelos de RLM foram executados 100, 300 e 500 vezes com um subconjunto das observações originais, cada vez removendo aleatoriamente 25% dessas observações. Em cada rodada, o modelo é livre para escolher as variáveis independentes com a metodologia *stepwise* e seguindo o critério adotado anteriormente (R^2 ajustado $>0,01$). As variáveis independentes com alta frequência de ocorrência nas múltiplas rodadas, indicam a sua relevância para descrever o processo estudado.

Posteriormente, o desempenho dos modelos diurno e noturno foram avaliados de duas formas:

i) Comparando o R^2 ajustado e a raiz do erro quadrático médio (RMSE) dos modelos com os calculados a partir das múltiplas modelações com *bootstrapping*. O RMSE representa a diferença entre os valores previstos pelo modelo e os valores observados, tem valor sempre positivo e quanto mais próximo de zero, maior a qualidade dos valores estimados (HAIR JR. *et al.*, 2009).

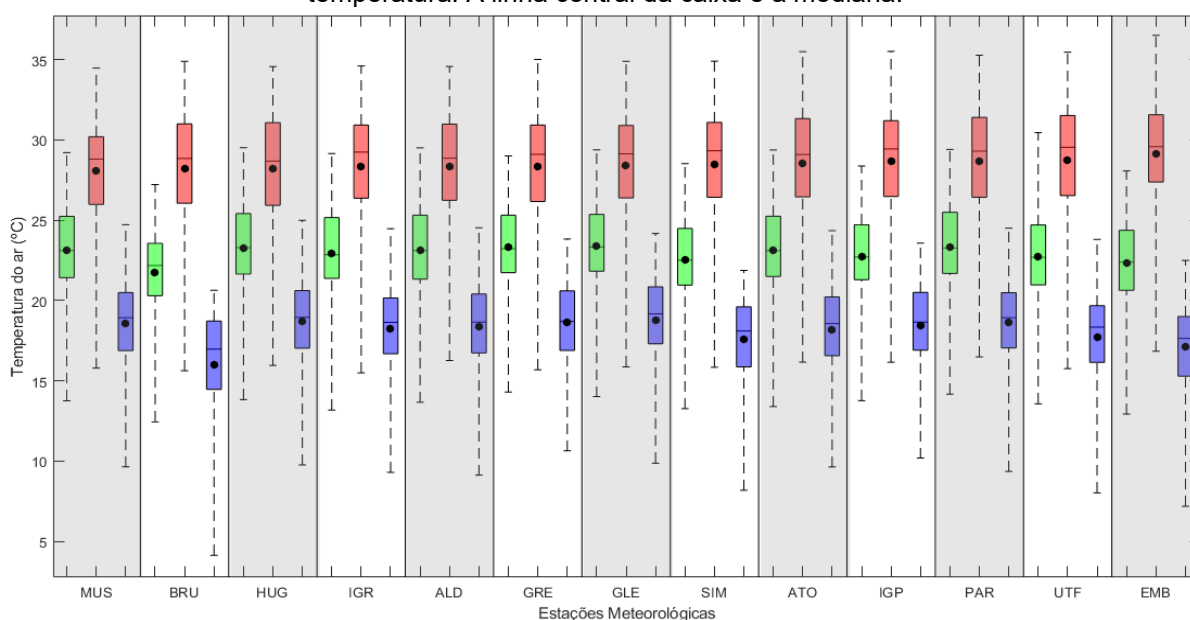
ii) Através da análise dos resíduos, calculados a partir da diferença entre os valores de temperatura do ar diurna e noturna coletadas para as 13 estações e os simulados com os modelos RLM. Foram plotados os histogramas dos resíduos e os diagramas de dispersão entre a temperatura observada e modelada. Para um comportamento de homoscedasticidade, o resíduo deve ter média zero e mostrar valores próximos a zero quando os valores de temperatura do ar modelados aumentam (HAIR JR. *et al.*, 2009).

4. RESULTADOS E DISCUSSÃO

4.1 TEMPERATURA DO AR

Durante o período de estudo, as temperaturas médias diárias variaram entre 12,5 °C (BRU) no dia 27/08/2018 e 30,5 °C (UTF) no dia 24/09/2018. A estação EMB apresentou os maiores valores de temperatura máxima média diária (29,1 °C), seguida de UTF, PAR E IGP (28,7 °C), enquanto as estações MUS, BRU e HUG registraram os menores valores máximos médios diários (28,2 °C). As menores temperaturas mínimas médias diárias, foram observadas na estação BRU (16,0 °C), seguida de EMB (17,1 °C) e SIM (17,6 °C), enquanto a estação GLE (18,8 °C) registrou o maior valor mínimo médio diário (Figura 11).

FIGURA 11 - Boxplot de temperatura máxima (vermelho), média (verde) e mínima (azul) diária para todo o período de estudo. Os pontos pretos são as médias. O limite inferior das caixas é o percentil 25 e o superior é o percentil 75. Os bigodes representam os valores mínimos e máximos de temperatura. A linha central da caixa é a mediana.



Fonte: Autoria própria (2021).

Nota: As estações foram ordenadas no gráfico de menor para maior temperatura máxima média diária.

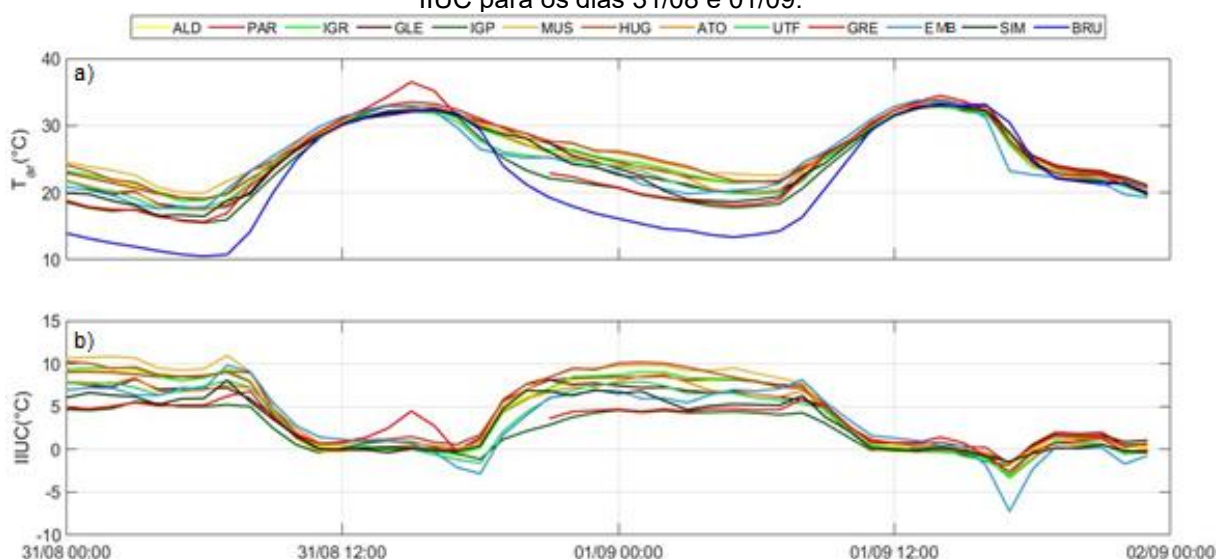
Os dias 31/08 e 01/09 foram escolhidos como base de comparação da temperatura do ar de cada estação (Figura 12a), já que esses dias registraram o maior e o menor valor de IIUC (11,0 °C e -7,2 °C) (Figura 12b), respectivamente. O dia 31/08 observou-se ventos mais fracos e céu claro, enquanto para o dia 01/09 o céu estava

nublado e chuvoso devido a passagem de uma frente fria (ANJOS *et al.*, 2020). A estação de referência BRU apresentou menores temperaturas médias diárias para os dois dias (20,9 °C e 22,2 °C) e houve uma grande diferença de temperatura do ar entre as estações urbanas e a estação rural. Por exemplo, diferenças horárias de até 10,1 °C e 9,4 °C foram observadas entre BRU e a estação MUS no período noturno (18h-06 h), indicando a presença de IUC.

Os resultados encontrados condizem com vários estudos que apresentaram também IIUC média mais intensas no período noturno, como em Atenas (3,5 - 4,5 °C, FOUNDA *et al.*, 2015), Beijing (0,6 - 0,9 °C, HE *et al.*, 2019), Irã (3 - 6°C, KEIKHOSRAVI, 2019) e Roma (1,5 - 3 °C, CIARDINI *et al.*, 2019).

Este fato pode estar associado ao resfriamento do ar ocasionado pela evapotranspiração e ao sombreamento do solo durante o dia e ao rápido resfriamento da superfície durante a noite na estação BRU (TAHA, 1997), apresentando temperaturas mais amenas do que nos locais mais urbanizados. Santamouris (2019) afirma que as superfícies com baixa capacidade térmica, como a vegetação, utilizam inicialmente a energia para o processo de evapotranspiração e posteriormente para aquecer a superfície e o ar adjacente

FIGURA 12 - a) Série horária da temperatura média para os dias 31/08 e 01/09 e b) Série horária da IIUC para os dias 31/08 e 01/09.



Fonte: Autoria própria (2021).

No dia 01/09, foram observadas condições de céu nublado e chuvoso, ocasionando menores IIUC durante a noite, e valores negativos de IIUC (também

conhecido como Ilha urbana fria – IUF) durante o dia. Ou seja, a temperatura do ar foi superior na estação de referência BRU do que observado nas estações urbanas. Anjos e colaboradores (2020) justificaram que a passagem de frente fria e complexos convectivos de mesoescala suavizam as diferenças de temperatura do ar causadas por variáveis locais. A estação EMB apresentou a IUF mais fria com $-7,2^{\circ}\text{C}$ (Figura 12b), o que pode ser justificado pela presença de vegetação e pelo aumento da umidade no ar e no solo (RASUL; BALZTER; SMITH; 2015).

Durante todo o período de estudo (27/08-13/12/2018), algumas estações apresentaram uma maior amplitude térmica, enquanto outras mostraram menores amplitudes (Tabela 3). A estação BRU apresentou a maior amplitude térmica ($12,4^{\circ}\text{C}$), pois registrou os menores valores de temperatura mínima se comparada às outras estações, possivelmente devido à existência de vegetação densa em uma alta porcentagem ao redor da estação (Tabela B1).

As estações IGP e MUS registraram as menores amplitudes térmicas, provavelmente pela alta presença de água e asfalto, respectivamente. A importância dos corpos d'água para o clima urbano está associado ao poder de equilíbrio da temperatura do ar, no entanto, deve-se considerar o tamanho, a forma e a profundidade do corpo hídrico. O comportamento de IGP segue o padrão de locais com asfalto e telhado devido ao aquecimento rápido durante o dia e ao resfriamento lento durante as noites, típico das superfícies aquáticas lénticas (TARGINO; CORAIOLA; KRECL, 2014).

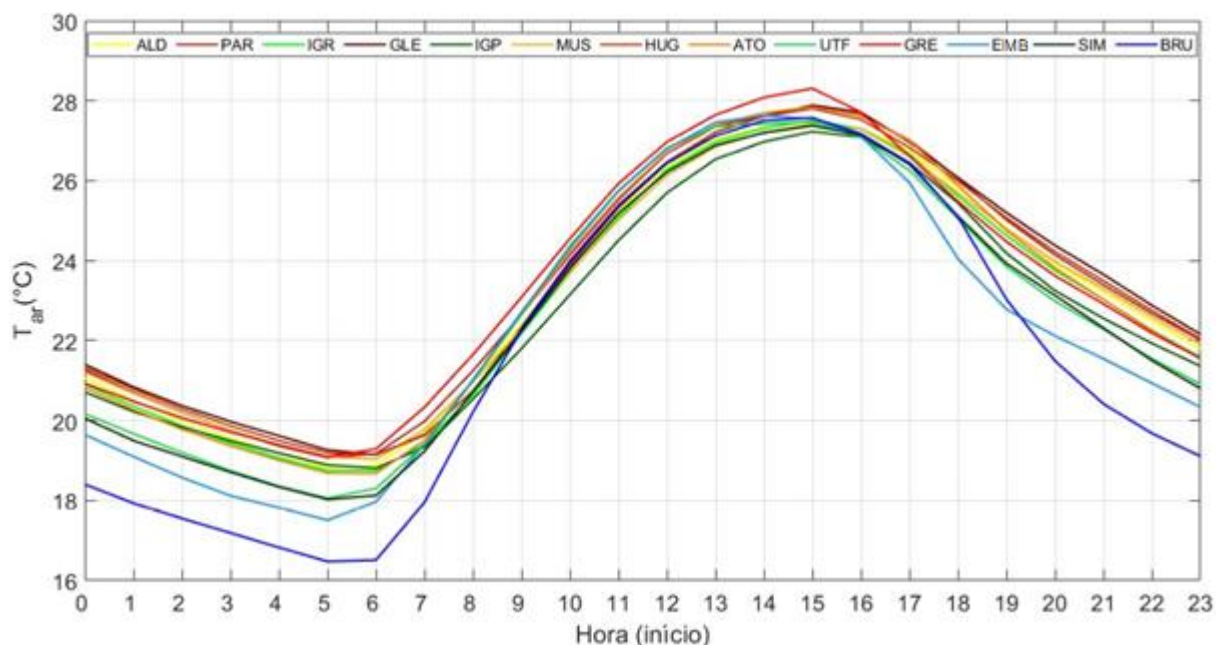
TABELA 3 - Amplitude térmica média diária para o período de 27/08 a 13/12/2018.

