

**RELAÇÃO ENTRE VEGETAÇÃO E TEMPERATURA DA
SUPERFÍCIE TERRESTRE: UMA ABORDAGEM BASEADA EM
SENSORIAMENTO REMOTO PARA ÁREA URBANA DE
BRASÍLIA, DF**

CARLOS MAGNO MOREIRA DE OLIVEIRA

**TESE DE DOUTORADO EM CIÊNCIAS FLORESTAIS
DEPARTAMENTO DE ENGENHARIA FLORESTAL**

**FACULDADE DE TECNOLOGIA
UNIVERSIDADE DE BRASÍLIA-UnB**

**UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS**

**RELAÇÃO ENTRE VEGETAÇÃO E TEMPERATURA DA
SUPERFÍCIE TERRESTRE: UMA ABORDAGEM BASEADA EM
SENSORIAMENTO REMOTO PARA ÁREA URBANA DE
BRASÍLIA, DF**

CARLOS MAGNO MOREIRA DE OLIVEIRA

**ORIENTADOR: Dra. ALBA VALÉRIA REZENDE
TESE DE DOUTORADO EM CIÊNCIAS FLORESTAIS**

PUBLICAÇÃO:

BRASÍLIA – DF OUTUBRO DE 2022

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA FLORESTAL
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS FLORESTAIS

**“RELAÇÃO ENTRE VEGETAÇÃO E TEMPERATURA DA
SUPERFÍCIE TERRESTRE: UMA ABORDAGEM BASEADA EM
SENSORIAMENTO REMOTO PARA ÁREA URBANA DE
BRASÍLIA, DF”**

CARLOS MAGNO MOREIRA DE OLIVEIRA

TESE DE DOUTORADO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA FLORESTAL DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS NECESSÁRIOS À OBTENÇÃO DO GRAU DE DOUTOR EM CIÊNCIAS FLORESTAIS.

APROVADA POR:

Prof. Dra. Alba Valéria Rezende (Departamento de Engenharia Florestal – EFL/UnB)
(Orientadora)

Prof. Dr. Eraldo Aparecido Trondoli Matricardi (Departamento de Engenharia Florestal – EFL/UnB)
(Examinador Interno)

Prof. Dr. Edson Eyji Sano (Embrapa Cerrados)
(Examinador Externo ao PPG-EFL)

Prof. Dr. Bruno Araujo Furtado de Mendonça (Departamento de Silvicultura – IF/UFRRJ)
(Examinador Externo à UnB)

Prof. Dr. Matheus Pinheiro Ferreira (Instituto Militar de Engenharia – Rio de Janeiro)
(Examinador Externo ao PPG-EFL)

BRASÍLIA/DF, 31 DE OUTUBRO DE 2022

FICHA CATALOGRÁFICA

Ficha catalográfica elaborada automaticamente,
com os dados fornecidos pelo(a) autor(a)

Or	Oliveira, Carlos Magno Moreira de Relação entre vegetação e temperatura da superfície terrestre: uma abordagem baseada em sensoriamento remoto para área urbana de Brasília, DF / Carlos Magno Moreira de Oliveira; orientador Alba Valéria Rezende. -- Brasília, 2022 148 p. Tese (Doutorado em Ciências Florestais) -- Universidade de Brasília, 2022. 1. ilha de calor urbano. 2. árvores urbanas. 3. métricas de paisagem. 4. conforto térmico. 5. planejamento urbano. I. Rezende, Alba Valéria, orient. II. Título.
----	---

REFERÊNCIA BIBLIOGRÁFICA

OLIVEIRA, C. M. M. (2022). Relação entre vegetação e temperatura da superfície terrestre: uma abordagem baseada em sensoriamento remoto para área urbana de Brasília, DF. Tese de Doutorado em Ciências Florestais, Publicação PPGEFL.TD-/2022. Departamento de Engenharia Florestal, Universidade de Brasília, Brasília, DF, 149 p.

CESSÃO DE DIREITOS

AUTOR: Carlos Magno Moreira de Oliveira

TÍTULO: Relação entre vegetação e temperatura da superfície terrestre: uma abordagem baseada em sensoriamento remoto para área urbana de Brasília, DF.

GRAU: Doutorado ANO: 2022

É concedido à Universidade de Brasília permissão para reproduzir cópias desta tese de doutorado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem autorização por escrito do autor.

Carlos Magno Moreira de Oliveira
cmagnoliveira@hotmail.com

À minha família,
dedico.

AGRADECIMENTOS

Agradeço a Deus pela vida e por ter me dado tranquilidade em momentos de incerteza.

Agradeço ao meu pai, Aldo, pelos diversos ensinamentos e por seu incessante esforço para me mostrar a importância do estudo. A minha mãe, Ires, por sempre me apoiar e estar ao meu lado nessa caminhada. Aos meus irmãos, Laura, Lorena e José Ângeles, pelos conselhos, companheirismo e apoio em vários momentos de minha vida.

A minha namorada, Milena, pelo companheirismo e incentivo.

Ao Instituto Federal do Norte de Minas Gerais (IFNMG) – *Campus Arinos* por ter me concedido a licença para capacitação.

A minha orientadora, Alba, por ter acreditado no meu trabalho e sempre ter me incentivado na busca por novas oportunidades para desenvolvimento da ciência.

Ao Prof. Eraldo, pelo apoio, orientação e pela troca de experiências durante esse período na UnB.

Ao Prof. Sano, pelas várias orientações e sugestões de melhoria no desenvolvimento da tese. Pelo auxílio na correção do artigo. Suas sugestões foram valiosas e contribuíram para minha formação.

A Universidade de Brasília (UnB) que, como as universidades brasileiras públicas, gratuitas e de qualidade, proporcionou o aparato necessário ao desenvolvimento da tese.

A Terracap, que por meio dos funcionários Vitor Hugo e Ana Luiza Cerdeira, concedeu acesso a dados utilizados nesse trabalho.

Ao Prof. Edilson Baias, que, gentilmente, cedeu acesso a dados do projeto SmartCampus UnB.

Aos amigos Adriana, Juliano, Máira, Mila, Niliane, Jorge e Guido, que tornaram a estadia em Brasília mais agradável, por meio da troca de experiências e momentos de descontração.

Ao Yuri e a Angélica, que sempre estiveram dispostos a auxiliar nas atividades administrativas no Programa de Pós-Graduação em Ciências Florestais – UnB.

SUMÁRIO

INTRODUÇÃO GERAL	1
CAPÍTULO I.....	4
Relação espaço-temporal entre a temperatura de superfície terrestre e coberturas de vegetação e de construção em Brasília (DF), Brasil.....	4
1 Introdução.....	6
2 Material e métodos	7
2.1 Área de estudo	7
2.2 Banco de dados	9
2.3 Métodos	10
2.3.1 Estimativa da temperatura da superfície terrestre (TST)	10
2.3.1.1 Estimativa da temperatura média efetiva da atmosfera (T_a)	12
2.3.1.2 Estimativa da transmitância atmosférica (τ_i)	13
2.3.1.3 Estimativa da emissividade da superfície (ϵ_i).....	15
2.4 Estimativa do NDVI e NDBI.....	16
2.5 Ilha de Calor Urbano de Superfície (ICUS).....	16
2.6 Análise estatística	16
3 Resultados	17
3.1 Variação anual da TST, NDVI e NDBI.....	17
3.2 Efeitos da vegetação urbana sobre a TST nas estações climáticas	21
3.3 Ilha de Calor Urbano de Superfície (ICUS) e variáveis biofísicas	23
3.4 Variação da temperatura da superfície terrestre em função do NDVI em área urbana e de vegetação nativa	26
4. Discussão.....	31
4.1 Evolução da temperatura da superfície terrestre (TST).....	31
4.2 Ocorrência sazonal das ilhas de calor urbano	33
5. Conclusões.....	35
6. Referências bibliográficas	36
CAPÍTULO II.....	41
Métricas da vegetação urbana e sua influência sobre a formação de ilhas de calor urbano: uma contribuição para o planejamento urbano.....	41
1.Introdução.....	43
2.Material e métodos	45
2.1 Área de estudo	45
2.2 Temperatura da superfície terrestre (TST).....	45
2.3 Mapeamento de uso e cobertura do solo.....	47
2.4 Unidades de análise	48
2.5 Métricas de paisagem da vegetação arbórea e rasteira em área urbana.....	48
2.6 Correlação e autocorrelação espacial.....	50
2.7 Modelagem da temperatura da superfície	52
3.Resultados.....	54
3.1 Temperatura de superfície em área de vegetação urbana	54
3.2 Relação entre a composição das áreas verdes urbanas e a temperatura da superfície terrestre (TST).....	55

3.3 Influência da configuração da vegetação urbana sobre a temperatura da superfície terrestre (TST).....	56
3.4 Autocorrelação da temperatura de superfície terrestre (TST).....	58
3.5 Autocorrelação da configuração e composição da vegetação arbórea urbana.....	60
3.6 Modelagem da temperatura da superfície em função de métricas da vegetação arbórea urbana.....	61
4. Discussão.....	68
4.1 Contribuição da vegetação urbana no resfriamento do ambiente.....	68
4.2 Associação espacial das métricas de paisagem com a temperatura de superfície terrestre (TST).....	69
4.3 Modelagem da contribuição da vegetação arbórea para redução das ilhas de calor urbano.....	71
5. Conclusão.....	73
6. Referências bibliográficas.....	74
CAPÍTULO III.....	79
Identificação e caracterização de árvores urbanas utilizando dados de laser aerotransportado.....	79
1. Introdução.....	81
2. Material e métodos.....	83
2.1 Área de estudo.....	83
2.2 Censo Florestal.....	84
2.3 Aquisição de dados LiDAR.....	85
2.4 Obtenção do modelo de altura de copa (<i>Canopy Height Model</i> - CHM).....	86
2.5 Identificação de árvores urbanas por meio de dados LiDAR.....	87
2.6 Precisão da estimativa do número de árvores.....	89
3. Resultados.....	89
4. Discussão.....	103
5. Conclusões.....	108
6. Referências bibliográficas.....	108
CAPÍTULO IV.....	114
Características tridimensionais da paisagem urbana e sua relação com a temperatura da superfície terrestre.....	114
1. Introdução.....	116
2. Material e métodos.....	117
2.1 Área de estudo.....	117
2.2 Temperatura da Superfície Terrestre (TST).....	118
2.3 Mapeamento de uso e cobertura do solo.....	119
2.4 Modelo de altura de copa (<i>Canopy Height Model</i> - CHM).....	120
2.5 Métricas de paisagem e estrutura vertical da vegetação arbórea urbana.....	121
3. Análise estatística.....	123
4. Resultados.....	124
5. Discussão.....	132
5.1 Efeitos das árvores urbanas e edificações sobre a temperatura.....	132
5.2 Pesquisas futuras.....	135

6. Conclusão	135
7. Referência bibliográficas.....	136
Considerações finais.....	139

LISTA DE TABELAS

CAPÍTULO I

Tabela 1. Equações utilizadas para estimar a temperatura atmosférica média efetiva (T_a).	13
Tabela 2. Tabela 2. Estimativa da transmitância da atmosfera para o Landsat 5 TM. R^2 = coeficiente de determinação; S_{yx} = desvio padrão.....	13
Tabela 3. Estimativa da transmitância da atmosfera para o Landsat 8 OLI. R^2 = coeficiente de determinação; S_{yx} = desvio padrão.	14
Tabela 4. Resultado dos testes de Mann-Kendall e Pettitt paraas variáveis temperatura de superfície terrestre (TST), índice de vegetação por diferença normalizada (NDVI) e índice de áreas construídas por diferença normalizada (NDBI).	18
Tabela 5. Teste de significância de variáveis ambientais e climáticas pelos testes de Mann-Kendall e Pettitt.	26

CAPÍTULO II

Tabela 1. Matriz de confusão da classificação da área urbana de Brasília (DF).	48
Tabela 2. Métricas de paisagem utilizadas para caracterização da vegetação urbana da cidade de Brasília, Brasil.	49
Tabela 3. Variação sazonal da temperatura da superfície terrestre (TST) na área urbana de Brasília, considerando áreas cobertas com vegetação arbórea e vegetação rasteira..	54
Tabela 4. Valores dos índices de autocorrelação global (Índice Global de Moran) e de associação espacial local (LISA) para a Temperatura da Superfície Terrestre (TST) nas áreas urbanas de Brasília, Brasil.....	58
Tabela 5. Coeficientes do ajuste do modelo de regressão linear múltiplo (MRL) para temperatura da superfície terrestre (TST) em função da composição e configuração da vegetação urbana de Brasília, Brasil.	62
Tabela 6. Valores do Índice de Moran, Multiplicador de Lagrange (ML) e Multiplicador de Lagrange Robusto provenientes do modelo de regressão linear múltipla (MRL).	64
Tabela 7. Ajuste do modelo de autorregressão espacial (MAE) para temperatura da superfície terrestre (TST) em função de métricas de paisagem da vegetação arbórea em diferentes escalas de unidades de análise para cidade de Brasília, Brasil.	65
Tabela 8. Ajuste do modelo de erro espacial (MEE) para temperatura da superfície terrestre (TST) em função de métricas de paisagem da vegetação arbórea em diferentes escalas de unidades de análise para cidade de Brasília, Brasil.....	67

CAPÍTULO III

Tabela 1. Código de classificação da nuvem de pontos LiDAR.	86
Tabela 2. Caracterização do inventário censo das árvores urbanas e cobertura florestal por unidade de área.	90
Tabela 3. Detecção de árvore individual (DAI) com diferentes combinações no tamanho do filtro de suavização (TJS) de média do CHM (<i>Canopy Height Model</i>) e no tamanho da janela de identificação de topo de árvore (TJA) pelo algoritmo local máximo (LM) em floresta urbana. Valores em negrito indicam a estimativa mais próximo do valor real. 92	92
Tabela 4. Acurácia na predição de árvores urbanas a partir de <i>Canopy Height Model</i> (CHM) suavizado com filtro média móvel com janela 5x5 e tamanho de janela de 5x5 para local máximo (LM).	95
Tabela 5. Detecção de árvore individual (DAI) utilizando variações no tamanho de janela de suavização (TJS) do modelo gaussiano e variações no tamanho de janela para identificação do topo de árvore (TJA) pelo algoritmo local máximo (LM). Valores em negrito indicam a estimativa mais próximo do valor real.	96
Tabela 6. Acurácia na predição de árvores urbanas a partir de <i>Canopy Height Model</i> (CHM) suavizado com filtro de gaussiano com janela de 7x7 m e tamanho de janela de 5x5 m para local máximo (LM).	98
Tabela 7. Detecção de árvore individual (DAI) utilizando os filtros média móvel e gaussiano e tamanho com variações no tamanho de janela de suavização (TJS), associado a tamanho de janela de árvore (TJA) variável em função da altura da árvore com algoritmo local máximo (LM). Valores em negrito indicam a estimativa mais próximo do valor real.	101
Tabela 8. Acurácia na predição de árvores urbanas a partir de <i>Canopy Height Model</i> (CHM) suavizado com filtro média móvel com tamanho de janela de suavização (TJS) 3x3 e local máximo (LM) com tamanho de janela de árvore (TJA) variável.	103

CAPÍTULO IV

Tabela 1. Métricas de paisagem utilizadas para caracterização da vegetação arbórea na área urbana da cidade de Brasília, Brasil.	122
Tabela 2. Variáveis estruturais das árvores urbanas derivados de dados LiDAR.	123
Tabela 3. Resumo estatístico de métricas de paisagem relativas à composição e configuração das árvores e edificações.	125
Tabela 4. Caracterização da estrutura vertical das árvores (metros) por indivíduo e por unidade de análise.	126

Tabela 5. Correlação entre variáveis tridimensionais da vegetação arbórea e a TST. A correlação parcial está em negrito. Para o PARv a configuração e a estrutura vertical das árvores foram as variáveis de controle. O PARv e a estrutura vertical foram as variáveis de controle para as métricas de configuração. Para as métricas da estrutura vertical das árvores, as variáveis de controle foram PARv e variáveis de configuração. O n foi de 1962. 128

Tabela 6. Correlação entre variáveis tridimensionais das edificações e a TST. A correlação parcial está em negrito. Para o PEdif, a configuração e a altura das edificações foram as variáveis de controle. O PEdif e a altura das edificações foram as variáveis de controle para as métricas de configuração. Para a altura das edificações, as variáveis de controle foram PEdif e variáveis de configuração. O n foi de 1962. 129

LISTA DE FIGURAS

CAPÍTULO I

Figura 1. Localização da área de estudo no Distrito Federal, representada por sete regiões administrativas.....	8
Figura 2. Fluxo do processo para obtenção da temperatura da superfície terrestre baseado em imagens Landsat.	11
Figura 3. Box plot (A) e variação média anual (B) da temperatura da superfície terrestre (TST), temperatura média do ar (TMA), índice de vegetação normalizada pela diferença (NDVI) e índice de área construída normalizada pela diferença (NDBI) obtidos a partir de imagens Landsat 5 TM e Landsat 8 OLI.	18
Figura 4. Variação espacial média do NDVI (A), NDBI (C) e TST (E) e respectivo desvio padrão (B, D e F) calculado para o período de 2000-2019.....	20
Figura 5. Perfis de variação da temperatura da superfície terrestre (TST) e do índice de vegetação por diferença normalizada (NDVI) ao longo dos transectos A, B e C na área de estudo (linha amarela).	21
Figura 6. Média e desvio padrão (S_{yx}) da temperatura da superfície terrestre (TST) nas estações climáticas, obtidas de imagens Landsat.	22
Figura 7. Variação sazonal da (a) temperatura da superfície terrestre (TST) e (b) do índice de vegetação por diferença normalizada (NDVI) e índice de área construída por diferença normalizada NDBI. (c) sazonalidade média da TST em área de floresta e área urbana e (d) formação de ilhas de calor urbana.	25
Figura 8. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nas primaveras de 2000 a 2018.	27
Figura 9. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nos verões de 2000 a 2019.	28
Figura 10. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nos outonos de 2000 a 2019.	29
Figura 11. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nos invernos de 2000 a 2019.	30

CAPÍTULO II

Figura 1. Mapa de localização da cidade de Brasília, Distrito Federal, Brasil.....	46
Figura 2. Variação do tamanho das unidades de análise utilizadas para extrair informações sobre a temperatura de superfície terrestre e métricas da vegetação arbórea urbana.	48
Figura 3. Correlação de Sperman entre a temperatura de superfície terrestre (TST) e métricas de paisagem da vegetação arbórea (a) e da vegetação rasteira (b), considerando variações de escalas para área urbana de Brasília (DF). Valores destacados em vermelho não foram significativos ($p\text{-valor} \leq 0,05$). PCob: Percentual de cobertura; DF: Densidade de fragmento; IMF: Índice de Maior Fragmento; DB: Densidade de Borda; Area: Área do fragmento; Forma: Forma do fragmento; IA: Índice de agregação.....	56
Figura 4. Temperatura da superfície terrestre (TST) na área urbana de Brasília, Brasil, e correlação espacial da TST pelo Indicador Local de Autocorrelação Espacial (<i>Local Indicator of Spatial Association</i> – LISA) para as estações e anos do outono de 2017, inverno de 2017, inverno de 2017, primavera de 2017 e verão de 2019 ($p\text{-valor} \leq 0,05$).	59
Figura 5. Indicador Local de Autocorrelação Espacial (<i>Local Indicator of Spatial Association</i> – LISA) das métricas de composição e configuração da vegetação arbórea em unidades de análise de 240 m para área urbana de Brasília, Brasil ($p\text{-valor} \leq 0,05$).	61

CAPÍTULO III

Figura 1. Localização da área de estudo no Distrito Federal, Brasília, Brasil.	84
Figura 2. Estimativa do erro relativo (%) para detecção de árvore individual (DAI) com variações no tamanho da janela de suavização do filtro média móvel de a) 3x3 m, b) 5x5 m e c) 7x7 m para suavização do CHM (<i>Canopy Height Model</i>), combinados a janelas de identificação de topo de árvore (TJA) 3x3 m, 5x5 m, 7x7 m e 9x9 m para o algoritmo local máximo (LM).....	94
Figura 3. Estimativa do erro relativo (%) para detecção de árvore individual (DAI) com variações no tamanho da janela de suavização do filtro gaussiano de a) 3x3 m, b) 5x5 m e c) 7x7 m para suavização do CHM (<i>Canopy Height Model</i>), combinados a janelas de identificação de topo de árvore (TJA) de 3x3 m, 5x5 m, 7x7 m e 9x9 m para o algoritmo local máximo (LM).....	97
Figura 4. Relação entre o diâmetro de copa e altura total de árvores urbanas em Brasília (DF).	100

Figura 5. Estimativa do erro relativo (%) para detecção árvore individual (DAI) a partir de variações no tamanho da janela dos filtros a) média móvel e b) gaussiano para suavização do CHM (*Canopy Height Model*) e local máximo (LM) com tamanho de janela de árvore (TJA) com dimensão variável. 102

CAPÍTULO IV

Figura 1. Mapa de localização da cidade de Brasília, Distrito Federal, Brasil..... 118

Figura 2. Variância explicativa da temperatura da superfície terrestre (TST) modelo *Random Forest* ajustado com conjuntos de variáveis. Comparação das médias dos conjuntos das variáveis explicativas par-a-par são indicadas por letras; modelos com mesma letra não diferem significativamente um do outro. 130

Figura 3. Incremento no Erro Quadrático Médio (IncMSE%) das variáveis explicativas para estimativa da temperatura de superfície terrestre (TST) na a) primavera, b) verão, c) outono e d) inverno. 132

RELAÇÃO ENTRE VEGETAÇÃO E TEMPERATURA DA SUPERFÍCIE TERRESTRE: UMA ABORDAGEM BASEADA EM SENSORIAMENTO REMOTO PARA ÁREA URBANA DE BRASÍLIA, DF

RESUMO GERAL

As cidades estão em constante transformação para atender as necessidades da população. No entanto, a substituição da vegetação nativa por infraestruturas urbanas aumenta a temperatura da superfície terrestre (TST) que está relacionado a diversos problemas ambientais e de saúde pública. Nesse sentido, essa tese teve por objetivo geral investigar a relação entre a vegetação urbana de Brasília e a TST e criar subsídios para auxiliar as práticas de manejo afim de reduzir o desconforto térmico. A tese foi estruturada em quatro capítulos. No Capítulo I foi avaliada a relação espaço-temporal entre a TST e coberturas de vegetação e de construção no período de 20 anos, utilizando imagens Landsat 5 TM (*Thematic Mapper*) e Landsat 8 OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*). Foi observada forte relação entre o índice *Normalized Difference Vegetation Index* (NDVI) e a TST, principalmente na primavera e verão que foram as estações com maiores valores de TST. A temperatura apresentou tendência de aumento significativo ao longo dos anos. O Capítulo II foi desenvolvido para identificar a contribuição das métricas da vegetação urbana no resfriamento do ambiente. As áreas com vegetação rasteira não contribuíram para reduzir a temperatura sazonal da superfície. A vegetação arbórea teve forte correlação com o resfriamento, principalmente devido à cobertura e ao efeito de borda dos fragmentos, que proporcionaram sombreamento e evapotranspiração. O modelo de erro espacial (MEE) apresentou potencial de previsão da TST em unidades de análise de 120 a 480 m utilizando métricas de configuração e composição relativa à vegetação arbórea urbana. No Capítulo III foram abordados métodos para identificação individual das árvores urbana a partir de modelo de altura de copa (*Canopy Height Model* – CHM) produzido com dados LiDAR. O CHM foi suavizado utilizando os filtros média móvel e gaussiano e aplicado o algoritmo local máximo (LM) para identificação de árvore individual. O filtro média móvel com janela de 5x5 e o LM com janela 5x5 foi o melhor algoritmo para identificação individual de árvore em 9 das 29 unidades amostrais, com R^2 de 0,86 e $S_{xy}(\%)$ 31,15. Por último, no Capítulo IV foram investigados os efeitos das variáveis tridimensionais das árvores urbanas e dos edifícios sobre a sazonalidade da TST. As métricas de percentual de cobertura e densidade de borda dos fragmentos, a altura média e a altura máxima das árvores apresentaram efeito negativo sobre a temperatura. As métricas de composição e configuração das edificações contribuíram para aumentar a temperatura, porém, a altura dos edifícios contribuiu para o resfriamento do entorno. A altura dos edifícios foi uma das variáveis com maior contribuição na explicação da variância do modelo *Random Forest*. Como consideração geral, observamos que o manejo da vegetação urbana deve ser realizado considerando os efeitos sazonais da temperatura de superfície. Para melhorar o conforto térmico, é importante aumentar o percentual de cobertura de árvores em relação a vegetação rasteira, fragmentos com formatos irregulares e composto por árvores altas, considerando que a altura das edificações também contribui para o conforto térmico.

Palavras-chave: ilha de calor urbano, árvores urbanas, métricas de paisagem, conforto térmico, planejamento urbano.

RELATIONSHIP BETWEEN VEGETATION AND LAND SURFACE TEMPERATURE: A REMOTE SENSING BASED-APPROACH FOR URBAN AREA OF BRASÍLIA, DF

GENERAL ABSTRACT

The cities are in constant transformation to attend the population necessities. However, the change of native vegetation to urban infrastructure increases the land surface temperature (LST) that is related with varying environment and public health problems. So, this thesis aimed to investigate the relationship between Brasília urban vegetation and the LST and produce information to assist the management practices to reduce thermic discomfort. The thesis was structured in four chapters. In the Chapter I, we evaluated the spatiotemporal relationship between LST and vegetation cover and built-up cover in the interval of 20 years, using Landsat 5 TM (*Thematic Mapper*) and Landsat 8 OLI (*Operational Land Imager*) and TIRS (*Thermal Infrared Sensor*) images. The Normalized Difference Vegetation Index (NDVI) and LST had stronger correlation, mainly in springer and summer which were the seasons with highest LST values. The temperature showed significant increasing trend over the years. The Chapter II was developed to identify the contribution of vegetation metrics in the environment cooling. The region with shrub did not influence in decrease of seasonality surface temperature. The trees had stronger correlation with the cooling due to cover and edge patches that influenced the shading and evapotranspiration. The spatial error model (SEM) showed potential in prediction of LST in unit analyses of 120 to 480 m, using composition and configuration metrics from urban trees. The Chapter III approached methods to identify individual urban trees using canopy height model (CHM) produced with LiDAR datas. The CHM was smoothed using mean and gaussian filter and applied local maximum (LM) algorithm to individual tree detection. The 5x5 moving windows filter and 5x5 LM window were the best algorithm to individual tree detection in 9 of the 29 sample units with R^2 of 0.86 and $S_{xy}(\%)$ 31.15. In the Chapter IV, we investigated the effects of tridimensional variables of urban tree and building on the LST seasonality. The percent cover and edged density metrics of patches and mean height and maximum height of trees showed negative effects on the temperature. The composition and configuration metrics contributed to increase the temperature, however, the buildings height contributes to the cooling around. The buildings height was one of the variables with great importance in the variance of Random Forest model. As a general consideration, we noted that urban vegetation management has to be conducted considering the seasonal of surface temperature. To improve thermal comfort, it is important to increase the percent tree cover compared to shrub vegetation, patches with irregular shapes and composed of tall trees, considering that tall buildings also contributed to thermal comfort.

Keywords: urban heat island, urban trees, landscape metrics, thermal comfort, urban planning.

INTRODUÇÃO GERAL

Várias cidades no mundo têm apresentado cenários onde há crescente aumento no número de habitantes, com projeções de expansão para os próximos anos (Gerland *et al.*, 2022). Esse cenário demanda maior atenção sobre os recursos naturais, devido à conversão de superfícies naturais em superfícies impermeáveis (Yuan e Bauer, 2007). Esse fenômeno tem originado diversos problemas relacionados a saúde populacional, ocorrência de inundações, redução de habitat e alimento para fauna, diminuição da diversidade de espécies vegetais nativas e aumento do desconforto térmico para a população (Dai, Guldmann e Hu, 2019; Filazzola, Shrestha e MacIvor, 2019; Kardan *et al.*, 2015; Oke, 1982; Walton, Nowak e Greenfield, 2008; Zhang, W. *et al.*, 2015).

A implantação de componentes naturais em ambientes urbanos visa reduzir os impactos negativos advindos da expansão das cidades (Zhou, Huang e Cadenasso, 2011). Esses componentes podem ser compostos por corpos d'água, gramados, arbustos e árvores isoladas ou florestas urbanas, implantados por meio de projetos urbanos ou pela conservação de remanescentes naturais. Os conjuntos de áreas compostas por corpos d'água, gramados, arbustos e árvores são considerados como áreas verdes urbanas (Hu, Dai e Guldmann, 2021). As árvores implantadas em áreas públicas ou privadas são, por si só, consideradas como arborização urbana. Nesse estudo, consideramos como definição de árvore o componente de fuste lenhosa com um ou mais caules eretos (troncos) que ramificam acima do nível do solo, com copa definida, com diâmetro a altura do peito (DAP) mínima de 5 cm e altura total mínima de 5 m (Batista, Couto e Filho, 2014).

Vários serviços ecossistêmicos são produzidos pelas florestas urbanas, que são percebidos e desfrutados pela população de forma direta ou indireta (Nowak, David J. *et al.*, 2008; Nowak *et al.*, 2016). A regulação da temperatura do ambiente urbano é um desses serviços ecossistêmicos produzidos pela vegetação urbana, proporcionado pelo sombreamento da superfície terrestre que reduz a incidência direta de radiação solar sobre a superfície, evitando a elevação da temperatura (Helletsgruber *et al.*, 2020). Além disso, no processo fisiológica a vegetação libera vapor d'água para atmosfera, contribuindo para redução do desconforto térmico (Wang *et al.*, 2020).

Alguns estudos tem se dedicado a avaliar a relação entre a vegetação urbana e a temperatura de superfície terrestre, utilizando dados de sensoriamento remoto (Guo, Wu e Chen, 2019; Santos, dos *et al.*, 2017; Weng, 2009). No entanto, essas avaliações são realizadas com poucas observações no tempo, não sendo possível identificar os efeitos da

sazonalidade da temperatura da superfície terrestre (TST) em relação a vegetação urbana e as edificações (Hou e Estoque, 2020; Wang *et al.*, 2016; Weng, 2009). Além disso, é importante avaliar a influência das características tridimensionais das árvores e edificações sobre a TST, indicando potenciais variáveis que subsidiem os planos de implantação e manejo da vegetação urbana, com objetivo de proporcionar conforto térmico na cidade (Alexander, 2021; Chen, J. *et al.*, 2021; Dai, Guldmann e Hu, 2019).

A disponibilidade de dados de sensoriamento remoto com alta resolução espacial e temporal permite monitorar as transformações dos ambientes urbanos e avaliar os impactos dessas transformações sobre a temperatura urbana. Nesse sentido, esse estudo tem por propósito avaliar a relação da vegetação urbana de Brasília sobre a temperatura da superfície terrestre (TST), utilizando dados de sensoriamento remoto e de inventário florestal. No capítulo 1 é avaliada a relação espaço-temporal da TST e índices de vegetação e construção em escala anual e sazonal no período de 20 anos. O capítulo 2 aborda os efeitos da vegetação arbórea e rasteira sobre a TST a partir de métricas de paisagem. O capítulo 3 trata do ajuste de algoritmo para identificação do ponto máximo do modelo de altura de copa (*Canopy Height Model* – CHM) como alternativa para detecção de árvore individual em ambiente urbano. No capítulo 4 é abordada a modelagem da TST a partir de variáveis tridimensionais relativas as árvores e as construções urbanas. Uma síntese sobre as principais contribuições dos quatro capítulos mencionados anteriormente é apresentada no capítulo 5.

Hipóteses

1. Tendência de aumento da temperatura da superfície terrestre (TST) e de índices de vegetação e construção são identificados por meio de dados de sensoriamento remoto. A variação sazonal da TST é explicada por índice de vegetação.
2. As métricas da vegetação arbórea e vegetação rasteira tem diferentes contribuições sobre o resfriamento do ambiente e explicam a variação sazonal da TST.
3. As árvores urbanas são identificadas com precisão a partir de algoritmo de suavização e detecção de local máximo por meio de modelo de altura de copa (*Canopy Height Model* – CHM) produzido a partir de dados LiDAR aerotransportado.

4. A TST é explicada por métricas tridimensionais das árvores e edificações urbanas e são fontes de informações importantes para implantação e manejo das árvores urbanas.

Objetivo geral

Avaliar a relação da floresta urbana sobre conforto térmico na cidade de Brasília, Distrito Federal, e criar subsídios para direcionar a implantação e o manejo da vegetação urbana.

Objetivos específicos

1. Relacionar a variação espaço-temporal da temperatura da superfície terrestre e a vegetação urbana e as áreas construídas por meio de índices espectrais.
2. Avaliar a possibilidade de redução do desconforto térmico a partir da modelagem de métricas de paisagem relacionadas à vegetação urbana.
3. Ajustar modelos para obtenção e atualização de informações sobre as árvores urbanas utilizando dados LiDAR.
4. Identificar as principais variáveis tridimensionais da vegetação e edificação que contribuem para redução da temperatura da superfície terrestre.

CAPÍTULO I

Relação espaço-temporal entre a temperatura de superfície terrestre e coberturas de vegetação e de construção em Brasília (DF), Brasil

Resumo

A implantação e o manejo de áreas verdes é uma alternativa para mitigar os efeitos de ilhas de calor urbano (ICU). O monitoramento convencional dos efeitos anuais e sazonais das ICU em áreas urbanas baseado em dados locais é difícil devido ao pouco número de estações meteorológicas em geral. Esse estudo tem por objetivo avaliar a relação espaço-temporal entre a temperatura de superfície terrestre (TST) e áreas com cobertura vegetal e construídas em Brasília, Distrito Federal, Brasil. Foram utilizadas imagens Landsat 5 e 8 para obter a TST e relacionar seus efeitos com o índice de vegetação por diferença normalizada (NDVI) e índice de construção por diferença normalizada (NDBI) utilizando análise de tendência e modelo de regressão linear nos últimos 20 anos (2000-2019). A TST e o NDVI apresentaram tendência de aumento estatisticamente significativo, indicando que o aumento de floresta urbana não foi suficiente para reduzir a TST no período analisado. Foi observado o aumento nos valores de TST e redução do NDVI na primavera (setembro a dezembro). O outono (março a junho) e o inverno (junho a setembro) apresentaram aumento progressivo nos valores de TST em relação as outras estações, indicando a presença de ICU em todas as estações. O NDVI explicou cerca de 81% da variação da temperatura em área nativa e 48% em área urbana. A composição e estrutura da vegetação urbana pode influenciar na mitigação das ICU. Os resultados demonstram que a avaliação da evolução espaço-temporal da TST em função de índices de vegetação e de construção é essencial para o manejo da cobertura verde urbana com vistas a melhorar o bem-estar da população.

Palavras-chave: desconforto térmico; floresta urbana; expansão urbana; espaço verde.

Spatio-temporal relation between land surface temperature and green vegetation cover and built-up areas in Brasília, Brazil, for mitigating effects of urban heat islands

Abstract

Green cover plantation and management are an alternative to mitigate the effects of urban heat islands (UHI). Conventional monitoring of the interannual and seasonal effects of temperature in urban areas based on in-situ data is difficult because of the overall few numbers of meteorological stations available. This study aims to evaluate the spatio-temporal relationship between land surface temperature (LST) and green vegetation cover and built-up areas in Brasília, Federal District, Brazil. We used Landsat 5 and 8 images to retrieve LST and relate its effects with the normalized difference vegetation index (NDVI) and the normalized difference built-up index (NDBI) using trend analysis and linear regression model in the last 20 years (2000-2019). The LST and the NDVI showed significant increasing trend, indicating that increasing in urban forest was insufficient to reduce LST during the period analyzed. We found the highest LST and the lowest NDVI values in spring (September to December). Autumn (March to June) and winter (June to September) showed progressive increasing in the LST values compared to other seasons, indicating the presence of UHI in all seasons. NDVI explained 81% of the temperature variation in native areas and 48% in urban areas. Composition and structure of urban vegetation may influence the mitigation of UHI. The results demonstrate that evaluating the spatio-temporal evolution of the LST as a function of vegetation and urban indices is essential to manage urban green cover in order to improve the population's well-being.

Keywords: thermal discomfort; urban forest; urban sprawl; greenspace.

1 Introdução

O número de habitantes nos centros urbanos do mundo inteiro vem aumentando progressivamente, passando de 30% em 1950 para 55% em 2018, com expectativa de aumentar para 68% em 2050 (United Nations, 2018). Uma das consequências desse aumento populacional é a expansão de áreas impermeáveis. O monitoramento dessas transformações na superfície é importante para promover estratégias que minimizem o aumento da temperatura do ar e minimize o desconforto térmico e consequente aumento na demanda por energia para o uso de ar-condicionado (Elmes *et al.*, 2017; Kardan *et al.*, 2015; Kong *et al.*, 2014; Liu e Zhang, 2011; Sekertekin, Kutoglu e Kaya, 2016; Zullo *et al.*, 2019).

Informações precisas de temperatura da superfície terrestre (TST) são importantes para definir estratégias para minimizar os efeitos espaço-temporais das ilhas de calor urbano (ICU) (Gage e Cooper, 2017a; Weng, Lu e Schubring, 2004). Torna-se importante, também, avaliar a relação entre a temperatura de superfície e o percentual de cobertura verde (Estoque, Murayama e Myint, 2017; Wang *et al.*, 2020). As árvores no entorno de construções atuam como reguladores de temperatura, reduzindo o uso de energia hidroelétrica ou termoelétrica para resfriamento ou aquecimento, ocasionando em redução do consumo anual de eletricidade de 20 a 50% (Nowak e Dwyer, 2007).

Dados de sensoriamento remoto podem ser utilizados para estimar a TST, produzindo informações para o planejamento e manejo dos espaços verdes urbanos (Du, Song e Yan, 2019; Schwarz, Lautenbach e Seppelt, 2011; Weng, Lu e Schubring, 2004). Algoritmos como o Mono Canal podem recuperar a TST a partir da banda termal (Qin, Karnieli e Berliner, 2001; Sobrino, Jiménez-Muñoz e Paolini, 2004). A maioria dos estudos tem sido desenvolvidos utilizando imagens monotemporais, desconsiderando os efeitos sazonais sobre a temperatura da superfície e mudanças na cobertura vegetal (Du, Song e Yan, 2019; Lazzarini, Marpu e Ghedira, 2013; Sekertekin, Kutoglu e Kaya, 2016; Yusuf, Pradhan e Idrees, 2014; Zhou *et al.*, 2010). A variação sazonal da cobertura vegetal pode ser uma importante variável para avaliar a influência do manejo da vegetação na redução da magnitude das ilhas de calor urbano. Alguns estudos também utilizam índices de superfície impermeável para analisar a TST e os padrões termais urbanos uma vez que é estável e não sofre variações sazonais (Zhang, Y. *et al.*, 2015; Zhang, Odeh e Han, 2009).

A TST varia ao longo das estações devido à variabilidade de fatores precursores como condições de irradiação solar, fatores antropogênicos e a variação espacial da cobertura vegetal (Peng *et al.*, 2018; Song *et al.*, 2021). Alexander (2020) demonstrou que a cobertura de árvores teve maior efeito de resfriamento que a cobertura vegetal urbana. Cao *et al.* (2021) não encontraram diferença entre a TST no verão (junho, julho e agosto) e no inverno (dezembro, janeiro e fevereiro) utilizando dados do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS) devido à predominância de floresta pluvial tropical. Guha *et al.* (2018) mostraram que a TST tem relação negativa com o NDVI e relação positiva com o *Normalized Difference Built-up Index* (NDBI), entretanto, os autores destacaram que estas relações podem variar de acordo com a extensão e/ou sazonalidade. Segundo Muro *et al.* (2018), series temporais de TST e de seus agentes podem fornecer indicadores de forma rápida e confiável relacionados a ICU. Atualmente, a partir do processamento em nuvem disponibilizado pelo GoogleTM ou AmazonTM permite produzir informações espaço-temporais rapidamente e sem a necessidade de computadores robustos em escritórios locais (Mutanga e Kumar, 2019).