ESTAÇÃO	AMPLITUDE TÉRMICA MÉDIA ($^{\circ}\text{C}$)
IGP	9,6
MUS	9,6
GLE	9,9
HUG	9,9
ADL	10,0
PAR	10,0
IGR	10,1
GRE	10,5
UTF	10,7
SIM	10,7
BRU	12,4

Fonte: Autoria própria (2021).

O ciclo médio diário da temperatura do ar para todo o período e por estação de amostragem (Figura 13) indica que os valores mínimos ocorreram as 5h (ADL, PAR, IGR, UTF, GRE, EMB, SIM, BRU) e 6h (GLE, IGP, MUS, HUG, ATO), enquanto os máximos ocorreram às 15h.

FIGURA 13 - Ciclo médio diário da temperatura do ar para as 13 estações meteorológicas.



Após o nascer do sol (05h15 - 06h30 para o período de estudo), a superfície inicia seu aquecimento devido a incidência de radiação solar e à medida que o dia avança, continua o processo de aquecimento e a temperatura máxima do ar é atingida por volta das 15h. Porém, após o pôr do sol (18h11-20h04 para o período de estudo), o processo de resfriamento nas áreas urbanas é mais lento se comparado ao da área rural. Isso se deve ao fato que os materiais presentes nas áreas urbanas, como por exemplo asfalto e concreto, apresentam alta capacidade térmica, absorvendo grande quantidade de radiação solar durante o dia e liberando calor lentamente durante a noite através do fluxo de calor sensível (CHAPMAN *et al.*, 2017).

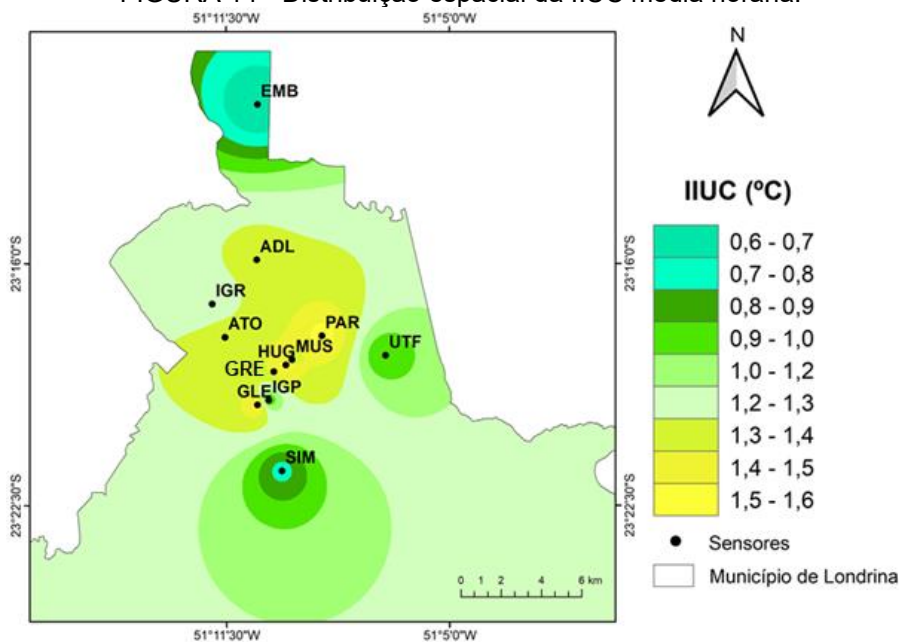
4.2 DISTRIBUIÇÃO ESPACIAL DA IIUC

Ao analisar a distribuição espacial da IIUC na área de estudo, recomenda-se uma interpretação cautelosa, visto que a interpolação pelo método de Krigagem

estabelece gradientes térmicos que podem não condizer com a realidade nos locais onde não foram feitas observações (AMORIM, 2019). No entanto, a escolha do método se justifica por ser o método mais comum de interpolação usado em estudos de IUC (YADAV; SHARMA, 2018; HARDIN *et al.*, 2018; SHAKER *et al.*, 2019; Anjos *et al.*, 2020; ZHANG; LI; HAN, 2020).

Os valores médios horários da IIUC registrados nas estações encontraram-se entre 0,6 °C e 1,6 °C (Figura 14). A IIUC se desenvolveu com maior intensidade nas estações dominadas por asfalto e telhado, as quais tiveram as respectivas porcentagens: GLE (25,3 e 40,3%), HUG (48,9 e 35,1%) e PAR (26,4 e 35,4%), e diminuiu em direção às regiões periféricas nas estações com maior presença de vegetação, EMB (82,7%), UTF (27,8%) e SIM (73,3%) (ver Tabela A1). O mesmo comportamento é observado em estudos urbanos no Reino Unido com IIUC variando entre -1 °C e 4 °C (FENG; CAI; CHAPMAN, 2019), na China com IIUC entre 0 e superior a 3 °C (HUANG *et al.*, 2019) e na Coreia do Sul com IIUC entre 1,5 °C e 3,5 °C (HONG *et al.*, 2019).

FIGURA 14 - Distribuição espacial da IIUC média horária.




Fonte: Autoria própria (2021).

Da mesma forma, foi analisada a distribuição espacial dos valores máximos de IIUC (Figura 15). Os valores máximos diários de IIUC variaram entre 1,1 °C e 3,0 °C. A estação HUG, localizada na região central da cidade de Londrina, apresentou

os maiores valores de IIUC entre 2,8 °C e 3,0 °C, seguida pelas estações GLE, GRE, MUS e PAR (2,5 °C a 2,8 °C).

Os valores máximos de IIUC foram encontrados para os valores mínimos de temperatura do ar, os quais ocorreram simultaneamente no período da noite (18h00 – 06h00), devido à lenta liberação de calor da infraestrutura urbana que apresenta diferentes propriedades térmicas, retardando o resfriamento da temperatura da superfície (DEILAMI; KAMRUZZAMAN; LIU, 2018).

Os resultados demonstram que as características do entorno das estações influenciam diretamente no valor da IIUC. A maior IIUC foi observada nas regiões centrais mais urbanizadas com concentração de telhados, prédios, asfalto e atividades antropogênicas, e a menor ocorreu em estações mais arborizadas e com pouca modificação na cobertura do solo. Em estudo realizado em Jing-Jin-Ji (China), foi registrada uma variação de IIUC entre 0,5 °C e 1,0 °C, com uma diminuição de 0,08 °C a 0,1°C da IIUC em áreas com vegetação (LIANG *et al.*, 2019). Yue *et al.* (2019) observaram uma variação de 0,3 °C a 5,3 °C na IIUC em 36 cidades chinesas, e concluíram que 40% do comportamento da IUC está associado às características do seu entorno. Também afirmaram que valores menores de IIUC ocorreram em áreas urbanas com vegetação.

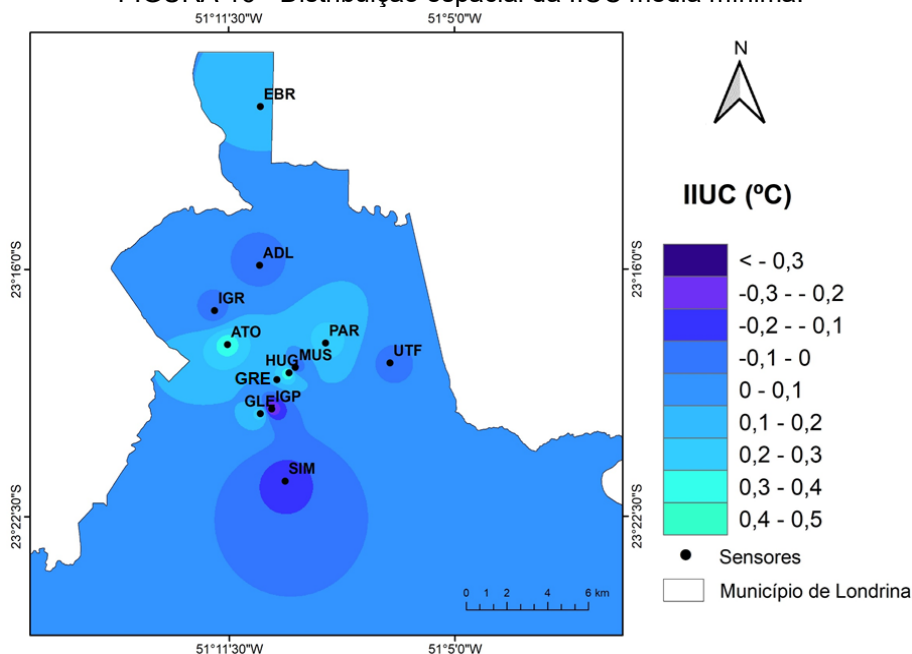


Fonte: Autoria própria (2021).

Considerando agora a temperatura máxima média do ar, os valores mínimos de IIUC variaram entre $-0,3\text{ }^{\circ}\text{C}$ e $0,5\text{ }^{\circ}\text{C}$ (Figura 16). Neste caso, foi possível observar a presença de IUF em seis das estações estudadas sendo quatro na região urbana (IGP, MUS, ADL, IGR) e duas na região periférica (SIM, UTF). A estação IGP apresentou a IUF com diferença térmica igual a $-0,8\text{ }^{\circ}\text{C}$.

Esse fenômeno de IUF pode ser ocasionado pela maior abundância de umidade nas áreas urbanas em comparação com as áreas rurais e à arborização (BOWLER *et al.*, 2010; CHEN; CAI; TONG, 2019), tamanho e largura das ruas e emissão de partículas espalhadoras pelos veículos (MEMON *et al.*, 2009), o efeito de sombreamento devido à grande quantidade de edificações com grandes pavimentos e a presença de corpos d'água (RIZWAN; DENIS; LIU, 2008). Neste estudo, as estações que apresentaram IUF em sua maioria possuem áreas com bastante vegetação (por exemplo árvores e gramado) em seu entorno, que são responsáveis pelo processo de evapotranspiração. IGP, além da presença de vegetação, tem ao seu entorno o lago Igapó.


FIGURA 16 - Distribuição espacial da IIUC média mínima.



A Figura 17 apresenta o ciclo médio diário da IIUC para todas as estações de monitoramento considerando todo o período de amostragem. Vê-se claramente que o

efeito da IUC foi mais pronunciado durante a noite do que durante o dia para as 12 estações urbanas, além da presença de IUF durante o dia e início do pôr do sol.

FIGURA 17 - Ciclo médio diário da IIUC. As linhas verticais correspondem ao período diurno (06h - 18h).



Fonte: Autoria própria (2021).

Observa-se que a IIUC começa a se desenvolver no pôr do sol (18h) e atinge seu ápice a noite (21h00), diminuindo logo após o nascer do sol, com intensidades médias variando entre 1,1 °C e 3,0 °C. Esse efeito também foi observado por Menon, Leung e Liu (2009) (1,5 °C a 2,5 °C), Targino, Coraiola e Krecl (2014) (-0,2 °C a superior 3 °C), Ünal *et al.* (2019) (0,2 °C a 1,7 °C) e CIARDINI *et al.* (2019) (-1,4 °C a 2,9 °C). No período das 10h às 20h, várias estações (ADL, IGP, MUS, IGR, SIM, UTF, HUG e EMB) apresentaram IUF. Em estudo realizado em Guadalajara (México), a IUF foi também registrada durante o dia (10h00 às 18h00), atingindo valores entre -0,5 e -1,5 °C (JAUREGUI; GODINEZ; CRUZ, 1992).

Entre as 18h e 22h, a IIUC aumenta rapidamente com pouca variação durante o restante da noite, embora as temperaturas ainda serem diferentes. Como as superfícies impermeáveis possuem uma elevada capacidade de armazenar calor sensível durante o dia, nas primeiras horas noturnas, há um maior fluxo de calor latente entre a superfície e o ar. Após algumas horas, a diferença da temperatura da superfície e do ar diminui e permanece pequena até a saída do sol, quando um novo

ciclo se inicia. O mesmo comportamento foi observado em Londrina por Targino, Coraiola e Krecl (2014) e Anjos e colaboradores (2020).

4.3 SELEÇÃO DAS VARIÁVEIS INDEPENDENTES

4.3.1 Teste de Normalidade e Transformação Logarítmica

Um conjunto de variáveis independentes (numéricas e categóricas) foi analisado para identificar as possíveis variáveis preditoras da temperatura do ar tanto para o dia, quanto para a noite (Quadro 7).

QUADRO 7 - Variáveis inseridas nos modelos.

(continua)

	Tipo	Nome	Variável	Descrição ¹	Unidade ²	Tipo
Variáveis espaciais	Cobertura do solo	USO1	Telhado	Valor representado entre 0 e 1 para cada <i>buffer</i>	% ³	Numérica
		USO2	Vegetação	Valor representado entre 0 e 1 para cada <i>buffer</i>	%	Numérica
		USO3	Asfalto	Valor representado entre 0 e 1 para cada <i>buffer</i>	%	Numérica
		USO4	Solo exposto	Valor representado entre 0 e 1 para cada <i>buffer</i>	%	Numérica
		USO5	Água	Valor representado entre 0 e 1 para cada <i>buffer</i>	%	Numérica
		USO1C	Telhado	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		USO2C	Vegetação	Valor representado 0 ou 1 para cada <i>buffer</i>	% ^c	Categórica
		USO3C	Asfalto	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		USO4C	Solo exposto	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		USO5C	Água	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		NDVI	Índice de vegetação por diferença normalizada	Valor representado entre -1 e 1 para cada <i>buffer</i>	-	Numérica
		NDBI	Índice de construções por diferença normalizada	Valor representado entre -1 e 1 para cada <i>buffer</i>	-	Numérica
		NDWI	Índice de água por diferença normalizada	Valor representado entre -1 e 1 para cada <i>buffer</i>	-	Numérica
	Distribuição populacional	POP	População total	Valor médio para cada <i>buffer</i>	hab	Numérica
		POPD	Densidade populacional	Valor médio para cada <i>buffer</i>	hab m ⁻²	Numérica
	Geometria urbana	ED	Altura dos edifícios	Valor médio para cada <i>buffer</i>	m	Numérica
		SVF	Fator de visão do céu	Valor único para cada local	%	Numérica
		HIP	Hipsometria	Valor médio para cada <i>buffer</i>	m	Numérica
		Dec1	Porcentagem de superfície plana	Valor único para cada <i>buffer</i>	%	Numérica

QUADRO 7 - Variáveis inseridas nos modelos. (conclusão)

	Tipo	Nome	Variável	Descrição ¹	Unidade ²	Tipo
Variáveis espaciais	Geometria urbana	Dec2	Porcentagem de superfície suave ondulada	Valor único para cada <i>buffer</i>	%	Numérica
		Dec3	Porcentagem de superfície ondulada	Valor único para cada <i>buffer</i>	%	Numérica
		Dec4	Porcentagem de superfície forte-ondulada	Valor único para cada <i>buffer</i>	%	Numérica
		Dec1C	Porcentagem de superfície plana	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		Dec2C	Porcentagem de superfície suave ondulada	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		Dec3C	Porcentagem de superfície ondulada	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
		Dec4C	Porcentagem de superfície forte-ondulada	Valor representado 0 ou 1 para cada <i>buffer</i>	%	Categórica
Variáveis temporais	Meteorologia	T	Temperatura	Valores horários	°C	Dependente
		VV	Velocidade do vento	Estação meteorológica SIM	m s ⁻¹	Numérica
		DV	Direção do vento	Estação meteorológica SIM	Setores ⁴	Categórica
		RAD	Irradiância	Estação meteorológica SIM	W m ⁻²	Numérica
		CN	Cobertura de nuvens	Estação meteorológica do aeroporto de LONDRINA	Oitavos ⁵	Numérica
		PA_1	Precipitação acumulada (Leve)	Estação meteorológica SIM	Categoria ⁶	Categórica
		PA_2	Precipitação acumulada (Moderada)	Estação meteorológica SIM	Categoria	Categórica
		PA_3	Precipitação acumulada (Forte)	Estação meteorológica SIM	Categoria	Categórica
		UREMB	Umidade relativa	Estação meteorológica EMB	%	Numérica
		URLON	Umidade relativa	Locais de monitoramento LONDRINET	%	Numérica
		PREA	Pressão atmosférica	Estação meteorológica SIM	hPa	Numérica

Fonte: Autoria própria (2021).

1 Os tamanhos de *buffers* são: 100, 200, 300, 400, 500 e 600 m.

2 Valores representados com um hífen (-) são adimensionais.

3 Normalização dos dados (porcentagem/100). Os dados apresentam valores entre 0 e 1.

4 Devido a descontinuidade entre os valores 1 e 360°, os dados foram divididos em oito setores.

5 Apenas dados de cobertura da primeira camada foram utilizados, pois apresentam maior correlação com T.

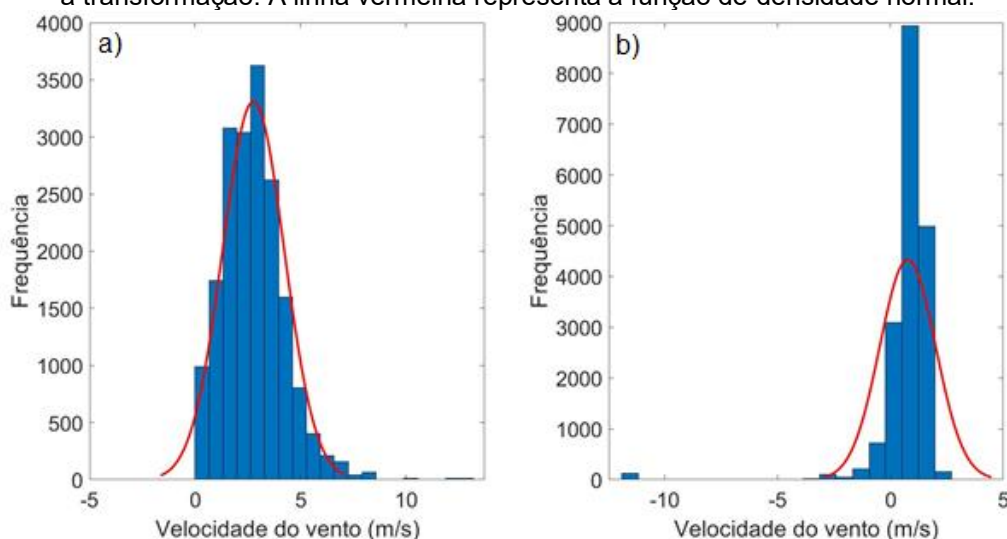
6 Os valores acumulados horários foram convertidos em 4 categorias: Leve (1), moderada (2), forte (3) e tempestade (4).

Averiguou-se a normalidade das variáveis quantitativas independentes e da variável resposta. Para as variáveis espaciais, foi assumido que todas as variáveis apresentavam distribuição normal. Isso se justifica pelo fato que o número de amostras ($n=13$) é muito pequeno e um grande número de amostras ($n>50$) é necessário para detectar desvios da normalidade (BIU; NWAKUYA; WONU, 2020).

Para as variáveis temporais, foram checados os histogramas, o gráfico de probabilidade normal e o teste de Anderson-Darling. Identificou-se que apenas a variável velocidade do vento (VV) não apresentava uma distribuição normal, exibindo uma alta assimetria para a esquerda.

Portanto, foi usada a transformação de potência (Figura 18) para transformar a VV para assim obter uma distribuição normal. No entanto, foi possível perceber que mesmo após a transformação a variável não apresentou uma distribuição normal, mas foi a transformação com melhor ajustamento dos dados estudados, melhorando a assimetria e a aumentando a correlação com a temperatura do ar.

FIGURA 18 - Histograma com a velocidade do vento. a) Dados sem a transformação e b) Dados após a transformação. A linha vermelha representa a função de densidade normal.



Fonte: Autoria própria (2021).

4.3.2 Análise de Multicolinearidade

Com base nos valores de r encontrados e respeitando o critério de seleção ($r \geq 0,6$), foram selecionadas as seguintes variáveis independentes para serem inseridas no modelo:

- Matriz diurna: POP_100, HIP_500, Dec1_100¹⁰, Dec4400, USO3_100, USO5_200, VV, RAD, UREMB, CN, PREA e T.
- Matriz noturna: POP_100, HIP_500, Dec1_100, Dec4_400, USO3_100, USO5_200, VV, RAD, URLON, CN, PREA e T.

A maior correlação observada entre a variável dependente e independente corresponde a UREMB para o dia e a URLON para a noite, com r igual a -0,75 e -0,55, respectivamente. Os demais resultados das correlações para ambas as matrizes podem ser observados no apêndice C. Após considerar a amostra de dados adequada para o objetivo do estudo e as suposições avaliadas para as variáveis, foi desenvolvido o modelo de regressão.

4.3.3 Resultados dos modelos *stepwise* diurno e noturno

Após a seleção das variáveis numéricas, foram acrescentadas as variáveis categóricas. Um total de 21 e 20 variáveis foram inseridas no modelo diurno e noturno, respectivamente.

Mesmo existindo a possibilidade de uma interação bilinear, não houve a escolha dessa configuração por meio do modelo. Portanto, o modelo linear, gerado para o período diurno (Equação 6) e para o noturno (Equação 7) foram os seguintes:

$$T_{\text{diurna}} = 729,88 + 0,003\text{RAD} - 0,160\text{UREMB} - 0,735\text{PREA} \quad \text{Equação (6),}$$

$$T_{\text{noturna}} = 647,27 - 0,149\text{VV} - 0,144\text{URLON} - 0,650\text{PREA} - 1,335\text{DV_SE} \quad \text{Equação (7).}$$

Foi possível observar que o modelo não escolheu nenhuma variável espacial, isto pode estar associado ao número de amostras das variáveis não serem suficientes para que o método fosse executado de maneira correta (rever quadro 6), ao tamanho dos buffers escolhidos, assim como, a não linearidade do problema. Portanto, os

¹⁰ O primeiro valor de cada variável corresponde a classe a qual esta faz parte. Já os três últimos números, correspondem ao tamanho do *buffer* (por exemplo, Dec1_100, corresponde a classe 1 de declividade para o *buffer* de 100m).

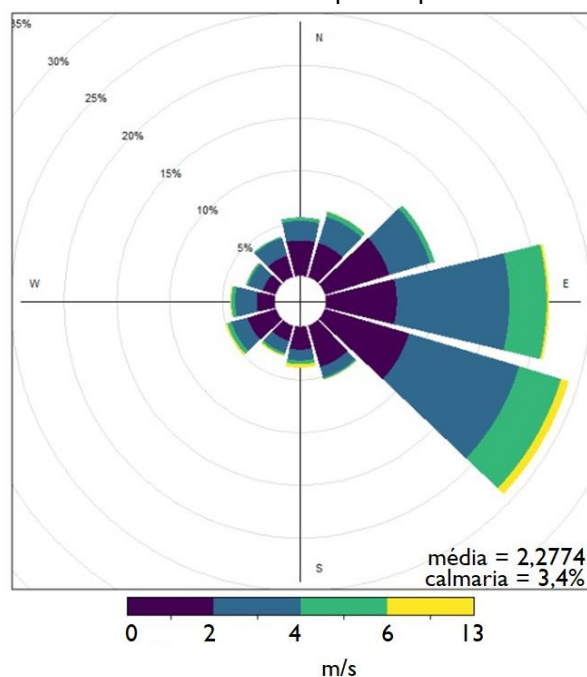
resultados obtidos permitem identificar as variáveis meteorológicas que controlam a temperatura do ar.

As variáveis selecionadas pelo método de *stepwise* foram, RAD, UREMB, PREA para o modelo diurno e VV, URLON, PREA e DV_SE para o modelo noturno. O comportamento negativo da variável PREA pode estar associado ao fato de que durante a primeira quinzena de setembro e segunda quinzena de outubro e novembro atuaram centros de baixa pressão (ciclones) associados a sistemas frontais, favorecendo episódios de friagem (INPE, 2019).

A baixa pressão favorece à ascensão do ar quente e convergência do ar próximo a superfície, gerando formação de nuvens. Desse modo, um centro de baixa pressão costuma ter tempo instável e chuvoso. Segundo Anjos *et al.* (2020), uma das principais configurações do campo de pressão que atuam sobre a região de Londrina são as regiões de baixa pressão, muitas vezes, precedidas de frente fria e formação de nuvens e precipitação. A variável independente com maior impacto sobre o modelo de temperatura do ar foi PREA e DV_SE, com valores de β iguais a $-0,735$ °C/hPa e $1,335$ °C/°, para a matriz diurna e noturna, respectivamente. Observe-se que para ambas as matrizes, as relações entre as variáveis foram negativas, demonstrando que essas variáveis contribuem para a diminuição da temperatura e conseqüentemente da IUC.

Para o período noturna, a variável DV_SE foi a que apresentou o maior valor de β . Estudos comprovam que a direção e velocidade do vento são ótimos indicadores da IUC (BERNAND *et al.*, 2017; DORIGON; AMORIM, 2019; GARDES *et al.*, 2020). Durante o período de estudo, os ventos predominantes foram de sudeste (24,1%), leste (21,2%) e nordeste (10,9%), com velocidade média de 2,28 m/s e calmaria de 3,4% (Figura 19).

FIGURA 19 - Rosa dos ventos para o período de estudo.



Fonte: Aatoria própria (2021).