Esse trabalho tem por objetivo responder as seguintes questões: (1) Qual a magnitude da variação sazonal das ICU localizadas em região savana tropical típica? (2) Qual a relação espaço-temporal entre a TST e o percentual de cobertura verde? (3) Qual a eficiência da vegetação urbana em reduzir a temperatura da superfície? Os resultados desse estudo podem auxiliar a entender a dinâmica espaço-temporal da ICU e sua relação com a vegetação urbana. Esse estudo foi conduzido na cidade de Brasília, Distrito Federal do Brasil, uma área urbana com extensos espaços verdes e alta densidade de árvores de floresta urbana, embora a densidade de árvores esteja diminuindo devido à expansão urbana.

2 Material e métodos

2.1 Área de estudo

O presente estudo foi desenvolvido na cidade de Brasília, localizada no Distrito Federal (DF), região centro-oeste do Brasil. Brasília é composta por seis regiões administrativas (RA): Plano Piloto, Cruzeiro, Sudoeste/ Octogonal, Lago Norte, Lago Sul e Varjão, perfazendo área de aproximadamente 600 km². A área de estudo está situada entre as latitudes 15,56° S e 15,91° S e entre as longitudes 48,09° W e 47,79° W (Figura

1). O Parque Nacional de Brasília (PNB) está localizado na região norte de Brasília, sendo a maior unidade de conservação em área urbana no Brasil.

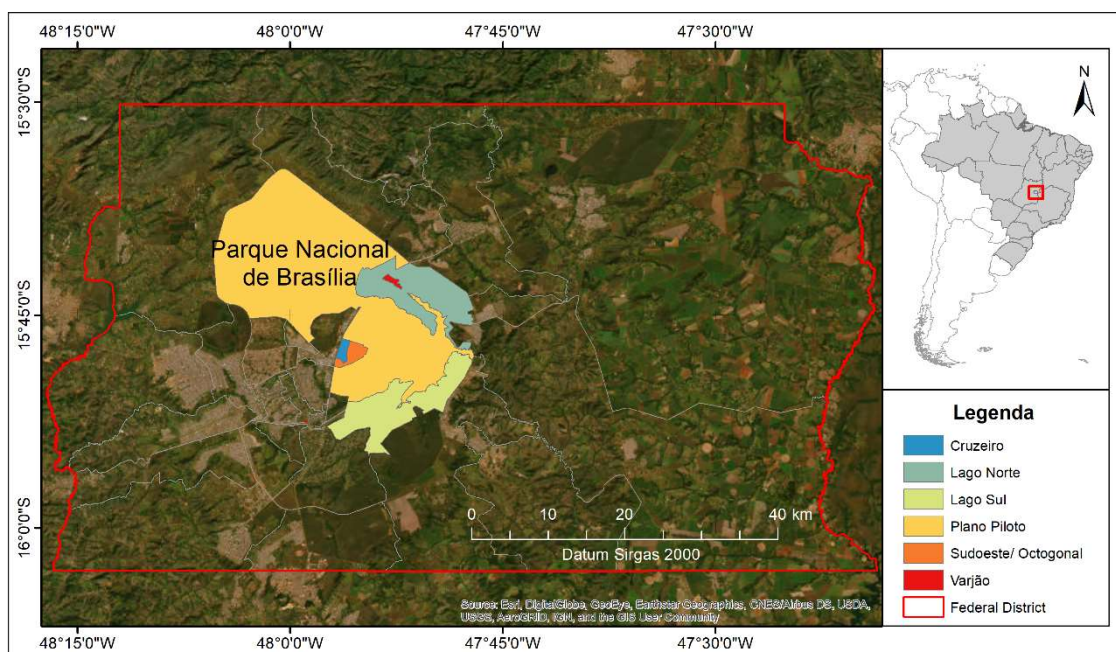


Figura 1. Localização da área de estudo no Distrito Federal, representada por sete regiões administrativas.

A RA Cruzeiro é formada pelas áreas urbanas do Cruzeiro Velho e Cruzeiro Novo. A RA Sudoeste/ Octogonal é composta por áreas residenciais, setores comerciais e quadras mistas. A RA Lago Norte é formada pelos Setores de Mansões Norte, Habitação Individual Norte e Área Comercial e a RA Lago Sul compreende o Setor de Habitação Individual Sul, de Mansões Urbanas Dom Bosco e de Estaleiros, Aeroporto Internacional Juscelino Kubitschek, Base Aérea de Brasília e o Campo Experimental Água Limpa da Universidade de Brasília. Rodeada pela RA Lago Norte, está a RA Varjão (Codeplan, 2012).

Segundo a Pesquisa Distrital por Amostra de Domicílios (PDAD), realizada em 2019 pela Companhia de Planejamento do Distrito Federal (Codeplan), a população estimada para Brasília/ Plano Piloto foi de 225 mil habitantes, enquanto para o Sudoeste/ Octogonal e Cruzeiro, a estimativa foi de 54 mil e 31 mil habitantes, respectivamente. O último levantamento populacional realizado pela Codeplan (2012) para as regiões Lago Norte, Lago Sul e Varjão foi em 2011 e indicava população de 33 mil, 29 mil e 9 mil habitantes, respectivamente.

A menor temperatura média é registrada no mês de julho (13,7 °C) e a máxima média no mês de setembro (28,4 °C), com temperatura média mensal variando entre 19,0 °C (junho e junho) a 22,4 °C (outubro) (INMET, 2021). A chuva anual média acumulada varia entre 1.300 mm a 1.600 mm, com os menores valores médios registrados no mês de junho, 4,90 mm, e os maiores valores médios em dezembro, 241,50 mm. O clima predominante da região é o Aw, com inverno seco e verão chuvoso (Alvares *et al.*, 2013). O verão ocorre de dezembro a março, o outono de março a junho, o inverno de junho a setembro e a primavera de setembro a dezembro.

O DF situa-se entre as altitudes 850 m e 1.400 m, com altitude média de 1.100 m. O DF está situado ainda dentro das bacias hidrográficas do Paraná, Tocantins/ Araguaia e São Francisco (Codeplan, 2012; SFB, 2016). Cerca de 23% do território do DF é ocupado por vegetação nativa, 2% por florestas plantadas e 75% por outros usos da terra, notadamente áreas urbanas consolidadas e em consolidação, culturas agrícolas e pastagens cultivadas. A maior parte da vegetação natural da região é ocupada por Cerrado *sensu stricto* e por Mata de Galeria. Dentre as regiões administrativas do DF, Brasília possui segunda maior proporção de área coberta por vegetação nativa, cerca de 45% (SFB, 2016).

2.2 Banco de dados

Para estimativa da temperatura da superfície, foram utilizadas imagens dos satélites Landsat 5 *Thematic Mapper* (TM) e Landsat 8 *Operational Land Imager* (OLI) e *Thermal Infrared Sensor* (TIRS), obtidas do banco de dados da plataforma *Google Earth Engine*. O Landsat 5 TM possui imagens ópticas com resolução espacial de 30 m e imagem na faixa do termal com resolução de 120 m, reamostrado para 30 m. O Landsat 8 OLI possui imagens ópticas com resolução espacial de 30 m e o TIRS com imagens de 100 m que foram reamostrados para 30 m. Foram selecionadas 42 imagens (órbita: 221; ponto: 71) sem cobertura de nuvens e com reflectância na superfície para bandas na faixa do óptico (Chander, Markham e Helder, 2009). Um total de 25 imagens do sensor TM foram obtidas no período de janeiro de 2000 a outubro 2011, e 17 imagens do sensor OLI foram obtidas no período de junho de 2013 a janeiro de 2019. Foram utilizadas imagens referentes ao verão (dezembro a março), outono (março a junho), inverno (junho a setembro) e primavera (setembro a dezembro). Para cada cena, foram selecionadas as bandas das faixas espectrais do vermelho, infravermelho próximo, infravermelho médio

e termal. Dados de 2012 não foram obtidos devido a falha operacional dos satélites Landsat 5 e Landsat 7 do final de 2011 até o lançamento do Landsat 8 em fevereiro de 2013.

Dados de temperatura do ar e umidade relativa na data de passagem dos satélites também foram utilizadas para realizar a correção atmosférica das bandas termais e obter a temperatura da superfície terrestre (TST). Essas informações foram adquiridas da estação meteorológica de Brasília – DF (Código OMM 83377), disponíveis no Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do Instituto Nacional de Meteorologia (INMET).

2.3 Métodos

2.3.1 Estimativa da temperatura da superfície terrestre (TST)

A radiância que chega ao sensor sofre interferências da atmosfera e da emissividade da superfície, sendo necessário à correção desses ruídos para obtenção da temperatura da superfície terrestre (TST) de forma precisa (Wang *et al.*, 2015). Para estimativa da TST, foi utilizado o algoritmo de Mono Canal ou *Mono-Window Algorithm* (Qin, Karnieli e Berliner, 2001). Esse algoritmo foi desenvolvido para imagens do Landsat 5 TM, sendo necessárias adaptações para as imagens do satélite Landsat 8 OLI (Figura 2). A radiância obtida pelo canal termal do sensor pode ser descrita pela equação de transferência radiativa (Equação 1), dada por:

$$B_i(T_i) = \tau_i[\varepsilon_i B_i(T_s) + (1 - \varepsilon_i)I_i^\downarrow] + I_i^\uparrow \quad (\text{Equação 1})$$

em que T_i é a temperatura de brilho do sensor na banda i ; T_s é a temperatura da superfície terrestre em graus kelvin; τ_i é a transmitância da atmosfera na banda i ; ε_i é a emissividade terrestre na banda i ; $B_i(T_i)$ é a radiância termal observada, expressa pela função de Planck de temperatura de brilho T_i na banda i ; $B_i T_s$ é a emitância da superfície terrestre expressa pela função de Planck para a temperatura da superfície T_s na banda i ; I_i^\downarrow e I_i^\uparrow correspondem à emitância atmosférica descendente e à emitância atmosférica ascendente, respectivamente, para a banda i .

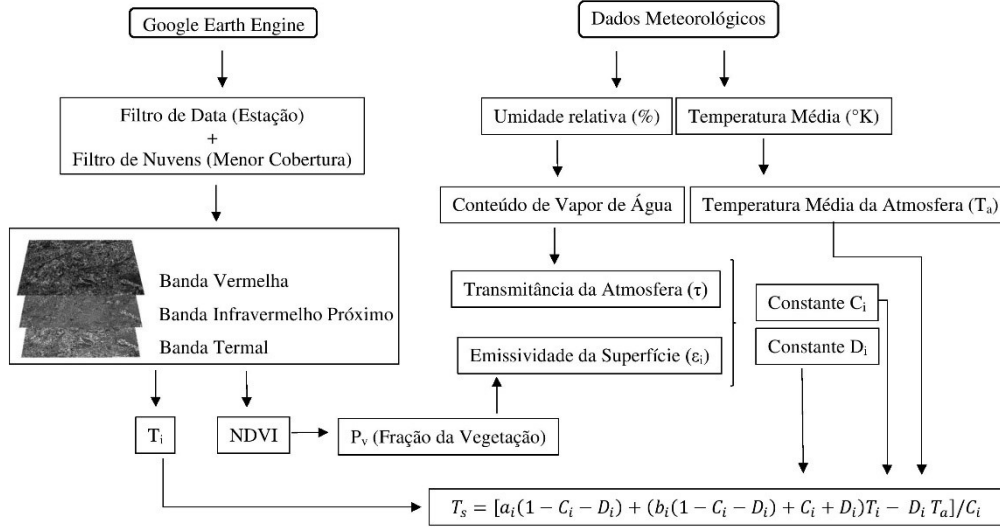


Figura 2. Fluxo do processo para obtenção da temperatura da superfície terrestre baseado em imagens Landsat.

Assumindo que a superfície terrestre é uma superfície Lambertiana, Qin et al. (2001) desenvolveram o algoritmo mono-window a partir da Equação (1). Para tanto, a emitância atmosférica ascendente e descendente foi resolvida por meio da integração da função de emitância atmosférica, representada pela função de radiância de Planck com a temperatura do ar, variando-se a altitude desde a superfície terrestre até a altitude do sensor (Equação 2), ou seja:

$$I_i^\uparrow = \int_0^Z B_i(T_z) \frac{\delta \tau_i(z, Z)}{\delta z} dz \quad (\text{Equação 2})$$

em que T_z é a temperatura atmosférica a altitude z ; Z é a altitude do sensor; e $\tau_i(z, Z)$ representa a transmitância atmosférica ascendente da altitude z até o sensor a altitude Z .

Por meio da integração da Equação (2), em função da temperatura do ar, tem-se as emitâncias atmosféricas ascendente (Equação 3) e descendente (Equação 4), que podem ser representadas, nessa ordem, por:

$$I_i^\uparrow = (1 - \tau_i) B_i(T_a) \quad (\text{Equação 3})$$

$$I_i^\downarrow = (1 - \tau_i) B_i(T_a^\downarrow) \quad (\text{Equação 4})$$

Dessa forma, substituindo as Equações (3) e (4) na Equação (1), e partindo de algumas premissas e pressuposições propostas por Qin et al. (2001) para resolver a Equação (1), pode-se estimar a TST por meio da seguinte expressão:

$$T_s = [a_i(1 - C_i - D_i) + (b_i(1 - C_i - D_i) + C_i + D_i)T_i - D_i T_a]/C_i \quad (\text{Equação 5})$$

em que T_s é a TST do sensor na banda i ; T_a é a temperatura atmosférica média efetiva; T_i é a temperatura de brilho do sensor na banda i ; a_i e b_i são constantes usadas para aproximar a derivada da função de radiação de Planck para a banda termal i do sensor; e C_i e D_i são parâmetros internos do algoritmo na banda i .

Para obter a TST a partir da banda 10 do Landsat 8 OLI, foram utilizados os parâmetros a_i e b_i descritos em Wang et al. (2015). Os parâmetros relativos a TST obtida do Landsat 5 TM está disponível em Qin et al. (2001). Os coeficientes C_i e D_i da Equação 5 foram estimados, respectivamente, em função da transmitância atmosférica (Equação 6) e da emissividade terrestre (Equação 7), respectivamente:

$$C_i = \tau_i \varepsilon_i \quad (\text{Equação 6})$$

$$D_i = (1 - \tau_i)[1 + (1 - \varepsilon_i)\tau_i] \quad (\text{Equação 7})$$

em que τ_i é a transmitância atmosférica do sensor na banda i e ε_i é a emissividade terrestre para a banda i .

2.3.1.1 Estimativa da temperatura média efetiva da atmosfera (T_a)

A temperatura média atmosférica foi estimada utilizando dados de temperatura do ar e o conteúdo de vapor de água para várias camadas atmosféricas, variando desde a região próxima à superfície do solo até o sensor. Aplicando o padrão de perfil atmosférico para zonas de clima tropical e a temperatura do ar próximo a superfície (T_0), obtida de estação climática, é possível estimar que temperatura atmosférica média de diferentes regiões (Qin, Karnieli e Berliner, 2001) (Tabela 1).

Tabela 1. Equações utilizadas para estimar a temperatura atmosférica média efetiva (T_a).

Modelos	Equações
Modelo tropical	$T_a = 17,9769 + 0,9172T_0$
Modelo Verão de latitude média	$T_a = 16,0110 + 0,9262T_0$
Modelo Inverno de latitude média	$T_a = 19,2704 + 0,9112T_0$

Fonte: Qin; Karnieli; Berliner (2001).

2.3.1.2 Estimativa da transmitância atmosférica (τ_i)

A radiância que chega ao sensor sofre variadas atenuações, principalmente pela absorção da radiação pela atmosfera. Dentre os fatores que implicam nessas atenuações estão o comprimento de onda, ozônio, componentes químicos, aerossóis e vapor de água, tendo esse último considerável efeito na absorção da radiação captada pelo sensor remoto (Wang *et al.*, 2015). Qin et al. (2001) propuseram que a estimativa da transmitância fosse realizada por meio de modelos lineares ajustados em função do conteúdo de vapor de água, onde há tendência de redução da transmitância atmosférica pelo aumento do conteúdo de vapor de água. A transmitância atmosférica para o Landsat 5 TM (τ_6) e para o Landsat 8 OLI (τ_{10}) foi estimada em função da largura da banda termal e do conteúdo de vapor de água da atmosfera (w), apresentando alto coeficiente de determinação (R^2) e baixo desvio padrão (S_{yx}) (Qin, Karnieli e Berliner, 2001; Wang *et al.*, 2015) (Tabelas 2 e 3).

Tabela 2. Estimativa da transmitância da atmosfera para o Landsat 5 TM. R^2 = coeficiente de determinação; S_{yx} = desvio padrão.

Atmosfera	Conteúdo de vapor de água (g cm⁻²)	Estimativa da transmitância	R²	S_{yx}
Temperatura do ar alta	0,4 - 1,6	$\tau_6 = 0,974290 - 0,08007 w$	0,996	0,0024
	1,6 - 3,0	$\tau_6 = 1,031412 - 0,11536 w$	0,999	0,0025
Temperatura do ar baixa	0,4 - 1,6	$\tau_6 = 0,982007 - 0,09611 w$	0,999	0,0033
	1,6 - 3,0	$\tau_6 = 1,053710 - 0,14142 w$	0,999	0,0024

Tabela 3. Estimativa da transmitância da atmosfera para o Landsat 8 OLI. R^2 = coeficiente de determinação; S_{yx} = desvio padrão.

Atmosfera	Conteúdo de vapor de água (g cm^{-2})	Estimativa da transmitância	R^2	S_{yx}
Modelo Verão de latitude média	0,2 – 1,6	$\tau_{10} = 0,9184 - 0,0725 w$	0,983	0,0043
	1,6 – 4,4	$\tau_{10} = 1,0163 - 0,1330 w$	0,999	0,0030
	4,4 – 5,4	$\tau_{10} = 0,7029 - 0,0620 w$	0,966	0,0081
Modelo tropical	0,2 – 2,0	$\tau_{10} = 0,9220 - 0,0780 w$	0,983	0,0059
	2,0 – 5,6	$\tau_{10} = 1,0222 - 0,1310 w$	0,999	0,0033
Modelo Inverno em latitude média	5,6 – 6,8	$\tau_{10} = 0,5422 - 0,0440 w$	0,991	0,0017
	0,2 – 1,4	$\tau_{10} = 0,9228 - 0,0735 w$	0,988	0,0033

O conteúdo de vapor de água presente entre a superfície terrestre e o satélite (w) foi estimado pela relação entre o conteúdo de vapor de água próximo a superfície $w(0)$ e o conteúdo de vapor de água da primeira camada e o total, expresso por $Rw(0)$. O $w(0)$ pode ser obtido por estação meteorológica automática próxima a área de estudo (Equação 9). Para variável $Rw(0)$ foi atribuído o valor 0,6834, referente a atmosfera tropical (Wang *et al.*, 2015).

$$w = w(0)/Rw(0) \quad (\text{Equação 9})$$

O conteúdo de vapor de água próximo a superfície, $w(0)$, pode ser obtido a partir da seguinte relação (Equação 10):

$$w(0) = H * E * A/1000 \quad (\text{Equação 10})$$

em que H é a umidade do ar próximo a superfície (%); E é a relação de mistura de saturação de vapor de água e ar para determinada temperatura (g kg^{-1}); e A é a densidade do ar em determinada temperatura do ar (g m^{-3}). O valor de H foi obtido de estação climática local e os valores das variáveis E e A foram obtidos conforme Wang *et al.* (2015).

2.3.1.3 Estimativa da emissividade da superfície (ε_i)

A emissividade é o fator proporcional a escala de radiância de um corpo negro para prever a radiância emitida, necessária para estimar a temperatura da superfície (Sobrino *et al.*, 2008). A emissividade da Terra apresenta variações em função da vegetação, umidade, rugosidade e ângulo de visada (Yang *et al.*, 2014). Para estimativa da emissividade da superfície terrestre, foi utilizada a metodologia proposta por Sobrino *et al.* (2008), que utiliza o índice de vegetação por diferença normalizada (NDVI) para identificação de limiares entre áreas com solo exposto ($NDVI_s$) e áreas com vegetação ($NDVI_v$). Nesse caso, admite-se que, para áreas de solo exposto, $NDVI < NDVI_s$ e, para áreas com vegetação, $NDVI > NDVI_v$ (Equação 11).

$$\varepsilon_i = \begin{cases} \alpha_i \rho_{red} + b_i & NDVI < 0,2 \\ \varepsilon_{v,i} P_v + \varepsilon_{s,i} (1 - P_v) + C_i & 0,2 \leq NDVI \leq 0,5 \\ \varepsilon_{v,i} + C_i & NDVI > 0,2 \end{cases} \quad (\text{Equação 11})$$

em que $\varepsilon_{v,i}$ e $\varepsilon_{s,i}$ são, respectivamente, a emissividade da vegetação e do solo, na banda i ; P_v é a proporção da vegetação ou cobertura vegetal fracionada; C_i é uma constante relativa ao efeito da cavidade em função da rugosidade da superfície para banda i .

A estimativa da fração da cobertura vegetal (P_v) foi obtida pela Equação 12, sendo que os valores considerados para $NDVI_v$ e $NDVI_s$ foram 0,5 e 0,2, respectivamente, como sugerido por Sobrino e Raissouni (2000) e Sobrino *et al.* (2008). Para $NDVI > NDVI_v$, ou seja, áreas com vegetação, P_v foi considerado como sendo igual a 1. Para $NDVI < NDVI_s$, ou seja, solo exposto, P_v foi considerado igual a 0 (zero). Os valores das constantes ε_v , ε_s , α_i e b_i são iguais a 0,9863, 0,9668, 0,047 e 0,973, respectivamente (Wang *et al.*, 2015; Yu, Guo e Wu, 2014).

$$P_v = \left[\frac{NDVI - NDVI_s}{NDVI_v - NDVI_s} \right]^2 \quad (\text{Equação 12})$$

A constante C ou efeito da cavidade em função da rugosidade da superfície terrestre, é obtida a partir da Equação 13, dada por:

$$C_i = (1 - \varepsilon_{s,i}) \varepsilon_{v,i} F'(1 - P_v) \quad (\text{Equação 13})$$

em que F' varia de 0 a 1, de acordo com a rugosidade da superfície. Neste estudo, foi considerado valor médio de F' igual a 0,55 (Sobrino *et al.*, 2008; Yu, Guo e Wu, 2014). Para o caso de superfícies planas, o valor de C é igual a 0 (zero).

2.4 Estimativa do NDVI e NDBI

Enquanto o NDVI é utilizado para obter informações sobre vegetação, o índice de área construída por diferença normalizada (NDBI) permite obter informações sobre construções e áreas urbanas. Os dois índices são obtidos a partir das seguintes relações, descritas pelas Equações 14 e 15, ou seja:

$$NDVI = \frac{IVP - V}{IVP + V} \quad (\text{Equação 14})$$

$$NDBI = \frac{IVM - I}{IVM + IVP} \quad (\text{Equação 15})$$

em que IVP é a reflectância na banda do infravermelho próximo; V é a reflectância na banda do vermelho; e IVM é a reflectância na banda do infravermelho médio.

2.5 Ilha de Calor Urbano de Superfície (ICUS)

A ilha de calor urbano superficial (ICUS) é formada quando a temperatura da superfície urbana está acima da temperatura de áreas rurais ou áreas de floresta situadas nas proximidades da região urbana. Para identificar esse fenômeno, foi calculada a diferença entre a média da temperatura da superfície no Parque Nacional de Brasília (PNB) e na área urbana (Equação 16).

$$ICUS = TST_{floresta} - TST_{urbano} \quad (\text{Equação 16})$$

em que $ICUS$ = ilha de calor urbano de superfície (°C); TST_{urbano} = temperatura da superfície média em área urbana (°C); e $TST_{floresta}$ = temperatura da superfície média em área de floresta nativa (°C).

2.6 Análise estatística

As variáveis TST, NDVI e NDBI foram avaliadas e interpretados por meio do cálculo do valor mínimo, médio, máximo e desvio padrão em períodos de escala anual e sazonal. A tendência de aumento ou redução dos valores das variáveis foi analisada através do teste de Mann-Kendall e Pettit disponíveis no pacote *trend* do programa R (R CORE TEAM, 2019), ao nível de significância de 5% (Pohlert, 2020). O teste de Mann-Kendall é não paramétrico, ou seja, não considera a pressuposição de normalidade dos dados. Este teste avalia a tendência monotônica nos dados e a hipótese alternativa assume que há tendência positiva ou negativa.

A relação entre a vegetação, representada pelo NDVI (variável independente), e a TST (variável dependente) foi avaliada por regressão dos mínimos quadrados ordinários para mensurar o impacto do NDVI sobre a variação da TST. Essa relação foi avaliada usando valores amostrais obtidos em região urbana e nativa, as quais permitem avaliar a TST em diferentes cenários. A força da relação entre as variáveis foi avaliada pelo coeficiente de determinação (R^2).

3 Resultados

3.1 Variação anual da TST, NDVI e NDBI

A partir da série temporal dos dados, foi observado que a temperatura da superfície teve valor mínimo próximo a 22 °C e valor máximo próximo a 43 °C em 2003 e 2017, respectivamente, indicando amplitude térmica de 11 °C (Figura 3). A temperatura média do ar (TMA) apresentou valores abaixo da TST, apresentando tendência similar a TST. O NDVI também apresentou variações ao longo do período observado, com valor mínimo de 0,24 em setembro de 2010 e valor máximo de 0,58 em janeiro de 2019. O menor valor médio do NDVI em 2010 coincide com um dos maiores valores de temperatura da superfície em setembro daquele ano (Figura 3B). O NDBI também apresentou maior valor em 2010, indicando que essa variável tem relação positiva com a TST (Figura 3B).




Figura 3. Box plot (A) e variação média anual (B) da temperatura da superfície terrestre (TST), temperatura média do ar (TMA), índice de vegetação normalizada pela diferença (NDVI) e índice de área construída normalizada pela diferença (NDBI) obtidos a partir de imagens Landsat 5 TM e Landsat 8 OLI.

A TST anual apresentou tendência de crescimento no período de 2000-2019, indicando que pode haver aumento no desconforto térmico para população local caso não sejam tomadas medidas para mitigar os fatores responsáveis por esse aumento. Essa tendência foi verificada pelo teste de Mann-Kandall, onde a variável TST anual mostrou-se significativa ($p < 0,05$). O teste de Pettitt indicou que em junho de 2013 foi o período de mudança da temperatura da superfície ($p < 0,05$), com aumento significativo da TST (Tabela 4). O NDVI e o NDBI não apresentaram tendências significativas ao longo dos anos (Tabela 4).

Tabela 4. Resultado dos testes de Mann-Kendall e Pettitt para as variáveis temperatura de superfície terrestre (TST), índice de vegetação por diferença normalizada (NDVI) e índice de áreas construídas por diferença normalizada (NDBI).

Teste	TST	Temperatura do Ar	NDVI	NDBI
Mann-Kendall	2,97*	1,76	1,77	-1,02
Pettitt	274*	185	172	128

* = variáveis que foram significativas nos testes de Mann-Kendall e Pettitt ($p < 0,05$).

A média do NDVI apresentou valores mínimo e máximo de -0,53 e 0,83, respectivamente (Figura 4A). Os maiores valores estiveram localizados em áreas de vegetação nativa, principalmente nas grotas onde há constante presença de umidade que favorece o desenvolvimento de espécies florestais com alto vigor fisiológico. A vegetação urbana apresentou NDVI médio próximo a 0,40, valor abaixo ao encontrado em áreas

nativas, o que pode estar relacionado com a baixa densidade de vegetação por unidade de área, já que o pixel da imagem representa a média da reflectância dos alvos presentes em uma área de 900 m². Os menores valores de NDVI são representados pelos cursos de água, que tem por característica absorver a radiação eletromagnética na faixa do infravermelho próximo (Figura 4A). Ao longo dos anos, algumas regiões urbanas apresentaram alta variação no NDVI, como demonstrado pelo alto desvio padrão (Figura 4B). O NDBI médio apresentou valores variando entre -0,52 e 0,37, com menores valores encontrados em áreas com presença de água e maiores valores em áreas onde há presença de edificações e solo exposto (Figura 4C). A presença de vegetação próximo a construções, reduz o valor médio e o desvio padrão do NDBI, minimizando a temperatura de superfície (Figuras 4C e 4D).

A temperatura da superfície apresentou valores médios mínimos e máximos de 21,00 °C e 36,40 °C, respectivamente, e amplitude próxima a 15 °C. Foram observados altos valores de temperatura na região centro-oeste, com temperatura variando entre 30 °C e 35 °C, e alto desvio padrão na região noroeste (Figura 4E). A vegetação arbórea urbana, identificada pelos maiores valores de NDVI, contribuiu para baixa variação da temperatura nas quadras urbanas, que apresentaram desvios padrões próximos a 5 °C. Em relação à área com predominância de vegetação nativa, o PNB apresentou valor médio próximo a 18 °C. A região Norte do parque apresentou baixa variação de temperatura, diferente da região sul do parque que apresentou altas variações de temperatura, variando de 7 °C a 9 °C (Figura 4F).

As variações da TST e do NDVI podem ser observadas por meio dos transectos longitudinais na Figura 5. O NDVI apresentou valor mínimo de 0,11 e máximo de 0,62, respectivamente, com variação de 82%, demonstrando ser uma vegetada na região norte da área de estudo (Figura 5A). Nesse local, a TST apresentou menor valor de 26,61 °C e maior valor de 32,23 °C, com variação de 17%. As regiões representadas por A e C na Figura 5 são similares quanto à divisão política dos blocos, ruas e estradas. Porém, a região representada na Figura 5C teve valores mínimos e máximos de 0,06 e 0,69 para NDVI e 25 °C e 32 °C para a TST, respectivamente, tendo a TST variação de 19%. Houve relação inversa entre NDVI e TST, onde os pixels com altos valores de NDVI apresentaram baixos valores de TST. Por outro lado, a região central da área de estudo apresentou valor de TST mínimo de 28 °C e máximo de 34 °C, variação de 18% ao longo do transecto, valores superiores aos encontrados em relação aos demais perfis (Figura 5C).

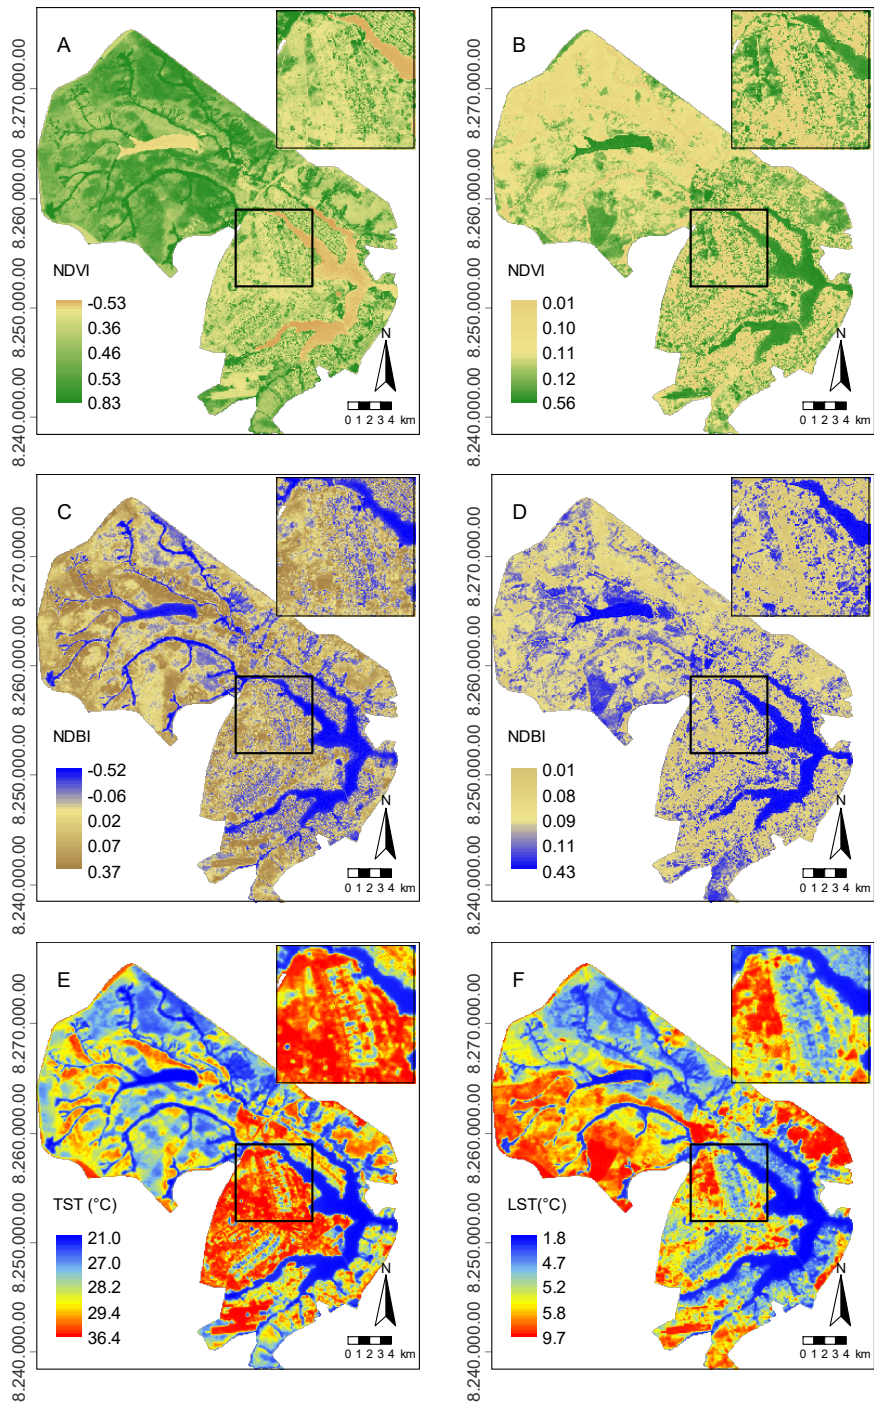


Figura 4. Variação espacial média do NDVI (A), NDBI (C) e TST (E) e respectivo desvio padrão (B, D e F) calculado para o período de 2000-2019.

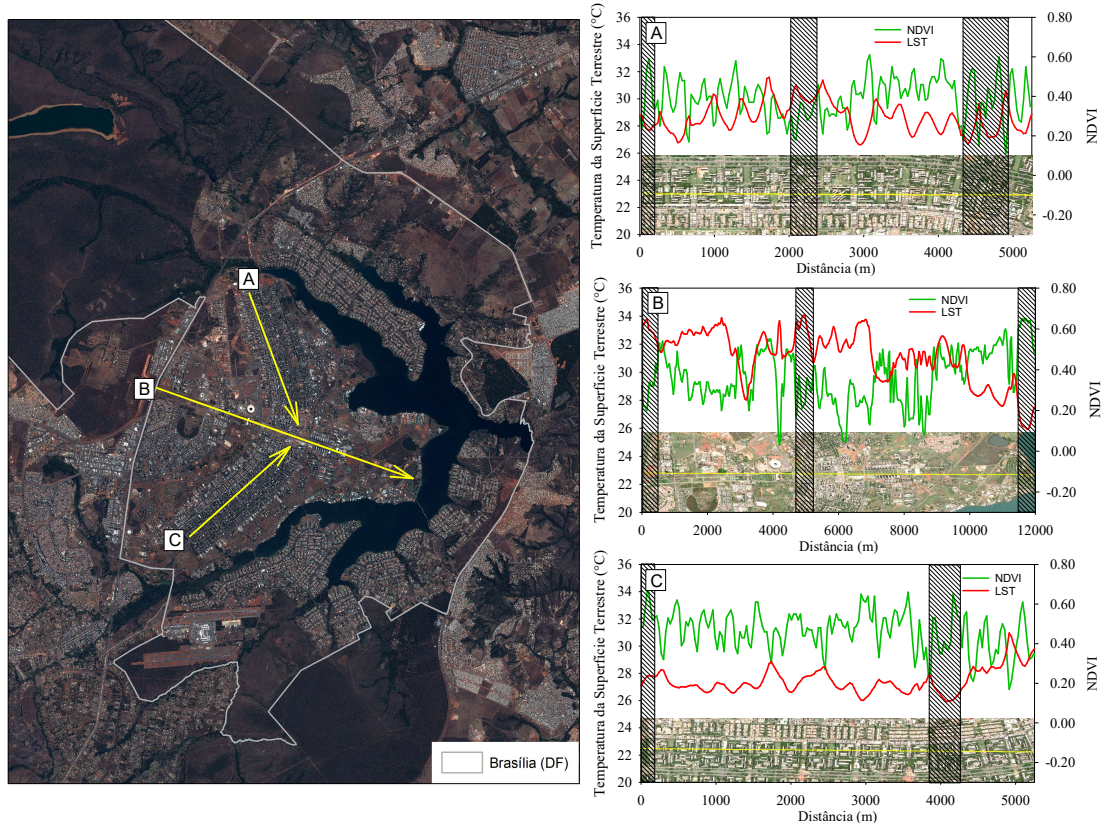


Figura 5. Perfis de variação da temperatura da superfície terrestre (TST) e do índice de vegetação por diferença normalizada (NDVI) ao longo dos transectos A, B e C na área de estudo (linha amarela).

3.2 Efeitos da vegetação urbana sobre a TST nas estações climáticas

A temperatura da superfície na primavera apresentou valores acima das outras estações, chegando à média máxima de 41,9 °C na região urbana e média mínima de 21,2 °C, indicando amplitude térmica de aproximadamente 21,2 °C (Figura 6A). Nessa estação, as regiões urbanas apresentaram valores de TST maiores que no PNB, principalmente em locais com alta densidade de construções e estradas, contribuindo para a formação de ilhas de calor urbano. A primavera foi a estação que apresentou os maiores valores médios, em relação as outras estações climáticas, com pico de temperatura em 2017 (42,5 °C), e menor média anual em 2000 (33,2 °C). Nessa estação, foi possível observar forte relação inversa entre TST e NDVI, pois foi a estação que apresentou os maiores valores de TST e os menores valores de NDVI. A primavera apresentou cerca de 185,15 km² de ICU, correspondendo a 61,80% da área de estudo.

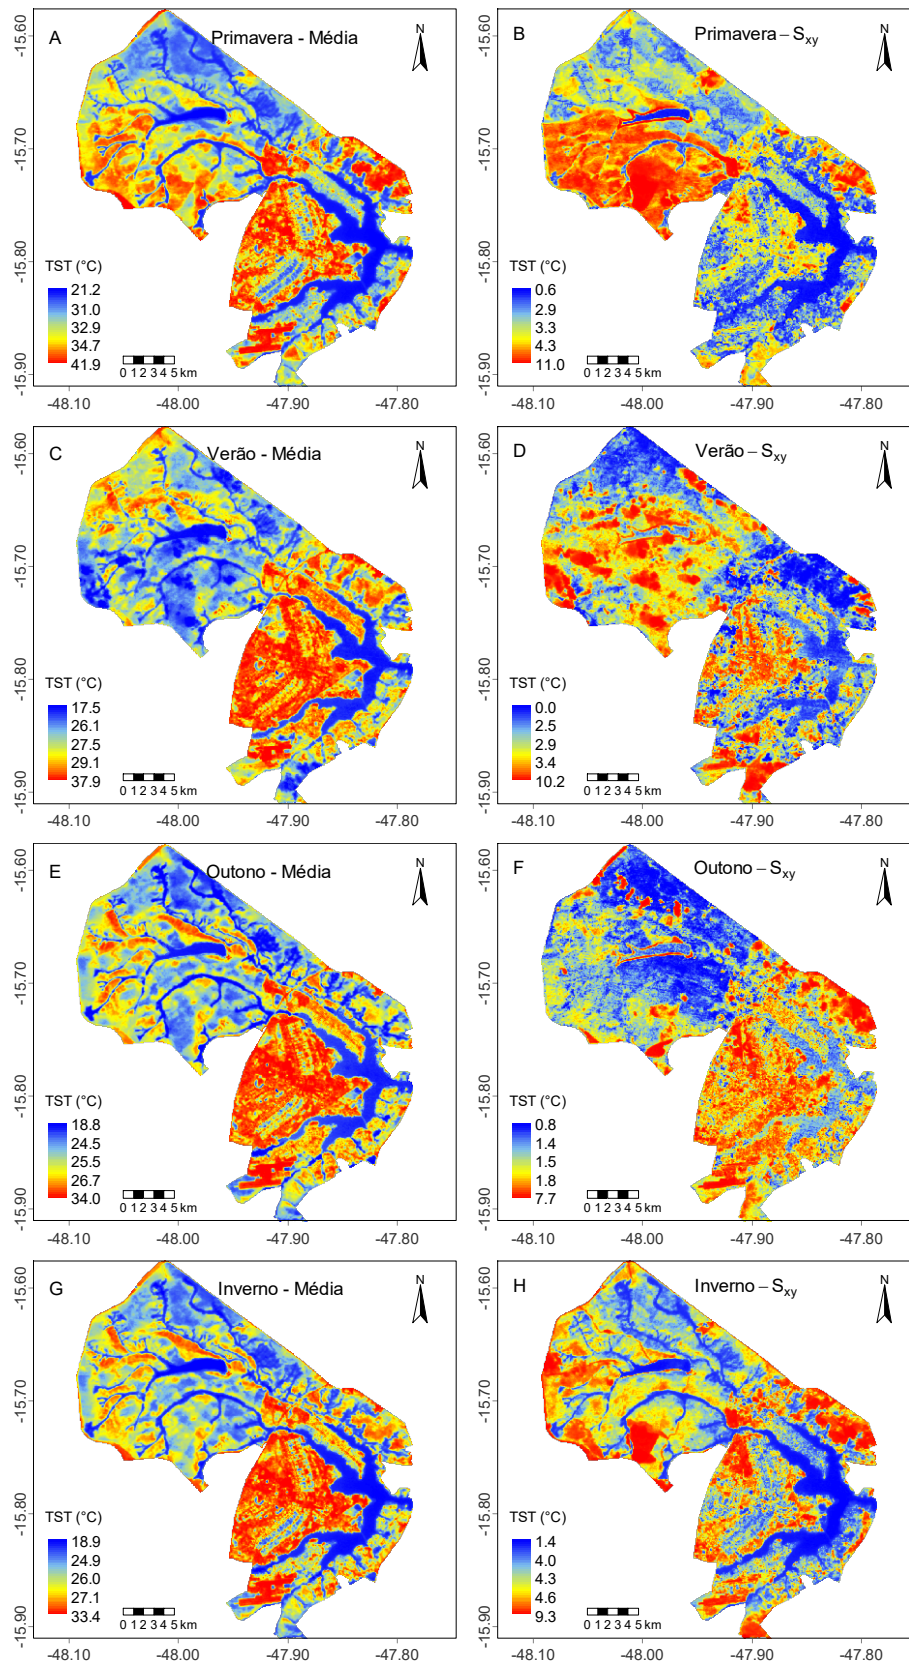


Figura 6. Média e desvio padrão (S_{yx}) da temperatura da superfície terrestre (TST) nas estações climáticas, obtidas de imagens Landsat.

Devido à ocorrência de chuvas no verão e à intensa cobertura de nuvens, apenas três imagens estavam adequadas para estimar a TST (Figuras 6C e 6D). Valores médios máximos de TST no verão foram maiores que os valores máximos de TST no outono e inverno e menor que a média máxima da TST na primavera. No verão, ocorreram altos valores de TST ao sul e focos de calor urbano na região central, principalmente em regiões comerciais. Considerando a diferença entre a temperatura urbana e a temperatura média em área com vegetação natural, a superfície da ICU foi de 228,6 km², que corresponde a 76,2% da região urbana de Brasília.

O outono caracterizou-se por apresentar baixos valores de TST e baixa variação em relação às outras estações (Figuras 6E e 6F). A baixa ocorrência de nuvens no inverno possibilitou a obtenção de 14 imagens livres de nuvens, número superior ao obtido nas demais estações climáticas. As ICU no outono apresentaram área média de 70,1% (210,10 km²) da área de estudo. Entretanto, a abrangência da ICU pode variar substancialmente entre os anos como ocorreu em 2000 que foi de -9,5 °C, chegando a -12,5 °C em 2016 e a -11,4 °C em 2019.

O inverno apresentou temperatura de superfície variando de 18,8 °C a 34,0 °C e desvio padrão máximo de -7,7 °C, principalmente na região sul do PNB, noroeste do Plano Piloto e no Lago Norte (Figuras 6G e 6H). Essa estação apresentou a menor área com ICU, aproximadamente 206,30 km² (68,80% da área de estudo).

3.3 Ilha de Calor Urbano de Superfície (ICUS) e variáveis biofísicas

Os dados da série temporal permitiram observar que a TST apresentou variabilidade constante e progressivo nos últimos anos durante as quatro estações. O forte aumento pode ser observado na primavera e no verão que apresentaram grande diferença de temperatura entre 2000 e 2019 (Figura 7A). Foi observado que o NDVI variou de 0,39 a 0,51 no mesmo período (Figura 7). O outono e o inverno apresentaram baixos valores de TST e alta variabilidade. Isso foi possível verificar devido ao alto número de imagens livres de nuvens disponível nesta estação.

Os valores biofísicos apresentaram variabilidade similar a TST independente da estação. Altos valores de NDVI foram encontrados no verão e baixos valores na primavera, o que pode estar relacionado aos baixos índices de precipitação na primavera. No inverno e no outono, NDVI teve valores que variaram entre os intervalos do NDVI encontrado no verão e primavera. Por outro lado, o NDBI teve comportamento inverso

ao observado para o NDVI que pode está relacionado a baixa cobertura de vegetação e alta exposição de solo exposto, o que eleva os de NDBI (Figura 7B).

A diferença estimada da temperatura entre a região de floresta nativa e urbana variou entorno -0,2 a -3,2 na primavera de 2017 e 2010, respectivamente, indicando a formação de ICU de superfície (Figuras 7C e 7D). Por outro lado, a ICU apresentaram valores positivos em alguns anos, principalmente no verão e na primavera. Isso pode está relacionado ao longo período sem chuva na primavera. A cobertura vegetal foi reduzida e contribuiu para o aumento da incidência de radiação solar na superfície, resultando em altos valores médios de TST in regiões nativas comparadas a área urbana. Não foram avaliadas as tendências no verão e primavera devido ao baixo número de imagens disponíveis para a estações no período analisado (Tabela 5).

A TST no outono apresentou baixa variação ao longo da série temporal. Do outono de 2000 a 2013, as ICUS variaram entre -1,34 e -0,74, depois que ICUS variaram de -1,08 a -2,04. A TST não teve tendência, mas o NDBI teve significativo decréscimo e o NDVI apresentou tendência de aumento com mudança em 2013 (Tabela 5).

O menor valor médio de TST foi encontrado durante o inverno de 2003, com 21.8 °C. Nesta estação, ICUS variou de -1,0 °C a -1,9 °C entre 2000 e 2009, enquanto que entre 2010 e 2019 a ICUS variou de -1,4 °C a -0,97 °C (Figura 7C,D). O NDVI e o NDBI tiveram tendência de crescimento e decréscimo, respectivamente, no inverno, mas isso

não foi o suficiente para reduzir a TST que apresentou tendência de crescimento após o ponto de mudança em 2011.

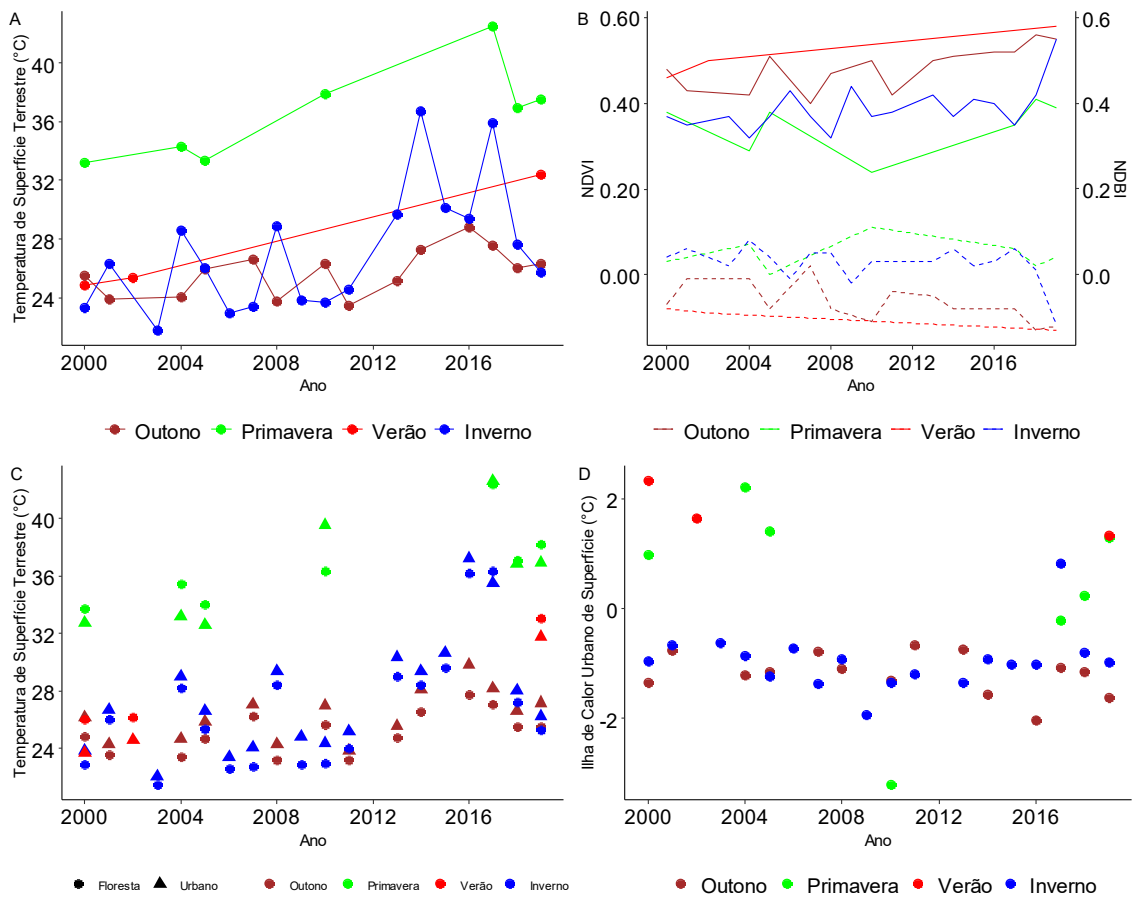


Figura 7. Variação sazonal da (a) temperatura da superfície terrestre (TST) e (b) do índice de vegetação por diferença normalizada (NDVI) e índice de área construída por diferença normalizada NDBI. (c) sazonalidade média da TST em área de floresta e área urbana e (d) formação de ilhas de calor urbana.

Tabela 5. Teste de significância de variáveis ambientais e climáticas pelos testes de Mann-Kendall e Pettitt.

Teste	Primavera			Verão		
	LST	NDVI	NDBI	LST	NDVI	NDBI
Mann-Kendall	1,50	0,60	0	1,04	1,04	1,04
Pettitt	12	10	4	2	2	2
	Outono			Inverno		
Mann-Kendall	LST	NDVI	NDBI	LST	NDVI*	NDBI
Pettitt	1,64	2,85*	-2,19*	2,20*	1,67	-0,19
	37	45*	33	52	36	38

* = variáveis que foram significativas nos testes de Mann-Kendall e Pettitt (valor $p < 0,05$)

3.4 Variação da temperatura da superfície terrestre em função do NDVI em área urbana e de vegetação nativa

Para observar a relação entre TST e NDVI, foram selecionados 100 pontos aleatórios em área com predominância urbana e 100 pontos em área com vegetação nativa. Durante a primavera, o maior valor de temperatura foi de 58,2 °C em área nativa no ano 2010 e o menor valor foi de 24,9 °C em área nativa no ano de 2004. Por meio da Figura 8, observa-se que a primavera de 2017 apresentou os maiores valores de TST quando comparado aos outros anos, tanto em área urbana quanto em área nativa, com valores máximos acima de 50 °C. A variação da temperatura da superfície em ambiente urbano foi explicada por cerca de 29% em 2000, chegando a 42% em 2018. Em área de vegetação nativa, a explicação da TST pelo NDVI variou entre 57% em 2000 e 80% em 2005, demonstrando forte relação entre essas duas variáveis. Entre 2000 e 2010, os locais com ausência de vegetação apresentaram temperatura próxima a 40 °C, enquanto no período de 2017 a 2019, locais nessas condições apresentaram temperatura superior a 40 °C, próximo a 50 °C.

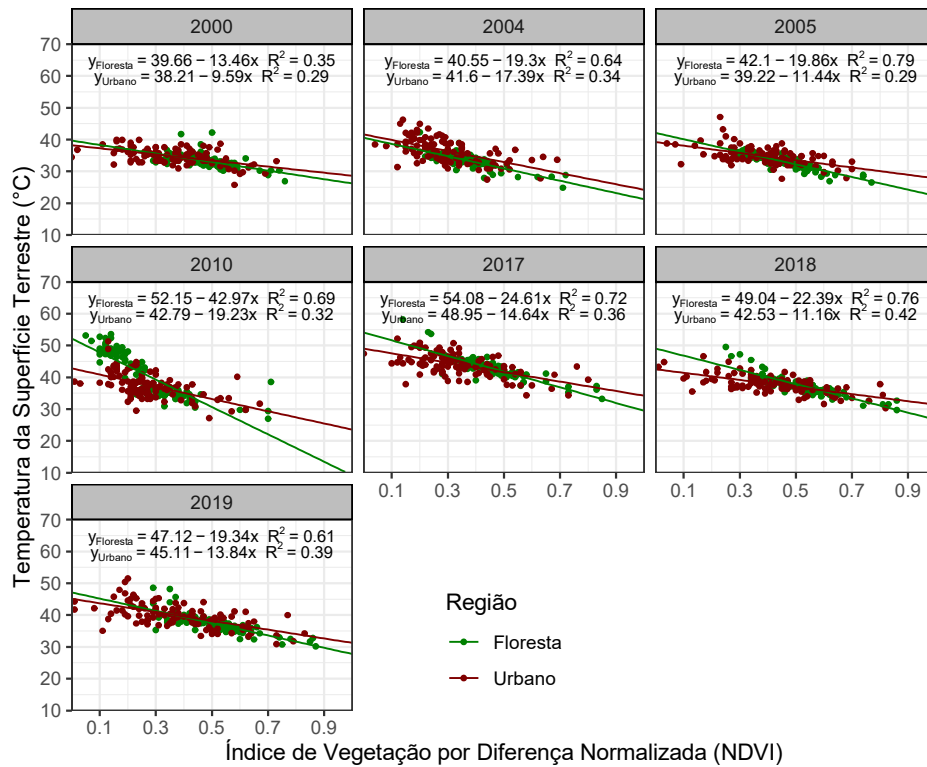


Figura 8. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nas primaveras de 2000 a 2018.

O verão foi caracterizado pela alta frequência de chuvas, o que dificulta o registro da reflectância da superfície terrestre pelo sensor, sendo possível estimar a TST e o NDVI apenas nos anos de 2000, 2002 e 2004. Nos outros anos, o percentual de cobertura de nuvens foi acima de 2%, comprometendo a estimativa da relação entre a TST e o NDVI. Nos anos de 2000 e 2002, os valores de temperatura máxima, tanto em área urbana quanto em área nativa, foram inferiores a 35 °C, enquanto em 2019, a temperatura máxima chegou a 40 °C em área urbana e a 37 °C em área nativa (Figura 9). O coeficiente de determinação entre NDVI e TST ficou em torno de 0,26 em 2000, 0,32 em 2002 e 0,44 em 2019, demonstrando aumento na explicação da variação da temperatura pela presença de vegetação (Figura 9). Em 2000, o R^2 para vegetação nativa foi de 0,51 e, em 2019, foi de 0,73. Em 2002, esse valor diminuiu para 0,40 devido à presença de valores difusos, relacionados com ocorrência de manchas de nuvens no PNB.

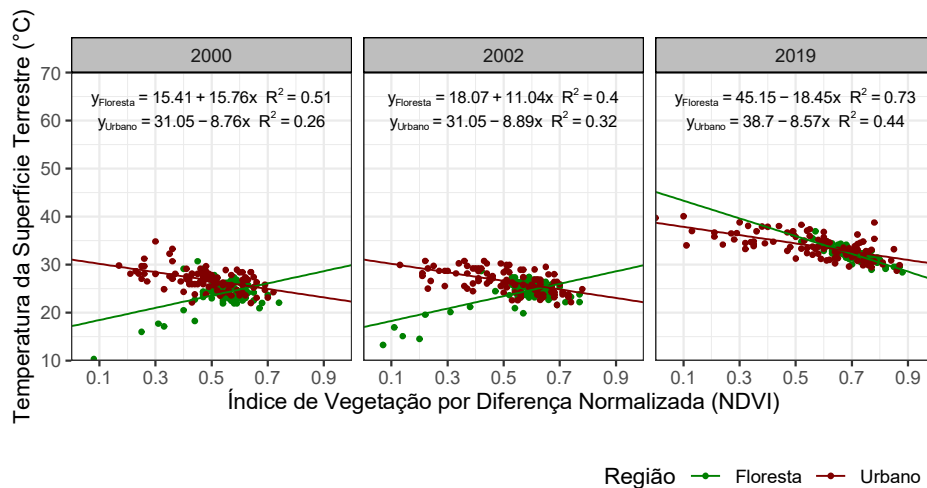


Figura 9. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nos verões de 2000 a 2019.

A NDVI explicou menos de 40% da variação da TST no outono entre 2000 e 2011. Após 2011, o R² da área urbana apresentou valores abaixo de 40%, apresentando alto valor em 2016 com 0,53. A predominância de baixos valores de R² indica que a vegetação urbana pouca explica as variações na TST, decorrente, provavelmente, da baixa porcentagem de cobertura de copas das árvores na região, fazendo com que a TST na área urbana fique próximo a 30 °C entre os anos de 2000 e 2018, chegando a 36 °C no outono de 2016 (Figura 10). Ainda no outono, a vegetação nativa apresentou valores de R² próximos a 0,70, com pouca variação entre os anos, contribuindo para explicar 80% da variação da TST em 2016 e 2018. O menor valor de R² foi em 2004, possivelmente ocasionado pela presença de solo exposto que reduz a correlação entre TST e NDVI (Jamei, Rajagopalan e Sun, 2019) (Figura 10).

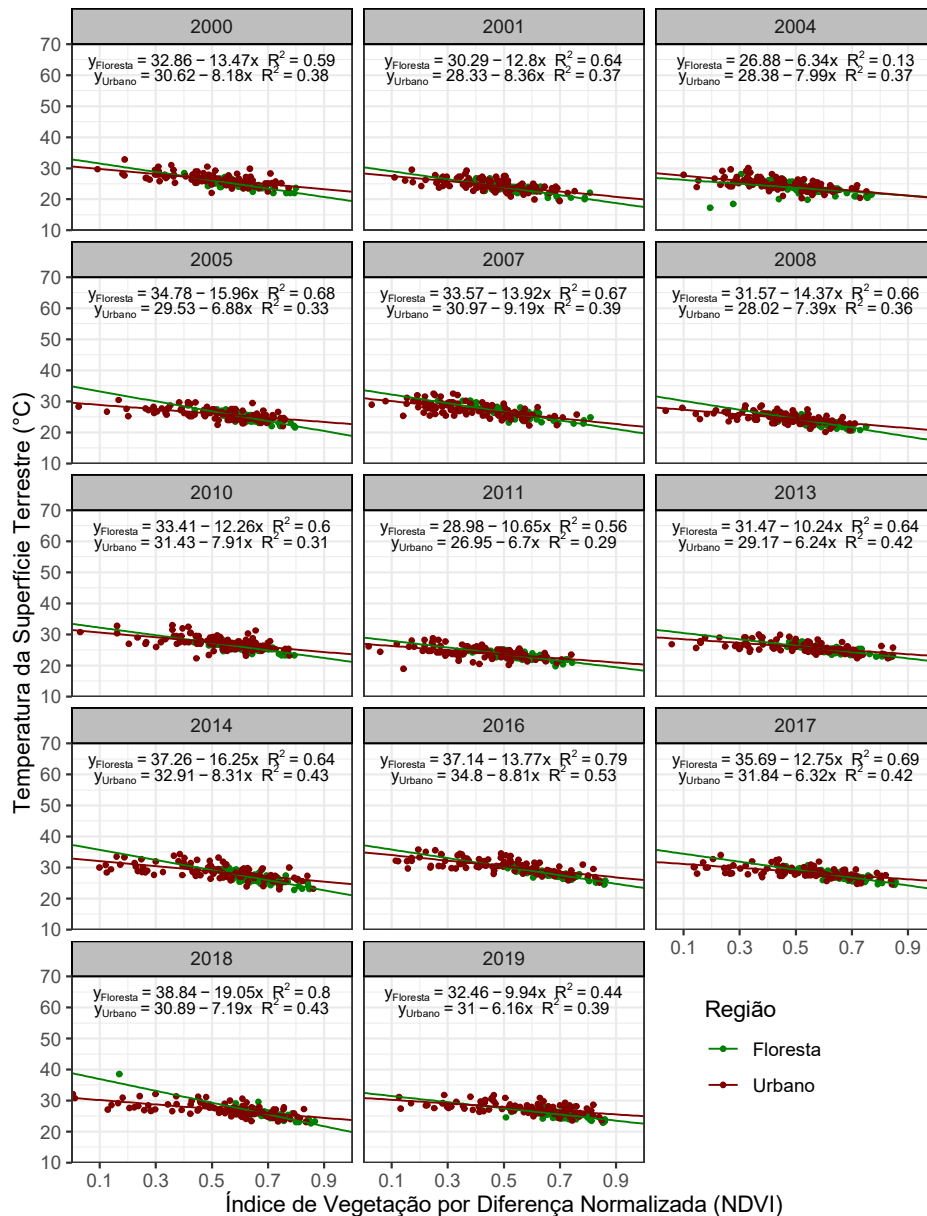


Figura 10. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nos outonos de 2000 a 2019.

A relação entre TST urbana e NDVI apresentou coeficiente de determinação variando entre 0,15 e 0,45 no inverno, demonstrando que a porcentagem de cobertura da copa das árvores, entre os anos de 2000 e 2018, influenciou na mitigação dos efeitos da temperatura da superfície (Figura 11). A vegetação nativa explicou a variação da TST em cerca de 75% para o ano de 2018, porém, em 2009, essa variável explicou apenas 0,30% da variação da temperatura. Essa baixa explicação pode estar relacionada com a

ocorrência de incêndios florestais que reduzem a porcentagem de cobertura de copa de árvores, ocasionando aumento da TST.

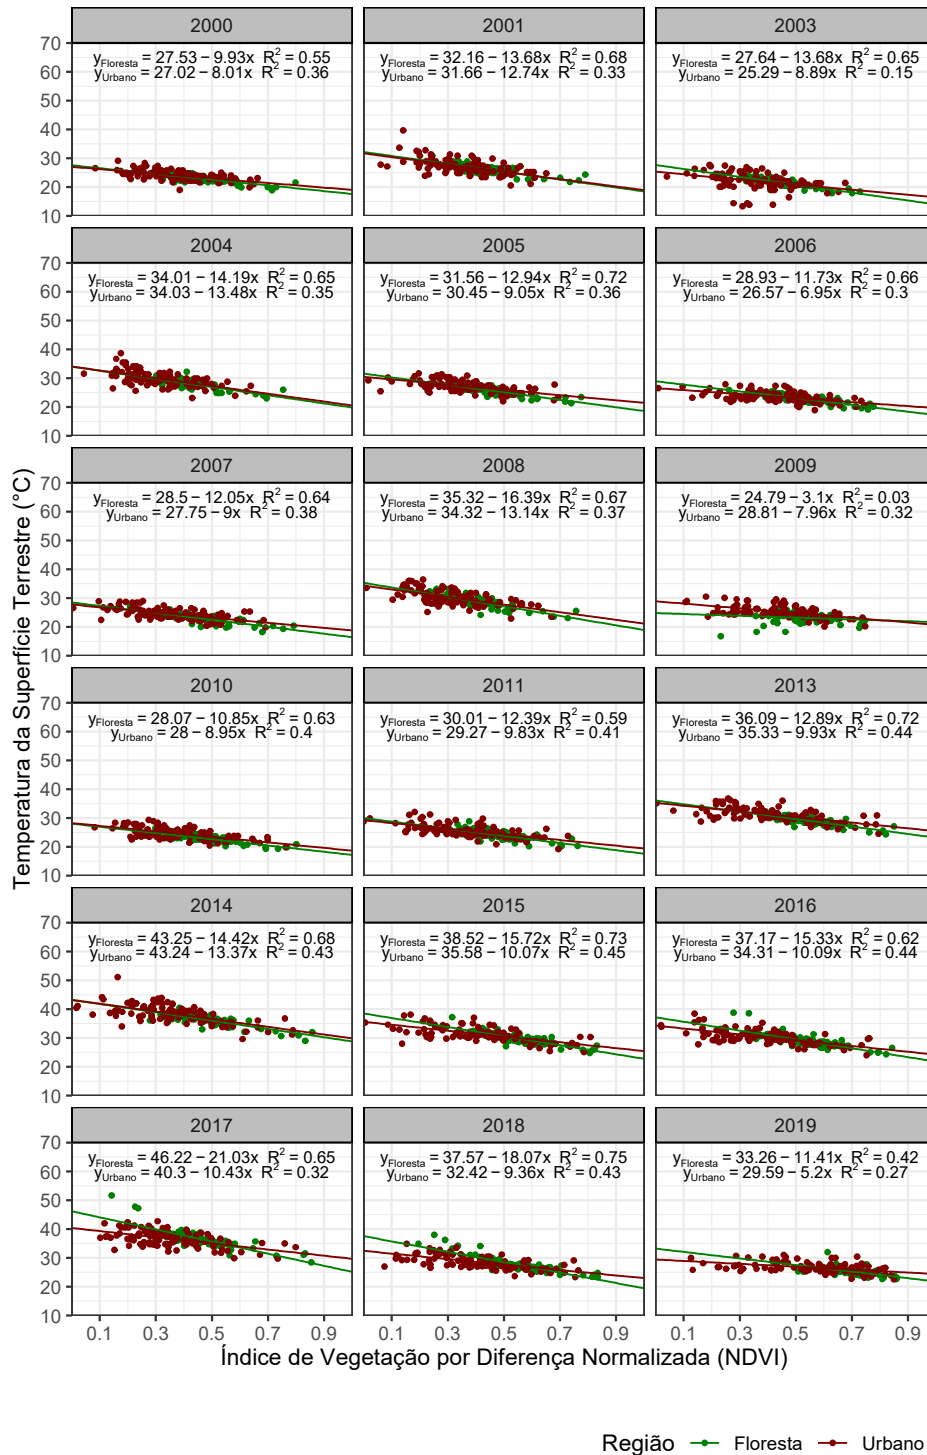


Figura 11. Relação entre as variáveis temperatura da superfície terrestre (TST) e índice de vegetação por diferença normalizada (NDVI) para área urbana (círculo marrom) e área de vegetação nativa (círculo verde) nos invernos de 2000 a 2019.

4. Discussão

4.1 Evolução da temperatura da superfície terrestre (TST)

Entre os anos de 2000 e 2009, houve baixa inclinação da curva média da TST, indicando moderado crescimento da temperatura na área urbana. Entre os anos de 2003 e 2004, houve aumento considerável em relação aos anos anteriores, com destaque para o aumento da TST entre 2004 e 2005, associado a redução do NDVI e elevação do NDBI (Figura 3B). O aumento do NDBI pode estar relacionado com a expansão de áreas antropizadas, com predominância de vias pavimentadas e construções artificiais que absorvem a radiação solar e aumentam a temperatura do ambiente durante o dia. Outro fator que pode ter ocasionado aumento de temperatura nesse período foi a ocorrência de evento climático extremo em 2005, relacionado com anomalia na temperatura do Oceano Atlântico Norte (Phillips *et al.*, 2009). Esse evento resultou em aumento da temperatura do ar e redução da precipitação na região tropical.

Entre os anos de 2009 e 2010, houve um pico de crescimento da TST, chegando a 38 °C em 2010, indicando mudança abrupta nas condições térmicas do ambiente (Figura 3B). A temperatura média do ar possui variação e tendência de crescimento semelhante à TST, porém, com valores médios menores (Ravanelli *et al.*, 2018; Yuan e Bauer, 2007). Após o ano de 2010, a TST teve considerável redução, chegando a apresentar valor médio de 24 °C em 2011. A partir de 2011, a TST apresentou aumento na inclinação da curva até 2019. Os anos de 2010 e 2015 também foram marcados pela ocorrência de fenômenos climáticos ocasionados por anomalias na temperatura dos oceanos, resultando em redução da precipitação na região tropical (Aragão *et al.*, 2018; Phillips *et al.*, 2009), contribuindo para o aumento da temperatura da superfície e redução da capacidade fotossintética da vegetação, como demonstrado pelos baixos valores de NDVI.

A região centro-oeste de Brasília apresentou considerável formação de ilhas de calor urbano, ocasionado pela mudança na cobertura do solo, como observado pelas variações no NDBI e no NDVI, que foram de 0,10 e 0,40, respectivamente. Como consequência, essa região apresentou alta variação de temperatura da superfície, indicado pelo desvio padrão das imagens (Figura 4F). Mudanças na cobertura do solo também foram observadas em alguns locais com baixa densidade de construções, como as regiões Nordeste e Sudeste de Brasília, conforme observado pela variação no índice de vegetação e pelo aumento da TST. A expansão da fronteira urbana está associada ao aumento no número de construções e à pavimentação de vias e conseqüente redução da cobertura

vegetal, criando condições para o aumento da temperatura e maior amplitude térmica do ambiente (Deng *et al.*, 2018; Jamei, Rajagopalan e Sun, 2019; Yusuf, Pradhan e Idrees, 2014). Segundo Wang *et al.* (2019), novas áreas urbanas tendem a apresentar maior temperatura de superfície em relação à antigas áreas urbanas, principalmente pelo fato de que áreas urbanas antigas tem incentivado projetos para expansão de áreas verdes, como praças e parques arborizados, além da arborização das vias públicas.

Por outro lado, a vegetação urbana, principalmente de porte arbórea, situada no entorno das quadras, mostrou-se pouco variável nos últimos 20 anos, sendo semelhante às variações do NDVI no PNB (Figuras 4A e 4E). Isso demonstra que a presença de árvores situadas em parques e no entorno de vias e construções contribui para redução da temperatura da superfície (Figuras 4H e 4I), principalmente pela projeção de sombra sobre a superfície, evitando a incidência direta de raios solares sobre o solo (Costa e Lima e Silva Júnior, 2019). Esse efeito foi observado e descrito com maior detalhe pelo perfil de variação da temperatura em relação ao NDVI.

Os pixels com os maiores valores de NDVI representam locais com alta concentração de árvores por unidade de área da imagem e apresentam relação inversa com a temperatura, principalmente na região central de Brasília (Figura 5). Os perfis 5A e 5C apresentaram valores de NDVI variando entre 0,2 e 0,4, no entanto, a variação de TST esteve acima do observado para o perfil 5B. Um dos fatores que explica essa diferença é o padrão de distribuição das árvores e dos fragmentos de vegetação arbórea na cidade. Feições de vegetação de maior porte têm alta capacidade de resfriamento local e no entorno, principalmente quando está próximo a outros fragmentos de tamanho menor (Kong *et al.*, 2014). Além do conforto térmico no interior de construções residenciais e comerciais, o sombreamento e a evapotranspiração das árvores também contribui para redução no consumo de energia elétrica por aparelhos refrigeradores (Nowak e Dwyer, 2007).

O padrão de distribuição das árvores é uma das variáveis que deve ser considerado no planejamento da arborização urbana de forma a proporcionar condições favoráveis ao desenvolvimento de atividades pela população cidadina (Deng *et al.*, 2018; Ferreira e Duarte, 2019; Zhang *et al.*, 2013). Em algumas regiões destacadas na Figura 5, observa-se que mesmo com o aumento do NDVI não houve redução da TST. Segundo Greene e Millward (2017), a presença de árvores de forma dispersa no espaço urbano não reduz efetivamente a temperatura da superfície, principalmente quando as árvores estão próximas a prédios e asfaltos que absorvem e armazenam radiação de ondas curtas e

liberam lentamente na forma de radiação de onda longa (térmica). Essas condições são favoráveis ao aumento da deficiência de pressão de vapor entre as folhas e o ar, levando ao fechamento do estômatos e reduzindo a transpiração e a umidade do ambiente (Elmes *et al.*, 2020; Hulley *et al.*, 2019; Wang *et al.*, 2020; Weng e Yang, 2004).

4.2 Ocorrência sazonal das ilhas de calor urbano

Alguns estudos têm demonstrado a importância em avaliar a variação da temperatura da superfície e a formação de ICU em diferentes estações climáticas (Schwarz, Lautenbach e Seppelt, 2011; Song *et al.*, 2014). Isso se deve ao fato de que a temperatura da superfície é influenciada por fatores climáticos como temperatura do ar e velocidade e direção do vento. A primavera foi a estação com maiores valores de temperatura média e desvio padrão nos últimos 20 anos. A região urbana, com predominância de áreas impermeáveis, apresentou os maiores valores de TST, quando comparado ao PNB que teve valores próximos a 36 °C, enquanto a região oeste urbana apresentou locais com 46 °C, amplitude de 10 °C entre duas regiões com distância aproximada de 20 km (Figura 7).

Ao longo da série temporal, foi observado elevação nos valores de TST, tanto em área nativa quanto em áreas urbanas nessa estação. A partir de 2010, áreas sem vegetação começaram a apresentar temperatura acima de 40 °C, diferente do observado nos anos anteriores que era próxima de 40 °C (Figura 8). Entre os anos de 2017 e 2019, alguns locais tiveram incremento no NDVI, passando de 0,70 entre 2000 e 2010 para aproximadamente 0,85 entre 2017 e 2019. Porém, o aumento nos valores de NDVI não reduziu a temperatura nesses locais, quando comparado aos anos anteriores.

A vegetação urbana contribuiu para o resfriamento do ambiente, no entanto, o padrão de distribuição espacial das árvores na paisagem, em relação às áreas impermeáveis, tem forte influência sobre a variação da temperatura (Estoque, Murayama e Myint, 2017; Zhou, Wang e Cadenasso, 2017). Além do NDVI, outras variáveis como porcentagem de cobertura de copa de árvore, umidade relativa do ar e velocidade do vento têm relação inversa com a temperatura da superfície e precisam ser consideradas como responsáveis pelo resfriamento do ambiente (Kong *et al.*, 2014; Wang *et al.*, 2020). A exemplo disso, as áreas urbanas a nordeste e sudeste de Brasília que, mesmo apresentando cobertura vegetal densa nas quadras, como mostrado pelos altos valores de NDVI (Figura

4), ainda apresentaram temperaturas de superfície superiores às da região centro-sul (Figura 7A).

O verão em Brasília apresentou valores de TST menores que na primavera, o que pode estar relacionado com a maior ocorrência de chuvas que contribuem para reduzir a temperatura das superfícies, além de aumentar a capacidade da vegetação em absorver energia solar durante a fotossíntese (Li *et al.*, 2020). Além disso, a eficiência de resfriamento da vegetação, medida pela relação entre a temperatura da superfície e a porcentagem de vegetação urbana, pode ser maior no verão, pois a eficiência de resfriamento da vegetação urbana é mais sensível à variação da umidade relativa do ar em biomas mais secos como o Cerrado (Wang *et al.*, 2020). Como no verão os valores de umidade relativa são mais altos em relação às demais estações, isso contribui para que as árvores controlem o microclima por meio de mecanismos ecofisiológicos como a abertura dos estômatos e liberação de umidade.

O aumento nos valores de NDVI no verão não foi suficiente para amenizar a temperatura da superfície, que variou de 35 °C em 2000 para 40 °C em 2019, ocasionando a formação de ilhas de calor e desconforto térmico para população local, implicando no aumento do desconforto térmico percebido pelos habitantes. Outros fatores podem estar relacionados com o aumento da temperatura da superfície, como a obstrução da passagem de ar pelos prédios, o que dificulta a troca de calor entre os ambientes.

As mudanças no uso e cobertura do solo das regiões vizinhas também contribuem para o constante aumento da temperatura nos centros urbanos, devido à falta de cobertura florestal que funciona como condicionante térmico por aumentar a evapotranspiração e resfriamento da atmosfera, favorecendo a formação de microclimas favoráveis ao bem estar da população (Santos, dos *et al.*, 2017). Hu *et al.* (2017) destacaram também que, a partir de determinado grau de expansão das cidades, a proporção de áreas verdes pode já não ter efeito significativo sobre a redução da TST. Assim, são necessários estudos para discriminação quali-quantitativa da vegetação urbana e seus efeitos sobre a temperatura e determinar um ponto de inflexão no processo de desenvolvimento da cidade onde é possível reduzir a temperatura do ambiente por meio do manejo de áreas verdes.

O outono e o inverno foram as estações que apresentaram os menores valores de TST ao longo da série temporal. O outono e o inverno apresentaram as menores amplitudes térmicas médias, próximo a 15 °C, enquanto na primavera essa amplitude chegou a 24 °C. As temperaturas máximas no inverno, observadas em regiões com baixa cobertura vegetal, variaram entre 26,50 °C e 34,50 °C, entre os anos 2000 e 2011,

passando a variar acima de 35 °C a partir de 2013. O outono também apresentou elevação na temperatura dos pixels com menor cobertura vegetal a partir de 2014, assim como os locais com maior cobertura vegetal apresentaram elevação de temperatura entorno de 2 °C a partir de 2009. O inverno é considerado o período mais seco do ano, favorecendo a redução do número de folhas nas árvores e, conseqüentemente, diminuição da atividade fotossintética, como demonstrado pelos baixos valores de NDVI (Figura 8B). Aliado a isso, a expansão da fronteira urbana contribui para reduzir áreas agrícolas e com vegetação nativa, favorecendo a formação de ICUS com altas temperaturas, como em 2009 (Figura 8D).

5. Conclusões

A partir da metodologia aplicada, foi possível identificar forte relação entre TST, NDVI e NDBI. O NDVI e o NDBI apresentaram relação inversa e direta com a temperatura da superfície, respectivamente, nos domínios temporal e espacial.

A temperatura da superfície apresentou tendência de aumento nos últimos 20 anos, indicando a necessidade de adoção de medidas de planejamento a longo prazo com vistas a reduzir a formação de ICUS que interferem diretamente nas atividades cotidianas da cidade. Por meio do processamento de imagens, foi possível observar que a redução do NDVI contribuiu para formação de ICUS, sendo necessária a aplicação de metodologias que conciliem o desenvolvimento das cidades com o manejo de fragmentos de florestas nativas e urbanas.

Alguns estudos sugerem que a temperatura de superfície e a vegetação urbana podem apresentar sazonalidade. Nesse estudo, foi observado que a primavera e o verão apresentam as maiores temperaturas e o outono e inverno apresentam as menores temperaturas. As maiores temperaturas de superfície e as maiores formações de ICU foram registradas na primavera, principalmente em áreas sem vegetação. Além disso, as variações do NDVI entre as estações nos últimos anos demonstraram que os aumentos não indicam redução da temperatura, sugerindo que outras variáveis também influenciam na sua magnitude.

Dessa forma, a identificação espaço-temporal de ICUs é fundamental para auxiliar os gestores na adoção de estratégias que visem o desenvolvimento sustentável das cidades. Dentre essas estratégias, está o planejamento e manutenção dos espaços verdes

urbanos que contribuem para evitar problemas de saúde pública que estão, de alguma forma, relacionados ao aumento da temperatura da superfície nos centros urbanos.

6. Referências bibliográficas

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; MORAES GONÇALVES, J. L. DE; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.

ARAGÃO, L. E. O. C. et al. 21st Century drought-related fires counteract the decline of Amazon deforestation carbon emissions. **Nature Communications**, v. 9, n. 1, p. 1–12, 2018.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+, and EO-1 ALI sensors. **Remote Sensing of Environment**, v. 113, n. 5, p. 893–903, 2009.