O vento transporta calor por advecção, assim como umidade (JARDIM, 2011) e auxilia na dispersão de poluentes atmosféricos (KRECL *et al.*, 2014). Deste modo, a presença da DV_SE e VV no modelo mostram que o vento diminui a IIUC (OKE, 1982; MARTINS, 2013) e pode causar uma realocação das áreas com temperaturas elevadas (GEDZELMAN *et al.*, 2003), criando uma distribuição espacial de temperatura do ar relativamente homogênea (STRAUB *et al.*, 2019) e reduzindo o efeito da IUC de dia e de noite (OKE *et al.*, 2017).

A escolha da variável DV_SE pelo modelo pode estar associada ao fato de ser uma das direções predominantes para a região de Londrina, assim como, ser a região onde está localizado o aeroporto, caracterizando a baixa verticalização e quantidade de obstáculos que podem influenciar no percurso do vento. Além de que, segundo Wagner (1989), altos valores de ventos na direção sul, sudeste e leste, no estado do Paraná, evidenciam uma correlação entre a entrada de massas de ar polares que são acompanhadas de ventos fortes do quadrante sul.

Outra variável que contribui para a diminuição da temperatura do ar tanto a noite quanto durante o dia é a umidade relativa. De acordo com o modelo, os valores do coeficiente β encontrados foram de $-0,160$ °C/% no modelo diurno e $-0,144$ °C/% no modelo noturno. A umidade relativa é inversamente proporcional à temperatura do

ar, visto que esta controla o teor de umidade máxima presente em um volume de ar (MENDONÇA; OLIVEIRA, 2009).

A variável URLON, apresentada na equação noturna, refere-se à umidade relativa coletada em cada ponto de estudo. Já a variável UREMB representa os valores observados em apenas um ponto de coleta (EMB). A causa do modelo escolher umidades diferentes pode estar associada ao fato que durante o dia, a umidade relativa para todos os pontos não seja tão diferente (variação entre 0% a 7,6%), se comparada à noite (variação entre 0% e 15,5%).

A distribuição espacial da umidade urbana é influenciada por uma mistura de fatores como rugosidade da superfície, campos térmicos, evapotranspiração e presença de superfícies impermeáveis (DEOSTHALI, 2000), e poderia justificar a escolha distinta feita pelo modelo para o dia e para a noite. O excesso de umidade na atmosfera urbana durante a noite é devido ao aumento da evaporação e transpiração das plantas reforçada pelo ar quente urbano (DEOSTHALI, 2000). Os valores negativos do coeficiente β para UREMB e URLON podem ser explicados pelo fato que conforme a temperatura diminui (devido a evaporação de corpos hídricos ou da vegetação), a umidade do ar ao redor da área aumenta. Por tanto, aumenta o potencial de resfriamento sensível do ar.

Por fim, a variável que apresentou influência positiva sobre o comportamento da temperatura durante o dia foi a RAD ($\beta=0,003 \text{ } ^\circ\text{C/W m}^{-2}$). O nível de contribuição da RAD no modelo diurno está diretamente ligado ao aquecimento das superfícies em decorrência da incidência da radiação de onda curta durante o dia.

O poder preditivo dos modelos diurno e noturno foi de 75,4 e 60,2%, respectivamente. A análise comparativa dos resultados desde estudo com a literatura é difícil, visto que existem diferenças importantes com relação a resolução temporal, tipo e fonte das variáveis preditoras, período de observação e localização geográfica. No entanto, a literatura usa métricas estatísticas semelhantes que podem ser observadas nos estudos apresentados na Tabela 4.

No modelo diurno o valor de RMSE foi de 2,39 $^\circ\text{C}$ e no noturno 2,38 $^\circ\text{C}$, indicando que a temperatura modelada se distanciou dos valores médios observados em 2,39 $^\circ\text{C}$ no período diurno e 2,38 $^\circ\text{C}$ à noite. A precisão da temperatura estimada no presente estudo foi menor do que comparado a estudos como: YAO *et al.* (2021)

com RMSE variando de 0,37 a 0,59, SANTOS (2020) com RMSE igual a 2,03 e SUN; WANG; WANG (2020) com RMSE de 2,03 e 1,74.

TABELA 4 - Comparação com estudos de IUC com métricas semelhantes as deste estudo.

(continua)

Referência	Cidades	País	Clima ¹¹	Dados	Período	Estação do ano	Intervalo de temperatura (°C)	IIUC (°C)	R ² ajustado	RMSE	Método
DORIGON; AMORIM, 2019	Paranavaí	Brasil	Cfa	-	Noturno	Janeiro e julho 2014	15,2 a 33,6	5,2	0,49 (janeiro) e 0,47 (julho).	-	RLM
KETTERER; MATZARAKIS, 2015	Stuttgart	Alemanha	Cfa	Valores médios horários	Diurno e Noturno	Verão 2000 - 2010	9,5 a 30,0	2	0,88	0,28	RLM
GARDES et al., 2020	42 cidades	França	Cfb	200,000 Unidades espaciais de referência	Noturno	Verão 2000-2009	-	1,5 a 2,6	0,11 a 0,39	RLM: Total - 0,85 42 cidades: (0,19 a 1,34) RF: Total - 0,85 42 cidades: (0,25 a 1,69)	RLM e Random Forest
STRAUB et al., 2019	Augsburg	Alemanha	Cfb	Valores médios horários e diários	Diurno e Noturno	Dezembro 2012 a Janeiro 2017	-4 a 24	5	0,85	-	RLM Random Forest

¹¹ Segundo a classificação de Köppen.

TABELA 4 – Comparação com estudos de IUC com métricas semelhantes as deste estudo.

(conclusão)

Referência	Cidades	País	Clima ¹²	Dados	Período	Estação do ano	Intervalo de temperatura (°C)	IIUC (°C)	R ² ajustado	RMSE	Método
SUN; WANG; WANG, 2020	Londres e Paris	Inglaterra e França	Cfb	Valores médios anuais	Diurno e Noturno	15 anos	-	-	0,63 – Londres 0,68 – França	2,03 - Londres 1,74 – França	Modelos de especificação espacial exponencial de matriz
AMORIM (2020)	Presidente Prudente	Brasil	Aw	Valores médios, máximos e mínimos horários	Diurno e Noturno	Agosto e dezembro 2015	18,2 a 35,8	2 a 6	-	-	RLM
EQUERE; MIRZAI; RIFFAT, 2020	São Francisco	EUA	Csc	-	-	Junho 2018	7 a 26	-	0,65 a 0,68	2,54-	RLM
ABBAS; ISMAEL, 2020	Qalyub	Egito	Bwh	-	Diurno e Noturno	Setembro 2019	6 a 34	1,5	0,96	0,6 a 1,1	RLM
Esse estudo	Londrina	Brasil	Cfa	Valores médios horários	Diurno e Noturno	Agosto a dezembro 2018	12,5 a 30,5	0,6 e 1,6	0,76 (dia) 0,60 (noite)	2,39 (dia) 2,38 (noite)	RLM

Fonte: Autoria própria (2021).

¹² Segundo a classificação de Köppen.

4.3.4 Validação do modelo

Os resultados de rodar o modelo 100, 300 e 500 vezes com o método de *bootstrapping*, retirando 25% das amostras cada vez, indicou que a variação das métricas (valores médios, mínimo, máximo de R^2 ajustado e RMSE) foi muito pequena quando os modelos foram rodados 300 e 500 vezes (ver detalhes na Tabela C1). Portanto, a estimativa da robustez do modelo foi baseada em 300 execuções, produzindo valores RMSE muito parecidos para os modelos diurno e noturno com média de 2,38 °C. Porém, os valores de R^2 ajustados foram bem diferentes comparando o modelo diurno e noturno com média de 0,76 vs. 0,60 (Tabela 5).

Para o modelo diurno, as variáveis selecionadas pelo método *stepwise* nas 300 simulações foram RAD, UREMB, PREA, DV_NE e DV_SE (Tabela 6) mas apenas as três primeiras estavam presentes em todas as equações de regressão, o que coincide com nosso resultado anterior e indica que essas variáveis são as mais impactantes ao prever temperatura do ar em Londrina. De forma semelhante, o modelo noturno mais frequente (91,3% das simulações) foi o mesmo já calculado quando considerado o total de amostras (ver Equação 7 e Tabela 5).

TABELA 5 - Métricas de desempenho do bootstrapping para os modelos diurno e noturno com 300 simulações.

Modelo	Estatístico	R^2 ajustado	RMSE (°C)
Diurno	Média	0,756	2,38
	Máximo	0,773	2,43
	Mínimo	0,745	2,31
Noturno	Média	0,602	2,38
	Máximo	0,627	2,42
	Mínimo	0,585	2,33

Fonte: Autoria própria (2021).

TABELA 6 - Equações de regressão linear para os modelos diurno e noturno a partir do bootstrapping com 300 simulações. (continua)

Modelo diurno		
Equação	Frequência [#]	Frequência [%]
$T \sim 1 + RAD + UREMB + PREA$	239	79,7
$T \sim 1 + RAD + UREMB + PREA + DV_NE$	60	20,0
$T \sim 1 + RAD + UREMB + PREA + DV_SE$	1	0,3
Total	300	100,0

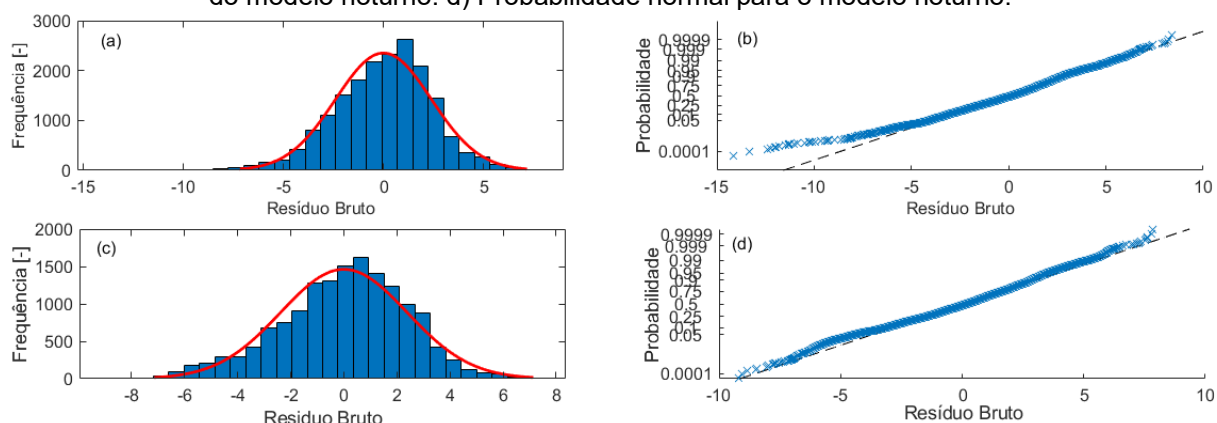
TABELA 6 - Equações de regressão linear para os modelos diurno e noturno a partir do *bootstrapping* com 300 simulações. (conclusão)

Modelo noturno		
Equação	Frequência [#]	Frequência [%]
$T \sim 1 + VV + URLON + PREA + DV_SE$	274	91,3
$T \sim 1 + Dec4_600 + VV + URLON + PREA + DV_SE$	26	8,7
Total	300	100,0

Fonte: Autoria própria (2021).

Os resíduos para o modelo diurno (Figura 20 a e b) e noturno (Figura 20 c e d) não apresentaram distribuição normal segundo indicado pelo teste de normalidade de Anderson-Darling.

FIGURA 20 - Análise de normalidade dos resíduos dos modelos diurno e noturno. a) Histograma do resíduo do modelo diurno. b) Probabilidade normal para o modelo diurno. c) Histograma do resíduo do modelo noturno. d) Probabilidade normal para o modelo noturno.



Fonte: Autoria própria (2021)

Ao aplicar diferentes diagnósticos (Tabela 7), 5,4% e 10,2% das observações diurnas e noturnas, respectivamente, foram identificados como observações influentes.

TABELA 7 - Diagnósticos considerados para identificar observações influentes e número de amostras identificadas.

Diagnóstico	Diurno	Noturno
	Número de amostras	Número de amostras
Resíduo estudentizado	938	870
Alavancagem	64	727
Razão de covariância	1027	1366
DFFIT	1113	1007
^a Total observações influentes	1002	1597


^aSem repetição.

Fonte: Autoria própria (2021).

As observações influentes totais consistem na soma de todos os números de amostras observados, sem considerar observações repetidas, pois a mesma observação pode ser identificada por mais de um diagnóstico. Destaca-se que a distância de cook's não identificou nenhuma observação.

Os valores influentes foram excluídos do modelo e este foi rodado novamente. A correlação entre os valores da temperatura do ar diurna e temperatura do ar noturna observadas e modeladas é apresentada na Figura 21. Os modelos diurnos e noturnos mostraram dificuldade para modelar os valores extremos, sendo que os menores valores de temperatura foram sobrestimados em 3,26 e 2,69 vezes e os maiores em, 1,08 e 1,03 vezes, para o dia e para a noite, respectivamente.