CODEPLAN. Distrito Federal em síntese: informações socioeconômicas e geográficas. Brasília - DF: [s.n.].

DENG, Y.; WANG, S.; BAI, X.; TIAN, Y.; WU, L.; XIAO, J.; CHEN, F.; QIAN, Q. Relationship among land surface temperature and LUCC, NDVI in typical karst area. **Scientific Reports**, v. 8, n. 1, p. 1–12, 2018.

DU, J.; SONG, K.; YAN, B. Impact of the Zhalong Wetland on Neighboring Land Surface Temperature Based on Remote Sensing and GIS. **Chinese Geographical Science**, v. 29, n. 5, p. 798–808, 2019.

ELMES, A.; HEALY, M.; GERON, N.; ANDREWS, M. M.; ROGAN, J.; MARTIN, D. G.; SANGERMANO, F.; WILLIAMS, C. A.; WEIL, B. Mapping spatiotemporal variability of the urban heat island across an urban gradient in Worcester, Massachusetts using in-situ Thermochrons and Landsat-8 Thermal Infrared Sensor (TIRS) data. **GIScience and Remote Sensing**, v. 57, n. 7, p. 845–864, 2020.

ELMES, A.; ROGAN, J.; WILLIAMS, C.; RATICK, S.; NOWAK, D.; MARTIN, D. Effects of urban tree canopy loss on land surface temperature magnitude and timing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, p. 338–353, jun. 2017.

ESTOQUE, R. C.; MURAYAMA, Y.; MYINT, S. W. Effects of landscape composition and pattern on land surface temperature: An urban heat island study in the megacities of Southeast Asia. **Science of the Total Environment**, v. 577, p. 349–359, 2017.

FERREIRA, L. S.; DUARTE, D. H. S. Exploring the relationship between urban form, land surface temperature and vegetation indices in a subtropical megacity. **Urban Climate**, v. 27, n. November 2018, p. 105–123, 2019.

- GAGE, E. A.; COOPER, D. J. Urban forest structure and land cover composition effects on land surface temperature in a semi-arid suburban area. **Urban Forestry and Urban Greening**, v. 28, n. September, p. 28–35, 2017.
- GREENE, C. S.; MILLWARD, A. A. Getting closure: The role of urban forest canopy density in moderating summer surface temperatures in a large city. **Urban Ecosystems**, v. 20, n. 1, p. 141–156, 2017.
- HU, X.; ZHOU, W.; QIAN, Y.; YU, W. Urban expansion and local land-cover change both significantly contribute to urban warming, but their relative importance changes over time. **Landscape Ecology**, v. 32, n. 4, p. 763–780, 2017.
- HULLEY, G. C.; GHENT, D.; GÖTTSCHE, F. M.; GUILLEVIC, P. C.; MILDREXLER, D. J.; COLL, C. Land Surface Temperature. In: **Taking the Temperature of the Earth**. [s.l.] Elsevier, 2019. p. 57–127.
- INMET, I. N. D. M. D. B. –. **Normais Climatológicas 1981-2010, 2021**. Disponível em: <<https://portal.inmet.gov.br/normais>>
- JAMEI, Y.; RAJAGOPALAN, P.; SUN, Q. (CHAYN). Spatial structure of surface urban heat island and its relationship with vegetation and built-up areas in Melbourne, Australia. **Science of the Total Environment**, v. 659, p. 1335–1351, 2019.
- KARDAN, O.; GOZDYRA, P.; MISIC, B.; MOOLA, F.; PALMER, L. J.; PAUS, T.; BERMAN, M. G. Neighborhood greenspace and health in a large urban center. **Scientific Reports**, v. 5, p. 1–14, 2015.
- KONG, F.; YIN, H.; JAMES, P.; HUTYRA, L. R.; HE, H. S. Effects of spatial pattern of greenspace on urban cooling in a large metropolitan area of eastern China. **Landscape and Urban Planning**, v. 128, p. 35–47, 2014.
- KUMARI, B.; TAYYAB, M.; SHAHFAHAD; SALMAN; MALLICK, J.; KHAN, M. F.; RAHMAN, A. Satellite-Driven Land Surface Temperature (LST) Using Landsat 5, 7 (TM/ETM+ SLC) and Landsat 8 (OLI/TIRS) Data and Its Association with Built-Up and Green Cover Over Urban Delhi, India. **Remote Sensing in Earth Systems Sciences**, v. 1, n. 3–4, p. 63–78, 2018.
- LAZZARINI, M.; MARPU, P. R.; GHEDIRA, H. Temperature-land cover interactions: The inversion of urban heat island phenomenon in desert city areas. **Remote Sensing of Environment**, v. 130, p. 136–152, 2013.
- LI, WEIFENG; HAN, C.; LI, WENJUN; ZHOU, W.; HAN, L. Multi-scale effects of urban agglomeration on thermal environment: A case of the Yangtze River Delta Megaregion, China. **Science of the Total Environment**, v. 713, p. 136556, 2020.
- LIU, L.; ZHANG, Y. Urban heat island analysis using the landsat TM data and ASTER Data: A case study in Hong Kong. **Remote Sensing**, v. 3, n. 7, p. 1535–1552, 2011.
- MARIA COSTA E LIMA, R.; CLÁUDIO SILVA JÚNIOR, M. Inventário da arborização urbana implantada na década de 60 no plano piloto, Brasília, DF. **Revista da Sociedade Brasileira de Arborização Urbana**, v. 5, n. 4, p. 110, 2019.

- MI, H.; QIAO, G.; WANG, W.; HONG, Y. Analysis of urban growth from 1960 to 2015 using historical DISP and Landsat time series data in Shanghai. **Arabian Journal of Geosciences**, v. 12, n. 7, p. 250, 2019.
- MUTANGA, O.; KUMAR, L. Google earth engine applications. **Remote Sensing**, v. 11, n. 5, p. 11–14, 2019.
- NOWAK, D. J.; DWYER, J. F. Understanding the Benefits and Costs of Urban Forest Ecosystems. In: KUSER, J. E. (Ed.). **Urban and Community Forestry in the Northeast**. 2. ed. Dordrecht: Springer Netherlands, 2007. p. 25–46.
- PHILLIPS, O. L. et al. Drought Sensitivity of the Amazon Rainforest. **Science**, v. 323, n. 5919, p. 1344–1347, 6 mar. 2009.
- POHLERT, T. **trend: Non-Parametric Trend Tests and Change-Point DetectionR package version 1.1.4**, 2020. Disponível em: <<https://cran.r-project.org/package=trend>>
- QIN, Z.; KARNIELI, A.; BERLINER, P. A mono-window algorithm for retrieving land surface temperature from Landsat TM. **International journal of remote sensing**, v. 22, n. 18, p. 3719–3746, 2001.
- RAVANELLI, R.; NASCETTI, A.; CIRIGLIANO, R. V.; RICO, C. DI; LEUZZI, G.; MONTI, P.; CRESPI, M. Monitoring the impact of land cover change on surface urban heat island through Google Earth Engine: Proposal of a global methodology, first applications and problems. **Remote Sensing**, v. 10, n. 9, p. 1–21, 2018.
- SANTOS, A. R. DOS et al. Spatial and temporal distribution of urban heat islands. **Science of the Total Environment**, v. 605–606, n. October, p. 946–956, 2017.
- SCHWARZ, N.; LAUTENBACH, S.; SEPPELT, R. Exploring indicators for quantifying surface urban heat islands of European cities with MODIS land surface temperatures. **Remote Sensing of Environment**, v. 115, n. 12, p. 3175–3186, 2011.
- SEKERTEKIN, A.; KUTOGLU, S. H.; KAYA, S. Evaluation of spatio-temporal variability in Land Surface Temperature: A case study of Zonguldak, Turkey. **Environmental Monitoring and Assessment**, v. 188, n. 1, p. 1–15, 2016.
- SFB, S. F. B. **Inventário Florestal Nacional: principais resultados Distrito Federal**. Distrito Federal: Biblioteca do Ministério do Meio Ambiente, 2016, 66p.
- SOBRINO, J. A.; COLL, C.; CASELLES, V. Atmospheric correction for land surface temperature using NOAA-11 AVHRR channels 4 and 5. **Remote Sensing of Environment**, v. 38, n. 1, p. 19–34, 1991.
- SOBRINO, J. A.; JIMÉNEZ-MUÑOZ, J. C.; PAOLINI, L. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**, v. 90, n. 4, p. 434–440, 2004.
- SOBRINO, J. A.; RAISSOUNI, N. Toward remote sensing methods for land cover dynamic monitoring: Application to Morocco. **International Journal of Remote Sensing**, v. 21, n. 2, p. 353–366, 2000.

SOBRINO, J.; JIMENEZ, J.; SORIA, G.; GUANTER, L.; MORENO, J.; PLAZA, A.; MARTINEZ, P. Land surface emissivity retrieval from different VNIR and TIR sensors. **IEEE Transactions on Geoscience and Remote Sensing**, v. 2, n. 46, p. 316–327, 2008.

SONG, J.; DU, S.; FENG, X.; GUO, L. The relationships between landscape compositions and land surface temperature: Quantifying their resolution sensitivity with spatial regression models. **Landscape and Urban Planning**, v. 123, p. 145–157, 2014.

TEAM, R. C. **R: A language and environment for statistical computing**. R Foundation for Statistical Computing Vienna - Austria, 2019. Disponível em: <<https://www.r-project.org/>>

UNITED NATIONS. **World Urbanization Prospects: The 2018 Revision**. Disponível em: <<https://population.un.org/wup/publications/Files/WUP2018-KeyFacts.pdf>>.

VENTER, Z. S.; KROG, N. H.; BARTON, D. N. Linking green infrastructure to urban heat and human health risk mitigation in Oslo, Norway. **Science of the Total Environment**, v. 709, p. 136193, 2020.

WANG, F.; QIN, Z.; SONG, C.; TU, L.; KARNIELI, A.; ZHAO, S. An improved mono-window algorithm for land surface temperature retrieval from Landsat 8 thermal infrared sensor data. **Remote Sensing**, v. 7, n. 4, p. 4268–4289, 2015.

WANG, J.; ZHOU, W.; JIAO, M.; ZHENG, Z.; REN, T.; ZHANG, Q. Significant effects of ecological context on urban trees' cooling efficiency. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, n. 18, p. 78–89, 2020.

WANG, JIA; ZHOU, W.; WANG, JING. Time-series analysis reveals intensified urban heat island effects but without significant urban warming. **Remote Sensing**, v. 11, n. 19, 2019.

WENG, Q.; LU, D.; SCHUBRING, J. Estimation of land surface temperature–vegetation abundance relationship for urban heat island studies. **Remote Sensing of Environment**, v. 89, n. 4, p. 467–483, 2004.

WENG, Q.; YANG, S. Managing the adverse thermal effects of urban development in a densely populated Chinese city. **Journal of Environmental Management**, v. 70, n. 2, p. 145–156, 2004.

YANG, L.; CAO, Y. G.; ZHU, X. H.; ZENG, S. H.; YANG, G. J.; HE, J. Y.; YANG, X. C. Land surface temperature retrieval for arid regions based on Landsat-8 TIRS data: A case study in Shihezi, Northwest China. **Journal of Arid Land**, v. 6, n. 6, p. 704–716, 2014.

YU, X.; GUO, X.; WU, Z. Land surface temperature retrieval from landsat 8 TIRS-comparison between radiative transfer equation-based method, split window algorithm and single channel method. **Remote Sensing**, v. 6, n. 10, p. 9829–9852, 2014.

YUAN, F.; BAUER, M. E. Comparison of impervious surface area and normalized difference vegetation index as indicators of surface urban heat island effects in Landsat imagery. **Remote Sensing of Environment**, v. 106, n. 3, p. 375–386, 2007.

YUSUF, Y. A.; PRADHAN, B.; IDREES, M. O. Spatio-temporal Assessment of Urban Heat Island Effects in Kuala Lumpur Metropolitan City Using Landsat Images. **Journal of the Indian Society of Remote Sensing**, v. 42, n. 4, p. 829–837, 2014.

ZHANG, H.; QI, Z. FANG; YE, X. YUE; CAI, Y. BIN; MA, W. CHUN; CHEN, M. NAN. Analysis of land use/land cover change, population shift, and their effects on spatiotemporal patterns of urban heat islands in metropolitan Shanghai, China. **Applied Geography**, v. 44, p. 121–133, 2013.

ZHOU, J.; ZHAN, W.; HU, D.; ZHAO, X. Improvement of mono-window algorithm for retrieving land surface temperature from HJ-1B satellite data. **Chinese Geographical Science**, v. 20, n. 2, p. 123–131, 2010.

ZHOU, W.; WANG, J.; CADENASSO, M. L. Effects of the spatial configuration of trees on urban heat mitigation: A comparative study. **Remote Sensing of Environment**, v. 195, p. 1–12, 2017.

ZULLO, F.; FAZIO, G.; ROMANO, B.; MARUCCI, A.; FIORINI, L. Effects of urban growth spatial pattern (UGSP) on the land surface temperature (LST): A study in the Po Valley (Italy). **Science of the Total Environment**, v. 650, p. 1740–1751, 2019.

CAPÍTULO II

Métricas da vegetação urbana e sua influência sobre a formação de ilhas de calor urbano: uma contribuição para o planejamento urbano

Resumo

A cobertura vegetal contribui para redução da temperatura da superfície nas cidades, por meio do sombreamento da superfície e pela evapotranspiração da vegetação. Esta contribuição pode variar devido à composição e configuração da vegetação urbana, sendo importante avaliar a relação dessas variáveis com a temperatura da superfície terrestre (TST). O objetivo deste estudo foi avaliar a relação e contribuição da composição e configuração da vegetação urbana sobre a TST. A vegetação foi classificada em rasteira e arbórea por meio de imagens e obtidas as métricas de configuração e composição. A TST sazonal foi modelada em função da configuração e composição da vegetação em unidades de análise com tamanhos variando de 120 x 120 m a 960 x 960 m. O percentual de cobertura de árvore (PCArv) e rasteira (PCRast) apresentou correlação inversa (-0,44 a -0,70) e direta (0,09 a 0,49), respectivamente. A densidade de borda (DB), área média do fragmento (Area) e o índice de maior fragmento (IMF) da vegetação arbórea apresentou efeito negativo sobre a TST. O IMF da vegetação rasteira contribuiu para o aumento da temperatura. A TST no verão e outono apresentou índices de Moran (I) acima de 0,70. O PCArv teve maior contribuição no ajuste dos modelos para explicação da TST sazonal, assim como a DB e o IMF. A vegetação arbórea apresentou efeito positivo sobre o resfriamento do ambiente, enquanto a vegetação rasteira contribuiu para aumentar a temperatura. Modelos de regressão que consideram a correlação espacial são mais indicados estimar a temperatura em função da PCArv, IMF e DB em unidades de análise de 120 a 480 m de dimensão.

Palavras-chave: temperatura de superfície terrestre; árvores; gramíneas; composição; configuração.

The influence of urban vegetation metrics in urban heat island: a contribution to urban planning

Abstract

The vegetation cover contributes to reduce the surface temperature in cities by shading surface and by evapotranspiration. This contribution may vary according to the composition and configuration of urban vegetation so that it is important to assess the relationship between these variables and land surface temperature (LST). The aim of this study was to assess the relation and contribution of the composition and configuration of the urban vegetation on LST. The urban vegetation was classified in shrub and trees using images. The tree and shrub classes were used to generate configuration and composition metrics. The seasonal LST was modeled in function of composition and configuration of the vegetation in units of analysis with size from 120 x 120 m to 960 x 960 m. The percent tree cover (PCArv) and shrub (PCRast) had negative (-0.44 to -0.70) and positive (0.09 to 0.49) correlations, respectively. The edge density (DB), mean patch area (Area) and largest patch index (IMF) of tree showed negative effects on the LST. The IMF from shrubs had positive effects on the LST. The LST from summer and autumn had Moran Index (I) above 0.70. The PCArv had highest contribution in the fit models to explain seasonal LST, as well as DB and IMF. The tree cover showed positive effects on the environment cooling, while the scrub contributed to the increase temperature. Regression models with spatial correlation are more indicated to estimate temperature as a function of PCArv, IMF and DB in units of analysis of 120 to 480 m.

Keywords: land surface temperature; trees; scrub; composition; configuration.

1.Introdução

A expansão de cidades tem aumentado a proporção de áreas impermeáveis e reduzido as superfícies cobertas por vegetação natural. Isso dificulta a infiltração de água no solo e altera o balanço de energia, impulsionando aumento na temperatura do ar das cidades em relação às áreas com vegetação nativa e com agricultura (Oke, 1982). Esse fenômeno é conhecido como ilha de calor urbano (ICU), quando a medição é realizada com base na temperatura do ar, e ilha de calor urbano de superfície (ICUS), quando se considera a temperatura da superfície terrestre (TST). Devido ao baixo número de estações de monitoramento de temperatura do ar, dados de sensores termais a bordo de satélites têm sido utilizados, pois, possibilita observações sobre TST em áreas urbanas de forma consistente e com repetitividade ao longo do tempo (Chen, L. *et al.*, 2021; Wu, Li e Li, 2021).

As ICU impactam negativamente o consumo de água e energia (Gage e Cooper, 2017^a), a ocorrência de espécies da fauna e flora, o desconforto térmico (Edmondson *et al.*, 2016; Estoque, Murayama e Myint, 2017; Huang, Zhou e Cadenasso, 2010), além de aumentar o número de enfermidades relacionadas ao fenômeno (Venter, Krog e Barton, 2020).

A expansão urbana sem o planejamento adequado tem acarretado em conversão de floresta, agricultura e corpos de água, em superfícies urbanas impermeáveis, potencializando a formação de ICUs (Alexander, 2020). Os efeitos das ICUs são ainda mais acentuados em ambientes de clima árido que têm apresentado elevação da temperatura do ar e redução da umidade relativa devido às mudanças climáticas (Maimaitiyiming *et al.*, 2014).

O plantio e o manejo de árvores no espaço urbano auxilia na redução da temperatura do ar e da superfície do solo, devido ao aumento na evapotranspiração e redução da emissividade em relação às temperaturas de áreas urbanizadas com menor cobertura vegetal, propiciando o resfriamento do ambiente e melhorando o conforto térmico (Hu *et al.*, 2017; Hu, Dai e Guldman, 2021; Nyelele, Kroll e Nowak, 2019; Wang *et al.*, 2020). A projeção da copa das árvores urbanas promove o sombreamento, evitando a incidência direta de radiação solar e conseqüente aquecimento da superfície (Zhou, Huang e Cadenasso, 2011).

Cada espaço de floresta urbana é importante na prestação de serviços ecossistêmicos, principalmente no resfriamento do ambiente. Assim, é necessário

considerar a composição e configuração no planejamento das áreas verdes urbanas (Chen *et al.*, 2014; Du *et al.*, 2016; Li, Zhou e Ouyang, 2013; Maimaitiyiming *et al.*, 2014). Em geral, muitos estudos consideram os efeitos da quantidade de área verde em relação a TST, e desconsideram a contribuição individual do componente arbóreo sobre resfriamento urbano (Athukorala e Murayama, 2021; Estoque, Murayama e Myint, 2017; Lu *et al.*, 2020; Ranagalage *et al.*, 2020; Srivanit e Iamtrakul, 2019). Outros estudos têm avaliado a relação entre áreas verdes urbanas e TST no verão, por ser esse um período com menor cobertura de nuvens e de temperaturas mais altas. Contudo, tais estudos desconsideram a relação sazonal da temperatura em relação aos diferentes estratos que compõe a floresta urbana (Chen *et al.*, 2014; Dai, Guldmann e Hu, 2019; Li, Zhou e Ouyang, 2013; Wu, Li e Li, 2021; Zhou, Wang e Cadenasso, 2017).

Em estudo recente realizado por Hu *et al.* (2021) foi observado que pequenos fragmentos de árvores apresentaram efeitos significativos sobre a TST, ao passo que áreas gramadas tinham que ser maiores e contínuas para conseguir aumentar o efeito de resfriamento. Por outro lado, Du *et al.* (2016) observaram efeito contrário, ao constatarem que a vegetação de textura fina, composta por gramíneas e herbáceas, apresentou forte efeito de resfriamento quando comparada com a vegetação arbórea e lenhosa. Para permitir a comparação entre os estudos dessa natureza, deve ser considerado alguns fatores importantes na coleta dos dados, como, por exemplo, o período da coleta dos dados, a metodologia utilizada para obter a temperatura, além das classes de uso e cobertura do solo, pois todos esses fatores podem influenciar nas inferências sobre a relação da vegetação com a TST (Estoque, Murayama e Myint, 2017). Vale destacar ainda que, para caracterizar a composição da vegetação urbana é imprescindível o uso de imagens de sensoriamento remoto de alta resolução espacial e espectral que permitam mapear a cobertura da copa das árvores urbanas e gramíneas e relacionar suas características a produção de serviços ecossistêmicos (Du *et al.*, 2016; Elmes *et al.*, 2017; Guo *et al.*, 2020).

A cidade de Brasília, local onde a presente pesquisa foi realizada, é reconhecida por possuir uma das mais belas arborizações urbanas do Brasil. Na região, a vegetação urbana arbórea tem sido modificada ao longo dos anos de forma a maximizar os seus serviços ecossistêmicos. O conforto térmico é um dos serviços ecossistêmicos oferecidos pela vegetação arbórea urbana, porém, deve-se observar que a composição e configuração da vegetação influenciam no resfriamento dos ambientes nas regiões comerciais e residenciais de Brasília. Assim, surgem os seguintes questionamentos: a vegetação

arbórea urbana de Brasília contribui para reduzir a temperatura da superfície? Quais as características da vegetação arbórea que são indicativos de redução da temperatura da superfície terrestre? O padrão de distribuição da vegetação arbórea influencia na temperatura da superfície sazonalmente? A busca por respostas a estas questões auxilia os órgãos responsáveis pela implantação e gestão dos espaços verdes urbanos, com vistas a reduzir os impactos do aumento da temperatura nas cidades, decorrentes de atividades humanas.

2. Material e métodos

2.1 Área de estudo

Esse estudo foi desenvolvido na região urbana de Brasília, capital do Brasil, situada na região Centro-Oeste do Brasil, no Planalto Central. Desde a construção de Brasília, que teve início na segunda metade da década de 1950, a cidade vem passando por transformações na sua divisão política, de forma a facilitar a gestão do seu espaço por meio de regiões administrativas. Atualmente, a cidade é composta pelas regiões administrativas do Lago Norte, Lago Sul, Varjão, Plano Piloto, Cruzeiro e Sudoeste/Octogonal, perfazendo uma área igual a, aproximadamente, 600 km² entre as latitudes 15,5780° S e 15,9137° S e entre as longitudes 48,0897° W e 47,7839° W (Figura 1). O Parque Nacional de Brasília não foi considerado como área de estudo por ser área de conservação com vegetação nativa, onde não ocorreu alteração da vegetação durante o desenvolvimento da cidade de Brasília.

2.2 Temperatura da superfície terrestre (TST)

Imagens do satélite Landsat 8 *Operational Land Imager* (OLI) e Landsat 8 *Thermal Infrared Sensor* (TIRS) foram utilizadas para obtenção da TST. Foram obtidas quatro imagens na órbita/ponto 220/71 em 06 de junho de 2017 (outono), 10 de setembro de 2017 (inverno), 12 de outubro de 2017 (primavera) e 02 de outubro de 2019 (verão). O período chuvoso na região inicia-se no verão e termina no início do outono, enquanto o período seco predomina entre inverno e primavera. Devido à alta ocorrência de chuvas no verão, não foi possível obter imagens com baixa cobertura de nuvens em 2017, sendo utilizada imagem referente ao verão de 2019. As imagens adquiridas nas demais estações apresentaram coberturas de nuvem abaixo de 0,06%.

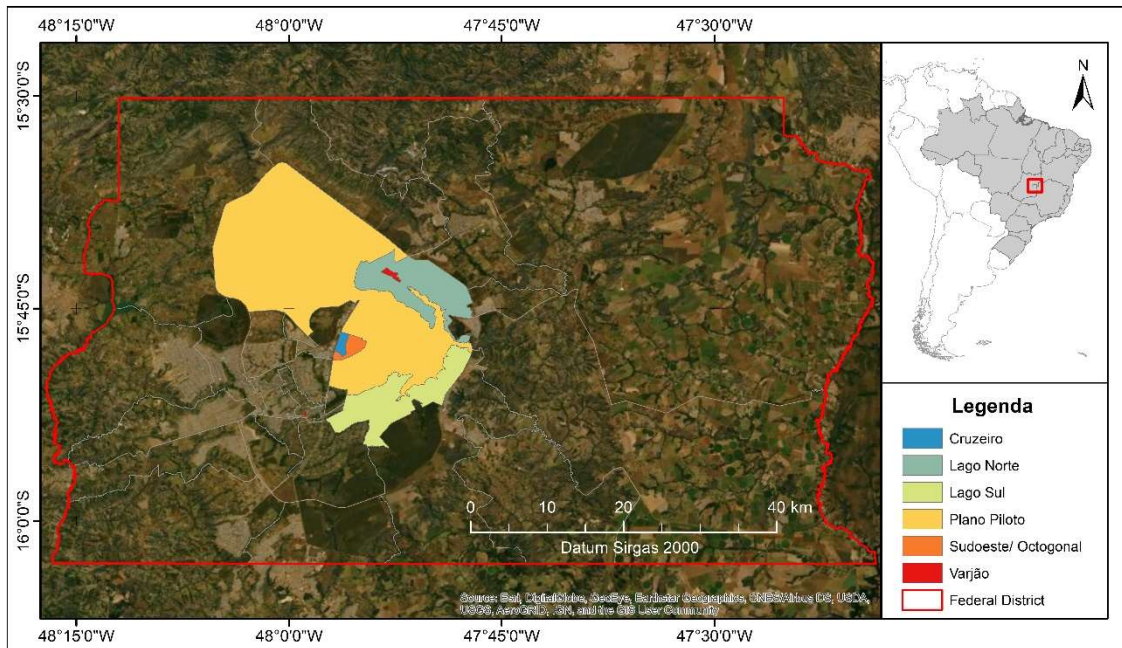


Figura 1. Mapa de localização da cidade de Brasília, Distrito Federal, Brasil.

O sensor TIR disponibiliza imagens nas bandas 10 (10,60-11,19 μm) e 11 (11,50-12,51 μm), com resolução espacial original de 100 m e reamostradas para 30 m pelo *United States Geological Survey* (USGS). Nesse estudo, foi utilizada a banda 10 para calcular a TST. Inicialmente, a imagem na faixa do termal é convertida para temperatura de brilho no sensor, assumindo que a emissividade é uniforme, ou seja, tendo como referência um corpo negro. Como nenhum objeto na natureza tem comportamento termodinâmico similar ao corpo negro, a temperatura de brilho no sensor deve ser corrigida considerando os parâmetros de emissividade e de condições atmosféricas do ambiente. Nesse caso, a temperatura de brilho foi corrigida por meio do algoritmo de janela única (Qin, Karnieli e Berliner, 2001; Wang *et al.*, 2015).

O algoritmo de janela única utiliza a emissividade da superfície para corrigir a temperatura. A emissividade pode ser definida como a diferença da radiância eletromagnética entre um objeto e um corpo negro. Essa variável não depende apenas da composição química e física do objeto, mas também de sua rugosidade. Nesse estudo, optou-se por estimar a emissividade a partir de aproximações utilizando o índice de vegetação por diferença normalizada (NDVI) para estimar a fração de vegetação (Sobrino *et al.*, 2008; Sobrino, Jiménez-Muñoz e Paolini, 2004). Os efeitos atmosféricos são corrigidos pela estimativa do conteúdo de vapor de água e pela temperatura do ar no momento de passagem do satélite. Esses dados foram obtidos por meio de estação

meteorológica automática do Instituto Nacional de Meteorologia (INMET) situada em Brasília (DF). Essas informações, junto com a emissividade, permitem corrigir os efeitos atmosféricos na imagem e obter a temperatura de superfície (Qin, Karnieli e Berliner, 2001; Wang *et al.*, 2015).

2.3 Mapeamento de uso e cobertura do solo

O mapeamento de uso e cobertura do solo foi realizado utilizando imagens Pleiades do ano 2017. Essas imagens possuem bandas espectrais na faixa do azul (430-550 μm), verde (500-620 μm), vermelho (590-710 μm), infravermelho próximo (740-940 μm) e pancromática (470-830 μm). A partir da fusão das imagens multiespectrais com a pancromática, foi produzida imagem multiespectral com resolução espacial de 0,50 m e ortorretificada. A alta resolução espacial da imagem permite a discriminação de pequenas feições que compõem o mosaico urbano (Li, Zhou e Ouyang, 2013).

A imagem multiespectral foi classificada nas classes (1) vegetação arbórea, que representa fragmentos florestais, parques e a arborização urbana; (2) vegetação rasteira, que engloba vegetação de baixo porte, representada pelas gramíneas e pelas plantas herbáceas e arbustivas de fragmentos florestais, parques e a arborização urbana, em locais públicos e privados; (3) edificação, que engloba áreas comerciais e residenciais; (4) estrada, categoria que representa as vias pavimentadas, como rodovias, avenidas e ruas; e (5) água, que representa áreas alagadas, rios, lagos e lagoas.

A identificação das classes foi feita por um algoritmo orientado a objeto que segmenta a imagem em áreas homogêneas. As áreas segmentadas foram classificadas quanto ao uso e cobertura do solo, pelo algoritmo *Support Vector Machine* (SVM), treinado a partir de amostras das assinaturas espectrais dos alvos. Na pós-classificação foi realizada verificação da classificação e reclassificação de algumas feições por interpretação visual da imagem e mapeamento dos alvos, visando melhorar a acurácia da classificação. As edificações e estradas foram agrupadas e reclassificadas como superfície impermeável. A acurácia da classificação foi avaliada por 255 pontos aleatórios distribuídos entre as classes de uso e cobertura do solo e interpretados visualmente pela imagem multiespectral com resolução espacial de 0,50 m. A classificação apresentou acurácia global de 0,82. As acurácias de produtor e de usuário variaram de 0,76 a 0,84 e de 0,68 a 0,95, respectivamente.

Tabela 1. Matriz de confusão da classificação da área urbana de Brasília (DF).

Classe	Verdade				Acurácia do usuário
	Vegetação arbórea	Vegetação rasteira	Impermeável	Água	
Vegetação arbórea	82	4	0	0	0,95
Vegetação rasteira	22	65	7	1	0,68
Impermeável	4	7	45	0	0,80
Água	0	1	1	16	0,89
Acurácia do produtor	0,76	0,84	0,85	0,94	

2.4 Unidades de análise

A divisão da área de interesse em quadrículas regulares permite avaliar a relação entre a TST e a vegetação, seja arbórea ou rasteira.

Foram criadas grades regulares proporcionais à resolução espacial de 30 metros da banda termal reamostrada do Landsat 8, correspondendo a janelas de 120 x 120 m, 240 x 240 m, ..., e 960 x 960 m, totalizando oito tamanhos de janelas, denominadas unidades de análise (Figura 2). Para cada unidade foram calculadas as estatísticas relacionando a TST e as métricas de composição e configuração da paisagem urbana, que considerou o tipo de vegetação, ou seja, se arbórea ou rasteira.




Figura 2. Variação do tamanho das unidades de análise utilizadas para extrair informações sobre a temperatura de superfície terrestre e métricas da vegetação arbórea urbana.

2.5 Métricas de paisagem da vegetação arbórea e rasteira em área urbana

A análise de métricas de paisagem relacionadas à vegetação auxilia na compreensão de quais característica da vegetação influenciam na TST. As métricas de paisagem podem ser agrupadas em métricas de composição e de configuração. A composição refere-se à variedade e à abundância de determinada cobertura na paisagem, como a proporção de diferentes tipos de cobertura. A configuração é determinada pelas características espaciais, arranjo, posição ou a complexidade geométrica das feições (Du

et al., 2016; Hu, Dai e Guldman, 2021). As métricas de paisagem foram produzidas para as classes de vegetação arbórea e rasteira.

As métricas para vegetação arbórea e rasteira foram produzidas no software Fragstat 4.2, utilizando a técnica de *moving window*, com regra de oito células vizinhas (McGarigal, 2015). Como resultados são produzidos dados *rasters* para as métricas desejadas. Foram selecionadas sete métricas, considerando a importância teórica e prática, a facilidade de obtenção e a interpretabilidade e baixa redundância (Li *et al.*, 2012). A métrica de composição foi a porcentagem de cobertura (PCob) e as métricas de configuração foram densidade de borda (DB), área média do fragmento (Area), índice de maior fragmento (IMF), índice da forma médio do fragmento (Forma), índice de densidade de fragmento (DF) e índice de agregação (IA) (McGarigal, 2015) (Tabela 2).

Tabela 2. Métricas de paisagem utilizadas para caracterização da vegetação urbana da cidade de Brasília, Brasil.

Métrica de paisagem	Descrição	Fórmula	Range	Citações
Porcentagem de cobertura de copa (PCob)	Abundância proporcional para cada tipo de fragmento na unidade de análise.	$\frac{\sum_{i=1}^n a_{ij}}{A} * 100$	$0\% < PCob \leq 100\%$	(Du <i>et al.</i> , 2016; Li <i>et al.</i> , 2012; Li, Zhou e Ouyang, 2013; Zhou, Wang e Cadenasso, 2017)
Densidade de borda (DB)	Perímetro da feição da cobertura de copa por hectare na unidade de análise.	$\frac{\sum_{i=1}^n p_{ij}}{A} * 10000$	$DB \geq 0$ m/ha	(Hu, Dai e Guldman, 2021; Li, Zhou e Ouyang, 2013)
Área média dos fragmentos (Area)	Média da área de copas de árvores por unidade de área	$\frac{\sum_{i=1}^n a_{ij}}{n}$	$Area \geq 0$ ha	(Das <i>et al.</i> , 2020; Hu, Dai e Guldman, 2021; Li, Zhou e Ouyang, 2013; Zhou, Wang e Cadenasso, 2017)
Índice de maior fragmento (IMF)	Proporção ocupada pelo maior fragmento na unidade de análise.	$\frac{\max(a_{ij})}{A} * 100$	$0\% < IMF \leq 100\%$	(Guo, Wu e Chen, 2019)
Forma média dos fragmentos (Forma)	Relação perímetro/área, corrigido por constante para padrão quadrado. Indica a complexidade da forma.	$\frac{1}{n_{ij}} \sum_{j=1}^n \frac{0,25p_{ij}}{\sqrt{a_{ij}}}$	$Forma \geq 1$	(Chen, Jin e Du, 2020; Zhou, Wang e Cadenasso, 2017)
Densidade de fragmento (DF)	Proporção de fragmentos por hectare a cada 100 ha.	$\frac{n_{ij}}{A} 10000 * 100$	$DF > 0$	(Das <i>et al.</i> , 2020)
Índice de agregação (IA)	Identifica a frequência de fragmentos adjacentes na classe	$\frac{g_{ii}}{\max \rightarrow g_{ii}}$	$0\% < IA \leq 100\%$	

a_{ij} = área da classe i no fragmento j ; p_{ij} = perímetro da classe i no fragmento j ; A = área da unidade de análise; n = número de fragmentos na classe i ; g_{ii} = número de pixels adjacentes na classe i .

2.6 Correlação e autocorrelação espacial

A relação entre as variáveis TST e as métricas de paisagem foi avaliada usando a correlação de Spearman (ρ), considerando um nível de significância de 5% (p-valor $\leq 0,05$) pelo teste t de Student. A correlação de Spearman (Equação 1) é uma estatística não paramétrica e mede a relação entre os dados de duas variáveis numéricas de interesse (Berger *et al.*, 2017), podendo variar de -1 a 1, indicando forte correlação negativa ou positiva próximo aos extremos, respectivamente. Se ρ é 0 (zero) indica que não há dependência estatística.

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{cov(x,y)}{s_x s_y} \quad (1)$$

em que ρ é a correlação de Spearman; x_i e y_i são as posições das variáveis x_i e y_i ; \bar{x} e \bar{y} são as médias das posições de x e y ; $cov(x, y)$ é a covariância de x e y ; $s_x s_y$ é o produto do desvio padrão das variáveis x e y .

A autocorrelação espacial entre as variáveis foi avaliada pelo Índice Global de Moran (I), que tem como hipótese nula (H_0), a ocorrência aleatória das variáveis no espaço, sendo obtido pela Equação 2 (Anselin, 1995; Câmara *et al.*, 2004). Este índice indica o grau de dependência espacial do valor de uma variável em relação a seus valores vizinhos, em uma região. Os valores de I podem ser positivos, variando de 0 a 1, o que indica correlação direta, ou negativos, variando de 0 a -1, o que indica correlação inversa. A significância do índice foi avaliada pelo teste de pseudo-significância, com a realização de 999 permutações dos valores em diferentes arranjos espaciais e produzindo uma frequência de distribuição dos índices pelo valor de Z (Anselin, 2003; Anselin, Syabri e Kho, 2006). O valor do índice é significativo, quando o valor do arranjo original se distancia do valor central da frequência simulada (p-valor $\leq 0,05$).

$$Indice\ Global\ de\ Moran = \frac{n \sum_{i=1}^n \sum_{j \neq i}^n w_{ij} (x_i - \bar{x})(x_j - \bar{x})}{\sum_{i=1}^n \sum_{j \neq i}^n w_{ij} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (2)$$

em que \bar{x} é a média dos n valores observados; w_{ij} é a matriz de proximidade espacial para um conjunto de n áreas; x_i e x_j são os valores observados nas posições i e j , respectivamente.

É importante esclarecer que o Índice Global de Moran não indica o padrão espacial de agrupamento das variáveis, e, portanto, é necessário aplicar o conceito da associação espacial do Índice Local (*Local Indicator of Spatial Association – LISA*), determinado a partir dos valores das observações locais padronizados em relação à média e ao desvio padrão da amostra (Anselin, 1995, 2003). O LISA (I_i) fornece uma estatística para cada local com nível de significância, além de estabelecer uma relação proporcional entre a soma das estatísticas locais e o Índice Global de Moran (I) (Anselin, 2003). O LISA tem valores variando entre -1 a 1, onde valores abaixo de 0 indicam correlação negativa e valores acima de 0 indicam correlação positiva. O peso das observações na matriz de proximidade espacial é padronizado em relação a linha da matriz (Anselin, 1995) (Equação 3).

$$\text{Índice Local de Moran} = \frac{n(x_i - \bar{x}) \sum_{j=1}^n w_{ij}(x_j - \bar{x})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (3)$$

em que \bar{x} é a média dos n valores observados; w_{ij} é a matriz de proximidade espacial para um conjunto de n áreas; x_i e x_j são os valores observados nas posições i e j , respectivamente.

A dependência espacial dos locais pode ser representada graficamente ou usando a denominação das classes, isto é: a) Alto-Alto, que corresponde ao quadrante onde as observações e a média dos vizinhos contíguos de uma determinada área apresentam valores positivos; b) Baixo-Baixo, que correspondente ao quadrante onde as observações e a média dos vizinhos contíguos apresentam valores negativos; c) Baixo-Alto, que corresponde ao quadrante onde as observações são negativas e a média dos vizinhos contíguos é positiva e d) Alto-Baixo, que corresponde ao quadrante onde os valores são positivos e a média dos vizinhos contíguos para a região é negativa (Anselin, 1995, 2003).

A significância do valor de LISA foi determinada a partir de 999 permutações sucessivas dos índices, produzindo uma distribuição normal para cada local pelo valor-Z com $n-1$ observações, resultando em pseudo p-valor para cada local. Os pseudo valores

de p foram utilizados para avaliar a significância dos índices a 5% (Anselin, 1995). Essa estatística foi processada no programa R versão 4.1.0 (Team, 2020), utilizando os pacotes *rgdal* (Bivand, Keitt e Rowlingson, 2021), *raster* (Hijmans, 2021), *exactextractr* (Baston, 2021), *dplyr* (Wickham *et al.*, 2021), *tmap* (Tennekes, 2018), *tigris* (Walker, 2021) e *spdep* (Anselin, 2005a; Bivand e Wong, 2018).

2.7 Modelagem da temperatura da superfície

Para modelar a temperatura da superfície terrestre (TST) foi ajustado o modelo de regressão linear (MRL), conforme Equação 4, que assume que as observações não são correlacionadas, e, portanto, os resíduos são independentes e não-correlacionados com a variável dependente, com variância constante e distribuição normal com média zero (Câmara *et al.*, 2004).

$$y = X\beta + \varepsilon \quad (4)$$

em que y é o vetor coluna da variável dependente; X é a matriz a matriz de dados para o conjunto de variáveis independentes ou exploratórias, nesse caso são as sete métricas de paisagem; β é o vetor coluna dos coeficientes da regressão e ε é um vetor de erros aleatórios independentes e normais.

A dependência espacial dos erros provenientes da regressão linear foi avaliada pelo índice de Moran I. Caso o valor do índice seja significativo, os modelos de regressão espacial são mais apropriados para modelagem da variável dependente em relação à variável independente (Câmara *et al.*, 2004; Dai, Guldmann e Hu, 2018; Hu, Dai e Guldmann, 2021). Nesse caso, foram aplicados o modelo de autocorrelação espacial (MAE) ou modelo espacial autorregressivo misto (*Spatial AutoRegressive* ou *Spatial Lag Model*) e o modelo de erro espacial (MEE - *Spatial Error Model*) (Anselin, 2005a). O MAE é aplicado para prever a TST por meio de variáveis preditoras, considerando a autocorrelação espacial das variáveis preditoras (Equação 5).

$$y = \rho WTST + X\beta + \varepsilon \quad (5)$$

em que y é o vetor coluna da variável dependente; W é a matriz de vizinhança ou matriz de proximidade espacial padronizada em relação à soma por linha, então $WTST$ é o vetor das variáveis independentes penalizadas pela dependência espacial; ρ é o fator de distância espacial que mensura a autocorrelação espacial; X é a matriz a matriz de dados para o conjunto de variáveis independentes ou exploratórias; β é o vetor coluna dos coeficientes da regressão e ε é um vetor de erros aleatórios independentes e normais.

Nesse estudo, a matriz de proximidade (W) foi de primeira ordem pelo método de contiguidade espacial, ou seja, apenas as unidades de análise adjacentes foram consideradas como vizinhas (Anselin, 2005a).

O MEE parte do pressuposto que os efeitos espaciais não explicados pelas variáveis exploratórias estão associadas ao erro do modelo (ε) de regressão linear (RL). Assim a estimativa da relação entre a TST e as métricas de paisagem pelo MEE, pode ser obtido pela Equação 6.

$$y = X\beta + \gamma W\varepsilon + \delta \quad (6)$$

em que y é o vetor coluna da variável dependente; X é a matriz a matriz de dados para o conjunto de variáveis independentes ou exploratórias; β é o vetor coluna dos coeficientes da regressão; $W\varepsilon$ é a matriz de erro com efeitos espaciais; γ é o coeficiente de autocorrelação; δ é a componente do erro com variância constante e não correlacionada.

A aplicação do MAE ou MEE é baseada no critério da significância do p-valor (p-valor $\leq 0,05$) pelo teste do qui-quadrado (χ^2), associado ao Multiplicador de Lagrange de autocorrelação (MLlag) e Multiplicador de Lagrange de erro (MLerro). Caso ambos sejam significativos, o critério de seleção é feito a partir da significância estatística e do maior valor do Multiplicador de Lagrange Robusto (MLRobusto), relativo a autorrelação (MLRlag) e ao erro (MLRerro) (Anselin, 2005b).

Os ajustes dos modelos MRL, MAE e MEE foram avaliados pelo coeficiente de determinação (R^2) e por meio do Critério de Informação de Akaike (*Akaike Information Criterion* - CIA). Os modelos foram ajustados no programa R versão 4.1.0 (Team, 2020), utilizando os pacotes rgdal (Bivand, Keitt e Rowlingson, 2021), raster (Hijmans, 2021), exactextractr (Baston, 2021) e spdep (Anselin, 2005a; Bivand e Wong, 2018).

3.Resultados

3.1 Temperatura de superfície em área de vegetação urbana

A vegetação presente na área urbana de Brasília corresponde a 64,11% (19.215 ha) da área urbana total (29.970 ha), e deste montante, 27,64% (8.285 ha) corresponde à vegetação de porte arbóreo e 36,47% (10.930 ha) ao estrato rasteiro, com predominância de gramíneas. O estrato arbóreo é representado por fragmentos com área média de 0,14 ha, porém, a variabilidade dos tamanhos é muito alta, com desvio padrão de 6,99 ha. O estrato rasteiro é composto por fragmentos que medem, em média, 0,40 ha, e o desvio padrão é também elevado (12,80 ha).

Ao longo das estações do ano, a vegetação urbana apresentou temperaturas variadas (Tabela 3). No outono, as áreas cobertas por vegetação arbórea e por vegetação rasteira apresentaram temperaturas de superfície mais baixas, com médias em torno de 27,19 °C e 28,97 °C, respectivamente. Por outro lado, na primavera as temperaturas médias foram mais elevadas para vegetação arbórea e rasteira, próximo a 42,80 °C e 45,61 °C, respectivamente. Em geral, em todas as estações do ano, a temperatura média da cobertura arbórea foi inferior às registradas em áreas com vegetação rasteira.

Tabela 3. Variação sazonal da temperatura da superfície terrestre (TST) na área urbana de Brasília, considerando áreas cobertas com vegetação arbórea e vegetação rasteira.

Estação do Ano	Cobertura	Temperatura da Superfície Terrestre - TST (°C)			
		Mínima	Máxima	Média	Desvio padrão
Primavera	Arbórea	27,34	62,72	42,80	3,73
	Rasteira	28,61	57,79	45,61	3,62
Verão	Arbórea	22,24	45,57	32,16	1,70
	Rasteira	22,24	47,32	34,24	2,20
Outono	Arbórea	20,63	35,46	27,19	1,33
	Rasteira	23,28	38,32	28,97	1,72
Inverno	Arbórea	24,77	52,91	36,63	3,21
	Rasteira	25,28	49,51	38,11	2,90

A vegetação urbana teve maior variação de temperatura na primavera, com desvio padrão acima de 3 °C tanto para vegetação arbórea quanto para vegetação rasteira. As menores variações de temperatura ocorreram no outono, onde a vegetação urbana arbórea e rasteira apresentaram desvio padrão de 1,33 e 1,72 °C, respectivamente.

3.2 Relação entre a composição das áreas verdes urbanas e a temperatura da superfície terrestre (TST)

A composição da vegetação foi representada pelo percentual de cobertura (PCob) para cada classe de vegetação urbana, considerando que os espaços verdes urbanos foram subdivididos em duas classes de vegetação, isto é, arbórea, composta por árvores, e rasteira, composta por gramíneas, plantas herbáceas e arbustivas.

O percentual de cobertura de árvores (PCArv) apresentou correlação inversa com a temperatura de superfície terrestre, variando de -0,44 a -0,70. Este resultado demonstra que o aumento na cobertura de árvores auxilia no resfriamento do ambiente urbano. Por outro lado, entre as estações do ano, as correlações variaram pouco, sendo ligeiramente mais forte no outono. Por outro lado, as correlações foram mais fortes com o aumento do tamanho da área de análise. Entre unidades de 120 m e 480 m, o incremento foi de 360 m, implicando no aumento da correlação inversa de aproximadamente -0,10, em todos em todas as estações climáticas. Entre as unidades de análise 480 m e 840 m, houve acréscimo na correlação próximo a -0,05, demonstrando estabilização na correlação entre PCArv e TST a partir da unidade de análise de 480 (Figura 3).

O percentual de cobertura de vegetação rasteira (PCRast) teve comportamento diferente ao observado para o percentual de cobertura de árvores (Figura 3). A correlação entre a PCRast e TST apresentou correlação direta, ou seja, a medida que aumenta PCRast por unidade de área, a TST tende a aumentar. As maiores correlações foram observadas na primavera e no inverno, com variações de 0,42 a 0,48, e de 0,36 a 0,38, respectivamente. Tanto no verão quanto no inverno, a correlação aumentou progressivamente com o aumento da unidade de análise no intervalo de 120 m a 600 m e apresentando estabilidade ou redução correlação acima desse intervalo.

No verão e outono, a correlação para PCRast apresentou variação ao longo do gradiente das unidades de análise e comportamento diferente ao observado para as demais estações. No verão, o aumento da unidade de análise é inversamente proporcional à correlação do PCRast com a TST, reduzindo a correlação de 0,14 para 0,09. Nessa estação, as correlações para as unidades de análise acima de 600 m, não foram significativas ao nível de significância de 5%. No outono a correlação diminuiu de 0,30 para 0,23 entre as unidades de análise de 120 m e 960 m.

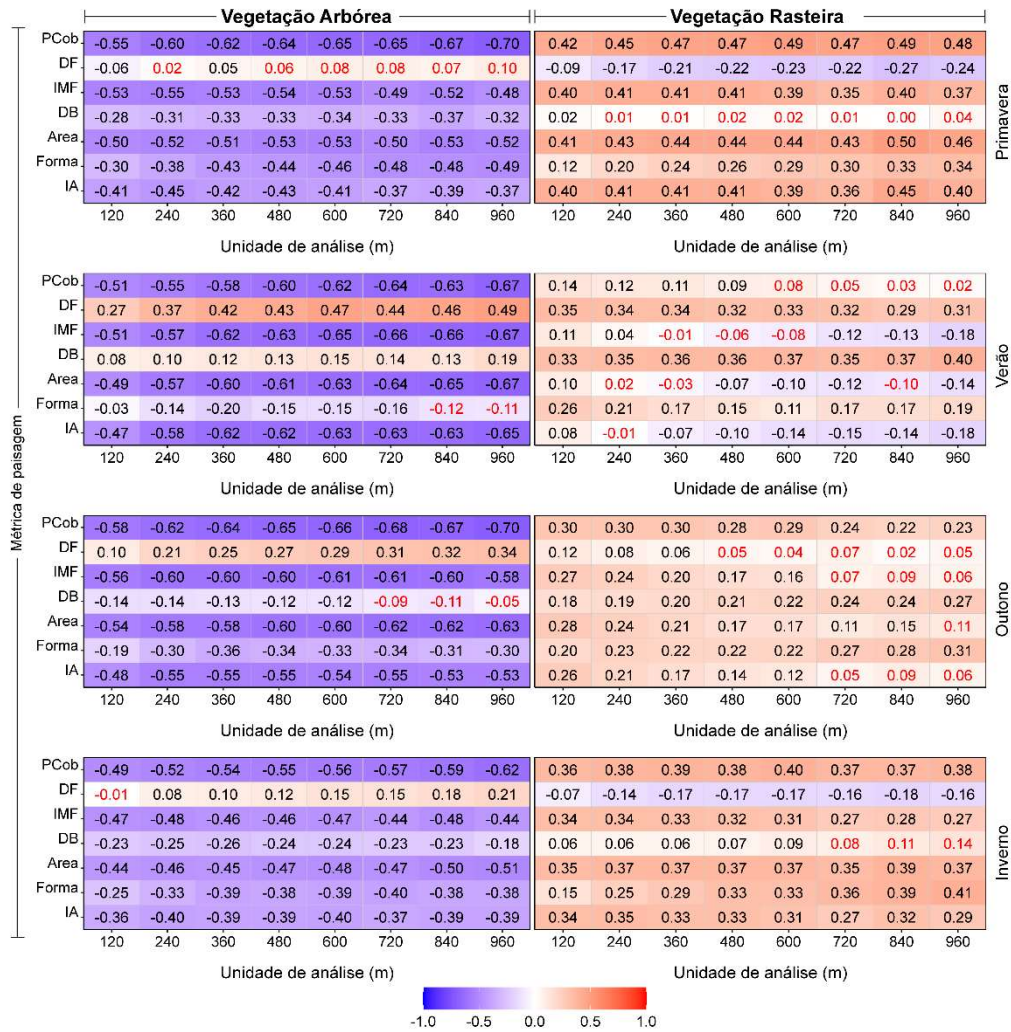


Figura 3. Correlação de SPM entre a temperatura de superfície terrestre (TST) e métricas de paisagem da vegetação arbórea (a) e da vegetação rasteira (b), considerando variações de escalas para área urbana de Brasília (DF). Valores destacados em vermelho não foram significativos (p -valor $\leq 0,05$). PCob: Percentual de cobertura; DF: Densidade de fragmento; IMF: Índice de Maior Fragmento; DB: Densidade de Borda; Area: Área do fragmento; Forma: Forma do fragmento; IA: Índice de agregação.

3.3 Influência da configuração da vegetação urbana sobre a temperatura da superfície terrestre (TST)

As métricas de configuração da vegetação arbórea, ou seja, densidade de borda (DB), área média do fragmento (Area), índice de maior fragmento (IMF), índice da forma média do fragmento (Forma), índice de densidade de fragmento (DF) e índice de agregação (IA), apresentaram, em sua maioria, correlação negativa com a TST (Figura 3). O IMF, que representa a ocupação do fragmento de maior tamanho na unidade de

análise, apresentou correlação negativa com a TST, indicando que os maiores fragmentos florestais reduzem o aquecimento do ambiente. O valor desse índice foi proporcional ao tamanho da unidade de análise e apresentou correlação pouco variável nos diferentes períodos do ano. Primavera e verão foram as estações em que o IMF apresentou maiores correlações, que variaram de -0,48 a -0,54 e de -0,46 a -0,47, respectivamente.

Para vegetação rasteira, o IMF apresentou correlação positiva com a TST, indicando que os maiores fragmentos de vegetação rasteira por unidade de análise contribuem para aumentar a temperatura local (Figura 3).

A partir da DB é possível avaliar a fragmentação da vegetação no ambiente, pois quanto maior a proporção de borda (m) dos fragmentos por unidade de área, maior é a fragmentação da vegetação no espaço. A DB teve correlação negativa para vegetação arbórea na primavera, outono e inverno, e positiva no verão. Para a vegetação rasteira, a correlação foi positiva em todas as estações climáticas, com valor proporcional ao aumento da unidade de análise (Figura 3).

Os índices Área e Forma da vegetação arbórea foram inversamente correlacionados com a temperatura em todas as estações. A área dos fragmentos de vegetação arbórea apresentou forte correlação negativa significativa com a temperatura, variando entre -0,49 e -0,67 no verão e de -0,54 a -0,63 no outono. A forma dos fragmentos apresentou maior correlação na primavera e no inverno, variando de -0,30 a -0,49 e -0,25 a -0,38, respectivamente. Em relação à vegetação rasteira, os índices Área e Forma apresentaram correlações positivas com a TST, indicando que o aumento de áreas gramadas e a presença de fragmentos com formatos complexos tendem a aumentar o calor, principalmente na primavera e no inverno. Nas demais estações, a correlação tende a reduzir com o aumento da área das unidades de análise, mas no verão a correlação passa de positiva para negativa nas unidades de análise superiores a 720 m.

Quanto à métrica IA para a vegetação arbórea, a correlação com a TST foi negativa em todas as estações e o aumento dessa correlação também indica redução de ilhas de calor em todas as estações do ano, principalmente no verão e no outono. Áreas com vegetação rasteira apresentaram comportamento inverso, ou seja, a proximidade de áreas com vegetação rasteira tende a aumentar a temperatura na primavera e no outono. No verão, os espaços gramados apresentaram correlação negativa e significativa em unidades de análise acima de 360 m.

3.4 Autocorrelação da temperatura de superfície terrestre (TST)

O verão e o outono foram as estações do ano com os maiores valores para o Índice Global de Moran (I), ou seja, acima de 0,70. Quanto ao inverno e a primavera, os valores desse índice foram similares e próximos a 0,60 (Tabela 4).

Tabela 4. Valores dos índices de autocorrelação global (Índice Global de Moran) e de associação espacial local (LISA) para a Temperatura da Superfície Terrestre (TST) nas áreas urbanas de Brasília, Brasil.

Estação do ano	Índice Global de Moran	LISA	
		Alto-Alto (%)	Baixo-Baixo (%)
Outono	0,73*	20,92	16,65
Inverno	0,65*	21,70	10,88
Primavera	0,64*	20,22	9,93
Verão	0,72*	22,29	16,40

* p-valor $\leq 0,05$.

O Índice LISA permite inferir sobre o padrão espacial do agrupamento das variáveis (Figura 4). A partir do LISA é possível identificar as regiões com agrupamentos ou clusters de áreas quentes e frias, ou de altos valores e baixos valores de índice em relação à média. Os clusters quentes ocorreram em maior quantidade na região central de Brasília, onde está localizado o Plano Piloto, sendo também identificado clusters na região sul do Lago Sul, onde está localizado o Aeroporto Internacional de Brasília (Figura 4). A quantidade de clusters quentes foi pouco variável ao longo do ano, sendo ligeiramente superior no verão com 22,29% e menor na primavera, com cobertura de 20,22%. Valores de agrupamento classificados como Alto-baixo e Baixo-Alto não foram significativos a 5%.

Os agrupamentos de áreas frias apresentaram variação de 9,93 a 16,65% ao longo do ano. A menor proporção de áreas frias foi observada no inverno e na primavera, principalmente nas áreas do entorno do Lago do Paranoá e em locais dispersos da região do Lago Norte (Figuras 4D e 4F). O outono e o verão foram as estações com maior proporção de clusters frios, localizados nas regiões nordeste, leste e sudeste de Brasília (Figuras 4B e 4H).

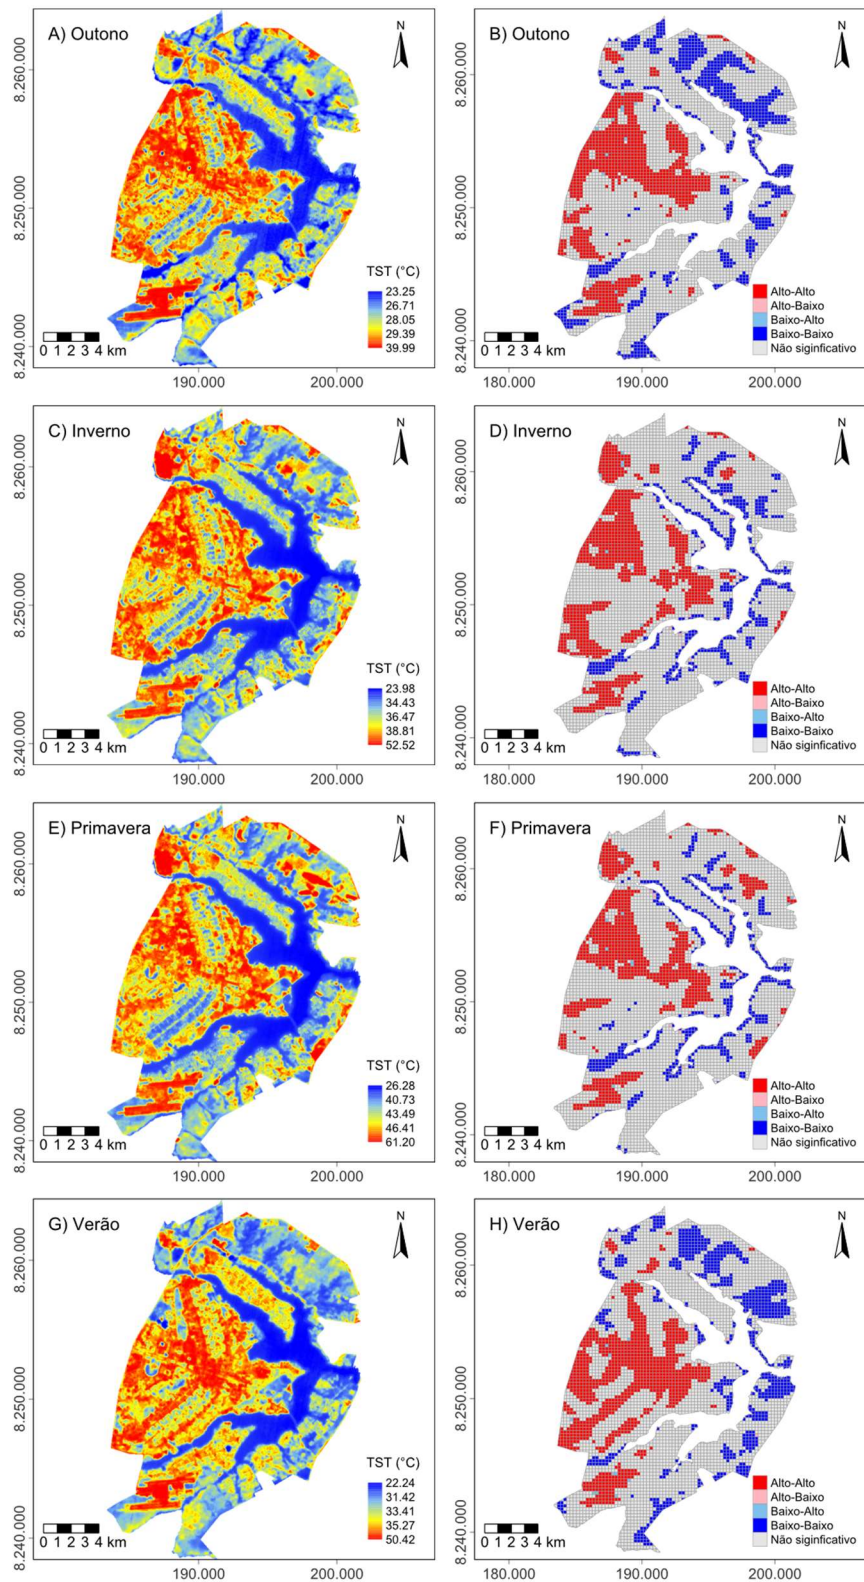


Figura 4. Temperatura da superfície terrestre (TST) na área urbana de Brasília, Brasil, e correlação espacial da TST pelo Indicador Local de Autocorrelação Espacial (*Local Indicator of Spatial Association – LISA*) para as estações e anos do outono de 2017, inverno de 2017, primavera de 2017 e verão de 2019 (p -valor $\leq 0,05$).

Da área total avaliada, 16,40% são classificadas como áreas frias no verão e 16,65% como frias no outono (Tabela 3). É importante destacar que o verão foi a estação que apresentou elevação tanto no percentual de áreas quentes quanto no de áreas frias. Além disso, poucos valores de outliers foram observados.

3.5 Autocorrelação da configuração e composição da vegetação arbórea urbana

Os fragmentos de vegetação arbórea situados no entorno de Brasília foram agrupados como áreas frias, em relação às métricas de densidade de fragmento (DF) e densidade de borda (DB), e como áreas quentes, em relação as métricas de percentual de cobertura de árvore (PCArv), índice de maior fragmento (IMF), área média (Área) e índice de agregação (IA). Os agrupamentos identificados como Alto-Alto para PCArv são, em sua maioria, fragmentos de vegetação nativa situados ao sul de Brasília, próximos ao aeroporto, e na região centro-leste, principalmente em parques ecológicos (Figura 5).

Os fragmentos de vegetação arbórea presentes no entorno de construções residenciais e comerciais na região central de Brasília foram classificados como Alto-Alto para as métricas DF e DB ao nível de significância de 5%. A vegetação arbórea na região Sul da cidade foi considerada como tendo agrupamento significativo para a variável Forma (Figura 5).

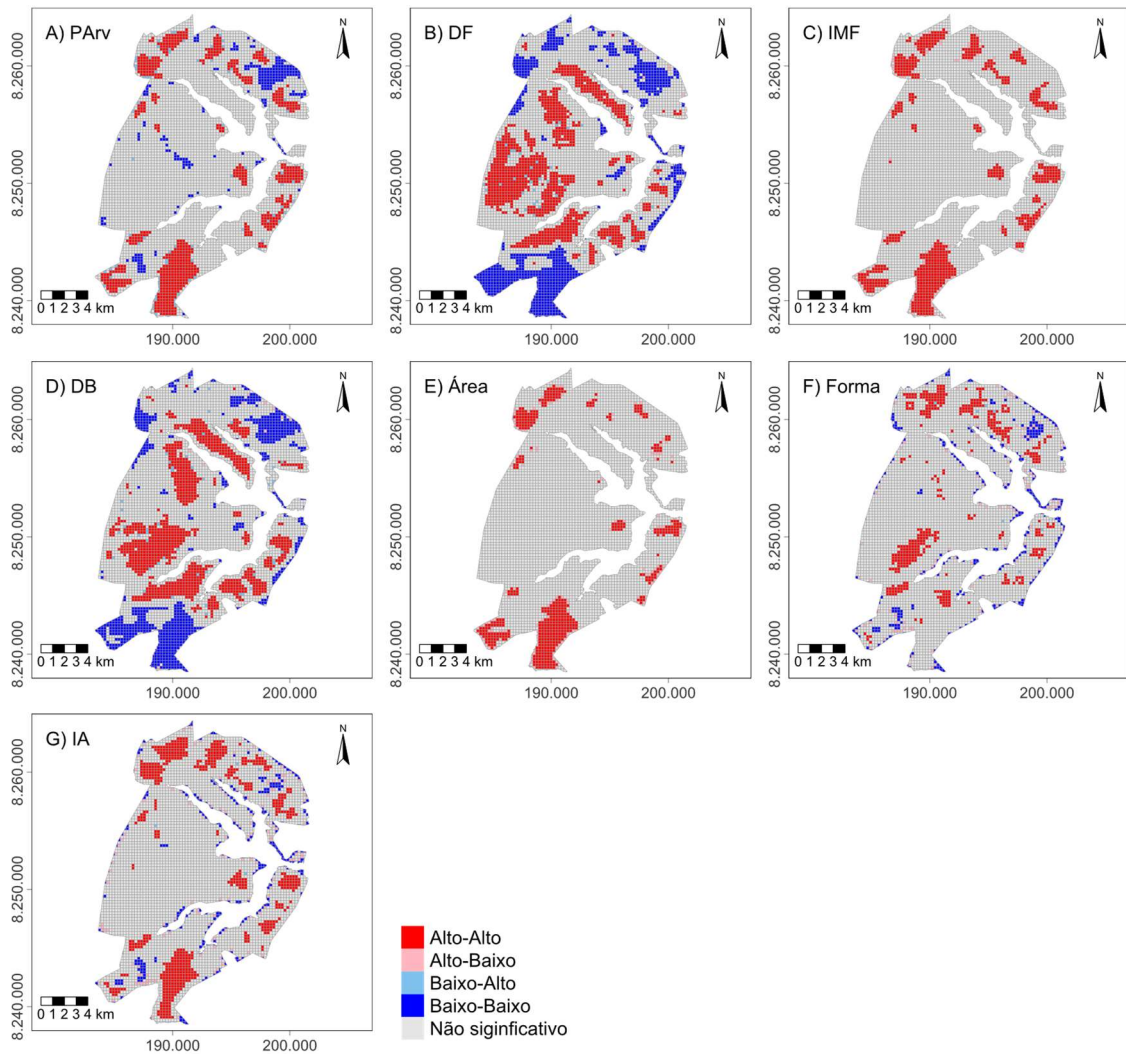


Figura 5. Indicador Local de Autocorrelação Espacial (*Local Indicator of Spatial Association* – LISA) das métricas de composição e configuração da vegetação arbórea em unidades de análise de 240 m para área urbana de Brasília, Brasil (p -valor $\leq 0,05$).

3.6 Modelagem da temperatura da superfície em função de métricas da vegetação arbórea urbana

O modelo de regressão linear (MRL) apresentou bons ajustes para estimativa da TST em função da composição e configuração da vegetação arbórea em Brasília. O aumento da unidade de análise propiciou maior explicação da variação da variável dependente temperatura em função das métricas da vegetação urbana. Os melhores ajustes foram obtidos com o aumento da unidade de análise, chegando aos maiores valores de R^2 nas unidades de análise de 840 m, considerando os ajustes de um modelo por estação climática (Tabela 5).

Tabela 5. Coeficientes do ajuste do modelo de regressão linear múltiplo (MRL) para temperatura da superfície terrestre (TST) em função da composição e configuração da vegetação urbana de Brasília, Brasil.

UA	Estação	N	PCArv	DF	IMF	DB	Área	Forma	IA	R ²	I Moran
120	Inverno		-4,95e-02*	1,04e-03*	4,05e-04*	-3,92e-03	1,18e+00*	3,51e-02*	3,88e-03	0,23	0,80*
			-5,83e-01	9,53e-02	4,90e-03	-2,98e-01	2,04e-01	5,35e-03	3,84e-02		
120	Outono		-3,81e-02*	2,22e-04*	-4,08e-03*	-1,39e-03	9,49e-01*	-4,92e-02*	1,05e-03	0,37	0,79*
			-7,31e-01	3,31e-02	-8,01e-02	-1,72e-01	2,66e-01	-1,22e-02	1,69e-02		
120	Primavera	17150	-7,88e-02*	4,54e-04*	9,40e-03*	-3,74e-03	1,76e+00*	-6,07e-01*	4,21e-03*	0,29	0,78*
			-7,43e-01	3,33e-02	9,09e-02	-2,28e-01	2,43e-01	-7,40e-02	3,34e-02		
120	Verão		-5,31e-02*	2,16e-04*	-1,79e-02*	5,82e-04*	2,02e+00*	-2,21e-01*	7,09e-03*	0,32	0,80*
			-7,07e-01	2,23e-02	-2,45e-01	5,00e-02	3,93e-01	-3,80e-02	7,93e-02		
240	Inverno		-3,35e-02*	3,71e-03*	-8,44e-03*	-6,83e-03	2,27e-01*	-2,64e-01*	7,55e-03	0,29	0,71*
			-3,82e-01	2,63e-01	-1,01e-01	-4,71e-01	1,44e-01	-3,10e-02	5,53e-02		
240	Outono		-2,86e-02*	1,43e-03*	-9,32e-03*	-2,74e-03	2,30e-01*	-1,51e-01*	-4,59e-03	0,43	0,70*
			-5,26e-01	1,64e-01	-1,79e-01	-5,05e-01	2,35e-01	-2,86e-02	-5,42e-02		
240	Primavera	4049	-5,69e-02*	2,86e-03*	-3,12e-03*	-7,51e-03	3,17e-01*	-8,18e-01*	2,88e-03*	0,36	0,66*
			-5,22e-01	1,63e-01	-3,00e-02	-4,17e-01	1,62e-01	-7,71e-02	1,69e-02		
240	Verão		-4,37e-02*	1,35e-03*	-2,09e-02*	6,06e-05*	5,47e-01	-4,09e-01*	-4,89e-03*	0,38	0,70*
			-5,53e-01	1,06e-01	-2,76e-01	4,64e-03	3,85e-01	-5,32e-02	-3,97e-02		
360	Inverno		-1,88e-02*	5,29e-03	-2,46e-02*	-8,46e-03*	1,45e-01*	-6,49e-01*	1,40e-02*	0,32	0,67*
			-2,12e-01	3,49e-01	-2,94e-01	-5,64e-01	1,92e-01	-6,30e-02	8,55e-02		
360	Outono		-1,91e-02*	2,19e-03*	-1,85e-02*	-3,83e-03*	1,21e-01*	-2,10e-01*	-6,16e-03	0,46	0,66*
			-3,43e-01	2,30e-01	-3,52e-01	-4,07e-01	2,56e-01	-3,25e-02	-5,99e-02		
360	Primavera	1701	-3,85e-02*	4,49e-03*	-2,22e-02*	-1,01e-02	1,61e-01*	-1,19e+00*	8,54e-03*	0,41	0,59*
			-3,50e-01	2,39e-01	-2,14e-01	-5,42e-01	1,72e-01	-9,29e-02	4,20e-02		
360	Verão		-3,60e-02*	2,04e-03*	-2,50e-02*	-7,53e-04*	2,61e-01	-4,05e-01*	-1,33e-02	0,42	0,63*
			-4,41e-01	1,46e-01	-3,25e-01	-5,46e-02	3,77e-01	-4,28e-02	-8,83e-02		
480	Inverno		5,08e-02*	6,89e-03*	-8,36e-02*	-1,22e-02*	4,08e-02*	-1,64e-01	5,13e-03	0,34	0,62*
			5,72e-01	4,43e-01	-1,00e+00	-8,21e-01	8,85e-02	-1,31e-02	2,90e-02		
480	Outono		-7,71e-03*	2,86e-03	-2,50e-02*	-4,93e-03*	5,68e-02*	1,73e-01*	-1,31e-02	0,47	0,66*
			-1,36e-01	2,88e-01	-4,68e-01	-5,18e-01	1,93e-01	2,16e-02	-1,16e-01		
480	Primavera	904	4,00e-02*	5,88e-03*	-9,12e-02*	-1,43e-02*	6,04e-02*	-6,15e-01*	-6,48e-03	0,45	0,52*
			3,64e-01	3,06e-01	-8,84e-01	-7,78e-01	1,06e-01	-3,95e-02	-2,96e-02		
480	Verão		-1,99e-02*	3,12e-03	-3,22e-02*	-2,61e-03*	1,35e-01*	8,56e-01*	-3,18e-02*	0,44	0,62*
			-2,37e-01	2,12e-01	-4,08e-01	-1,86e-01	3,10e-01	7,20e-02	-1,90e-01		
600	Inverno		3,85e-02*	8,68e-03*	-7,09e-02*	-1,31e-02*	3,66e-02*	-2,54e-01*	8,94e-03	0,36	0,61*
			4,15e-01	5,35e-01	-8,12e-01	-8,42e-01	1,14e-01	-1,54e-02	3,91e-02		
600	Outono		-1,29e-02*	3,77e-03	-2,30e-02*	-5,66e-03*	4,42e-02*	4,96e-01*	-6,94e-03	0,49	0,65*
			-2,22e-01	3,69e-01	-4,19e-01	-5,79e-01	2,19e-01	4,76e-02	-4,83e-02		
600	Primavera	539	2,92e-02*	7,78e-03	-7,69e-02*	-1,59e-02*	3,27e-02*	-1,05e+00	-2,48e-03	0,46	0,51*
			2,55e-01	3,89e-01	-7,14e-01	-8,31e-01	8,27e-02	-5,13e-02	-8,81e-03		
600	Verão		-2,72e-02*	3,72e-03	-2,63e-02*	-3,15e-03	8,88e-02*	1,21e+00*	-3,38e-02*	0,47	0,61*
			-3,14e-01	2,46e-01	-3,22e-01	-2,17e-01	2,97e-01	7,81e-02	-1,59e-01		
720	Inverno		7,55e-02*	8,67e-03*	-1,10e-01*	-1,43e-02*	3,86e-02*	-8,04e-01*	-7,60e-04	0,40	0,57*
			8,15e-01	5,32e-01	-1,28e+00	-9,32e-01	1,87e-01	-5,44e-02	-3,13e-03		
720	Outono		-8,07e-03*	3,35e-03	-2,53e-02*	-5,79e-03*	3,12e-02*	2,98e-01*	-2,54e-02	0,51	0,63*
			-1,38e-01	3,25e-01	-4,64e-01	-5,97e-01	2,39e-01	3,19e-02	-1,65e-01		
720	Primavera	360	6,33e-02*	8,07e-03*	-1,17e-01*	-1,74e-02*	4,23e-02*	-1,34e+00*	-9,49e-03	0,51	0,46*
			5,58e-01	4,05e-01	-1,11e+00	-9,26e-01	1,67e-01	-7,38e-02	-3,19e-02		
720	Verão		-2,50e-02*	2,22e-03	-2,68e-02	-2,80e-03	6,35e-02*	5,02e-01*	-6,15e-02	0,48	0,56*
			-2,85e-01	1,43e-01	-3,28e-01	-1,92e-01	3,24e-01	3,58e-02	-2,67e-01		
840	Inverno		8,77e-02*	9,85e-03*	-1,11e-01*	-1,65e-02*	-1,11e-02*	1,02e+00	-1,54e-02	0,48	0,52*
			9,50e-01	6,18e-01	-1,28e+00	-1,10e+00	-6,60e-02	5,96e-02	-6,56e-02		
840	Outono		-4,16e-03*	3,97e-03	-2,70e-02*	-6,57e-03*	1,81e-02*	8,30e-01*	-2,42e-02	0,50	0,61*
			-6,79e-02	3,75e-01	-4,66e-01	-6,64e-01	1,62e-01	7,29e-02	-1,55e-01		
840	Primavera	240	7,51e-02*	7,43e-03*	-1,14e-01*	-1,94e-02*	-1,42e-02*	1,53e-01	-5,38e-02	0,59	0,35*
			6,51e-01	3,74e-01	-1,04e+00	-1,04e+00	-6,73e-02	7,16e-03	-1,83e-01		
840	Verão		-1,84e-02*	3,61e-03	-2,95e-02*	-4,10e-03	4,29e-02*	1,46e+00*	-6,08e-02	0,48	0,53*
			-2,01e-01	2,28e-01	-3,41e-01	-2,77e-01	2,56e-01	8,56e-02	-2,60e-01		
960	Inverno		6,42e-02*	1,11e-02*	-8,31e-02*	-1,69e-02*	-1,00e-02*	1,31e+00	-2,53e-02	0,41	0,48*
			6,83e-01	6,73e-01	-9,52e-01	-1,09e+00	-7,72e-02	8,19e-02	-1,02e-01		
960	Outono		-1,04e-02*	4,70e-03	-2,13e-02*	-6,81e-03	1,31e-02*	8,57e-01	-1,91e-02	0,49	0,62*
			-1,72e-01	4,44e-01	-3,81e-01	-6,81e-01	1,57e-01	8,38e-02	-1,21e-01		
960	Primavera	180	4,09e-02*	9,03e-03	-7,28e-02*	-1,99e-02*	-1,45e-02*	6,66e-01	-6,10e-02	0,53	0,36*
			3,59e-01	4,52e-01	-6,87e-01	-1,05e+00	-9,25e-02	3,45e-02	-2,03e-01		
960	Verão		-2,68e-02*	3,82e-03	-2,25e-02	-4,17e-03	3,02e-02*	1,62e+00*	-5,90e-02	0,49	0,51*
			-2,96e-01	2,41e-01	-2,68e-01	-2,78e-01	2,42e-01	1,05e-01	-2,48e-01		

* p-valor ≤ 0,05; UA: Unidade de análise; N: Número de observações.

A maior unidade de análise, 960 m, apresentou R^2 abaixo do observado para unidades de 840 m. O CIA teve relação inversa em relação a unidade de análise, indicando que as melhores estimativas ocorrem nas unidades de análise de maior área.

Os betas coeficientes ou coeficientes padronizados indicam a contribuição de cada métrica da vegetação arbórea urbana na explicação da variação da TST. Foi observado que o percentual de cobertura de árvore (PARv) teve o maior efeito de resfriamento quando comparado com as demais variáveis. Esse efeito é crescente com o aumento da unidade de análise, tendo os maiores efeitos na unidade de 840 m. A DF foi a variável com segundo maior efeito sobre a temperatura, chegando a maiores efeitos na unidade de 960 m. As variáveis IMF, DB, Area e IA apresentaram efeito inverso em relação às unidades de análise, demonstrando que apresentam maiores efeitos sobre a temperatura nas unidades de menor área.

Os índices de Moran foram significativos em todas as unidades de análise e nas quatro estações climáticas, indicando significativa autocorrelação espacial do termo erro da regressão linear. Nesse caso, modelos baseados na dependência espacial das variáveis são mais indicados, como o MAE e o MEE. Os valores do Multiplicador de Lagrange (ML) foram significativos pelo teste do qui-quadrado ($p \leq 0,05$), tanto para Multiplicador de Lagrange de Autocorrelação (MLlag) quanto para Multiplicador de Lagrange de Erro (MLerro), reforçando a dependência espacial das variáveis. Nesse caso, a escolha do modelo se faz pelo maior valor significativo do Multiplicador de Lagrange Robusto (MLrobusto) (Tabela 6). A Tabela 6 indica que o modelo de erro espacial (MEE) é mais indicado, contudo o modelo de autorregressão espacial (MAE) teve melhor ajuste para as estações primavera e verão em unidades de análise acima de 720 m.