Figura 21 - Correlação entre os valores de temperatura coletados e modelados para os períodos diurno (a) e noturno (b), quando as observações influentes foram excluídas da análise.



Fonte: Autoria própria (2021).

5 CONSIDERAÇÕES FINAIS

Este estudo caracterizou o desenvolvimento da IUC a partir de 13 pontos de coleta para a cidade de Londrina, utilizando medições de temperatura do ar, bem com uma análise estatística a partir de uma regressão linear múltipla. Cálculos da IIUC demonstraram que os locais mais urbanos, com maior cobertura de telhado e asfalto (estações GLE, HUG e PAR) apresentaram maiores valores de IIUC. Em contra partida, as estações EMB, UTF e SIM localizadas na periferia e com maior quantidade de vegetação, apresentaram os menores valores de IIUC.

Os picos da IUC ocorrem no período entre às 00h e 06h, mas a duração e intensidade dependem das condições meteorológicas e do entorno de cada estação. A análise das características atmosféricas durante o período de coleta de dados mostrou que, a relação entre o centro da cidade e sua área periférica apresenta diferentes comportamentos da IUC próxima à superfície, causando características distintas da temperatura do ar.

Os modelos de RLM identificaram que as variáveis mais importantes para explicar a variação da temperatura do ar foram irradiância, umidade relativa e pressão atmosférica para o dia, e velocidade do vento, direção do vento, umidade relativa e pressão atmosférica para a noite. Vale ressaltar que o modelo identificou apenas a variável irradiância com contribuição positivamente para o aumento da temperatura.

Os modelos lineares explicaram 75,4 e 60,2% da variância da temperatura do ar a partir das variáveis independentes já mencionadas para o período diurno e noturno, respectivamente.

5.1 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

As variáveis espaciais não foram escolhidas pelo modelo RLM, possivelmente devido a pequena quantidade de dias analisados ou aos tamanhos dos *buffers* serem inapropriados. Portanto, para estudos futuros recomenda-se: I) aumentar o período de estudo para esse tipo de variável, talvez em sazonalidades ou anos, para que os dados das variáveis sofram alterações perceptíveis, ampliando o número de observações e melhorando o desempenho do modelo, já que são características que não se alteram consideravelmente por um pequeno intervalo de tempo, II) considerar

diferentes escolhas do tamanho dos *buffers*, como por exemplo, *buffers* maiores do que 600 m ou até mesmo com intervalos de 50 m entre cada um.

Ainda sobre as variáveis espaciais, são características que não se alteram consideravelmente por um pequeno intervalo de tempo, portanto, para estudos futuros, recomenda-se aumentar o período de estudo, talvez em anos, para que os dados das variáveis sofram alterações perceptíveis, aumentando o número de observações e melhorando o desempenho do modelo. Por exemplo, avaliar a diferença sazonal do uso do solo dentro do mesmo ano.

Quanto a técnica de estimação escolhida (*stepwise*) talvez não tenha sido a melhor e tenha interferido na escolha das variáveis, visto que o número de amostras para as variáveis espaciais não era suficiente para que o método fosse executado de maneira correta, podendo dessa forma, excluir as variáveis sem que fosse analisado se elas tinham ou não influência no comportamento da temperatura. Portanto, escolher outro método de estimação (por exemplo: *forward* ou *backward*).

A relação básica apresentada na regressão múltipla é a associação linear entre as variáveis dependente e independentes. Neste caso, evitar o acréscimo de variáveis não métricas é outra recomendação que pode vir a melhorar a estimação do modelo pesquisado, visto que a regressão é limitada a dados métricos.

O fato de aceitar que as variáveis eram lineares, quando não eram, pode ter prejudicado a estimação, logo, usar a transformação dos dados para atender as suposições, faz-se necessário para estudos futuros.

Enquanto a RLM pertence às abordagens paramétricas lineares, outra abordagem utilizada com sucesso em estudos de temperatura, é a Floresta Aleatória (inglês *Random Forest*). É um método não paramétrico, que modela processos não lineares, permitindo a combinação de preditores categóricos e contínuos e ser menos susceptível a alta correlação das variáveis. Portanto, recomenda-se utilizar este método para estudos futuros.

REFERÊNCIAS

ABBAS, W.; ISMAEL, H. Assessment of constructing canopy urban heat island temperatures from thermal images: An integrated multi-scale approach. **Scientific African**, v. 10, e00607, 2020.

AFLAKI, A.; MIRNEZHAD, M.; GHAFARIANHOSEINI, A.; GHAFARIANHOSEINI, A.; OMRANY, H.; WANG, Z.; AKBARI, H. Urban heat island mitigation strategies: A state-of-the-art review on Kuala Lumpur Singapore and Hong Kong. **Cities**, v. 62, p. 131-145, 2017.

ALVES, M. F.; LOTUFO, A. D. P.; LOPES, M. L. M. Seleção de variáveis stepwise aplicadas em rede neurais artificiais para previsão de demanda de cargas elétricas. **Proceeding series of the Brazilian Society of Computational and Applied Mathematics**, v. 1, 2013.

AMORIM, M. C. C. T. Climatologia e gestão do espaço urbano. **Mercator**, p. 71-90, 2010.

AMORIM, M. C. C. T.; DUBREUIL, V.; CARDOSO, R. S. Modelagem espacial da ilha de calor urbana em Presidente Prudente (SP) – Brasil. **Revista Brasileira de Climatologia**, v.16, p. 29-45, 2015.

AMORIM, M. C. T. Ilha de Calor Urbanas: Métodos e técnicas de análise. **Revista Brasileira de Climatologia**, v.25, p. 22-46, 2019.

AMORIM, M. C. C. T. Ilhas de calor urbano em cidades de pequeno e médio porte no Brasil e o contexto das mudanças climáticas. **Paru dans Confins**, v.46, 2020a.

AMORIM, M. C. C. T. Daily Evolution of urban heat islands in a Brazilian tropical continental climate during dry and rainy periods. **Urban Climate**, v. 34, 100715, 2020b.

ANA. **Bacias Hidrográficas do Paraná: Série Histórica**. Curitiba. 2010.

ANJOS, M.; TARGINO, A. C.; KRECL, P.; OUKAWA, G. Y.; BRAGA, R. F. Analysis of urban heat island. Under different synoptic patterns using local climate zones. **Building and environment**, v.185, 107268, 2020.

ARGUESO, D.; EVANS, J. P.; FITA, L.; BORMANN, K. J. Temperature response to future urbanization and climate change. **Climate Dynamics**, v. 42, p. 2183-2199, 2014.

ARNFIELD, A. J. Two decades of urban climate research: A review of turbulence, exchanges of energy and water, and the urban heat island. **International Journal of Climate**, v. 23, p. 1-26, 2003.

AYOADE, J. O. **Introdução à Climatologia para os trópicos**. 4ª ed. Rio de Janeiro: Bertrand Brasi, 1996.

BAKLANOV, A.; GRIMMOND, C. S. B.; CARLSON, D.; TERBLANCHE, D.; TANG, X.; BOUCHET, V.; LEE, B.; LANGENDIJK, G.; KOLLI, R. K.; HOVSEPYAN, A. From urban meteorology, climate and environment research to integrated city services. **Urban Climate**, v.23, p. 330-341, 2018.

BERNARD, J.; MUSY, M.; CALMET, I.; BOCHER, E.; KERAVEC, P. Urban heat island temporal and spatial variations: Empirical modeling from geographical and meteorological data. **Building and Environment**, v. 125, p. 423-438, 2017.

BIU, E. O.; NWAKUYA, M. T.; WONU, N. Detection of non-normality in data sets and comparison between different normality tests. **Asian Journal of Probability and Statistics**, v.5, p. 1-20, 2020.

BRAGANÇA, S. L. Introdução à análise estatística de variáveis dicotômicas e aplicações em dados socioeconômicos. **Revista Brasileira de Economia**, 31 (2), p. 323-352, 1977.

BEK, M.A.; AZMY, N.; ELKAFRAWY, S. The effect unplanned growth of urban areas on heat island phenomena. **Ain Shams Engineering Journal**. v. 9, p. 3169-3177, 2018.

BOWLER, D. E.; BUYUNG-ALI, L.; KNIGHT, T. M.; PULLIN, A. S. Urban greening to cool towns and cities: A systematic review of the empirical evidence. **Landscape and Urban Planning**, v. 97, p. 147-155, 2010.

BOX, G. E. P.; COX, D. R. An analysis of transformations. **Journal of the Royal Society. Series B (Methodological)**, v. 26, p.211-252, 1964.

CAI, D.; FRAEDRICH, K., GUAN, Y.; GUO, S.; ZHANG, C.; ZHU, X. Urbanization and climate change: Insights from eco-hydrological diagnostics. **Science of the Total Environment**, v.647, p. 29-36, 2019.

CAMARGO, E. C. G. **Desenvolvimento, Implementação e Teste de Procedimentos Geoestatísticos (Krigagem) no Sistema de Informações Georreferenciadas (SPRING)**. Ministério da Ciência e Tecnologia, 1998.

CARDOSO, R. S.; AMORIM, C. C. T. Variações espaciais das temperaturas noturnas em Presidente Prudente – SP em episódios de verão. **Raega**, v. 42, p. 257-268, 2017.

CHAPMAN, S.; WATSON, J. E. M.; SALAZAR, A.; THATCHER, M.; MCALPINE, C. A. The impact of urbanization and climate change on urban temperatures: a systematic review. **Landscape Ecology**, v. 32, p. 1921-1935, 2017.

CHEN, L.; NG, E.; AN, X.; REN, C.; LEE, M. WANG, U.; HE, Z. Sky view factor analysis of street canyons and its implications for daytime intra-urban air temperature

differentials in high-rise, high-density urban areas of Hong Kong: a GIS-based simulation approach. **International Journal of Climatology**, v. 32, p. 121-136, 2012.

CHEN, Y.; CAI, Y.; TONG, C. Quantitative analysis of urban cold island effects on the evolution of green spaces in a coastal city: A case of Fuzhou, China. **Environmental Monitoring and Assessment**, p. 191-221, 2019

CIARDINI, V.; CAPORASO, L.; SOZZI, R.; PETENKO, I.; BOLIGNANO, A.; MORELLI, M.; MELAS, D.; ARGENTINI, S. Interconnections of the urban heat island with the spatial and temporal micrometeorological variability in Rome. **Urban Climate**, v. 29, p. 100493, 2019.

CONGEDO, L. **Semi-automatic classification plugin documentation**. 2016.

COUTTS, A.; WHITE, E. C.; TAPPER, N. J.; BERINGER, J.; LIVESLEY, S. J. Temperature and human thermal comfort effects of street trees across three contrasting street canyon environments. **Theoretical and Applied Climatology**, v. 124, p. 55-68, 2016.

DASH, P.; GOTTSCHKE, F.M.; OLESEN, F.S.; FISCHER, H. Land surface temperature and emissivity estimation from passive sensor data: Theory and practice-current trends. **International Journal of Remote Sensing**, v. 23, p. 2563 – 2594, 2004.

DEILAMI, K.; KAMRUZZAMAN, M.; LIU. Urban heat island effect: A systematic review of spatio-temporal factors, data, methods, and mitigation measures. **International Journal of Applied Earth Observation and Geoinformation**, v. 67, p. 30-42, 2018.

DEOSTHALI, V. Impact of rapid urban growth on heat and moisture islands in Pune City, India. **Atmospheric Environment**, v.34, p. 2745-2754, 2000.

DORIGON, L. P.; AMORIM, M. C. C. T. Spatial modeling of an urban Brazilian heat island in a tropical continental climate. **Urban Climate**, v. 28, p. 01-13, 2019.

DUAN, S.; LUO, Z.; YANG, X.; LI, Y. The impact of building operations on urban heat/cool island under urban densification: A comparison between naturally-ventilated and air-conditioned buildings. **Applied Energy**, v. 235, p. 129-138, 2019.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA – EMBRAPA. **Sistema brasileiro de classificação de solos**. Brasília, Serviço de Produção de Informação, 412p. 1999.

EQUERE, V.; MIRZAEI, P. A.; RIFFAT, S. Definition of a new morphological parameter to improve prediction of urban heat island. **Sustainable Cities and Society**, v. 56, 102021, 2020.

ESPINOZA, N. S. **Avaliação da ilha de calor urbana em Manaus com dados observados *in situ* e sensoriamento remoto**. Orientador: Carlos Antonio Costa

dos Santos e Maria Bethânia Leal de Oliveira. 2017. 71f. Dissertação (Mestrado em Meteorologia) – Universidade de Campina Grande, Campina Grande, Paraíba, 2017.

FALLAHI, S.; AMANOLLAHI, J.; TZANIS, C. G.; RAMLI, M. F. Estimating solar radiation using NOAA/AVHRR and ground measurement data. **Atmospheric Research**, v. 199, p. 93-102, 2018.

FENG, J. L.; CAI, X. M.; CHAPMAN, L. Impact of atmospheric conditions and level of urbanization on the relationship between nocturnal surface and urban canopy heat island. **Quarterly Journal of the Royal Meteorological Society**, v. 145, p.3284-3299, 2019.