O modelo de autorregressão espacial (MAE) e o modelo de erro espacial (MEE) apresentaram bons ajustes para estimativa da temperatura de superfície em função das métricas da vegetação arbórea. Isso pode ser constatado pelos valores de R^2 que foram superiores aos observados no ajuste utilizando regressão linear (Tabela 6). As equações ajustadas tiveram maiores valores de R^2 nas unidades de análise de menor área, estabilizando o valor de R^2 próximo a 0,70 nas unidades de maior área para o MAE (Tabela 7).

Tabela 6. Valores do Índice de Moran, Multiplicador de Lagrange (ML) e Multiplicador de Lagrange Robusto provenientes do modelo de regressão linear múltipla (MRL).

UA	Estação	Multiplicador de Lagrange		Multiplicador de Lagrange Robusto	
		Autocorrelação (MLlag)	Erro (MLerro)	Autocorrelação (MLRlag)	Erro (MLRerro)
120	Inverno	38941,08*	41781,30*	1103,92*	3944,14*
120	Outono	35188,75*	40418,57*	1196,09*	6425,91*
120	Primavera	36524,29*	39455,84*	1386,33*	4317,88*
120	Verão	38708,29*	42333,24*	1052,10*	4677,05*
240	Inverno	6664,02*	7354,03*	192,13*	882,14*
240	Outono	6128,69*	7217,08*	238,93*	1327,31*
240	Primavera	5679,4*	6380,29*	240,09*	940,97*
240	Verão	6646,75*	7138,46*	312,24*	803,95*
360	Inverno	2262,81*	2600,44*	62,11*	399,74*
360	Outono	2055,22*	2558,83*	83,42*	587,03*
360	Primavera	1731,92*	2048,74*	76,03*	392,85*
360	Verão	2189,93*	2335,11*	155,89*	301,07*
480	Inverno	1003,37*	1133,09*	42,02*	171,74*
480	Outono	1018,78*	1285,02*	45,47*	311,71*
480	Primavera	698,87*	801,16*	50,67*	152,97*
480	Verão	1095,87*	1140,08*	103,64*	147,86*
600	Inverno	522,12*	626,31*	10,99*	115,18*
600	Outono	570,78*	715,00*	25,64*	169,86*
600	Primavera	369,45*	434,19*	20,77*	85,52*
600	Verão	605,69*	613,64*	65,96*	73,91*
720	Inverno	311,01*	343,37*	17,64*	50,00*
720	Outono	327,61*	413,58*	16,27*	102,25*
720	Primavera	215,43*	221,31*	26,45*	32,33*
720	Verão	331,11*	328,31*	42,12*	39,33*
840	Inverno	143,34*	165,07*	7,81*	29,55*
840	Outono	210,04*	233,49*	18,17*	41,62*
840	Primavera	75,63*	74,94*	12,2*	11,51*
840	Verão	201,34*	175,92*	38,24*	12,82*
960	Inverno	82,87*	105,11*	0,71	22,96*
960	Outono	141,52*	172,88*	6,17*	37,52*
960	Primavera	44,7*	58,84*	1,45	15,59*
960	Verão	132,31*	117,06*	23,71*	8,47*

* p-valor $\leq 0,05$

Tabela 7. Ajuste do modelo de autorregressão espacial (MAE) para temperatura da superfície terrestre (TST) em função de métricas de paisagem da vegetação arbórea em diferentes escalas de unidades de análise para cidade de Brasília, Brasil.

UA	Estação	PCArv	DF	IMF	DB	Área	Forma	IA	R ²	CIA
120	Inverno	-5,14e-03*	2,84e-04*	-4,17e-03*	-1,29e-03*	1,33e-01*	1,26e-01*	3,11e-04	0,91	46775,60
		-6,06e-02	2,60e-02	-5,05e-02	-9,78e-02	2,30e-02	1,92e-02	3,08e-03		
120	Outono	-3,63e-03*	8,53e+00*	-4,32e-03*	-7,60e-04*	1,34e-01*	8,18e-02*	-5,94e+00	0,92	28441,40
		-6,96e-02	1,27e-02	-8,49e-02	-9,39e-02	3,77e-02	2,03e-02	-9,56e-04		
120	Primavera	-1,03e-02*	2,48e-04*	-4,21e-03	-1,28e-03*	3,31e-01*	4,26e-02	9,10e-04	0,92	53725,60
		-9,69e-02	1,82e-02	-4,07e-02	-7,79e-02	4,56e-02	5,20e-03	7,21e-03		
120	Verão	-5,63e-03*	2,71e+00	-5,95e-03*	-4,40e-04*	3,13e-01*	2,11e-02	1,30e-03*	0,93	39883,20
		-7,49e-02	2,81e-02	-8,12e-02	-3,78e-02	6,10e-02	3,62e-03	1,45e-02		
240	Inverno	-1,14e-02*	1,33e-03*	-6,76e-03*	-2,76e-03	9,53e-02*	-1,20e-02*	2,63e-03	0,78	13351,92
		-1,30e-01	9,40e-02	-8,06e-02	-1,90e-01	6,05e-02	-1,41e-03	1,93e-02		
240	Outono	-8,57e-03*	5,04e-04*	-7,60e-03*	-1,42e-03*	1,08e-01*	4,02e-02*	-1,99e-03	0,82	8809,02
		-1,58e-01	5,77e-02	-1,46e-01	-1,58e-01	1,11e-01	7,61e-03	-2,35e-02		
240	Primavera	-1,95e-02*	1,24e-03*	-8,32e-03*	-3,07e-03	1,88e-01*	-1,19e-01*	9,58e-04	0,78	15160,24
		-1,79e-01	7,10e-02	-7,98e-02	-1,70e-01	9,60e-02	-1,13e-02	5,64e-03		
240	Verão	-1,11e-02*	2,70e-04*	-1,18e-02	-5,70e-04*	2,02e-01*	-5,97e-02*	-1,87e-03	0,82	11870,9
		-1,41e-01	2,12e-02	-1,56e-01	-4,36e-02	1,42e-01	-7,77e-03	-1,52e-02		
360	Inverno	-7,93e-03*	1,86e-03	-1,67e-02*	-3,73e-03*	8,77e-02*	-1,39e-01*	3,94e-03	0,75	5719,94
		-8,93e-02	1,22e-01	-1,99e-01	-2,49e-01	1,16e-01	-1,35e-02	2,40e-02		
360	Outono	-6,78e-03*	6,63e-04	-1,41e-02*	-2,00e-03*	7,24e-02*	1,41e-02*	-4,01e-03	0,78	3865,99
		-1,22e-01	6,97e-02	-2,69e-01	-2,13e-01	1,53e-01	2,19e-03	-3,90e-02		
360	Primavera	-1,74e-02*	1,65e-03	-1,86e-02*	-4,43e-03*	1,27e-01*	-3,56e-01*	6,89e-04	0,73	6535,36
		-1,58e-01	8,80e-02	-1,79e-01	-2,39e-01	1,36e-01	-2,79e-02	3,39e-03		
360	Verão	-1,15e-02*	2,41e-04	-1,76e-02	-6,21e-04*	1,28e-01	-1,33e-01*	-6,53e-03	0,78	5216,05
		-1,40e-01	1,73e-02	-2,28e-01	-4,50e-02	1,85e-01	-1,40e-02	-4,33e-02		
480	Inverno	2,59e-02*	2,89e-03*	-4,69e-02*	-6,18e-03*	3,22e-02*	-8,85e-02*	-4,32e-04	0,71	3051,05
		2,91e-01	1,86e-01	-5,62e-01	-4,15e-01	6,99e-02	-7,03e-03	-2,44e-03		
480	Outono	-3,44e-03*	8,86e-04	-1,60e-02*	-2,60e-03*	3,51e-02*	8,58e-02*	-9,96e-03	0,77	2026,17
		-6,07e-02	8,93e-02	-3,00e-01	-2,74e-01	1,19e-01	1,07e-02	-8,82e-02		
480	Primavera	2,31e-02*	2,56e-03	-5,76e-02*	-7,43e-03*	6,48e-02*	-3,92e-01*	-7,50e-03	0,70	3473,59
		2,10e-01	1,33e-01	-5,58e-01	-4,04e-01	1,14e-01	-2,52e-02	-3,43e-02		
480	Verão	-2,61e-03*	6,87e-04	-2,34e-02	-1,71e-03*	7,04e-02*	4,96e-01*	-2,06e-02*	0,78	2709,28
		-3,11e-02	4,67e-02	-2,97e-01	-1,22e-01	1,62e-01	4,17e-02	-1,23e-01		
600	Inverno	2,13e-02*	4,14e-03	-4,56e-02*	-7,29e-03*	3,83e-02*	1,12e-01*	2,09e-03	0,69	1857,32
		2,29e-01	2,55e-01	-5,22e-01	-4,69e-01	1,19e-01	6,77e-03	9,14e-03		
600	Outono	-1,04e-02*	1,31e-03	-1,25e-02*	-3,09e-03*	3,14e-02*	4,39e-01*	-9,12e-03	0,77	1192,31
		-1,79e-01	1,28e-01	-2,28e-01	-3,16e-01	1,56e-01	4,22e-02	-6,35e-02		
600	Primavera	1,89e-02*	4,37e-03	-5,50e-02*	-9,42e-03*	4,55e-02*	-6,76e-02*	3,30e-04	0,69	2082,46
		1,65e-01	2,18e-01	-5,11e-01	-4,91e-01	1,15e-01	-3,31e-03	1,17e-03		
600	Verão	-1,58e-02*	6,33e-04	-1,32e-02	-1,63e-03	5,29e-02*	8,95e-01*	-2,88e-02*	0,77	1611
		-1,83e-01	4,18e-02	-1,62e-01	-1,13e-01	1,77e-01	5,80e-02	-1,35e-01		
720	Inverno	4,20e-02*	4,33e-03*	-6,98e-02*	-8,14e-03*	3,60e-02*	-3,45e-01*	-7,14e-04	0,69	1221,99
		4,53e-01	2,66e-01	-8,10e-01	-5,29e-01	1,74e-01	-2,33e-02	-2,94e-03		
720	Outono	-9,19e-03*	1,06e-03	-1,37e-02	-3,14e-03	2,27e-02*	1,57e-01*	-1,95e-02	0,76	805,83
		-1,57e-01	1,03e-01	-2,52e-01	-3,23e-01	1,74e-01	1,68e-02	-1,27e-01		
720	Primavera	3,95e-02*	4,91e-03*	-8,28e-02*	-1,07e-02*	4,54e-02*	-4,54e-01*	1,23e-03	0,70	1362,27
		3,48e-01	2,46e-01	-7,85e-01	-5,67e-01	1,80e-01	-2,51e-02	4,13e-03		
720	Verão	-2,18e-02*	-3,13e-04	-1,15e-02	-1,00e-03	4,24e-02	1,39e-01*	-3,81e-02	0,75	1115,05
		-2,49e-01	-2,03e-02	-1,41e-01	-6,89e-02	2,16e-01	9,94e-03	-1,66e-01		
840	Inverno	7,23e-02*	4,97e-03*	-9,10e-02*	-1,06e-02*	3,67e-03*	-2,18e-02	-1,75e-02	0,67	803,57
		7,83e-01	3,12e-01	-1,04e+00	-7,12e-01	2,17e-02	-1,27e-03	-7,43e-02		
840	Outono	-5,49e-03*	5,96e-04	-1,55e-02	-3,06e-03	1,63e-02*	1,14e-01*	-2,63e-02	0,76	530,05
		-8,95e-02	5,64e-02	-2,67e-01	-3,09e-01	1,46e-01	9,98e-03	-1,69e-01		
840	Primavera	6,99e-02*	4,40e-03*	-1,02e-01*	-1,40e-02*	3,04e-03*	-1,72e-01	-4,66e-02	0,69	900,98
		6,06e-01	2,21e-01	-9,38e-01	-7,51e-01	1,44e-02	-8,02e-03	-1,58e-01		
840	Verão	-2,22e-02*	-7,37e-04	-8,42e-03	-8,61e-04	3,22e-02	3,09e-01*	-5,11e-02	0,75	738,5
		-2,42e-01	-4,66e-02	-9,72e-02	-5,82e-02	1,92e-01	1,82e-02	-2,19e-01		
960	Inverno	5,27e-02*	6,53e-03*	-7,14e-02*	-1,19e-02*	3,77e-03*	3,53e-01	-1,98e-02	0,59	652,12
		5,61e-01	3,97e-01	-8,18e-01	-7,63e-01	2,91e-02	2,22e-02	-8,03e-02		
960	Outono	-1,49e-02*	1,60e-03	-1,13e-02	-3,66e-03	1,28e-02*	2,67e-01*	-9,11e-03	0,74	407,52
		-2,48e-01	1,51e-01	-2,01e-01	-3,66e-01	1,54e-01	2,61e-02	-5,74e-02		
960	Primavera	3,80e-02*	6,26e-03	-6,68e-02*	-1,52e-02*	-1,01e-03*	4,09e-01	-4,85e-02	0,62	705,95
		3,34e-01	3,13e-01	-6,31e-01	-8,03e-01	-6,45e-03	2,12e-02	-1,62e-01		
960	Verão	-3,78e-02*	4,33e-05*	-9,76e-04	-1,24e-03	2,41e-02	6,06e-01*	-3,04e-02	0,73	561,83
		-4,17e-01	2,73e-03	-1,16e-02	-8,27e-02	1,93e-01	3,94e-02	-1,28e-01		

* p-valor ≤ 0,05

A variável PARv apresentou efeito negativo sobre a TST nas unidades de análise de 120 a 360 m e efeito positivo sobre a TST em unidades acima de 480 m. Porém, no outono, o PARv contribuiu para reduzir a temperatura em todas as unidades de análise pelo modelo MAE (Tabela 7). O IMF apresentou efeitos negativos sobre a TST em locais amplos, principalmente no inverno e outono. Efeito similar ao IMF também foi observado para a DB, onde o aumento da borda dos fragmentos arbóreos urbanos por unidade de área contribuiu para o resfriamento do ambiente nas maiores unidades de análise. O IA teve pouca contribuição sobre a redução da TST, tendo contribuição ligeiramente em áreas amplas no verão e outono (Tabela 7). As variáveis DF e Area não contribuíram para o resfriamento do ambiente pelo MAE.

Foi observado que o MEE apresentou valores de R^2 ligeiramente superiores aos encontrados com MAE, demonstrando ser o modelo mais indicado para estimativa da TST. O critério de informação de Akaike (CIA) apresentou valores altos nas unidades de análise de menor área entre 120 m e 360 m. A partir de 480 m, o valor de CIA tem pouca variação tendendo a uma estabilização (Tabela 8).

As métricas de composição e configuração contribuíram de forma diferente na explicação da variação da temperatura. A variável de composição PARv teve importante contribuição no resfriamento do ambiente nas unidades de 120 a 480 m em todas as estações climáticas, quando comparado com as demais métricas de paisagem. Em unidades de análise acima de 600 m, o PARv não contribuiu para o resfriamento nas estações primavera e inverno, apenas no verão e no outono pelo MEE (Tabela 7). As variáveis IMF e DB também contribuíram para o efeito de resfriamento, tendo menor efeito nas unidades de 120 a 480 m em relação ao PARv. Porém, entre 600 e 960 m, o IMF e DB apresentaram contribuição significativa para redução da TST, tendo contribuição superior ao observado para o PARv. Por outro lado, a DF teve efeito positivo sobre a temperatura, indicando que a fragmentação da vegetação arbórea não contribui para o resfriamento do ambiente em unidades de análise acima de 360 m.

Tabela 8. Ajuste do modelo de erro espacial (MEE) para temperatura da superfície terrestre (TST) em função de métricas de paisagem da vegetação arbórea em diferentes escalas de unidades de análise para cidade de Brasília, Brasil.

UA	Estação	PCArv	DF	IMF	DB	Área	Forma	IA	R ²	CIA
120	Inverno	-2,69e-02*	-2,81e-04*	4,12e-03*	-4,67e-04*	7,68e-02	-4,07e-02	3,34e-02	0,92	46128,80
		-3,17e-01	-2,58e-02	4,98e-02	-3,55e-02	1,32e-02	-6,21e-03	3,31e-04		
120	Outono	-1,87e-02*	-3,14e-04*	2,17e-03*	-2,12e-04*	6,32e-02*	-4,37e-02*	-1,71e-04	0,93	27632,50
		-3,58e-01	-4,68e-02	4,27e-02	-2,62e-02	1,77e-02	-1,08e-02	-2,74e-03		
120	Primavera	-3,77e-02*	-4,38e-04*	6,34e-03*	-2,16e-04*	2,11e-01*	-1,40e-01*	6,26e-04	0,92	53056,20
		-3,56e-01	-3,22e-02	6,13e-02	-1,32e-02	2,91e-02	-1,71e-02	4,96e-03		
120	Verão	-2,41e-02*	-3,88e-04*	3,27e-03*	1,68e-04*	1,48e-01*	-1,06e-01*	8,29e-04*	0,93	39293,50
		-3,21e-01	-4,02e-02	4,46e-02	1,44e-02	2,87e-02	-1,82e-02	9,27e-03		
240	Inverno	-4,54e-02*	6,23e-04*	1,25e-02*	-2,26e-03*	-3,57e-02*	1,39e-02	-1,13e-03	0,80	13008,33
		-5,17e-01	4,42e-02	1,49e-01	-1,56e-01	-2,27e-02	1,63e-03	-8,24e-03		
240	Outono	-3,10e-02*	-1,74e-05*	5,38e-03	-1,09e-03*	4,81e-03*	3,32e-02	-3,55e-03	0,84	8355,3
		-5,71e-01	-2,00e-03	1,03e-01	-1,21e-01	4,92e-03	6,27e-03	-4,19e-02		
240	Primavera	-6,44e-02*	4,64e-04*	1,62e-02	-2,15e-03*	3,08e-02*	-2,59e-02	-3,16e-03	0,80	14816,34
		-5,91e-01	2,65e-02	1,56e-01	-1,19e-01	1,57e-02	-2,44e-03	-1,86e-02		
240	Verão	-3,74e-02*	-2,60e-04*	3,99e-03	-1,50e-04	4,86e-02	-7,37e-02*	-3,85e-03	0,83	11600,59
		-4,74e-01	-2,05e-02	5,28e-02	-1,15e-02	3,43e-02	-9,59e-03	-3,13e-02		
360	Inverno	-4,21e-02*	1,24e-03*	3,60e-03*	-3,65e-03	4,53e-02*	-2,13e-01*	-1,27e-03	0,77	5565,4
		-4,74e-01	8,19e-02	4,29e-02	-2,43e-01	6,01e-02	-2,07e-02	-7,75e-03		
360	Outono	-2,87e-02*	1,62e-04*	-1,70e-03	-1,82e-03	2,30e-02*	-5,53e-02	-5,66e-03	0,81	3634,42
		-5,16e-01	1,71e-02	-3,23e-02	-1,94e-01	4,86e-02	-8,57e-03	-5,50e-02		
360	Primavera	-6,29e-02*	7,39e-04*	7,04e-03	-3,66e-03	8,65e-02*	-3,54e-01*	-5,80e-03	0,75	6393,75
		-5,72e-01	3,93e-02	6,78e-02	-1,97e-01	9,27e-02	-2,77e-02	-2,85e-02		
360	Verão	-3,54e-02*	8,04e-06*	-3,42e-03	-2,49e-04	4,96e-02	-2,72e-01*	-7,16e-03	0,79	5120,59
		-4,34e-01	5,77e-04	-4,44e-02	-1,80e-02	7,16e-02	-2,87e-02	-4,75e-02		
480	Inverno	-1,56e-02*	2,33e-03	-1,79e-02*	-5,92e-03*	1,09e-02*	-1,60e-01	-4,21e-03	0,74	2967,97
		-1,76e-01	1,50e-01	-2,14e-01	-3,98e-01	2,37e-02	-1,27e-02	-2,38e-02		
480	Outono	-2,78e-02*	1,25e-04*	-1,88e-03	-2,34e-03	1,24e-02*	-5,01e-03	-9,51e-03	0,81	1871,37
		-4,91e-01	1,26e-02	-3,52e-02	-2,46e-01	4,22e-02	-6,24e-04	-8,42e-02		
480	Primavera	-3,26e-02*	1,40e-03*	-2,00e-02	-6,11e-03	6,55e-02*	-5,13e-01*	-1,10e-02	0,72	3417,91
		-2,97e-01	7,27e-02	-1,94e-01	-3,32e-01	1,15e-01	-3,29e-02	-5,02e-02		
480	Verão	-2,57e-02*	4,80e-04*	-1,09e-02	-1,37e-03	3,91e-02*	3,53e-01*	-1,80e-02	0,79	2661,94
		-3,07e-01	3,27e-02	-1,39e-01	-9,74e-02	8,97e-02	2,97e-02	-1,08e-01		
600	Inverno	-3,13e-03*	4,52e-03	-3,02e-02*	-8,93e-03*	4,01e-02*	1,44e-01*	-4,89e-03	0,72	1803,15
		-3,37e-02	2,78e-01	-3,46e-01	-5,74e-01	1,25e-01	8,72e-03	-2,14e-02		
600	Outono	-2,86e-02*	7,88e-04*	-1,52e-03	-3,65e-03	1,64e-02*	3,74e-01*	-1,49e-02	0,81	1085,75
		-4,91e-01	7,72e-02	-2,76e-02	-3,73e-01	8,13e-02	3,59e-02	-1,03e-01		
600	Primavera	-1,20e-02*	4,67e-03	-3,51e-02*	-1,08e-02*	4,87e-02*	2,43e-01*	-5,84e-03	0,70	2057,38
		-1,05e-01	2,33e-01	-3,26e-01	-5,61e-01	1,23e-01	1,19e-02	-2,07e-02		
600	Verão	-3,31e-02*	6,15e-04*	-2,68e-03	-1,86e-03	2,59e-02*	7,34e-01*	-3,46e-02*	0,79	1580,83
		-3,83e-01	4,06e-02	-3,29e-02	-1,28e-01	8,67e-02	4,76e-02	-1,63e-01		
720	Inverno	1,54e-02*	4,86e-03	-5,04e-02*	-9,39e-03*	4,06e-02*	-6,55e-01*	-1,35e-02	0,72	1187,84
		1,66e-01	2,99e-01	-5,85e-01	-6,11e-01	1,97e-01	-4,43e-02	-5,55e-02		
720	Outono	-2,63e-02*	5,67e-04*	-3,91e-03	-3,59e-03	1,02e-02*	-2,41e-02	-2,63e-02	0,80	732,17
		-4,49e-01	5,51e-02	-7,19e-02	-3,70e-01	7,82e-02	-2,58e-03	-1,72e-01		
720	Primavera	9,00e-03*	5,37e-03	-6,04e-02*	-1,14e-02*	4,93e-02*	-5,66e-01*	-8,28e-03	0,70	1355,79
		7,93e-02	2,69e-01	-5,72e-01	-6,05e-01	1,95e-01	-3,13e-02	-2,79e-02		
720	Verão	-4,32e-02*	-9,46e-04*	2,82e-04	-1,01e-03	1,94e-02	-5,73e-02	-4,08e-02	0,76	1093,03
		-4,91e-01	-6,12e-02	3,45e-03	-6,90e-02	9,91e-02	-4,09e-03	-1,77e-01		
840	Inverno	6,12e-02*	5,54e-03*	-8,75e-02*	-1,24e-02*	8,20e-03*	-1,02e+00	-1,35e-02	0,70	783,29
		6,62e-01	3,48e-01	-1,00e+00	-8,30e-01	4,86e-02	-5,93e-02	-5,75e-02		
840	Outono	-1,72e-02*	-7,79e-05*	-1,00e-02	-3,31e-03	1,32e-02*	-5,96e-01	-2,60e-02	0,80	495,58
		-2,81e-01	-7,37e-03	-1,73e-01	-3,35e-01	1,18e-01	-5,24e-02	-1,66e-01		
840	Primavera	5,94e-02*	4,96e-03*	-1,02e-01*	-1,53e-02*	5,24e-03*	-7,30e-01	-3,28e-02	0,69	900,94
		5,15e-01	2,49e-01	-9,37e-01	-8,23e-01	2,49e-02	-3,41e-02	-1,12e-01		
840	Verão	-4,13e-02*	-1,95e-03*	3,42e-03	-2,00e-04	2,54e-02	-6,79e-01*	-4,77e-02	0,75	733,44
		-4,51e-01	-1,23e-01	3,95e-02	-1,35e-02	1,52e-01	-3,99e-02	-2,04e-01		
960	Inverno	3,86e-02*	6,83e-03*	-6,03e-02*	-1,46e-02*	1,09e-02*	-6,04e-01	-3,87e-02	0,64	627,08
		4,11e-01	4,15e-01	-6,91e-01	-9,39e-01	8,41e-02	-3,79e-02	-1,57e-01		
960	Outono	-2,68e-02*	3,39e-04*	-4,36e-03	-4,72e-03	6,65e-03*	-1,86e-01	-2,12e-02	0,80	362,87
		-4,45e-01	3,21e-02	-7,77e-02	-4,72e-01	8,00e-02	-1,81e-02	-1,33e-01		
960	Primavera	2,23e-02*	6,02e-03	-5,58e-02*	-1,72e-02*	5,92e-03*	-2,03e-01	-6,28e-02	0,65	693,6
		1,96e-01	3,01e-01	-5,27e-01	-9,11e-01	3,77e-02	-1,05e-02	-2,10e-01		
960	Verão	-5,61e-02*	-2,70e-03*	1,15e-02	-1,06e-03	1,52e-02	-2,35e-01	-4,49e-02	0,75	552,09
		-6,20e-01	-1,70e-01	1,36e-01	-7,09e-02	1,22e-01	-1,53e-02	-1,88e-01		

* p-valor $\leq 0,05$

4. Discussão

4.1 Contribuição da vegetação urbana no resfriamento do ambiente

Na área urbana de Brasília, onde o estudo foi realizado, o período chuvoso está concentrado no verão, que se inicia em dezembro e termina no início de março. Antes desse período ocorre longa estiagem, com duração de cerca de oito a nove meses, fazendo com que a vegetação arbórea e rasteira diminua a biomassa de folhas, o que contribui para reduzir a umidade no interior das células. Ao iniciar o período chuvoso, a vegetação arbórea e rasteira inicia a emissão de novas folhas, aumentando o índice de área foliar e reduzindo a incidência direta da radiação solar sobre o solo, contribuindo assim para a redução da temperatura de superfície.

A temperatura da vegetação arbórea apresenta os menores valores no outono, o que pode estar relacionado com a máxima cobertura de copa das árvores, em resposta ao período de chuva que ocorre no verão. Após o período chuvoso, a região passa por um longo período com baixa incidência de chuvas no inverno e na primavera, caracterizado pela baixa umidade relativa do ar e pela redução da cobertura de folhas. Isto certamente contribui para formação de ilhas de calor.

Áreas cobertas por vegetação rasteira não apresentaram qualquer efeito negativo em relação à temperatura da superfície terrestre, o que demonstra baixa eficiência desse componente da vegetação na redução da temperatura. Porém, este resultado é contrário ao observado em outros estudos (Dai, Guldmann e Hu, 2018; Hu, Dai e Guldmann, 2021). Segundo Hu *et al.* (2021), a capacidade de evapotranspiração da copa das árvores é superior a das áreas gramadas, pois as árvores tem copa tridimensional, enquanto que as áreas gramadas possuem superfície plana e menor evapotranspiração. Além disso, as árvores produzem sombra e quebra vento, diminuindo a evaporação e mantendo a umidade, produzindo efeito negativo sobre a temperatura da superfície. Devido às características climáticas da região, é importante a adoção de boas práticas de manejo aos gramados, como a irrigação no período de estiagem para que a vegetação tenha alto vigor fisiológico e reduza do desconforto térmico (Zhou, Wang e Cadenasso, 2017).

Além desses aspectos, deve-se considerar que as áreas gramadas podem apresentar eficiência no resfriamento quando associado a outros componentes urbanos, como prédios e casas residenciais (Wu, Li e Li, 2021). Essa associação pode potencializar os serviços ecossistêmicos prestados pelos gramados, como o aumento da evapotranspiração local, que somado ao sombreamento das construções pode contribuir

para melhoria no conforto térmico. Alguns estudos destacam, que árvores situadas próximas a prédios podem reduzir a temperatura interna no verão, diminuindo o uso de aparelhos refrigeradores de ambiente (Elmes *et al.*, 2017; Gage e Cooper, 2017a; Nowak *et al.*, 2002, 2016). Por outro lado, pode potencializar o resfriamento interno das construções no inverno, acarretando o aumento do consumo de energia para aquecimento. Dessa forma, deve-se avaliar o porte da vegetação que será implantada, espaçamento, distância das construções, dentre outras, para evitar possíveis conflitos na execução do projeto.

4.2 Associação espacial das métricas de paisagem com a temperatura de superfície terrestre (TST)

Os espaços com predominância de gramíneas apresentaram diferentes efeitos sobre a TST ao longo do ano. No período chuvoso, que coincide com o verão, as métricas de Area e IA da vegetação rasteira apresentaram efeito negativo sobre a TST, indicando redução da temperatura (Figura 3). Esse efeito é progressivamente mais forte quando há aumento da unidade de análise, ou seja, são necessárias áreas gramadas maiores e próximas para auxiliar no resfriamento, como observado por Hu *et al.* (2021).

Por outro lado, a vegetação nativa presente em remanescentes florestais e em áreas protegidas definidas no Sistema Nacional de Unidade de Conservação da Natureza (Lei 9.985 de 2000) foi caracterizada em função do PCArv, da Area e do IA (Figura 5). Observa-se que essas regiões contribuíram para redução da temperatura da superfície ao longo das estações secas e úmidas, demonstrando a importância desses ambientes na prevenção de ilhas de calor urbano (Figura 4). Além disso, essas áreas protegidas contribuem para a formação de corredores ecológicos entre os fragmentos florestais situados no entorno de Brasília com a vegetação arbórea urbana (Kowe *et al.*, 2020).

A vegetação arbórea urbana apresentaram características diferentes quando comparadas aos fragmentos naturais de floresta. As variáveis que melhor caracterizaram a vegetação arbórea urbana foram a densidade de fragmento (DF) e densidade de borda (DB) demonstrando que os fragmentos de vegetação arbórea no centro de Brasília estão dispersos e não apresentam tendência de agrupamento. Os locais onde a DF e a DB foram não significativos, coincide com áreas de ocorrência de clusters Alto-Alto de TST na região oeste-leste (Figuras 4 e 5). Nessa região há predominância de prédios comerciais, contribuindo para formação de agrupamentos Alto-Alto para temperatura de superfície,

principalmente no verão, decorrentes não apenas das características biofísicas urbanas, mas também da variabilidade do clima e do calor antrópico (Guo, Wu e Chen, 2019). Por outro lado, o agrupamento significativo de clusters de DF e DB em Alto-Alto para vegetação arbórea urbana pode estar relacionado com o efeito não significativo do agrupamento da TST no outono, inverno e primavera, indicando que essas características da vegetação arbórea urbana tiveram influência sobre a TST (Figuras 4 e 5).

A vegetação arbórea situada na região centro-sul apresentou unidades de análise agrupadas como Alto-Alto para métrica Forma, indicando a predominância de fragmentos florestais de alta complexidade, com valores acima de 1,19. Isso pode estar relacionado com a disposição de faixas de árvores no entorno das construções, distribuídas nas quadras e próximas a vias públicas (Asgarian, Amiri e Sakieh, 2015). Quando a variável Forma tem valor próximo a 1, indica que os fragmentos têm forma regular, aproximando-se de um quadrado ou círculo. Valores superiores a 1 indicam que maior é a complexidade da forma do fragmento (McGarigal, 2015). A alta complexidade da forma da arborização urbana contribuiu para reduzir e manter a temperatura da superfície baixa quando comparado a outras regiões com alta densidade de construção e pavimentação (Figura 5E).

O aumento da tortuosidade da borda e a forma complexa dos fragmentos florestais contínuos proporcionam aumento do fluxo de calor latente da copa pela evapotranspiração e reduz o fluxo de calor sensível pelo sombreamento da borda dos fragmentos (Asgarian, Amiri e Sakieh, 2015; Peng, Wang e Bai, 2020). Assim, a forma complexa da vegetação arbórea é uma variável que pode ser explorada no planejamento da arborização urbana, visando reduzir a temperatura e produzir zonas de resfriamento sem aumentar o percentual de cobertura vegetal (Peng, Wang e Bai, 2020). No entanto, deve-se evitar a formação de fragmentos dispersos, caracterizados pelo aumento da densidade de borda (DB) e ocasionando na redução da umidade e maior amplitude de temperatura no interior dos fragmentos.

A região com alta concentração de construções no centro-norte da cidade apresentou divisão política semelhante ao centro-sul, com prolongamento de vias que ligam as duas regiões, além do número e tamanho das quadras que são semelhantes. No entanto, mesmo a região centro-norte apresentando considerável concentração de árvores no entorno das vias, praças e nas quadras, esse efeito não foi significativo para que as árvores fossem agrupadas em função da variável Forma, como ocorreu na região centro-sul (Figura 5).

Em estudo que relacionou a configuração das árvores urbanas à temperatura, Zhou *et al.* (2017) observaram que a densidade de borda das árvores reduziu a temperatura em Baltimore, mas teve efeito positivo em Sacramento, ambas cidades dos EUA. Esse resultado indica que é necessário avaliar qual característica da vegetação arbórea produz melhor efeito sobre a temperatura, seja pelo aumento da evapotranspiração proveniente do agrupamento das árvores ou pelo aumento do sombreamento, proveniente do aumento da densidade de borda. O mesmo número de árvores com alta densidade de borda indica que são feições pequenas e fragmentadas, podendo levar a baixa evapotranspiração (Hu, Dai e Guldmann, 2021). Deve-se considerar também que a proporção entre essas duas variáveis afeta a temperatura de forma diferente, em função das espécies, da configuração espacial das árvores, das práticas de manejo e das condições climáticas que influenciam a temperatura do ar, a radiação local e deficiência de pressão de vapor (Guo, Wu e Chen, 2019; Heinemann *et al.*, 2020; Li *et al.*, 2017; Wang *et al.*, 2011).

4.3 Modelagem da contribuição da vegetação arbórea para redução das ilhas de calor urbano

A composição e configuração da vegetação arbórea urbana contribuiu para explicar aproximadamente de 50% da variação da temperatura nas diferentes estações pelo MRL (Modelo de Regressão Linear), valor subestimado devido à autocorrelação espacial das variáveis, principalmente em grades menores onde a TST tem maior amplitude, menor variação e forte autocorrelação espacial devido à proximidade das unidades de análise (Dai, Guldmann e Hu, 2019; Hu, Dai e Guldmann, 2021). Devido à autocorrelação espacial das variáveis, é interessante utilizar modelos que considerem a autocorrelação espacial, evitando possíveis subestimativas dos efeitos das variáveis ou mesmo a interpretação equivocada dos dados (Li *et al.*, 2012; Song *et al.*, 2014; Zhou, Wang e Cadenasso, 2017).

A partir do coeficiente padronizado ou coeficiente beta é possível observar que as métricas PCArv (Percentual de Cobertura de Árvore), DB (Densidade de Borda) e IMF (Índice de Maior Fragmento) foram aquelas que mais contribuíram para redução da temperatura nos três modelos avaliados, o que é consistente com outros estudos (Dai, Guldmann e Hu, 2018; Hu, Dai e Guldmann, 2021). O PCArv apresentou efeito significativo na TST em unidades de 120 m a 360 m, porém ocorreu inversão do efeito a partir da grade 480 m na primavera e no inverno, utilizando o MRL e o MAE.

O MEE captou o efeito negativo do PCArv até unidades de 600, invertendo o sinal do coeficiente em grades superiores a esse valor. Algumas espécies arbóreas perdem grande parte da cobertura vegetal entre o inverno e a primavera devido à escassez de chuva e também para investir energia na produção de flores e frutos na primavera, indicando a necessidade de estratégias que melhorem o ambiente durante todo ano (Hu, Dai e Guldmann, 2020).

A eficiência de resfriamento da vegetação, avaliada a partir da redução da temperatura da superfície terrestre com o aumento de 1% de cobertura arbórea, foi maior nas unidades de análise de 120 e 240 m. O MEE indicou que a eficiência de resfriamento na unidade de análise 120 m foi maior no inverno com $-0,03$ °C e menor no verão com $0,01$ °C. Na unidade de análise de 240 m o maior efeito de resfriamento foi de $-0,06$ °C na primavera e a menor foi de $-0,03$ °C no outono.

As variáveis de configuração apresentaram efeitos positivos e negativos em relação a temperatura. O MAE e MEE indicaram que a DF tem contribuído para o aumento da temperatura, com aumento no valor do coeficiente proporcional a área da grade, enquanto o IMF indicou que a predominância de maiores fragmentos de vegetação arbórea permite a redução da temperatura do ambiente, principalmente na primavera e no inverno (Tabelas 6 e 7).

De forma similar ao IMF, a DB dos fragmentos teve relação negativa com a temperatura nos três modelos avaliados. Assim, com o aumento da unidade de análise, o PCArv tem menor efeito e as variáveis DB e IMF apresentam maior contribuição no resfriamento do ambiente. Esse comportamento também foi observado por Zhou *et al.* (2017) na cidade de Sacramento, que apresenta clima quente e seco, semelhante ao clima de Brasília. Em ambiente quente e úmido, a elevação da DB, considerando uma mesma quantidade de cobertura de árvores, produz maior sombra e maior fluxo e troca de energia entre a vegetação e áreas do entorno, contribuindo para redução da TST. Por outro lado, o aumento da DB em ambientes quentes e com baixa umidade relativa do ar, considerando uma mesma quantidade de cobertura de árvores, tende a aumentar o estresse da vegetação arbórea e reduzir a transpiração, contribuindo positivamente para o aumento da TST (Zhou, Wang e Cadenasso, 2017). Assim, as características climáticas da área de interesse devem ser consideradas no arranjo espacial das árvores urbanas e na compreensão dos efeitos da vegetação arbórea sobre a temperatura.

Como o IMF também teve efeito negativo sobre a temperatura, pode-se inferir que a vegetação arbórea disposta em grandes fragmentos interligados tem maior efeito sobre

a temperatura em grandes áreas quando comparado aos percentuais de cobertura arbórea para região de estudo.

Os modelos de regressão demonstraram que a área média dos fragmentos arbóreos (Area) tem relação positiva com a temperatura, porém o coeficiente de correlação demonstrou relação inversa entre a área média e a temperatura em todas as unidades de análise nas quatro estações do ano. Segundo Zhou *et al.* (2017), essa inconsistência nas análises pode ocorrer devido à alta correlação positiva existente entre a área média dos fragmentos e o percentual de cobertura, e isto pode ser corrigido utilizando o PCArv na correlação parcial da Área com a TST. Além da correlação parcial, o uso de modelos de regressão linear e autocorrelação parcial também permitem identificar a existência de inconsistências na predição da temperatura por meio de métricas de vegetação (Zhou, Wang e Cadenasso, 2017).

A variável Forma apresentou valores negativos entre as unidades de 120 a 360, porém não foram todas as estações que apresentaram valores significativos. Isso demonstra que o aumento da complexidade da forma dos fragmentos pode contribuir para o resfriamento do ambiente, como já indicado pelo DB. Por outro lado, o IA não apresentou valores consistentes entre os modelos avaliados.

5. Conclusão

Nesse estudo, foi possível observar que a vegetação arbórea urbana contribuiu de forma significativa para redução da temperatura, amenizando o desconforto térmico ocasionado pelas áreas impermeáveis na cidade. As áreas cobertas por vegetação rasteira, que neste estudo incluiu plantas herbáceas, arbustiva e gramíneas, apresentaram correlação positiva com a temperatura de superfície terrestre (TST), indicando pouca contribuição no resfriamento do ambiente.

Foi observado que o coeficiente de correlação e o modelo de regressão linear desconsideram a correlação espacial dos dados, podendo levar a interpretações equivocadas. Assim, o modelo de erro espacial (MEE) mostrou-se ligeiramente melhor que o modelo de autorregressão espacial (MAE) para predição da temperatura de superfície terrestre (TST) em função de métricas provenientes da vegetação arbórea. Dentre as métricas, o percentual de cobertura arbórea (PCArv), o índice de maior fragmento (IMF) e a densidade de borda (DB) apresentaram maior contribuição na

redução da temperatura, informação esta que deve ser considerada no plano de manejo da vegetação arbórea.

As unidades de análise entre 120 e 480 m mostraram-se melhores para modelagem da temperatura em função da vegetação arbórea, podendo ser implementado para produção de cenários auxiliares no planejamento das áreas verdes urbanas. É importante considerar no planejamento que a atual configuração e composição da vegetação arbórea urbana tem maior contribuição para redução da temperatura no verão e no outono, sendo necessário considerar as informações acima mencionadas para melhorar o conforto térmico também no inverno e primavera.

6. Referências bibliográficas

ALEXANDER, C. Normalised difference spectral indices and urban land cover as indicators of land surface temperature (LST). **International Journal of Applied Earth Observation and Geoinformation**, v. 86, n. July 2019, p. 102013, 2020.

ANSELIN, L. Local Indicators of Spatial Association—LISA. **Geographical Analysis**, v. 27, n. 2, p. 93–115, 1995.

_____. **GeoDa 0.9 User's Guide**. 2003.

_____. **Spatial Regression Analysis in R: A Workbook**. [s.l.: s.n.].

_____. **Exploring Spatial Data with GeoDaTM: A Workbook**. [s.l.: s.n.].

ANSELIN, L.; SYABRI, I.; KHO, Y. GeoDa: An introduction to spatial data analysis. **Geographical Analysis**, v. 38, n. 1, p. 5–22, 2006.

ASGARIAN, A.; AMIRI, B. J.; SAKIEH, Y. Assessing the effect of green cover spatial patterns on urban land surface temperature using landscape metrics approach. **Urban Ecosystems**, v. 18, n. 1, p. 209–222, 2015.

ATHUKORALA, D.; MURAYAMA, Y. Urban heat island formation in greater cairo: Spatio-temporal analysis of daytime and nighttime land surface temperatures along the urban-rural gradient. **Remote Sensing**, v. 13, n. 7, 2021.

BASTON, D. **exactextractr: Fast Extraction from Raster Datasets using Polygons**, 2021. Disponível em: <<https://cran.r-project.org/package=exactextractr>>

BERGER, C.; ROSENRETER, J.; VOLTERSEN, M.; BAUMGART, C.; SCHMULLIUS, C.; HESE, S. Spatio-temporal analysis of the relationship between 2D/3D urban site characteristics and land surface temperature. **Remote Sensing of Environment**, v. 193, p. 225–243, 2017.

BIVAND, R.; KEITT, T.; ROWLINGSON, B. **rgdal: Bindings for the “Geospatial” Data Abstraction Library**, 2021. Disponível em: <<https://cran.r-project.org/package=rgdal>>

- BIVAND, R. S.; WONG, D. W. S. Comparing implementations of global and local indicators of spatial association. **TEST**, v. 27, n. 3, p. 716–748, 2018.
- CÂMARA, G.; CARVALHO, M. S.; CRUZ, O. G.; CORREA, V. Análise espacial de áreas. In: DRUCK, S.; CARVALHO, MARÍLIA SÁ; CÂMARA, G.; MONTEIRO, A. M. V. (Eds.). **Análise Espacial de Dados Geográficos**. Brasília: [s.n.]. .
- CHEN, A.; YAO, X. A.; SUN, R.; CHEN, L. Effect of urban green patterns on surface urban cool islands and its seasonal variations. **Urban Forestry and Urban Greening**, v. 13, n. 4, p. 646–654, 2014.
- CHEN, L.; WANG, X.; CAI, X.; YANG, C.; LU, X. Seasonal variations of daytime land surface temperature and their underlying drivers over Wuhan, China. **Remote Sensing**, v. 13, n. 2, p. 1–22, 2021.
- DAI, Z.; GULDMANN, J. M.; HU, Y. Spatial regression models of park and land-use impacts on the urban heat island in central Beijing. **Science of the Total Environment**, v. 626, p. 1136–1147, 2018.
- DAI, Z.; GULDMANN, J. M.; HU, Y. Thermal impacts of greenery, water, and impervious structures in Beijing’s Olympic area: A spatial regression approach. **Ecological Indicators**, v. 97, n. July 2018, p. 77–88, 2019.
- DAS, D. N.; CHAKRABORTI, S.; SAHA, G.; BANERJEE, A.; SINGH, D. Analysing the dynamic relationship of land surface temperature and landuse pattern: A city level analysis of two climatic regions in India. **City and Environment Interactions**, v. 8, p. 100046, 2020.
- DU, S.; XIONG, Z.; WANG, Y. C.; GUO, L. Quantifying the multilevel effects of landscape composition and configuration on land surface temperature. **Remote Sensing of Environment**, v. 178, p. 84–92, 2016.
- EDMONDSON, J. L.; STOTT, I.; DAVIES, Z. G.; GASTON, K. J.; LEAKE, J. R. Soil surface temperatures reveal moderation of the urban heat island effect by trees and shrubs. **Scientific Reports**, v. 6, p. 1–8, 2016.
- ELMES, A.; ROGAN, J.; WILLIAMS, C.; RATICK, S.; NOWAK, D.; MARTIN, D. Effects of urban tree canopy loss on land surface temperature magnitude and timing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 128, p. 338–353, 2017.
- ESTOQUE, R. C.; MURAYAMA, Y.; MYINT, S. W. Effects of landscape composition and pattern on land surface temperature: An urban heat island study in the megacities of Southeast Asia. **Science of the Total Environment**, v. 577, p. 349–359, 2017.
- GAGE, E. A.; COOPER, D. J. Urban forest structure and land cover composition effects on land surface temperature in a semi-arid suburban area. **Urban Forestry and Urban Greening**, v. 28, n. September, p. 28–35, 2017.
- GUO, A.; YANG, J.; SUN, W.; XIAO, X.; XIA CECILIA, J.; JIN, C.; LI, X. Impact of urban morphology and landscape characteristics on spatiotemporal heterogeneity of

- land surface temperature. **Sustainable Cities and Society**, v. 63, n. August, p. 102443, 2020.
- GUO, G.; WU, Z.; CHEN, Y. Complex mechanisms linking land surface temperature to greenspace spatial patterns: Evidence from four southeastern Chinese cities. **Science of the Total Environment**, v. 674, n. 230, p. 77–87, 2019.
- HEINEMANN, S. et al. Land surface temperature retrieval for agricultural areas using a novel UAV platform equipped with a thermal infrared and multispectral sensor. **Remote Sensing**, v. 12, n. 7, 2020.
- HIJMANS, R. J. **raster: Geographic Data Analysis and Modeling**, 2021. Disponível em: <<https://cran.r-project.org/package=raster>>
- HU, X.; ZHOU, W.; QIAN, Y.; YU, W. Urban expansion and local land-cover change both significantly contribute to urban warming, but their relative importance changes over time. **Landscape Ecology**, v. 32, n. 4, p. 763–780, 2017.
- HU, Y.; DAI, Z.; GULDMANN, J. M. Modeling the impact of 2D/3D urban indicators on the urban heat island over different seasons: A boosted regression tree approach. **Journal of Environmental Management**, v. 266, n. 11, p. 110424, 2020.
- HU, Y.; DAI, Z.; GULDMANN, J. M. Greenspace configuration impact on the urban heat island in the Olympic Area of Beijing. **Environmental Science and Pollution Research**, n. 2017, 2021.
- HUANG, G.; ZHOU, W.; CADENASSO, M. L. Understanding the relationship between urban land surface temperature, landscape heterogeneity and social structure. **International Geoscience and Remote Sensing Symposium (IGARSS)**, n. January 2015, p. 3933–3936, 2010.
- KOWE, P.; MUTANGA, O.; ODINDI, J.; DUBE, T. A quantitative framework for analysing long term spatial clustering and vegetation fragmentation in an urban landscape using multi-temporal landsat data. **International Journal of Applied Earth Observation and Geoinformation**, v. 88, n. January, p. 102057, 2020.
- LI, X.; ZHOU, W.; OUYANG, Z. Relationship between land surface temperature and spatial pattern of greenspace: What are the effects of spatial resolution? **Landscape and Urban Planning**, v. 114, p. 1–8, 2013.
- LI, X.; ZHOU, W.; OUYANG, Z.; XU, W.; ZHENG, H. Spatial pattern of greenspace affects land surface temperature: Evidence from the heavily urbanized Beijing metropolitan area, China. **Landscape Ecology**, v. 27, n. 6, p. 887–898, 2012.
- LI, Z.; WU, W.; LIU, XUEHUA; FATH, B. D.; SUN, H.; LIU, XINCHAO; XIAO, X.; CAO, J. Land use/cover change and regional climate change in an arid grassland ecosystem of Inner Mongolia, China. **Ecological Modelling**, v. 353, p. 86–94, 2017.
- LU, L.; WENG, Q.; XIAO, D.; GUO, H.; LI, Q.; HUI, W. Spatiotemporal variation of surface urban heat islands in relation to land cover composition and configuration: A multi-scale case study of Xi'an, China. **Remote Sensing**, v. 12, n. 17, 2020.

- MAIMAITIYIMING, M.; GHULAM, A.; TIYIP, T.; PLA, F.; LATORRE-CARMONA, P.; HALIK, Ü.; SAWUT, M.; CAETANO, M. Effects of green space spatial pattern on land surface temperature: Implications for sustainable urban planning and climate change adaptation. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 89, p. 59–66, 2014.
- MCGARIGAL, K. **Fragstats. Fragstats**, n. April, p. 1–182, 2015.
- NOWAK, D. J.; HOEHN, R. E.; BODINE, A. R.; GREENFIELD, E. J.; O’NEIL-DUNNE, J. Urban forest structure, ecosystem services and change in Syracuse, NY. **Urban Ecosystems**, v. 19, n. 4, p. 1455–1477, 2016.
- NOWAK, D. J.; STEVENS, J. C.; SISINNI, S. M.; LULEY, C. Effects of urban tree management and species selection on atmospheric carbon dioxide. **Journal of Arboriculture**, v. 28, n. 3, p. 113–122, 2002.
- NYELELE, C.; KROLL, C. N.; NOWAK, D. J. Present and future ecosystem services of trees in the Bronx, NY. **Urban Forestry and Urban Greening**, v. 42, p. 10–20, 2019.
- OKE, T. R. The energetic basis of the urban heat island. **Quarterly Journal of the Royal Meteorological Society**, v. 108, n. 455, p. 1–24, 1982.
- PENG, Y.; WANG, Q.; BAI, L. Identification of the key landscape metrics indicating regional temperature at different spatial scales and vegetation transpiration. **Ecological Indicators**, v. 111, n. January, p. 106066, 2020.
- QIN, Z.; KARNIELI, A.; BERLINER, P. A mono-window algorithm for retrieving land surface temperature from Landsat TM. **International journal of remote sensing**, v. 22, n. 18, p. 3719–3746, 2001.
- RANAGALAGE, M. et al. Spatiotemporal variation of urban heat islands for implementing nature-based solutions: A case study of kurunegala, Sri Lanka. **ISPRS International Journal of Geo-Information**, v. 9, n. 7, 2020.
- SOBRINO, J. A.; JIMÉNEZ-MUÑOZ, J. C.; PAOLINI, L. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**, v. 90, n. 4, p. 434–440, 2004.
- SOBRINO, J.; JIMENEZ, J.; SORIA, G.; GUANTER, L.; MORENO, J.; PLAZA, A.; MARTINEZ, P. Land surface emissivity retrieval from different VNIR and TIR sensors. **IEEE Transactions on Geoscience and Remote Sensing**, v. 2, n. 46, p. 316–327, 2008.
- SONG, J.; DU, S.; FENG, X.; GUO, L. The relationships between landscape compositions and land surface temperature: Quantifying their resolution sensitivity with spatial regression models. **Landscape and Urban Planning**, v. 123, p. 145–157, 2014.
- SRIVANIT, M.; IAMTRAKUL, P. Spatial patterns of greenspace cool islands and their relationship to cooling effectiveness in the tropical city of Chiang Mai, Thailand. **Environmental Monitoring and Assessment**, v. 191, n. 9, 2019.

- TEAM, R. C. **R: A Language and Environment for Statistical Computing** Vienna, Austria **R Foundation for Statistical Computing**, 2020. Disponível em: <<https://www.r-project.org/>>
- TENNEKES, M. **tmap: Thematic Maps in R**. **Journal of Statistical Software**, v. 84, n. 6, p. 1–39, 2018.
- VENTER, Z. S.; KROG, N. H.; BARTON, D. N. Linking green infrastructure to urban heat and human health risk mitigation in Oslo, Norway. **Science of the Total Environment**, v. 709, p. 136193, 2020.
- WALKER, K. **tigris: Load Census TIGER/Line Shapefiles**, 2021. Disponível em: <<https://cran.r-project.org/package=tigris>>
- WANG, F.; QIN, Z.; SONG, C.; TU, L.; KARNIELI, A.; ZHAO, S. An improved mono-window algorithm for land surface temperature retrieval from landsat 8 thermal infrared sensor data. **Remote Sensing**, v. 7, n. 4, p. 4268–4289, 2015.
- WANG, H.; OUYANG, Z.; CHEN, W.; WANG, X.; ZHENG, H.; REN, Y. Water, heat, and airborne pollutants effects on transpiration of urban trees. **Environmental Pollution**, v. 159, n. 8–9, p. 2127–2137, 2011.
- WANG, J.; ZHOU, W.; JIAO, M.; ZHENG, Z.; REN, T.; ZHANG, Q. Significant effects of ecological context on urban trees' cooling efficiency. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, n. 18, p. 78–89, 2020.
- WICKHAM, H.; FRANÇOIS, R.; HENRY, L.; MÜLLER, K. **dplyr: A Grammar of Data Manipulation**, 2021. Disponível em: <<https://cran.r-project.org/package=dplyr>>
- WU, W.; LI, L.; LI, C. Seasonal variation in the effects of urban environmental factors on land surface temperature in a winter city. **Journal of Cleaner Production**, v. 299, p. 126897, 2021.
- ZHOU, W.; HUANG, G.; CADENASSO, M. L. Does spatial configuration matter? Understanding the effects of land cover pattern on land surface temperature in urban landscapes. **Landscape and Urban Planning**, v. 102, n. 1, p. 54–63, 2011.
- ZHOU, W.; WANG, J.; CADENASSO, M. L. Effects of the spatial configuration of trees on urban heat mitigation: A comparative study. **Remote Sensing of Environment**, v. 195, p. 1–12, 2017.

CAPÍTULO III

Identificação e caracterização de árvores urbanas utilizando dados de laser aerotransportado

Resumo

A obtenção de informações sobre a vegetação arbórea urbana é importante para conhecer o patrimônio natural e auxiliar na implantação e manejo da arborização. No entanto, inventários florestais contínuos tem custo elevado, podendo inviabilizar sua execução, ocasionando em defasagem das informações ao longo do tempo. Os órgãos responsáveis pela gestão das cidades adquiririam dados de sensoriamento remoto para atender outros fins e podem ser utilizados para gerar informações sobre as árvores urbanas. Esse estudo teve por objetivo avaliar identificação de árvores individuais a partir de dados LiDAR (*Light Detection and Ranging*) em área urbana de Brasília. As árvores foram identificadas a partir de modelo de altura de copa (*Canopy Height Model-CHM*), suavizado com filtro média móvel e modelo gaussiano com diferentes tamanhos de janela de suavização (TJS). A identificação foi realizada pelo local máximo (LM) com variações no tamanho de janela de árvore (TJA) pelo método de janela fixa e janela variável em função da altura do CHM. A suavização com filtro média móvel apresentou melhores estimativas do número de árvores por unidade amostral, em relação ao modelo gaussiano. O LM com janela variável não apresentou melhoria na estimativa do número de árvores, em relação ao método janela fixa. A configuração TJA-TJS 5x5-5x5 estimou melhor o número de árvores em 9 das 29 unidades amostrais, com R^2 de 0,86 e $S_{xy}(\%)$ 31,15. A metodologia aplicada apresentou resultados satisfatório, considerando que as florestas urbanas tropicais são complexas, e pode ser aplicada em outras situações semelhantes.

Palavras-chave: floresta urbana, modelo de altura de copa, local máximo, árvore individual.

CHAPTER III

Identification and characterization of urban trees using airborne laser data

Abstract

Information on urban tree is important to know the natural heritage and to assist in the management of trees. However, continuous forest inventory has high costs and can make their time-demanding execution out-of-dated quickly. The institutions responsible for the urban information management acquire remote sensing data to several purposes and can be used to identify and monitor urban trees. The aim of this study was to evaluate algorithm to identify individual trees using LiDAR (Light Detection and Ranging) data in the Brasília urban area. The trees were identified using canopy height model (CHM) smoothed with mean and Gaussian filter with smoothing window sizes (SWS). Identification was performed by location (LM) with variations in tree window size (TWS) using the fixed and variable window method as a function of the height of the CHM. Smoothing with moving average filter presented the best estimates of the number of trees per unit model, in relation to the Gaussian. The LM with variable window showed no improvement in the estimation of the number of trees, in relation to the method of fixed window. The TWS-SWS 5x5-5x5 configuration better estimates the number of trees in 9 of the 29 sample units, with R^2 of 0.86 and $S_{xy}(\%)$ 31.15. The applied urban methodology presents satisfactory results, considering that forests are complex and can be applied in other common situations.

Keywords: urban forest, canopy height model, local maximum, individual tree.

1. Introdução

O aumento da população urbana mundial tem sido cada vez mais elevado (KAMMEN; SUNTER, 201). Algumas projeções indicam que o número de habitantes em áreas urbanas triplicará entre os anos de 2000 e 2030 (Mitchell *et al.*, 2018), e até 2050, aproximadamente dois terços da população mundial estará vivendo em centros urbanos (United Nations, 2018).

De uma forma geral, a expansão de áreas urbanas pode causar vários impactos aos recursos naturais de uma região, como, por exemplo, a redução de serviços ecossistêmicos essenciais que os recursos naturais são capazes de fornecer. Por esta razão, um dos maiores desafios de vários países no mundo inteiro é encontrar estratégias que permitam minimizar esses impactos. Entre essas estratégias, está a implantação e manutenção de árvores urbanas, capazes de fornecer inúmeros benefícios as populações citadinas (Chang *et al.*, 2017; Kardan *et al.*, 2015), considerando a importância das florestas urbanas na manutenção do equilíbrio ambiental das cidades. Aliado a isso, é necessário gerar informações precisas que auxiliem na gestão das florestas urbanas e que permitam avaliar o potencial dessas florestas em melhorar o conforto térmico, reduzir o consumo de energia, absorver carbono da atmosfera, dentre outras (Chen, Xu e Gao, 2015; Kaartinen *et al.*, 2012).

Portanto, a existência de um banco de dados com informações sobre as árvores urbanas é fundamental para o planejamento das cidades (Guo *et al.*, 2019; Tanhuanpää *et al.*, 2014). Porém, a complexidade das características estruturais das cidades e da distribuição espacial das árvores urbanas, tanto em áreas públicas quanto privadas, acaba dificultando a estimativa de parâmetros relativos às áreas arborizadas (He *et al.*, 2013; Liu *et al.*, 2013; Nowak, David J *et al.*, 2008).

Nas últimas décadas, pesquisas realizadas com imagens aéreas de alta resolução espacial têm mostrado o potencial dessa tecnologia na produção de informações sobre as florestas urbanas, principalmente na identificação da copa de árvores, entretanto, deve-se considerar suas limitações quanto à estimativa de variáveis tridimensionais (Singh *et al.*, 2015; Wagner *et al.*, 2018; Wulder, Niemann e Goodenough, 2000). Em contrapartida, o

LiDAR (*Light Detection and Ranging*) têm apresentado maior eficiência em relação às imagens aéreas, na obtenção de atributos florestais, considerando que tais tecnologias aerotransportadas permitem estimar com maior precisão as variáveis biométricas tridimensionais das florestas (He *et al.*, 2013; Popescu e Wynne, 2004), como altura das árvores, diâmetro a altura do peito, diâmetro de copas etc.

Além disso, a obtenção de informações tridimensionais de árvores urbanas a partir de perfilamento a laser apresenta menor custo em relação às informações geradas por métodos tradicionais de campo, que demandam maior tempo para execução (Kaartinen *et al.*, 2012; Popescu, Wynne e Nelson, 2003). Esse custo é ainda menor quando as cidades já possuem dados de laser aerotransportado adquiridos para outros propósitos, como planejamento de áreas residenciais e comerciais, rede de drenagem, implantação de vias, entre outros (Tanhuanpää *et al.*, 2014).

A altura das árvores é um dos atributos florestais mais importantes para compor o banco de dados das árvores urbanas, já que essa variável pode ser utilizada tanto para avaliar o estado ecológico da árvore (Leites, Robinson e Crookston, 2009) quanto para estimar os serviços ecossistêmicos que as árvores podem fornecer para um local, como, por exemplo, o sequestro de carbono (Brando, 2018; Stereńczak *et al.*, 2019). Em inventários florestais, as tecnologias laser aerotransportadas já estão sendo amplamente utilizadas para medir a altura das árvores (Alexander, Korstjens e Hill, 2018; Andersen, Reutebuch e McGaughey, 2006; Barnes *et al.*, 2017; Bottalico *et al.*, 2017; González-Ferreiro *et al.*, 2013; Mohan *et al.*, 2019).

Modelos de altura de dossel ou *canopy height model* (CHM), produzidos a partir de nuvem de pontos do laser aerotransportado, têm sido muito utilizados para detecção de árvores individuais (DAI), possibilitando a determinação de métricas, como diâmetro e área da copa, que caracterizam a estrutura das árvores e que são essenciais para avaliar e monitorar a cobertura de copa em relação a possíveis distúrbios (Dalagnol *et al.*, 2019; Erfanfard *et al.*, 2018; Fujimoto *et al.*, 2019). Existem vários algoritmos que podem ser aplicados para detecção e extração de árvores a partir do CHM, porém, cada algoritmo apresenta desempenho diferente em função das características da floresta (Kaartinen *et al.*, 2012), sendo necessário aplicar e avaliar a performance do algoritmo em florestas com estruturas complexas, como é o caso das florestas urbanas (Liu *et al.*, 2013).

O algoritmo local máximo (LM) tem apresentado bons resultados na DAI em florestas temperadas (Gu, Grybas e Congalton, 2020; Hyyppä *et al.*, 2012; Liu *et al.*, 2019; Mohan *et al.*, 2017; Song *et al.*, 2010; Wulder, Niemann e Goodenough, 2000), em

florestas tropicais (Millikan *et al.*, 2019), em plantios florestais (Corte *et al.*, 2020) e em culturas agrícolas (García-Murillo, Caicedo-Acosta e Castellanos-Dominguez, 2020; Mohan *et al.*, 2019), podendo, também, apresentar resultados satisfatórios quando aplicado em florestas urbanas. O LM foi desenvolvido e avaliado inicialmente em paisagens florestais, não apresentando pré-processamento para separação de árvores e edifícios (Chen, Xu e Gao, 2015). Assim, é necessário determinar o tamanho da janela de filtro do algoritmo que contemple a estrutura espacial das árvores urbanas, já que janelas de filtro muito pequenas ou muito grandes podem ocasionar em subestimativa ou superestimativa (Popescu e Wynne, 2004; Popescu, Wynne e Nelson, 2003).

Portanto, objetivo do presente estudo foi identificar e produzir métricas de árvores urbanas a partir dados LiDAR aerotransportado em Brasília (DF). Para identificação das árvores urbanas serão testados (a) os métodos de suavização do CHM por média móvel e pelo modelo gaussiano, associados a (b) diferentes tamanhos de janela de identificação do topo de árvore pelo algoritmo local máximo (LM). A parametrização de algoritmo para DAI urbana é fundamental para conhecer o patrimônio natural das cidades e auxiliar na gestão das árvores urbanas.

2. Material e métodos

2.1 Área de estudo

O presente estudo foi desenvolvido em uma área urbana situada em Brasília, Distrito Federal (Figura 1). A precipitação média anual e a temperatura média anual na região varia entre 1.300 e 1.600 mm e 20 e 22 °C, respectivamente. O clima predominante da região é classificado como Aw, com inverno seco e verão chuvoso (Alvares *et al.*, 2013). O relevo da região situa-se entre as altitudes 850 e 1.400 m em relação ao nível do mar, com altitude média de 1.100 m.



Figura 1. Localização da área de estudo no Distrito Federal, Brasília, Brasil.

O Distrito Federal está situado dentro das bacias hidrográficas do Paraná, Tocantins/Araguaia e São Francisco (Codeplan, 2012; SFB, 2016). Cerca de 23% do território do Distrito Federal é ocupado por florestas nativas, 2% por florestas plantadas e 75% por outros usos da terra. A maior parte da vegetação nativa da região é representada por duas fitofisionomias do Bioma Cerrado, ou seja, cerrado *sensu stricto* e mata de galeria. Dentre as regiões administrativas do Distrito Federal, Brasília possui segunda maior proporção de área coberta por vegetação nativa, cerca de 45% (SFB, 2016).

2.2 Censo Florestal

Os dados do censo florestal utilizado neste estudo, foi obtido do projeto SmartUnB, conduzido em parte da área urbana de Brasília (DF), perfazendo área de aproximadamente 132 ha. Foram considerados no censo florestal indivíduos lenhosos com diâmetro a altura do peito (DAP) maior ou igual a 10 cm. Esse levantamento contemplou total de 4.726 árvores. Os indivíduos arbóreos foram identificados ao nível de espécie, mensurado o DAP e obtida a altura total da árvore. A localização geográfica dos indivíduos lenhosos foi obtida por Sistema de Posicionamento Global (GNSS – *Global Navigation Satellite System*) no sistema RTK (*Real Time Kinematic*) com resolução espacial de 50 cm.

As árvores urbanas mensuradas no censo florestal foram agrupadas por setores administrativos (SA) urbanos. Isso foi possível a partir da localização geográfica das árvores e pela representação espacial dos SA em sistema de informação geográfica (SIG). Foram selecionadas 29 SAs com dimensões variando de 0,70 a 11,52 hectares. Nesse estudo, os SAs foram considerados como unidades amostrais (UA), afim de avaliar a precisão do algoritmo na estimativa das variáveis

2.3 Aquisição de dados LiDAR

Foram utilizados dados LiDAR (*Light Detection and Ranging*) aerotransportado por avião, com a emissão de feixes de laser na faixa do infravermelho próximo que escaneia o terreno e a cobertura vegetal, assim como edificações presentes na área. O aerolevanteamento foi realizado em toda área de estudo a uma altitude que permitiu a obtenção de densidade mínima de 4 pontos/m², com sobreposição lateral de 20%. Essa quantidade de pontos por m² é considerada adequada (Singh *et al.*, 2015). O sensor utilizado foi o ALS-60, fabricado pela Leica Geosystems, trabalhando com comprimento de onda $\lambda = 1.064$ nm, amplitude operacional de 200 a 5.000 m e abertura máxima do ângulo de visada de 75°.

Devido as condições meteorológicas, os voos não puderam ser realizados em períodos contínuos e em curto espaço de tempo. Dessa forma, o aerolevanteamento foi realizado no período de 28/06/2016 a 29/08/2016. Para garantir a superposição lateral de 20% entre faixas contínuas e para garantir que todos os pontos da área de interesse tivessem recobrimento em regiões influenciadas pela variação do relevo foram consideradas as seguintes características do LiDAR: altura média de voo de 575 m, altitude média de 1.575 m, potência do sensor de 360 kHz, velocidade da aeronave de 80 m.s⁻¹ e sensor com ângulo de abertura (*Field of View*) de 60°.

No processamento da nuvem de pontos foi realizada a classificação dos pontos por meio dos múltiplos retornos e pela intensidade do sinal, sendo possível classificar em solo, edificação e vegetação (alta, média e baixa) (Figura 1).

Tabela 1. Código de classificação da nuvem de pontos LiDAR.

Código	Classe
1	Não classificado
2	Solo
3	Baixa vegetação
4	Média vegetação
5	Alta vegetação
6	Construção

2.4 Obtenção do modelo de altura de copa (*Canopy Height Model* - CHM)

Para produção do modelo de altura de dossel (*Canopy Height Model* - CHM) foram utilizados os pontos correspondentes às árvores urbanas, sendo necessário a remoção dos pontos relativos a construções e edifícios, pois essas informações podem ser utilizadas de forma indevida no processamento e produção do CHM (Man *et al.*, 2020). Dessa forma, a classe relativa a construções (classe 6) foi removida do banco de dados.

O CHM foi obtido pela diferença entre o modelo digital de superfície (MDS) e o modelo digital de terreno (MDT). Esses modelos foram obtidos pela interpolação das elevações dos pontos LiDAR, porém, durante o processo de interpolação pode surgir espaços vazios ou espúrios (pits), decorrente da passagem do feixe de laser pelos galhos e folhas antes do primeiro retorno ou devido a ocorrência de feixes de laser em diferentes ângulos de visada, a partir de diferentes linhas de voo, ocasionando em variação na altura do ponto (Khosravipour *et al.*, 2014).

Os dados espúrios registrados no processo de interpolação foram suavizados com filtro média móvel ou filtro gaussiano, porém, o processo de suavização pode causar alterações nos valores de altura do CHM e importantes informações podem ser perdidas (Khosravipour *et al.*, 2014; Zhao *et al.*, 2013). Desta forma, para contornar esse problema, o algoritmo pit-free CHM utiliza como metodologia a produção de diferentes camadas de CHM, em diferentes alturas do solo, e posterior sobreposição dessas camadas (Khosravipour *et al.*, 2013, 2014). Para atender essa metodologia, os dados de altitude dos pontos de laser foram normalizados, ou seja, os valores dos pontos foram alterados para a altura vertical do ponto em relação ao solo pelo modelo digital de terreno (MDT).

A partir da interpretação visual da imagem aérea e da nuvem de pontos em locais com áreas com árvores urbanas foi possível definir os limiares de 0 m, 5 m, 10 m, 15 m e 20 m para produção das camadas de CHM com a interpolação dos pontos pelo algoritmo TIN (*Triangular Irregular Network*). As camadas de CHM produzidas são sobrepostas de modo a compor o CHM sem dados espúrios (pit-free CHM), onde cada pixel sobreposto terá como valor a maior altura entre os pixels das diferentes camadas (Khosravipour *et al.*, 2013). O tamanho dos pixels do CHM ou resolução espacial do CHM pode ser determinado a partir da densidade dos primeiros retornos do LiDAR (Eq. 1) (Chen *et al.*, 2006). No levantamento por aerofotogrametria foram obtidos em média 4 pontos por m², ou seja, a resolução espacial do CHM foi de 0,50 m.

$$d = \sqrt{1/n} \quad \text{Eq.1}$$

em que n é o número de retornos por m².

2.5 Identificação de árvores urbanas por meio de dados LiDAR

A detecção individual das árvores (DAI) urbanas foi realizada pelo processamento automático do CHM, porém, a identificação do topo das árvores por meio de algoritmos pode ser realizada de modo equivocado, devido à presença de galhos espalhados nas copas das árvores, que podem ser classificados como topos de árvore, ocasionando em superestimativa dos pontos máximos das árvores. Os valores do CHM podem ser suavizados utilizando diferentes tipos de filtros, reduzindo a presença de valores discrepantes nas copas das árvores (galhos dominantes) e aumentando a precisão na identificação das árvores. Os filtros média móvel e gaussiano têm sido utilizados para suavização do CHM no processo de identificação de árvores individuais. Entretanto, é necessário avaliar e definir valores adequados para os parâmetros dos filtros, aumentando a precisão na DAI em cada tipo de vegetação.

Os filtros média móvel e gaussiano foram avaliados pelo tamanho da janela de suavização (TJS) com dimensões de 3x3 m, 5x5 m e 7x7 m. O filtro gaussiano tem o parâmetro desvio padrão (σ), porém, o seu valor apresenta pouca influência sobre a suavização do CHM. Alguns estudos adotam o valor 2 para esse parâmetro (Barnes *et al.*, 2017; Chen *et al.*, 2006), no entanto, prévias avaliações atribuindo os valores 1, 2 e 3 para σ , mostraram melhor desempenho para $\sigma=3$ (Eq. 2).

$$G(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{(x^2+y^2)}{2\sigma^2}} \quad \text{Eq. 2}$$

em que G é o kernel gaussiano, com desvio padrão σ e localização determinada por x e y.

A convolução do filtro tem suavização com desvio padrão (σ). A suavização do CHM por média móvel ou gaussiano reduz os dados espúrios ou ruídos, além de reduzir os pixels vazios, produzidos durante a interpolação da nuvem de pontos.

Após remoção dos dados espúrios do CHM foi aplicado o algoritmo local máximo (LM) para identificação do topo das árvores, determinando a posição geográfica e a obtenção de métricas de cada árvore. O filtro LM identifica o pixel de maior valor dentro de uma janela móvel de dimensão fixa. Esse valor corresponde ao topo da árvore ou a um ponto mais próximo ao seu topo. A dimensão da janela pode variar de tamanho em função das características estruturais das árvores e em função da resolução espacial da imagem, sendo recomendado que a resolução espacial da imagem deva ser melhor que a média do diâmetro da copa das árvores (Wulder, Niemann e Goodenough, 2000).

Foram aplicados tamanhos de janela de árvore (TJA) com dimensões de 3x3 m, 5x5 m e 7x7 m para identificação do local máximo. Combinações entre os parâmetros de suavização do CHM e tamanhos de janelas móveis foram realizadas visando melhorar a precisão do algoritmo na identificação do topo das árvores.

Também foi avaliado o potencial de identificação de árvores individuais utilizando uma função ajustada relacionando o diâmetro médio da copa e a altura da árvore. Uma amostra composta por 308 árvores urbanas, com DAP variando entre 5,80 e 205 cm e altura total variando de 2,10 e 28,28 m, foi utilizada para obter o diâmetro médio de copa a partir da interpretação visual de imagem em ambiente de sistema de informação geográfica (SIG). As árvores selecionadas pertencem a diferentes classes de DAP (diâmetro a altura do peito) e apresentam copas com perímetro visível nas imagens. O diâmetro médio da copa das árvores foi obtido a partir da mensuração manual do diâmetro de copa da árvore a partir da interpretação do CHM e imagens áreas obtidas por aerofotogrametria com resoluções de 0,50 m e 0,10 m, respectivamente. O diâmetro médio da copa de cada árvore foi obtido a partir da média de duas medições do diâmetro de copa no sentido Norte-Sul e Leste-Oeste.

O processamento dos dados LiDAR foi realizado no software R (Team, 2020), utilizando o pacote lidR (Roussel *et al.*, 2020). O pacote lidR permite ajustar o tamanho

da janela de suavização do CHM e o tamanho da janela de identificação do topo das árvores pelo algoritmo LM.

2.6 Precisão da estimativa do número de árvores

A estimativa do número de árvores foi realizada por unidade amostral. Foram selecionadas 29 unidades amostrais, considerando áreas com ocorrência de infraestrutura urbana e árvores. Foi considerado como unidade amostral os setores administrativos (SA), com tamanhos variáveis. O número de árvores por unidade amostral foi comparado aos valores encontrados pelo algoritmo utilizando as diferentes combinações dos parâmetros de tamanho de janela de suavização (TJS) e tamanho de janela de árvore (TJA). A qualidade dos ajustes dos algoritmos foi avaliada por meio do coeficiente de determinação (R^2), desvio padrão absoluto (S_{yx}) e desvio padrão relativo ($S_{yx}\%$).

$$R^2 = 1 - \left(\frac{SQ_{res}}{SQ_t} \right) \quad (1)$$

$$S_{yx} = \sqrt{\frac{\sum_{i=1}^n (P_i - O_i)^2}{n-p-1}} \quad (2)$$

$$S_{yx}\% = \frac{S_{yx}}{O} * 100 \quad (3)$$

A precisão das estimativas também foi avaliada pelo positivo verdadeiro (PV), que indica o número de árvores identificadas corretamente; pelo falso negativo (FN), que indica o número de árvores não identificadas; pelo falso positivo (FP), que corresponde ao número de objetos identificados incorretamente como árvores. A partir dessas informações, é possível obter o recall (r) que representa a quantidade de dados classificados como positivos em relação aos reais positivos; a precisão (p) representa os positivos em relação as todas as classificações positivas; e F-score (F) determina a qualidade geral do modelo (Goutte e Gaussier, 2005).

$$r = \frac{PV}{PV+FN} \quad (4)$$

$$p = \frac{PV}{PV+FP} \quad (5)$$

$$F = 2 * \frac{r*p}{r+p} \quad (6)$$

3. Resultados

3.1 Inventário Florestal Urbano

As UA apresentaram áreas variando de 0,70 ha a 11,52 ha, totalizando 132 ha de área urbana inventariada (Tabela 2). De acordo com a Tabela 1, a cobertura florestal média na área inventariada é de aproximadamente 27%, com variação de 2,98 a 51,81% entre unidades amostrais.

Tabela 2. Caracterização do inventário censo das árvores urbanas e cobertura florestal por unidade de área.

UA	Área (ha)	N	Altura (m)		DAP (cm)		Cobertura arbórea		
			Média	S _{yx}	Média	S _{yx}	Area (ha)	%	S _{yx}
1	11,03	359	7,99	4,96	34,46	22,84	3,95	35,85	504,87
2	0,70	35	5,51	2,08	23,53	12,49	0,17	25,05	96,01
3	5,01	186	7,03	3,47	32,36	20,74	1,63	32,47	407,51
4	4,07	157	7,99	2,99	31,63	17,01	1,19	29,31	534,84
5	2,19	106	7,07	2,36	40,12	17,24	1,09	49,70	903,50
6	7,75	382	6,77	2,33	32,44	15,61	2,28	29,44	422,53
7	2,77	133	11,78	3,83	37,15	22,04	1,09	39,45	518,29
8	2,52	84	8,98	5,45	36,15	19,99	0,65	25,82	209,83
9	2,60	100	6,30	2,20	34,04	16,50	0,72	27,62	293,36
10	4,08	95	7,19	4,39	26,62	15,45	0,51	12,53	202,88
11	4,65	243	7,98	2,96	32,85	19,26	1,75	37,72	581,17
12	4,98	186	10,03	3,96	40,07	22,39	2,11	42,32	988,19
13	1,09	14	10,09	3,46	46,60	29,33	0,28	25,98	193,95
14	11,52	508	6,94	3,06	34,93	19,76	4,09	35,53	425,40
15	4,70	64	10,20	4,52	45,46	20,55	0,56	11,90	182,07
16	2,46	44	4,47	1,92	13,88	6,29	0,07	2,98	30,93
17	10,76	144	6,22	4,12	23,44	20,02	0,65	6,02	145,39
18	5,97	208	7,56	3,00	32,79	18,69	1,58	26,44	222,98
19	3,34	83	6,37	2,61	26,00	16,22	0,43	12,94	113,35
20	8,66	104	5,78	2,13	21,78	10,35	0,50	5,82	43,74
21	2,23	86	9,83	3,65	51,96	75,67	0,93	41,78	1457,79
22	0,74	31	7,14	2,79	30,90	14,13	0,13	16,95	163,88
23	2,30	105	6,14	1,88	20,44	16,61	0,48	21,08	136,56
24	1,75	83	6,54	2,59	32,15	23,44	0,45	25,81	287,67
25	5,44	255	9,78	3,74	35,00	18,17	2,82	51,81	1120,19
26	6,23	279	5,15	2,07	21,60	11,78	1,01	16,18	156,73
27	5,48	318	6,48	2,15	27,83	13,58	1,92	34,96	626,70
28	3,11	153	7,08	3,89	38,20	23,56	1,15	36,81	418,37
29	3,63	181	9,15	3,61	35,32	19,34	1,85	51,12	747,13

UA: Unidade amostral; N: número de árvores registradas.

A distribuição de árvores não apresentou relação direta com o tamanho das UA, indicando que a arborização urbana na região não considerou a manutenção de proporção de cobertura florestal por UA durante o planejamento e manejo das árvores urbanas no local (Tabela 2). O menor número de árvores (14) foi registrado na UA 13 com cerca de 1,09 ha e o maior número (382) foi registrado na UA 6, que ocupa cerca de 7,75 ha.