FENGER, J.; TJELL, J.C. **Air Pollution from a local to a global perspective**. 1^a ed. Polyteknisk Forlag. 2009.

FERREIRA, M. J. **Estudo do balanço de energia na superfície da cidade de São Paulo**. Orientador: Amauri Pereira de Oliveira. 2010. 183f. Tese (Doutorado em Ciência Atmosférica) – Instituto de Astronomia, Geofísica e Ciências Atmosféricas, Universidade de São Paulo, São Paulo, 2010.

FOISSARD, X. **L'îlot de chaleur urbain et le changement climatique: application à l'agglomération rennaise**. These (Docteur) - Université de Rennes II, Rennes, 248p. 2015.

FOISSARD, X.; DUBREUIL, V.; QUÉNOL, H. Defining scales of the land use effect to map the urban heat island. In a mid-size European city: Rennes (France). **Urban Climate**, v. 29, p. 100490, 2019.

FONG, C. S.; AGHAMOHAMMADI, N.; RAMAKRESHNAN, L.; SULAIMAN, N. M.; MOHAMMADI, P. Holistic recommendations for future outdoor thermal comfort assessment in tropical Southeast Asia: critical appraisal. **Sustainable Cities and Society**, v. 46, p. 101428, 2019.

FOUNDA, D.; PIERROS, F.; PETRAKIS, M.; ZEREFOS, C. Interdecadal variations and trends of the urban heat island in Athens (Greece) and its response to heat waves. **Atmospheric Research**, v.161-162, p. 1-13, 2015.

GABRIEL, K. M.; ENDLICHER, W. R. Urban and rural mortality rates during heat waves in Berlin and Brandenburg, Germany. **Environmental Pollution**, v. 159, p. 2044-2050, 2011.

GAL, T.; UNGER, J. A new software tool for SVF calculations using building and tree-crowns data bases. **Urban Climate**, v.10, p. 594-606, 2014.

GARDES, T.; SCHOETTER, R.; HIDALGO, J.; LONG, N.; MARQUÈS, E.; MASSON, V. Statistical prediction of the nocturnal urban heat island intensity based on urban morphology and geographical factors – An investigation based on numerical model results for a large ensemble of French cities. **Science of the Total Environment**, v.737, p. 13953, 2020.

GARTLAND, L. **Ilhas de calor: como mitigar zonas de calor em áreas urbanas.** Tradução Silvia Helena Gonçalves. São Paulo: Oficina de Textos, 2010.

GEDZELMAN, S. D.; AUSTIN, S.; CERMARK, R.; STEFANO, N.; PARTRIDGE, S.; QUESENBERRY, S.; ROBINSON, D. A. Mesoscale aspects of the urban heat island around New York City. **Theoretical and applied climatology**, v. 75, p. 93-103, 2003.

GEIRINHAS, J. L.; TRIGO, R. M.; LIBONATI, R.; CASTRO, L. C. O.; SOUSA, P. M.; COELHO, C. A. S.; PERES, L. F.; MAGALHÃES, M. A. F. M. Characterizing the atmospheric conditions during the 2010 heat wave in Rio de Janeiro marked by excessive mortality rates. **Science of the Total Environment**, v. 650, p-796-808, 2019.

GHOBADI, A.; KHOSRAVI, M.; TAVOUSHI, T. Surveying of heat waves impact on the urban heat islands: Case study, the Karaj city in Iran. **Urban Climate**, v. 24, p. 600-615, 2018.

GIORDANO, R.; PILLI-SIHVOLA, K.; PLUCHINOTTA, I.; MATARRESE, R. Urban adaptation to climate change: Climate services for supporting collaborative planning. **Climate Services**, p.100100, 2019.

GIRIDHARAN, R.; EMMANUEL, R. The impact of urban compactness, comfort strategies and energy consumption on tropical urban heat island intensity: A review. **Sustainable Cities and Society**, v.40, p. 677-687, 2018.

GOLDEN, J. S.; KALOUSH, K. E. Mesoscale and microscale evaluation of surface pavement impacts on the urban heat island effects. **International Journal of Pavement Engineering**, v. 7, p. 37-52, 2006.

GRIMMOND, S. urbanization and global environmental change: local effects of urban warming. **The Geographical Journal**, v.173, p. 83-88, 2007.

GROVER, A.; SINGH, R. B. Monitoring Spatial Patterns of Land Surface Temperature and Urban Heat Island for Sustainable Megacity: A Case Study of Mumbai, India, Using Landsat TM Data. **Environment and Urbanization ASIA**, 7(1), p.38-54, 2016.

HAIR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise Multivariada de Dados**. 6ª ed. Porto Alegre: Bookman, 2009.

HARDIN, A. W.; LIU, Y.; CO, G.; VANOS, J.K. Urban heat island intensity and spatial variability by synoptic weather type in the northeast U.S. **Urban Climate**, v. 24, p. 747-762, 2018.

HE, X.; WANG, J.; FENG, J.; YAN, Z.; MIAO, S.; ZHANG, Y.; XIA, J. Observational and modeling study of interactions between urban heat island and heatwave in Beijing. **Journal of Cleaner Production**, p.119169, 2019.

HIDALGO, J.; MASSON, V.; GIMENO, L. Scaling the daytime urban heat island and urban-breeze circulation. **Journal of Applied Meteorology and Climatology**, v. 49, p. 889-901, 2010.

HINTZ, M. J.; LUEDERITZ, C.; LANG, D. J.; WEHRDEN, H. V. Facing the heat: A systematic literature review exploring the transferability of solutions to cope with urban heat waves. **Urban Climate**, v. 24, p. 714-727, 2017.

HOCKING, R. R. The analysis and selection of variables in linear regression. **A Biometrics Invited Paper**, v. 32, p. 1-49, 1976.

HOFFMANN, P.; K, KRUEGER, O.; SCHLUNZEN, K. H. A statistical model for the urban heat island and its application to a climate change scenario. **International Journal of Climatology**, v.32, p. 1238-1248, 2012.

HONG, J. W.; HONG, J.; KWON, E. E.; YOON, D. K. Temporal dynamics of urban heat island correlated with the socio-economic development over the past half-century in Seoul, Korea. **Environmental Pollution**, v. 254, p. 112934, 2019.

HU, Y.; HOU, M.; JIA, G.; HAO, C.; ZHEN, X.; XU, Y. Comparison of surface and canopy urban heat islands within megacities of eastern China. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 156, p. 160-168, 2019.

HUANG, Q.; HUANG, J.; YANG, X.; FANG, C.; LIANG, Y. Quantifying the seasonal contribution of coupling urban land use types on urban heat island using land contribution index: A case study in Wuhan, China. **Sustainable Cities and Society**, v. 44, p. 666-675, 2019.

IBGE. **Censo Demográfico 2010**. 2019. Disponível em: <https://censo2010.ibge.gov.br/resultados.html> Acesso em: 20 out. 2019.

ICHINOSE, T.; MATSUMOTO, F.; KATAOKA, K. Chapter 15-Counteracting Urban Heat Islands in Japan. **Urban Energy Transition**, v.1, p. 365-380, 2008.

INPE. **Síntese sinótica – Setembro, Outubro, Novembro e Dezembro de 2018**. Grupo de Previsão de tempo. 2019.

IPCC. **Climate change 2014: impacts, adaptation, and vulnerability**. Chapter 8: Urban Areas. Contribution of working [SILVA, J.; DODMAN, D.; MASKEY, A.; GAJJAR, S. P.; TUTS, R]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA. 2014.

IPING, A.; KIDSTON-LATARRI, J.; SIMPSON-YOUNG, A.; DUNCAN, E.; MCMANUS, P. (Re)presenting urban heat islands in Australian cities: A study of media reporting and implications for urban heat and climate change debates. **Urban Climate**, v. 27, p. 420-429, 2019.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An Introduction to applied Geostatistics**. NY: Oxford University Press, Includes Index, 1989.

JARDIM, C. Relações entre temperatura, umidade relativa do ar e pressão atmosférica em área urbana: comparação horária entre dois bairros no município de São Paulo – SP. **Geografias**, v. 07, p. 128-142, 2011.

JAUREGUI, E.; GODINEZ, L.; CRUZ, F. Aspects of heat-island development in Guadalajara, Mexico. **Atmospheric Environment. Part B. Urban Atmosphere**, v. 3, p. 391-396, 1992.

JENSEN, J. R. **Remote sensing of the environment**. London, Prentice Hall, 544p. 2000.

KHAN, N.; SHAHID, S.; JUNENG, L.; AHMED, K.; ISMAIL, T.; NAWAZ, N. Prediction of heat waves in Pakistan using quantile regression forests. **Atmospheric Research**, v. 221, p. 1-11, 2019.

KEIKHOSRAVI, Q. The effect of heat waves on the intensification of the heat island of Iran's metropolises (Tehran, Mashhad, Tabriz, Ahvaz). **Urban Climate**, v. 28, p.100453, 2019.

KETTERER, C.; MATZARAKIS, A. Comparison of different methods for the assessment of the urban heat island in Stuttgart, Germany. **International Journal of Biometeorology**, v.59, p. 1299-1309, 2015.

KLEEREKOPER, L.; ESCH, M.; SALCEDO, T. B. How to make a city climate-proof, addressing the urban heat island effect. **Resources, Conservation and Recycling**, v.64, p. 30-38, 2012.

KOLOKOTRONI, M.; GIRIDHARAN, R. Urban heat island intensity in London: An investigation of the impact of physical characteristics on changes in outdoor air temperature during summer. **Solar Energy**, v. 82, p. 986-998, 2008.

KOPEC, R. Further observations of the urban heat island a small city. **Bulletin American Meteorological Society**, v. 51, p. 602-606, 1970.

KRECL, P.; JOHANSSON, C.; STRÖM, J.; LÖVENHEIM, B.; GALLET, J.C. A feasibility study of mapping light-absorbing carbon using a taxi fleet as a mobile platform. **Tellus B: Chemical and Physical Meteorology**, v. 66, p. 1-17, 2014.

LEMONSU, A.; VIGUIÉ, V.; DANIEL, M.; MASSON, V. Vulnerability to heat waves: Impact of urban expansion scenarios on urban heat island and heat stress in Paris (France). **Urban Climate**, v. 14, p. 586-605, 2015.

LI, D.; BOU-ZEID, E. Synergistic interactions between urban heat islands and heat waves: The impacts in cities is larger than the sum of its parts. **Journal of Applied Meteorology and Climatology**, v. 52, p. 2051-2064, 2013.

LI, H.; MEIER, F.; LEE, X.; CHAKRABORTY, T.; LIU, J.; SCHAAP, M.; SODOUDI, S. Interaction between urban heat island and urban pollution island during summer in Berlin. **Science of the Total Environment**, v. 636, p. 818-828, 2018.

LI, X.; ZHOU, W. Optimizing urban greenspace spatial pattern to mitigate urban heat island effects: Extending understanding from local to the city scale. **Urban Forestry & Urban Greening**, v. 2, p. 1-32, 2019.

LI, X.; ZHOU, Y.; YU, S.; JIA, G.; LI, H.; LI, W. Urban heat island. Impacts on building energy consumption: A review of approaches and findings. **Energy**, v. 174, p. 407-419, 2019.

LI, L.; ZHA, Y.; ZHANG, J. Spatially non-stationary effect of underlying driving factors on surface urban heat islands in global major cities. **International Journal of Applied Earth Observation and Geoinformation**, v.90, p. 102131, 2020.

LIANG, Z.; WU, S.; WANG, Y.; WEI, F.; HUANG, J.; SHEN, J.; LI, S. The relationship between urban form and heat island intensity along the urban development gradients. **Science of the Total Environment**, v. 4, p. 135011, 2019.

LIN, Y.; LIU, A.; MA, E.; LI, X.; SHI, W. Impacts of future urban expansion on regional climate in the Northeast Megalopolis, USA. **Advances in Meteorology**, p. 1-10, 2013.

LIU, L.; LIN, Y.; LIU, J.; WANG, L.; WANG, D.; SHUI, T.; CHEN, X.; WU, Q. Analysis of local-scale urban heat island characteristics using an integrated method of mobile measurement and GIS-based spatial interpolation. **Building and Environment**, v. 117, p. 191-207, 2017.

LIU, Z.; YAO, Z.; WANG, R. Assessing methods of identifying open water bodies using Landsat 8 OLI imagery. **Environmental Earth Sciences**, v. 75, 873, 2016.

LORENZO, A.; LIAÑO, F. Altas temperaturas y nefrología: a propósito del cambio climático. **Nefrología**, v.5, p. 492-500, 2017.

MANOBS – **MANUAL OF SURFACE WEATHER OBSERVATIONS**. Seventh Edition, Amendment 18, Meteorological Service of Canada, 2013.

MARGALHO, E. S. **Avaliação de ilha de calor urbana na localidade de Belém – PA a partir de técnicas de sensoriamento remoto e dados observacionais**. Orientador: Madson Tavares Silva. 2019. 85f. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Campina Grande, Paraíba, 2019.

MARTINS, C. **Caracterização da ilha urbana de calor na cidade de Londrina, Brasil: cobertura do solo, fatores meteorológicos e conforto térmico**. Orientadora: Patricia Krecl. 2013. 71f. Trabalho de conclusão de curso. Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

MARTIN-VIDE, J. Probability values for the intensity of Barcelona's urban heat island (SPAIN). **Atmospheric Research**, v.240, p.104877, 2020.

MASSON, V. A physically-based scheme for the urban energy budget in atmospheric models. **Boundary-Layer Meteorology**, v. 94, p. 357-397, 2000.

MATHWORKS. **Box-Cox transformation**. 2020. Disponível em: <<https://www.mathworks.com/help/finance/boxcox.html>>. Acesso em: 11 mar. 2021.

MEINEKE, E.; YOUNGSTEADT, E.; DUNN, R. R.; FRANK, S. D. Urban warming reduces aboveground carbon storage, **Proceedings of the Royal Society B**, v.283, p. 1-9, 2016.

MENDONÇA, F.; OLIVEIRA, I. M. D. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de Texto, 2009.

MEMON, R. A.; LEUNG, D. Y. C.; LIU, C. H. An investigation of urban heat island intensity (UHII) as an indication of urban heating. **Atmospheric Research**, v. 94, p. 491-500, 2009.

MINITAB. **Methods and formulas for transformations in individual Distribution Identification**. 2020. Disponível em: <<https://support.minitab.com/en-us/minitab/19/help-and-how-to/quality-and-process-improvement/quality-tools/how-to/individual-distribution-identification/methods-and-formulas/transformations/>>. Acesso em: 11 mar. 2021.

MIKA, J.; FORGO, P.; LAKATOS, L.; OLAH, A. B.; RAPI, S.; UTASI, Z. Impact of 1.5k global warming on urban air pollution and heat island with outlook on human health effects. **Current Opinion in Environmental Sustainability**, v. 30, p. 151-159, 2018.

MIRCHOOI, F.; SADEGHI, S. H.; DARVISHAN, A. K. Analyzing spatial variations of relationship between Land Surface Temperature and some remotely sensed indices in different land uses. **Remote Sensing Applications: Society and Environment**, v. 19, 100359, 2020.

MIRZAEI, P. A.; HAGHIGHAT, F. Approaches to study Urban Heat Island – Abilities and limitations. **Building and Environment**, v. 45, p. 2192-2201, 2010.

MIRZAEI, P. A. Recent challenges in modeling of urban heat island. **Sustainable Cities and Society**, v. 19, p. 200-206, 2015.

MOHAJERANI, A.; BAKARIC, J.; JEFFREY-BAILEY, T. The urban heat island effect, its causes, and mitigation, with reference to the thermal properties of asphalt concrete. **Journal of Environmental Management**, v.197, p. 522-538, 2017.

NORO, M.; BUSATO, F.; LAZZARIN, R. M. Urban heat island. In Padua, Italy: Experimental and Theoretical analysis. **Indoor and Built Environmental**, v. 24, p. 514-533, 2015.

NORTON, B. A.; COUTTS, A. M.; LIVESLEY, S. J.; HARRIS, R. J.; HUNTER, A. M.;

WILLIAMS, N. S. G. Planning for cooler cities: A framework to prioritise green infrastructure to mitigate high temperatures in urban landscapes. **Landscape and Urban Planning**, v. 134, p. 127-138, 2015.

OLIVEIRA, B.S. **Satélites e Sensores**. Instituto Nacional de Pesquisas Espaciais. 2018. Disponível em: <http://www.dsr.inpe.br/DSR/educacao/uso-escolar-sensoriamento-remoto/material-didatico-anos-anteriores/arquivos/3-satelites-e-sensores.pdf>. Acesso em: 06 mar. 2021.

OLIVEIRA, J. V.; COHEN, J. C. P.; PIMENTEL, M.; TOURINHO, H. L.Z.; LÔBO, M. A.; SODRÉ, G.; ABDALA, A. Urban climate and environmental perception about climate change in Belém, Pará, Brazil. **Urban Climate**, v. 31, p. 100579, 2020.

ONU. **A ONU e a população mundial**. 2019. Disponível em: <https://nacoesunidas.org/acao/populacao-mundial/> Acesso em: 27 ago. 2019.

OKE, T. R. The energetic basis of the urban heat island. **Quarterly Journal of the Royal Meteorological Society**, v. 108, p. 1-24, 1982.

OKE, T. R. **Boundary Layer Climates**. 2ª ed. Routledge, 1987.

OKE, T. R. The Heat Island of the urban Boundary Layer: Characteristics, Causes and Effects. **Wind Climate in Cities**, p. 81-107, 1995.

OKE, T. R.; SPRONKEN-SMITH, R. A.; JAUREGUI, E.; GRIMMOND, C. S. B. The energy balance of central Mexico City during the dry season. **Atmospheric Environment**, v. 33, p.3919-3930, 1999.

OKE, T. R.; MILLS, G.; CHRISTEN, A.; VOOGT, J. A. **Urban Climate**. Cambridge University Press. 2017.

PANTAVOU, K.; THEIHARATOS, G.; MAVRAKIS, A.; SATAMOURIS, M. Evaluating thermal comfort conditions and health responses during an extremely hot summer in Athens. **Building and Environment**, v.46, p. 339-344, 2011.

PINHO, O. S.; ORGAZ, M. D. The urban heat island in a small city in coastal Portugal. **International Journal of Biometeorology**, v. 44, p. 198-203, 2000.

QAID, A.; LAMIT, H. B.; OSSEN, D. R.; SHAHMINAN, R. N. R. Urban heat island and thermal comfort conditions at micro-climate scale in a tropical planned city. **Energy and Building**, v 133, p. 577-595, 2016.

QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System: Open Source Geospatial Foundation Project**. 2020.

RAMYAR, R.; ZARGHAMI, E.; BRYANT, M. Spatio-temporal planning of urban neighborhoods in the context of global climate change: Lessons for urban form design in Tehran, Iran. **Sustainable Cities and Society**, v. 51, p. 101554, 2019.

RANI, M.; KUMAR, P.; PANDEY, P. C.; SRIVASTAVA, P. K.; CHAUDHARY, B. S.; TOMAR, V.; MANDAL, V. P. Multi-temporal NDVI and surface temperature analysis

for Urban Heat Island inbuilt surrounding of sub-humid region: A case study if two geographical regions. **Remote Sensing Applications: Society and Environment**, v. 10, p. 163-172, 2018.

RASUL, A.; BALZTER, H.; SMITH, C. Spatial variation of the daytime surface urban cool island during the dry season in Erbil, Iraqi Kurdistan, from Landsat 8. **Urban Climate**, v. 14, p. 176-186, 2015.

REVI, A.; SATTERTHWAITE, D. E.; ARAGÓN-DURAND, F.; CORFEE-MORLOT, J.; KIUNSI, R. B. R.; PELLING, M.; ROBERTS, D. C.; SOLECKI, W. **Urban Areas**. In: *Climate Change 2014: Impacts, Adaptation and Vulnerability. Part A: Global and Sectorial Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change* [Field, C.B.; Barros, V.R.; Dokken, D.J.; Mach, K.J.; Mastrandrea, M.D.; Bilir, T.E.; Chatterjee, M.; Ebi, K.L.; Estrada, Y.O.; Genova, R.C.; Girma, B.; Kissel, E.S.; Levy, A.N.; MacCracken, S.; Mastrandrea, P.R.; White. L.L. (eds.)]. Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA, p. 535-612, 2014.

RIZVI, S. H.; ALAM, K.; IQBAL, M. J. Spatio-temporal variations in urban heat island and its interaction with heat wave. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 185, p. 50-57, 2019.

RIZWAN, A. M.; DENNIS, L. Y. C.; LIU, C. A review on the generation, determination and mitigation of urban heat island. **Journal of Environmental Sciences**, v. 20, p. 120-128, 2008.

RODRÍGUEZ, L. R.; RAMOS, J. S.; FÉLIX, J. L. M.; DOMÍNGUEZ, S. A. Urban-scale air temperatura estimation: development of an empirical model based on mobile transects. **Sustainable Cities and Society**, v. 63, 102471, 2020a.

RODRÍGUEZ, L. R.; RAMOS, J. S.; FLOR, F. J. S.; DOMÍNGUEZ, S. A. Analyzing the urban heat island: Comprehensive methodology for data gathering and optimal design of mobile transects. **Sustainable Cities and Society**, v. 55, 102027, 2020b.

SANTAMOURIS, M. On the energy impact of urban heat island and global warming on buildings. **Energy and Buildings**, v. 82, p. 100-113, 2014.

SANTAMOURIS, M. Chapter 3^o - Urban Heat Island and Local Climate Change. In: SANTAMOURIS, M. **Minimizing energy consumption, energy poverty and global and local climate change in the built environment: innovating to zero**. Elsevier, p. 65-102, 2019.

SANTOS, R. S. Estimating spatio-temporal air temperature in London (UK) using machine learning and earth observation satellite data. **International Journal of Applied earth Observation and Geoinformation**, v. 88, 102066, 2020.

SETO, K. C.; GUNERALP, B.; HUTYRA, L. R. Global forecasts of urban expansion to 2030 and direct impacts on biodiversity and carbon pools. **Proceedings of the National Academy of Sciences**, v. 109, p. 16083-16088, 2012.

SHAKER, R. R.; ALTMAN, Y.; DENG, C.; VAZ, E.; FORSYTHE, K. W. Investigating urban heat island through spatial analysis of New York City streetscapes. **Journal of Cleaner Production**, v.233, p. 972-992, 2019.

SHARIFI, E.; LEHMANN, S. Comparative analysis of surface urban heat island effect in central Sydney. **Journal of Sustainable Development**, v. 7, p. 23-34, 2014.

SHI, Y.; KATZSCHNER, L.; NG, E. Modelling the fine-scale spatiotemporal pattern of urban heat island effect using land use regression approach in a megacity. **Science of the Total Environment**, v. 618, p. 891-904, 2018.

SIGLON. **Dados Geográficos**. Londrina. 2019. Disponível em: https://www.londrina.pr.gov.br/index.php?option=com_content&view=article&id=20114&Itemid=1988 Acesso em: 26 jul. 2019.

SILLEOS, N. G.; ALEXANDRIDIS, T.K.; GITAS, I. Z.; PERAKIS, K. Vegetation Indices: Advances made in Biomass estimation and vegetation monitoring in the last 30 years. **Geocarto International**, v. 21, n.4, p. 21-28, 2006.

SILVA, V. J.; SILVA, C. R.; ALMEIDA, L.S.; SILVA, C. R.; CARVALHO, H. P.; CAMARGO, R. Mobile transect for identification of intra-urban heat islands in Uberlandia, Brazil. **Interdisciplinary Journal of Applied Science**, v. 13, 2018.

SPRING. **Manuais: Tutorial de Geoprocessamento**. 2006. Disponível em: <http://www.dpi.inpe.br/spring/portugues/tutorial/index.html>. Acesso em: 10 mar. 2021.

SIQUEIRA, A. L. **Uso de transformação em análise de variância e análise de regressão**. 1983. 154p. Tese (Doutorado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, São Paulo, 183.

STRAUB, A.; BERGER, K.; BREITNER, S.; CYRYS, J.; GERUSCHKAT, U.; JACOBET, J.; KÜHLBACH, B.; KUSCH, T.; PHIPLIPP, A.; SCHNEIDER, A.; UMMINGER, R.; WOLF, K.; BECK, C. Statistical modelling of spatial patterns of the urban heat island intensity in the urban environment of Augsburg, Germany. **Urban Climate**, v. 29, 100491, 2019.

SULTANA, S.; SATYANARAYANA, A. N.V. Urban heat island intensity during winter over metropolitan cities of India using remote-sensing techniques: impact of urbanization. **International Journal of Remote Sensing**, p. 1-40, 2018.

SUN, Y.; WANG, S.; WANG, Y. Estimating local-scale urban heat island intensity using nighttime light satellite imageries. **Sustainable Cities and Society**, v. 57, 102125, 2020.

TAHA, H. Urban climates and heat islands: albedo, evapotranspiration, and anthropogenic heat. **Energy and Buildings**, v. 25, p. 99-103, 1997.

TARGINO, A. C.; KRECL, P.; CORAIOLA, G. C. Effects of the large-scale atmospheric circulation on the onset and strength of urban heat islands: a case study. **Theoretical and Applied Climatology**, v. 117, p. 73-87, 2014.

TEIXEIRA, D. C. F.; AMORIM, M. C. C. T. Ilhas de calor: representações espaciais de cidades de pequeno porte por meio de modelagem. **Geosp - Espaço e Tempo**, v.21, p. 239-256, 2017.

THOMPSON, R.; HORNIGOLD, R.; PAGE, L.; WAITE, T. Associations between high ambient temperatures and heat waves with mental health outcomes: a systematic review. **Public Health**, v.161, p. 171-191, 2018.

TRUSILOVA, K.; JUNG, M.; CHURKINA, G. On climate impacts of a potential expansion of urban land in Europe. **Journal of Applied Meteorology and Climatology**, v. 48, p. 1971-1980, 2009.

TSOKA, S.; TSIKALOUKAKI, K.; THEODOSIOU, T. Urban space's morphology and microclimatic analysis: A study for a typical urban district in the Mediterranean city of Thessaloniki, Greece. **Energy and Buildings**, v. 156, p. 96-108, 2017.

ULPIANI, G. On the linkage between urban heat island and urban pollution island: Three-decade literature review towards a conceptual framework. **Science of the Total Environment**, v. 751, p. 141727, 2021.

ÜNAL, Y. S.; SONUÇ, C. Y.; INCECIK, S.; TOPCU, H. S.; "STÜN, D. H. D.; TEMIZÖZ, H. P. Investigating urban heat island intensity in Istanbul. **Theoretical and Applied Climatology**, p. 1-16, 2019.

VENTER, A.; MXWELL, S. E. Issues in the Use and Application of Multiple Regression Analysis. **Handbook of Applied multivariate Statistics and Mathematical Modeling**, p. 151-182, 2000.

VIEIRA, S.R.; MILLETE, J.A.; TOPP, G. C.; REYNOLDS, W.D. Handbook for Geostatistical analysis of variability in soil and meteorological parameters. **Tópicos em Ciência do Solo**, v.2, p.1-45, 2002.

WAGNER, C. S. Velocidade e direção predominante dos ventos no estado do Paraná. Londrina: **Instituto Agrônômico do Paraná**, 56p., 1989.

WANG, Y.; DU, H.; XU, T.; LU, D.; WANG, X.; GUO, Z. Temporal and spatial variation relationship and influence factors on surface urban heat island and ozone pollution in the Yangtze River Delta, China. **Science of the Total Environment**, v. 631-632, p. 921-933, 2018a.

WANG, R.; REN, C.; XU, Y.; LAU, K. K.; SHI, Y. Mapping the local climate ones of urban areas by GIS-based and WUDAPT methods: A case study of Hong Kong. **Urban Climate**, v. 24, p. 567-576, 2018b.

WENG, Q. Thermal infrared remote sensing for urban climate and environmental studies: Methods, applications, and trends. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 64, p. 335-344, 2009.

WORLD BANK. **Urban Development**. 2019. Disponível em: <https://www.worldbank.org/en/topic/urbandevelopment/overview> Acesso em: 11 out. 2019.

WMO – WORLD METEOROLOGICAL ORGANIZATION. **Manual on Codes: international codes**, v. I. Part A-alphanumeric codes. WMO n, 306, ed.2011. rev.2017.

WMO – WORLD METEOROLOGICAL ORGANIZATION. **Frequently asked questions (FAQ)**. 2019. Disponível em: http://www.wmo.int/pages/prog/wcp/ccl/faq/faq_doc_en.html. Acesso em: 28 jan.2020.

YADAV, N.; SHARMA, C. Spatial variations of intra-city urban heat island in megacity Delhi. **Sustainable Cities and Society**, v. 37, p. 298-306, 2018.

YAMAMOTO, Y. Measures to mitigate urban heat island. **Science & Technology Trends Quarterly Review**, v. 18, p. 65-86, 2006.

YANG, J; WANG, Z.H.; KALOUSH, K. E. Environmental impacts of reflective materials: is high albedo a 'silver bullet' for mitigating urban heat island? **Renewable and Sustainable Energy Reviews**, v.47, p. 830-843, 2015.

YAO, R.; WANG, L.; HUANG, X.; LIU, Y.; NIU, Z.; WANG, S.; WANG, L. Long-term trends of surface and canopy layer urban heat island intensity in 272 cities in the mainland of China. **Science of the Total Environment**, 145607, 2021.

YUE, W.; LIU, X.; ZHOU, Y.; LIU, Y. Impacts of urban configuration on urban heat island: An empirical study in China mega-cities. **Science of the Total Environment**, v. 671, p. 1036- 1046, 2019.

ZHANG, H.; LI, T. T.; HAN, J.J. Quantifying the relationship between land use features and intra-surface urban heat island effect: Study on downtown Shanghai. **Applied Geography**, v.125, 102305, 2020.

APÊNDICE A – MÉTODO DE INTERPOLAÇÃO POR KRIGAGEM

A espacialização da IIUC resulta na previsão dos valores de uma variável primária por meio da interpolação de medições individuais dentro da mesma região dos locais amostrados (LIU *et al.*, 2017; YADAV; SHARMA, 2018; AMORIM, 2019). Isso significa que é possível transformar dados pontuais em dados espaciais contínuos em toda a área de pesquisa (RODRÍGUEZ *et al.*, 2020b). Tais interpolações podem ser processadas por dois grupos de métodos: multicritérios (estocástico) e geoestatísticos (determinístico) (FOISSARD, 2015).

Nos métodos multicritérios de espacialização das variáveis meteorológicas (radiação, temperatura, pressão e umidade), são considerados simultaneamente diversos fatores (por exemplo: cobertura da terra, relevo e presença de vegetação) que interferem na sua distribuição espacial (AMORIM, 2019).

Já a interpolação pela geoestatística ocorre com base no princípio da autocorrelação espacial, ou seja, a semelhança de um ponto com seu entorno próximo (AMORIM, 2019). As amostras de observação mais próximas têm mais probabilidade de serem semelhantes do que as amostras distantes (YADAV; SHARMA, 2018).

O método geoestatístico mais amplamente usado é a krigagem, que consiste em ponderar os vizinhos mais próximos do ponto a ser estimado, obedecendo os critérios de não tendenciosidade e de variância mínima (VIEIRA *et al.*, 2002). Apresenta vantagem sobre outras técnicas (por exemplo: IDW – Distância inversa ponderada) pois envolve a estimativa da variação da estrutura espacial por meio de semivariograma e leva em consideração a relação estatística de autocorrelação. (YADAV; SHARMA, 2018). O método de krigagem pode ser representado pela seguinte equação:

$$Z(S_0) = \sum_{i=1}^N \lambda_i Z(S_i) \quad \text{Equação (A1)}$$

em que:

$Z(S_0)$ é o valor medido no local;

λ_i um peso desconhecido para o valor medido no local i ,

S_0 é o local de predição,

Z é o valor previsto em (S_0) e

N é o número de valores medidos.

A interpolação por krigagem é uma técnica que deriva diferentes métodos de estimação, incluindo: krigagem simples, krigagem ordinária, krigagem universal, krigagem disjuntiva e cokrigagem; entre outras de caráter não lineares como: krigagem indicativa (CAMARGO, 1998) (Quadro A1).

QUADRO A1: Tipos de Krigagem

TIPOS	DEFINIÇÃO
Simple	Utilizada quando estatisticamente se assume que a média é conhecida e constante para toda a área.
Ordinária	Considera que os valores de uma variável regionalizada apresentam uma média constante, porém desconhecida.
Universal	Aplicado quando a variável regionalizada não é estacionária mas apresenta uma tendência e seus resíduos contém a hipótese intrínseca.
Disjuntiva	Procura estimar em um domínio bem definido, a proporção de valores superiores a um valor de corte, a partir das observações experimentais disponíveis.
Cokrigagem	É um procedimento de interpolação no qual diversas variáveis regionalizadas podem ser estimadas em conjunto, com base numa correlação espacial multivariada entre si
Indicativa	Utiliza procedimentos não lineares para modelar a variabilidade dos atributos

Fonte: Adaptado de CAMARGO (1998)

APÊNDICE B- PORCENTAGEM DE OCUPAÇÃO DO SOLO PARA CADA ESTAÇÃO DE MONITORAMENTO

TABELA B1 - Porcentagem de ocupação do solo para cada estação de monitoramento considerando o menor (100 m) e maior (600) tamanho de *buffer*. Os valores em negrito são as classes com maior porcentagem para cada estação.

Estação	<i>Buffer 100 m</i>					<i>Buffer 600 m</i>				
	Telhado (%)	Vegetação (%)	Asfalto (%)	Solo exposto (%)	Água (%)	Telhado (%)	Vegetação (%)	Asfalto (%)	Solo exposto (%)	Água (%)
ADL	48,0	3,4	10,2	38,2	0,2	47,8	3,1	14,3	34,6	0,3
ATO	49,0	1,5	35,1	13,2	1,3	32,9	10,1	25,2	30,6	1,2
BRU	14,3	51,4	3,6	26,7	4,0	10,7	49,1	5,2	29,2	5,9
EMB	3,2	82,7	0,3	13,8	0,0	1,0	70,2	0,1	28,6	0,0
GLE	40,3	7,4	25,3	20,5	6,5	29,7	12,2	16,4	24,9	16,8
GRE	27,4	2,2	45,3	15,1	10,1	30,0	10,6	32,4	20,6	6,6
HUG	32,1	0,2	48,9	7,4	11,4	33,9	4,8	40,2	14,1	7,0
IGP	7,4	23,8	15,4	11,6	41,7	19,3	14,1	21,4	24,3	20,9
IGR	44,1	5,7	22,2	27,6	0,5	34,1	10,2	16,9	37,5	1,4
MUS	31,1	10,9	37,1	17,7	3,3	35,4	5,2	40,8	14,6	4,0
PAR	35,4	12,2	26,4	24,6	1,5	30,2	9,4	20,7	37,8	1,9
SIM	0,0	73,3	0,3	26,2	0,2	1,8	67,4	2,3	27,8	0,8
UTF	25,8	27,8	11,7	34,3	0,4	11,0	44,1	6,0	38,3	0,5

Fonte: Autoria própria (2021).

APÊNDICE C- RESULTADOS DA MULTICOLINEARIDADE

TABELA C1 – Matriz diurna de correlação entre a temperatura do ar e as variáveis independentes quantitativas

	POP_100	HIP_500	Dec1_100	Dec4_400	USO3_100	USO5_200	VV	RAD	UREMB	CN	PREA	T
POP_100	1											
HIP_500	0,043	1										
Dec1_100	-0,206	-0,119	1									
Dec4_400	0,131	0,363	-0,196	1								
USO3_100	0,484	0,598	-0,455	0,398	1							
USO5_200	-0,065	-0,401	-0,316	-0,078	0,028	1						
VV	0,000	0,000	0,000	0,000	0,000	0,000	1					
RAD	0,000	0,000	0,000	0,000	0,000	0,000	0,264	1				
UREMB	0,000	0,000	0,000	0,000	0,000	0,000	-0,073	-0,514	1			
CN	0,000	0,000	0,000	0,000	0,000	0,000	-0,002	-0,052	0,076	1		
PREA	0,000	0,000	0,000	0,000	0,000	0,000	0,057	0,145	0,084	-0,009	1	
T	0,036	0,024	-0,002	0,002	0,037	-0,021	0,050	0,420	-0,747*	-0,044	-0,48	1

Fonte: Autoria própria (2021)

TABELA C2 – Matriz noturna de correlação entre a temperatura do ar e as variáveis independentes quantitativas

	POP100	HIP300	NDVI600	Dec4600	USO4500	USO5600	VV	URLON	CN	PREA	T
POP100	1										
HIP300	0,017	1									
NDVI600	-0,420	-0,362	1								
Dec4600	0,541	0,027	-0,369	1							
USO4500	0,060	0,021	0,459	-0,513	1						
USO5600	0,025	0,013	-0,336	-0,015	-0,471	1					
VV	0,000	0,000	0,000	0,000	0,000	2,2E-18	1				
URLON	-0,081	-0,132	0,241	0,004	0,051	-8,3E-02	0,061	1			
CN	0,000	0,000	0,000	0,000	0,000	7,2E-18	-0,175	0,077	1		
PREA	0,000	0,000	0,000	0,000	0,000	-2,5E-18	0,029	-0,104	-0,007	1	
T	0,088	0,081	-0,186	0,054	-0,059	4,4E-02	-0,176	-0,553*	-0,032	-0,447	1

Fonte: Autoria própria (2020)

Nota:*Maior correlação com a variável dependente observada.

APÊNDICE D- RESULTADOS OBTIDOS COM O MÉTODO *BOOTSTRAPPING*

TABELA C1 - Resultados obtidos com o método *bootstrapping* quando os modelos MLR foram rodados 100, 300 e 500 vezes.

	n=100	n=300	n=500
Modelo diurno			
R^2 Min. [-]	0,743	0,745	0,745
R^2 Máx. [-]	0,771	0,773	0,771
R^2 Médio [-]	0,756	0,756	0,756
RMSE Min. [°C]	2,301	2,310	2,303
RMSE Máx. [°C]	2,438	2,434	2,450
RMSE Médio [°C]	2,381	2,383	2,383
Modelo noturno			
R^2 Min. [-]	0,587	0,585	0,584
R^2 Máx. [-]	0,626	0,627	0,619
R^2 Médio [-]	0,603	0,602	0,602
RMSE Min. [°C]	2,319	2,328	2,326
RMSE Máx. [°C]	2,409	2,422	2,419
RMSE Médio [°C]	2,376	2,378	2,378

Fonte: Autoria própria (2021)

Nota: Os valores em vermelho correspondem aos valores médios encontrados em casa modelo.