A altura média das árvores registradas nas 29 UA variou de 4,47 m a 11,78 m. A menor variabilidade entre as alturas das árvores ocorreu na UA 23, em que o desvio padrão foi de 1,88 m. A UA 8 apresentou maior variabilidade entre as alturas das árvores, com desvio padrão de 5,45 m. O DAP das árvores registradas nas UA variou de 13,88 cm a 51,96 cm (Tabela 2).

3.2 Detecção de árvore individual em área urbana

3.2.1 Filtro média móvel e local máximo (LM) com tamanho de janela fixa

A variação no tamanho de janela de suavização (TJS) associada a variação no tamanho de janela de topo de árvore (TJA) apresentou diferentes desempenhos na detecção de árvore individual (DAI). A suavização do CHM utilizando filtro média móvel com janela menor, tende a aumentar o número de pontos máximos por árvores, ocasionando em superestimativas dos valores.

A ampliação do TJS de 3x3 m para 5x5 m resultou em considerável redução na estimativa do número de árvores, principalmente quando associado ao TJA de 3x3 m (Tabela 3). Entretanto, o aumento da janela de suavização não apresenta relação linear com a estimativa do número de árvores, o que pode ser observado pela diferença de estimativas de número de árvores suavizando o CHM com as janelas de 3x3 m, 5x5 m e 7x7 m.

As UA apresentaram redução de 24 a 45% no número de árvores estimadas com TJS de 5x5 m em relação ao TJS de 3x3 m. Essa diferença é ainda maior quando se compara a TJS 7x7 m com a 3x3 m, considerando a TJA de 3x3 m, resultando em estimativas do número de árvores por UA que varia de 40 a 64% em relação ao observado em campo.

Tabela 3. Detecção de árvore individual (DAI) com diferentes combinações no tamanho do filtro de suavização (TJS) de média do CHM (*Canopy Height Model*) e no tamanho da janela de identificação de topo de árvore (TJA) pelo algoritmo local máximo (LM) em floresta urbana. Valores em negrito indicam a estimativa mais próximo do valor real.

UA	N	Tamanho de janela de filtro											
		3x3 m				5x5 m				7x7 m			
		Tamanho de janela de árvore (TJA)											
3x3 m	5x5 m	7x7 m	9x9 m	3x3 m	5x5 m	7x7 m	9x9 m	3x3 m	5x5 m	7x7 m	9x9 m		
1	359	1200	683	478	354	745	550	439	333	543	431	374	309
2	35	58	38	30	26	42	33	29	22	35	30	28	22
3	186	472	277	197	159	289	218	175	148	209	173	156	133
4	157	341	200	131	97	201	153	115	90	138	118	100	82
5	106	226	109	73	52	124	87	61	47	81	62	50	43
6	382	735	401	282	207	450	328	246	179	306	243	199	161
7	133	321	177	113	81	190	130	97	75	128	98	81	65
8	84	163	100	72	55	101	78	67	49	75	63	56	47
9	100	183	109	81	67	119	90	72	63	88	74	70	60
10	95	165	127	107	89	100	91	83	67	85	80	75	61
11	243	467	250	175	134	270	197	156	124	190	155	136	120
12	186	455	254	174	130	267	195	155	119	194	165	134	113
13	14	52	28	21	17	26	18	17	13	16	12	12	10
14	508	1050	612	456	346	658	510	413	327	492	409	360	288
15	64	152	104	81	71	105	88	77	66	81	70	62	57
16	44	41	34	28	24	26	22	20	18	18	17	16	15
17	144	264	193	162	138	173	151	131	113	128	113	103	89
18	208	469	262	179	145	263	205	163	136	196	165	143	126
19	83	160	96	73	55	102	81	69	53	73	63	57	45
20	104	228	167	140	121	143	130	116	105	117	104	102	93
21	86	231	100	56	39	128	75	55	36	76	64	49	36
22	31	34	21	13	12	25	16	14	12	18	16	14	13
23	105	123	81	67	53	93	76	61	50	76	61	54	46
24	83	125	65	48	42	78	53	46	40	54	44	41	37
25	255	878	495	315	208	538	377	275	200	363	280	235	174
26	279	301	228	189	150	228	197	166	141	180	163	145	132
27	318	445	296	243	193	310	260	222	192	249	232	215	185
28	153	336	194	129	96	196	152	122	85	150	117	100	83
29	181	440	235	159	113	247	192	135	106	188	153	123	100
R ²		0,80	0,83	0,87	0,87	0,83	0,86	0,87	0,87	0,85	0,87	0,87	0,87
S _{xy}		272,13	87,03	46,30	70,39	103,35	50,77	54,19	78,67	51,58	53,59	68,25	88,54
S _{xy} (%)		166,99	53,41	28,41	43,20	63,42	31,15	33,25	48,27	31,65	32,88	41,88	54,33

UA: unidade amostral; N: número de árvores.

O parâmetro TJA também influenciou na DAI. A ampliação da área de identificação do topo das árvores reduz a estimativa do número de árvores por UA. Considerando valores fixos para TJS, foi observado que o número de árvores reduz com o aumento do TJA do local máximo (LM). Considerando o TJS de 3x3 m, a redução do número de árvores estimadas nas unidades amostrais variou de 42 a 83% com o TJA de 9x9 m em relação ao TJA de 3x3 m (Tabela 3). Reduzindo os valores discrepantes do CHM com média móvel de 7x7 m, foi observado menor variação na DAI utilizando TJA entre 3x3 m e 9x9 m.

Comparando os valores estimados pelas combinações de TJS e TJA com os valores obtidos pelo inventário censo foi verificado que a combinação dos filtros de suavização e de identificação do local máximo gerou maior precisão na estimativa do número de árvores nas UA. Porém, dentre as diferentes combinações de valores propostos para os parâmetros relativos à suavização e identificação do local máximo, não houve uma combinação em que o número de árvores estimado fosse igual ao número de árvores observado nas 29 UA.

A Tabela 2 destaca os valores estimados mais próximos ao valor observado. O TJS 3x3 m combinado ao TJA 3x3 m resultou em maior superestimativa do número de árvores (Tabela 3). Por outro lado, os maiores valores atribuídos a janela do filtro média móvel para suavização do CHM, associados aos maiores valores do TJA, tendem a reduzir o número de árvores identificadas por UA, subestimando o número de árvores em relação ao censo florestal.

Para cada UA houve uma combinação dos parâmetros que melhor se adequou para estimar o número de árvores, considerando como aceitável um erro relativo de $\pm 10\%$. A UA 14, com maior número de árvores entre as unidades, teve melhor estimativa do número de árvores individuais utilizando o TJS-TJA 5x5 m - 5x5 m, enquanto a UA 13, que tinha menor número de árvores, teve melhor estimativa do número de árvores utilizando a combinação TJS-TJA 5x5 m - 9x9 m. A combinação TJS-TJA 5x5 m - 5x5 m apresentou os melhores resultados para estimativa do topo de árvore, com erro relativo de $\pm 10\%$ para 13 UA, ficando o 7x7 m - 3x3 m com o segundo melhor desempenho em 7 UA (Figura 2).




Figura 2. Estimativa do erro relativo (%) para detecção de árvore individual (DAI) com variações no tamanho da janela de suavização do filtro média móvel de a) 3x3 m, b) 5x5 m e c) 7x7 m para suavização do CHM (*Canopy Height Model*), combinados a janelas de identificação de topo de árvore (TJA) 3x3 m, 5x5 m, 7x7 m e 9x9 m para o algoritmo local máximo (LM).

Considerando que foram obtidos os melhores resultados para identificação das árvores urbanas com o filtro média móvel com TJS-TJA 5x5 m - 5x5 m, é possível observar que as UA 16 e 22 apresentaram os menores valores de recall (r), indicando que o modelo subestimou o número de árvores. Nas demais UA, o valor de r foi próximo a 1, demonstrando que o número de árvores identificadas foi igual ou superior ao número real de árvores. Por outro lado, as UA 1 e 25 apresentaram os menores valores de precisão, indicando que o algoritmo superestimou o número de árvores em relação as árvores identificadas no censo florestal (Tabela 4).

A estimativa do número de árvores para a UA 25 foi superior em relação ao inventário florestal devido a ocorrência de palmeiras e/ou touceiras de bambu, que foram indevidamente identificadas como árvores. Já a UA 27 apresentou valores de r e p iguais a 0,82 e 1, respectivamente, indicando boa precisão na estimativa das árvores urbanas, o que pode ser verificado pelo valor de F-Score que foi de 0,90 (Tabela 4).

Tabela 4. Acurácia na predição de árvores urbanas a partir de *Canopy Height Model* (CHM) suavizado com filtro média móvel com janela 5x5 e tamanho de janela de 5x5 para local máximo (LM).

UA	N	PV	FN	FP	Recall (r)	Precisão (p)	F-Score (F)
1	359	359	0	191	1,00	0,65	0,79
2	35	33	2	0	0,94	1,00	0,97
3	186	186	0	32	1,00	0,85	0,92
4	157	153	4	0	0,97	1,00	0,99
5	106	87	19	0	0,82	1,00	0,90
6	382	328	54	0	0,86	1,00	0,92
7	133	130	3	0	0,98	1,00	0,99
8	84	78	6	0	0,93	1,00	0,96
9	100	90	10	0	0,90	1,00	0,95
10	95	91	4	0	0,96	1,00	0,98
11	243	197	46	0	0,81	1,00	0,90
12	186	186	0	9	1,00	0,95	0,98
13	14	14	0	4	1,00	0,78	0,88
14	508	508	0	2	1,00	1,00	1,00
15	64	64	0	24	1,00	0,73	0,84
16	44	22	22	0	0,50	1,00	0,67
17	144	144	0	7	1,00	0,95	0,98
18	208	205	3	0	0,99	1,00	0,99
19	83	81	2	0	0,98	1,00	0,99
20	104	104	0	26	1,00	0,80	0,89
21	86	75	11	0	0,87	1,00	0,93
22	31	16	15	0	0,52	1,00	0,68
23	105	76	29	0	0,72	1,00	0,84
24	83	53	30	0	0,64	1,00	0,78
25	255	255	0	122	1,00	0,68	0,81
26	279	197	82	0	0,71	1,00	0,83
27	318	260	58	0	0,82	1,00	0,90
28	153	152	1	0	0,99	1,00	1,00
29	181	181	0	11	1,00	0,94	0,97

UA: Unidade amostral; N: número de árvores de referência; PV: positivo verdadeiro; FP: Falso positivo.

3.2.2 Filtro gaussiano e local máximo com tamanho de janela fixa

De uma forma geral, o filtro de suavização gaussiano apresentou resultados menos acurados em relação ao filtro média móvel (Tabela 4).

Tabela 5. Detecção de árvore individual (DAI) utilizando variações no tamanho de janela de suavização (TJS) do modelo gaussiano e variações no tamanho de janela para identificação do topo de árvore (TJA) pelo algoritmo local máximo (LM). Valores em negrito indicam a estimativa mais próximo do valor real.

		Tamanho de Janela de Suavização (TJS)											
UA	N	3x3 m				5x5 m				7x7 m			
		Tamanho de janela de árvore (TJA)											
		3x3 m	5x5 m	7x7 m	9x9 m	3x3 m	5x5 m	7x7 m	9x9 m	3x3 m	5x5 m	7x7 m	9x9 m
1	359	1949	1192	673	393	998	759	589	397	681	580	478	366
2	35	76	52	39	17	49	40	32	20	40	33	30	26
3	186	702	462	260	164	387	298	233	162	252	227	192	148
4	157	567	341	212	132	281	220	163	124	181	147	125	105
5	106	388	227	142	89	181	126	99	70	117	96	72	59
6	382	1192	716	419	253	614	468	349	242	404	329	271	205
7	133	505	338	221	140	257	207	167	120	166	141	128	100
8	84	270	161	104	56	136	104	84	58	97	81	68	55
9	100	324	198	122	75	158	126	101	75	108	92	80	73
10	95	193	121	71	43	118	99	70	42	90	84	70	42
11	243	778	480	280	175	374	287	219	158	244	205	168	143
12	186	732	457	291	201	365	271	209	163	233	195	169	142
13	14	87	45	24	17	37	24	16	13	19	17	12	11
14	508	1690	1002	565	338	887	646	479	340	586	506	419	323
15	64	235	146	87	57	131	100	77	60	88	75	65	55
16	44	44	24	8	1	32	21	10	1	23	18	12	4
17	144	350	159	64	33	213	132	79	40	170	115	75	43
18	208	717	452	261	150	374	276	210	146	251	212	171	141
19	83	251	140	75	40	134	104	63	43	92	74	57	40
20	104	289	161	72	27	178	133	86	42	136	118	90	52
21	86	411	251	154	83	192	146	92	63	103	83	68	55
22	31	60	32	22	13	30	26	19	12	23	18	14	12
23	105	189	126	81	50	114	93	80	55	87	76	70	55
24	83	196	127	82	40	113	84	60	37	65	58	54	38
25	255	1379	897	553	334	754	567	444	292	472	393	327	263
26	279	444	258	155	81	264	221	162	94	203	182	153	114
27	318	665	438	268	169	376	320	257	179	284	261	238	196
28	153	505	331	200	124	267	209	161	112	183	156	133	110
29	181	732	463	269	171	358	265	199	153	230	197	167	136
R ²		0,79	0,77	0,75	0,74	0,80	0,81	0,80	0,79	0,83	0,84	0,84	0,83
S _{xy}		543,71	267,56	97,97	74,78	197,60	110,48	65,78	73,03	80,60	56,97	54,32	74,80
S _{xy} (%)		333,63	164,18	60,12	45,89	121,25	67,79	40,36	44,81	49,46	34,96	33,33	45,90

UA: unidade amostral; N: número de árvores.

Os menores tamanhos de janelas de suavização (TJS) tendem a aumentar o erro na identificação das árvores (superestimar), principalmente quando associado a menores

tamanhos de janela de árvore (TJA). Por outro lado, janelas de suavização maiores proporcionam menores erros na estimativa do número de árvores, porém podem subestimar o número de árvores quando associado a maiores janelas para o algoritmo local máximo (Tabela 5). Apenas em duas UA foi possível estimar o mesmo número de árvores identificadas no inventário censo (Tabela 5). Outras 7 UA apresentaram erro de subestimativa ou superestimativa devido a diferença de uma árvore em relação ao valor real.

O progressivo aumento do TJS de 3x3 m para 7x7 m contribuiu para reduzir a superestimativa do LM ao identificar o topo das árvores (Figura 3). De forma semelhante ao TJS do filtro gaussiano, o TJA do algoritmo LM também influenciou no número de árvores identificadas. O TJA de 3x3 m ocasionou em superestimativas no número de árvores, principalmente quando combinado ao valor de TJS 3x3 m, chegando a superestimar em 442,90% o número de árvores na unidade amostral 01 (Figura 3). Porém, quando há o aumento no TJA de 3x3 m para 9x9 m, associado ao TJS 3x3 m, essa mesma unidade amostral teve superestimativa de apenas 9,47%, aumentando a precisão do modelo em identificar o ponto máximo da copa da árvore.




Figura 3. Estimativa do erro relativo (%) para detecção de árvore individual (DAI) com variações no tamanho da janela de suavização do filtro gaussiano de a) 3x3 m, b) 5x5 m e c) 7x7 m para suavização do CHM (*Canopy Height Model*), combinados a janelas de identificação de topo de árvore (TJA) de 3x3 m, 5x5 m, 7x7 m e 9x9 m para o algoritmo local máximo (LM).

O TJA de 5x5 m associado a diferentes valores de TJS proporcionou redução na superestimativa do modelo, principalmente quando atribuído o valor de 7x7 m para suavização do CHM. Com essa configuração do modelo, cerca de 12 das 29 unidades amostrais apresentaram erro relativo variando de -10 a 10%, melhor resultado obtido em relação as demais configurações. Isso também foi observado quando o algoritmo foi

configurado com TJS-TJA 5x5 m - 7x7 m. Por outro lado, a ampliação das janelas para identificação do topo das árvores de 5x5 m para 9x9 m ocasionou em redução da estimativa do número de árvores, resultando em subestimativas em algumas unidades amostrais, tanto utilizando o TJS 5x5 m quanto o 7x7 m.

A Tabela 6 apresenta os valores estatísticos relativos à estimativa do número de árvores urbanas nas diferentes UA, considerando que a combinação TJS-TJA 7x7m - 5x5 m apresentou os melhores resultados para estimativa do topo das árvores.

Tabela 6. Acurácia na predição de árvores urbanas a partir de *Canopy Height Model* (CHM) suavizado com filtro de gaussiano com janela de 7x7 m e tamanho de janela de 5x5 m para local máximo (LM).

UA	N	PV	FN	FP	Recall (r)	Precisão (p)	F-Score (F)
1	359	359	0	221	1,00	0,62	0,76
2	35	33	2	0	0,94	1,00	0,97
3	186	186	0	41	1,00	0,82	0,90
4	157	147	10	0	0,94	1,00	0,97
5	106	96	10	0	0,91	1,00	0,95
6	382	329	53	0	0,86	1,00	0,93
7	133	133	0	8	1,00	0,94	0,97
8	84	81	3	0	0,96	1,00	0,98
9	100	92	8	0	0,92	1,00	0,96
10	95	84	11	0	0,88	1,00	0,94
11	243	205	38	0	0,84	1,00	0,92
12	186	186	0	9	1,00	0,95	0,98
13	14	14	0	3	1,00	0,82	0,90
14	508	506	2	0	1,00	1,00	1,00
15	64	64	0	11	1,00	0,85	0,92
16	44	18	26	0	0,41	1,00	0,58
17	144	115	29	0	0,80	1,00	0,89
18	208	208	0	4	1,00	0,98	0,99
19	83	74	9	0	0,89	1,00	0,94
20	104	104	0	14	1,00	0,88	0,94
21	86	83	3	0	0,97	1,00	0,98
22	31	18	13	0	0,58	1,00	0,73
23	105	76	29	0	0,72	1,00	0,84
24	83	58	25	0	0,70	1,00	0,82
25	255	255	0	138	1,00	0,65	0,79
26	279	182	97	0	0,65	1,00	0,79
27	318	261	57	0	0,82	1,00	0,90
28	153	153	0	3	1,00	0,98	0,99
29	181	181	0	16	1,00	0,92	0,96

UA: Unidade amostral; N: número de árvores de referência; PV: positivo verdadeiro; FP: Falso positivo.

O menor valor de recall (r) foi observado nas UA 16 e 22, demonstrando a ocorrência de altos valores de falso-negativo, ou seja, houve subestimativa do número de árvores (Tabela 5). As UA 1 e 25 apresentaram valor de r igual a 1, o que poderia indicar boa precisão do modelo em estimar o número de árvores (Tabela 5). Porém, os valores de p demonstraram que houve superestimativa do número de árvores para essas unidades amostrais e isto está relacionado a ocorrência de palmeiras, que não foram incluídas no inventário censo. Além disso, o desenvolvimento de galhos em diferentes direções ocasiona na formação de diferentes pontos máximos em janelas de 5x5 m.

3.2.3 Suavização do CHM com filtros média móvel e gaussiano e local máximo do tamanho de janela variável

A relação entre a altura total das árvores urbanas e o diâmetro de copa indica que há relação linear entre as duas variáveis (Figura 4). Assim, torna-se possível determinar o tamanho da janela de identificação do ponto máximo da árvore por meio da altura obtida pelo CHM (*Canopy Height Model*). A regressão linear simples ajustada a partir das árvores amostradas, apresentou coeficiente de determinação (R^2) de 0,65, indicando que cerca de 65% da variação do diâmetro da copa das árvores, variável dependente, pode ser explicado pelas alturas das árvores, variável independente. No entanto, o modelo ajustado pode apresentar maiores erros de estimativa para árvores com maiores alturas, uma vez que o número de árvores amostradas nas maiores classes de altura foi baixo, devido ao pouco número de árvores com altura acima de 15 m (Figura 4).

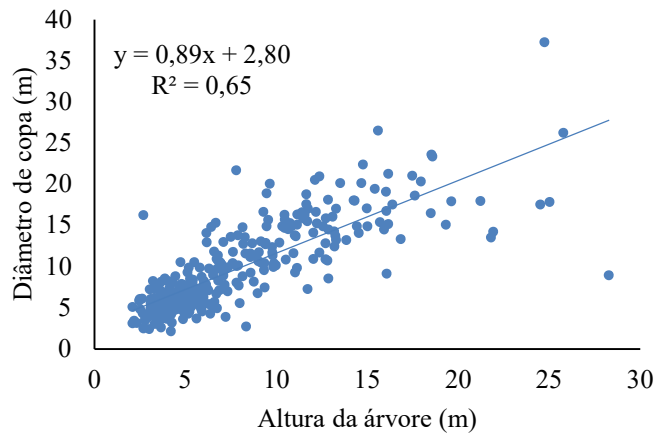


Figura 4. Relação entre o diâmetro de copa e altura total de árvores urbanas em Brasília (DF).

Os filtros média móvel e gaussiano apresentaram R^2 variando de 0,84 a 0,88, demonstrando forte relação entre o número de árvores observadas e o número de árvores estimadas pelos algoritmos nas unidades amostrais. No entanto, o desvio padrão (S_{xy}) indica que os erros nas estimativas foram superiores a 49%, chegando a 58% com o filtro média móvel 7x7 m. Esse erro é atribuído a subestimativa do número de árvores estimado pelo algoritmo local máximo (LM) com janela variável (Tabela 7).

Tabela 7. Detecção de árvore individual (DAI) utilizando os filtros média móvel e gaussiano e tamanho com variações no tamanho de janela de suavização (TJS), associado a tamanho de janela de árvore (TJA) variável em função da altura da árvore com algoritmo local máximo (LM). Valores em negrito indicam a estimativa mais próximo do valor real.

UA	N	Filtro de Suavização					
		Média Móvel			Gaussiano		
		Tamanho de Janela de Suavização (TJS)					
		3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	359	315	297	274	315	299	279
2	35	29	24	26	29	25	25
3	186	141	135	122	140	132	127
4	157	93	88	78	92	90	80
5	106	36	37	35	36	37	35
6	382	178	166	144	177	169	150
7	133	57	55	52	57	56	53
8	84	50	46	42	50	47	43
9	100	61	56	54	61	57	53
10	95	101	72	66	100	72	66
11	243	114	114	104	114	112	108
12	186	90	83	80	90	84	78
13	14	17	13	11	17	13	12
14	508	349	333	296	349	329	312
15	64	56	54	50	56	54	49
16	44	29	21	17	29	21	18
17	144	159	122	96	159	125	106
18	208	140	123	112	139	125	113
19	83	61	58	50	61	60	54
20	104	137	114	97	137	116	99
21	86	25	23	22	25	24	22
22	31	13	12	9	13	12	9
23	105	53	51	49	53	50	50
24	83	39	39	36	39	38	36
25	255	139	143	139	141	143	138
26	279	169	160	143	168	161	154
27	318	212	205	198	211	203	202
28	153	81	83	78	81	83	79
29	181	99	89	86	100	92	88
	R ²	0,84	0,88	0,88	0,84	0,87	0,88
	S _{xy}	79,81	84,87	94,61	79,93	84,69	91,25
	S _{xy} (%)	48,97	52,08	58,06	49,05	51,97	56,00

Os filtros média móvel e gaussiano apresentaram erro relativo similar e com pouca variação nas diferentes unidades amostrais, com tendência de subestimativa em 25 UA e

ligeira superestimativa em 4 UA. A suavização do CHM com janela de 3x3 m tende a apresentar erros menores em relação as janelas de 5x5 m e 7x7 m, com abrupta redução da superestimativa das árvores em algumas unidades amostrais, chegando a apresentar erro relativo próximo a 0% nas UA 10, 13, 17 e 20 (Figura 5). As janelas de suavização com dimensões de 5x5 m e 7x7 m apresentaram erros relativos semelhantes, com subestimativa do número de árvores próximo a 70% na UA 21.

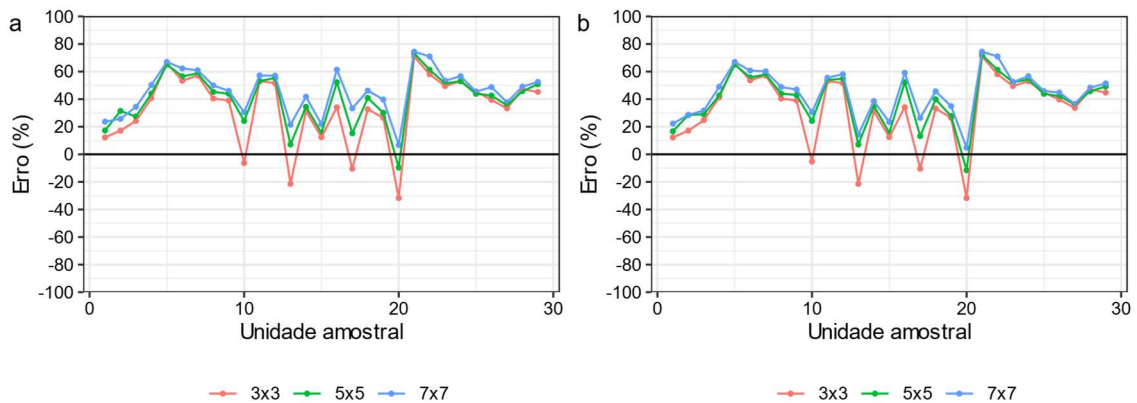


Figura 5. Estimativa do erro relativo (%) para detecção árvore individual (DAI) a partir de variações no tamanho da janela dos filtros a) média móvel e b) gaussiano para suavização do CHM (*Canopy Height Model*) e local máximo (LM) com tamanho de janela de árvore (TJA) com dimensão variável.

Dentre as combinações de janelas de suavização dos filtros e o local máximo (LM) com janela variável para identificação de árvores por meio do CHM, foi observado que o filtro média móvel com janela 3x3 m apresentou o melhor desempenho, sendo possível avaliar a precisão do algoritmo por unidade amostral. A Tabela 7 mostra que essa configuração do algoritmo de identificação de árvore individual não superestimou o número de árvores na UA 25, ou seja, não foram identificadas árvores acima do número previsto no censo. Por outro lado, essas unidades apresentaram altos falsos negativos (FN), devido as árvores que não foram identificadas pelo mapeamento automático. Apenas 6 UA apresentaram valor de F-Score (F) acima de 0,90, que representa áreas com baixo valores de FP e FN (Tabela 7).

Tabela 8. Acurácia na predição de árvores urbanas a partir de *Canopy Height Model* (CHM) suavizado com filtro média móvel com tamanho de janela de suavização (TJS) 3x3 e local máximo (LM) com tamanho de janela de árvore (TJA) variável.

UA	N	PV	FN	FP	Recall (r)	Precisão (p)	F-Score (F)
1	359	315	44	0	0,88	1,00	0,93
2	35	29	6	0	0,83	1,00	0,91
3	186	141	45	0	0,76	1,00	0,86
4	157	93	64	0	0,59	1,00	0,74
5	106	36	70	0	0,34	1,00	0,51
6	382	178	204	0	0,47	1,00	0,64
7	133	57	76	0	0,43	1,00	0,60
8	84	50	34	0	0,60	1,00	0,75
9	100	61	39	0	0,61	1,00	0,76
10	95	95	0	6	1,00	0,94	0,97
11	243	114	129	0	0,47	1,00	0,64
12	186	90	96	0	0,48	1,00	0,65
13	14	14	0	3	1,00	0,82	0,90
14	508	349	159	0	0,69	1,00	0,81
15	64	56	8	0	0,88	1,00	0,93
16	44	29	15	0	0,66	1,00	0,79
17	144	144	0	15	1,00	0,91	0,95
18	208	140	68	0	0,67	1,00	0,80
19	83	61	22	0	0,73	1,00	0,85
20	104	104	0	33	1,00	0,76	0,86
21	86	25	61	0	0,29	1,00	0,45
22	31	13	18	0	0,42	1,00	0,59
23	105	53	52	0	0,50	1,00	0,67
24	83	39	44	0	0,47	1,00	0,64
25	255	139	116	0	0,55	1,00	0,71
26	279	169	110	0	0,61	1,00	0,75
27	318	212	106	0	0,67	1,00	0,80
28	153	81	72	0	0,53	1,00	0,69
29	181	99	82	0	0,55	1,00	0,71

UA: Unidade amostral; N: número de árvores de referência; PV: positivo verdadeiro; FP: Falso positivo.

4. Discussão

A identificação e caracterização das árvores urbanas a partir de dados tridimensionais gera informações importantes para o manejo e planejamento das florestas urbanas, potencializando a produção de serviços ecossistêmicos que influenciam de

forma direta ou indireta no bem-estar dos habitantes. Nesse sentido, o aumento da densidade de árvores em vias públicas, parques urbanos, jardins residenciais e em áreas comerciais, por exemplo, auxilia na produção de serviços. No entanto, a gestão incorreta desses componentes pode gerar prejuízos econômicos as infraestruturas públicas e privadas, além de limitar o desenvolvimento das árvores.

Poucas são as unidades de gestão responsáveis pelo manejo das florestas urbanas que tem essas informações, devido ao alto custo para aquisição de dados por inventários in loco ou quando há os dados, as informações estão desatualizadas devido ao custo elevado para atualização periódica do banco de dados. Diante disso, dados oriundos de ferramentas de sensoriamento podem auxiliar na produção de informações com baixo custo, visto que algumas cidades adquirem dados de sensoriamento remoto para outras aplicações e podem ser utilizados na gestão das florestas urbanas, como na região onde esse estudo foi realizado (Kwong e Fung, 2020).

O ajuste de algoritmos e modelos matemáticos utilizando dados de campo e dados LiDAR tem sido empregado no monitoramento dos recursos naturais em florestas nativas, plantadas e em florestas urbanas (Hartling *et al.*, 2019; Man *et al.*, 2020; Matasci *et al.*, 2018; Mohan *et al.*, 2019; Plowright *et al.*, 2016; Stereńczak *et al.*, 2020). Algumas espécies de árvores provenientes de florestas temperadas apresentam copas com formato regular, similares a um cone, o que facilita o ajuste de um modelo preciso para extensas áreas. Por outro lado, esses algoritmos podem apresentar baixa precisão quando aplicados em florestas urbanas que estão sob diferentes condições ambientais, o que altera significativamente a morfologia natural da copa das árvores (Barnes *et al.*, 2017; Wallace *et al.*, 2021). A diversidade morfológica de copas de diferentes espécies de árvores, associado aos diferentes critérios para poda ocasiona na formação de dossel urbano com alta heterogeneidade, sendo necessário aplicação e avaliação de metodologias capazes de produzir informações confiáveis e detalhadas sobre os indivíduos (Stereńczak *et al.*, 2020). Segundo Kwong e Fung (2020) as árvores urbanas dispostas em parques, área nativa e em calçadas são identificadas com precisão variável em função das tecnologias LiDAR, VANT e fotografias áreas digitais.

Na área urbana de Brasília, as árvores não apresentaram padrão espacial definido, com disposição espacial variável de acordo com a infraestrutura urbana predominante. Isso ocorre devido à falta de planejamento das áreas verdes urbanas, ou mesmo pela adequação do projeto de arborização a disposição espacial das vias públicas e edificações,

demonstrando que a implantação e o manejo das áreas verdes ocorrem após a formação do mosaico urbano.

Os indivíduos arbóreos podem estar dispostos espacialmente em grupos de árvores, dispersos em parques e/ou quintais, ou alinhados no entorno de vias públicas, com distribuição espacial regular. Essa heterogeneidade no padrão espacial das árvores urbanas dificulta a determinação de parâmetros para suavização do CHM e a definição de tamanho de janela para identificação do topo da árvore, dificultando a obtenção de configuração de algoritmo que seja adequado para identificação das árvores de toda floresta urbana (Kwong e Fung, 2020; Xu *et al.*, 2021).

O número de árvores estimadas a partir do CHM suavizado com filtro gaussiano teve alta variação em relação ao número de árvores identificadas em campo, enquanto a identificação pelo filtro média móvel teve menor variação. O R^2 apresentou altos valores e baixa variação para os dois filtros utilizados no CHM, indicando que ambos filtros são potenciais para suavização do CHM, o que não é observado quando se avalia a precisão das estimativas do número de árvores pelo S_{xy} (Mielcarek, Stereńczak e Khosravipour, 2018). O parâmetro R^2 indica o quanto da variação da estimativa do número de árvores pode ser explicada pelas variáveis independentes (parâmetro de suavização do CHM e tamanho de janela de árvore), enquanto o desvio padrão indica o quanto a estimativa variou em relação a média do número de árvores.

Na área urbana de estudo, foi observado alta variação no número de árvores estimados pelo LM utilizando o CHM suavizado com os filtros média móvel e gaussiano com janelas de tamanhos fixos, o que pode estar relacionado à disposição espacial e a variação do formato da copa das árvores. As árvores dispostas próximas umas das outras, onde a copa das árvores se encontram, são identificadas com melhor precisão com TJA maiores, diminuindo a possibilidade de superestimativa do topo de árvores pelos múltiplos galhos das copa (Stereńczak *et al.*, 2020). Por outro lado, as árvores de menor porte e situadas próximas as árvores de grande porte não foram identificadas pelo LM quando configurado com janelas igual ou superior a 5x5. As copas das árvores parcialmente cobertas ou completamente cobertas pela copa de árvores vizinhas são difíceis de serem identificadas pelo algoritmo, devido a obstrução da passagem dos pontos de laser pelas copas superiores, deixando as árvores do estrato inferior invisíveis no modelo de altura de copa (Man *et al.*, 2020; Mielcarek, Stereńczak e Khosravipour, 2018; Stereńczak *et al.*, 2020).

As árvores dispostas em linhas e/ou no entorno de vias públicas e alinhadas em estacionamentos, foram estimadas com precisão pelo LM utilizando janelas de menor dimensão. A formação de padrões espaciais das árvores urbanas contribui na aplicação de métodos automatizados para identificação individual de árvores, principalmente pela definição de distâncias pré-determinadas no plantio das árvores. Isso reduz a possibilidade de sobreposição das copas e permite o desenvolvimento das copas com formato padrão para cada espécie, devido à baixa competitividade por espaço com árvores vizinhas (Aval *et al.*, 2018).

O ajuste de regressão linear para estimar o diâmetro da copa de árvore em função da altura das árvores permitiu ajustar janelas variáveis para identificação do ponto máximo. No entanto, o algoritmo de janela variável subestimou o número de árvores por unidade amostral resultando em baixa precisão, quando comparado método de janela fixa (Kwong e Fung, 2020). Isso pode estar relacionado a estimativa de janelas maiores em áreas com agrupamento de árvores, onde ocorre sobreposição de copas no estrato superior e ocorrência de árvores no estrato inferior, resultando na subestimativa do número de pontos máximos referentes as copas das árvores. Além disso, ao assumir que árvores altas apresentam copas maiores e conseqüente maior tamanho de janela, pode gerar em erros de estimativa em florestas tropicais que são formadas por alta diversidade de espécies (Kwong e Fung, 2020).

A densidade de pontos por área influencia na precisão da detecção do topo das árvores, devido a possibilidade de variação da estrutura da copa no espaço. A alta densidade de pontos LiDAR auxilia na caracterização da estrutura vertical das florestas, possibilitando a identificação acurada do topo das árvores do estrato superior, bem como de árvores situadas no estrato inferior a partir da penetração dos pulsos de laser (Kwong e Fung, 2020). Em ambientes com predominância de espécies coníferas é interessante o uso de dados LiDAR com alta densidade, permitindo a caracterização do topo das árvores em formato cônico. Por outro lado, dados LiDAR com densidade variando de 2 a 9 pulsos.m⁻² podem ser aplicados e ter bons resultados em florestas tropicais (Matasci *et al.*, 2018)

É importante observar que a precisão na identificação individual das árvores influencia na precisão das demais métricas relativas aos indivíduos arbóreos, uma vez que é a partir da localização geográfica e da copa que são produzidas métricas a partir de dados LiDAR. Em algumas situações, a medição da altura das árvores em campo pode ser comprometida pela complexidade da copa das árvores, impossibilitando a

visualização do ponto máximo da copa, principalmente em espécies tropicais que apresentam copas irregulares (Matasci *et al.*, 2018; Mielcarek, Stereńczak e Khosravipour, 2018). Assim, a obtenção da altura de espécies tropicais pode ser mais acurada quando obtidas por LiDAR. Neste caso, é interessante que a localização geográfica da árvore seja obtida em campo e, com esta informação, obter a altura da árvore pelo CHM ou pela nuvem de pontos LiDAR.

A localização geográfica das árvores deve ser obtida utilizando metodologia que proporcione precisão na localização espacial das árvores, conferindo confiabilidade na atualização do inventário a partir de informações obtidas remotamente. Wallace et al. (2021) observaram que as coordenadas geográficas adquiridas em campo a partir de receptor GPS (*Global Positioning System*) de navegação apresentam erro aleatório, indicando o topo das árvores distantes do local real. Assim, a atualização do inventário urbano a partir de imagens aéreas e dados LiDAR pode ter baixa precisão devido a obtenção de dados de feições adjacentes as copas das árvores.

Alguns trabalhos sugerem que a identificação e produção de métricas das árvores utilizando os dados vetoriais do LiDAR podem ser mais precisos, que utilizando o CHM. Porém, a DAI a partir de nuvem de pontos requer maior tempo de processamento e computadores robustos, limitando a aplicação dessa metodologia. Por outro lado, o CHM requer pouco espaço para armazenamento e pode ser processado em menos tempo (Wu *et al.*, 2016). Além disso, o uso de algoritmos para redução de múltiplos galhos e para correção de dados espúrios (pit-free) produz dados acurados tanto quanto os dados LiDAR brutos e os dados obtidos em levantamentos em campo (Mielcarek, Stereńczak e Khosravipour, 2018).

Além disso, é importante observar que o período de obtenção dos dados de laser influencia na precisão da estimativa do número de árvores a partir da metodologia proposta neste estudo, pois algumas espécies reduzem ou perdem totalmente as folhas entre o outono e primavera. Já no verão, que coincide com o período chuvoso na região de estudo, as espécies estão com alta cobertura de folhas. Assim, o índice de área foliar das árvores urbanas influencia nos retornos dos pulsos de laser. Nesse sentido, a alta cobertura foliar é interessante para identificação, principalmente, de árvores com copas bem definidas e sem sobreposição de copa com árvores vizinhas. Por outro lado, a redução da cobertura foliar aumentaria os retornos dos pulsos de laser em diferentes estratos em regiões com alta densidade de árvores e com sobreposição de copas, o que poderia auxiliar identificação das árvores individuais (Aval *et al.*, 2018). No entanto,

espécies caducifólias podem não ser identificadas no inverno por sistemas de laser com baixa densidade de pulsos por unidade de área, podendo subestimar o número de árvores urbanas (Matasci *et al.*, 2018), sendo importante avaliar o efeito da densidade de pulsos na identificação das árvores urbanas.

5. Conclusões

A metodologia aplicada apresentou potencial para ser aplicada em áreas de floresta urbana tropical, onde as árvores apresentam tamanho e formato de copa distintos, além de apresentar disposição espacial variada.

O algoritmo local máximo (LM) com janela fixa apresentou melhor desempenho em relação a janela variável, principalmente quando o modelo de copa de árvore (*Canopy Height Model* – CHM) foi suavizado com filtro média móvel com tamanho de janela de suavização (TJS) e tamanho de janela de árvore (TJA) 5x5-5x5. Essa configuração do algoritmo teve $S_{xy}(\%)$ ligeiramente superior ao TJS-TJA 7x7-3x3 e apresentou melhor desempenho na estimativa do número de árvores por unidade amostral.

Devido à heterogeneidade das florestas urbanas e a disponibilidade de dados LiDAR que foram adquiridos para outros fins, considera-se que a metodologia empregada foi satisfatório. Em trabalhos futuros, é importante avaliar outras fontes dados e algoritmos que podem apresentar melhor desempenho, como LiDAR e sensor hiperespectral abordo de aeronave remotamente pilotada (ARP) que permite a obtenção de alta densidade de pulsos e resposta espectral dos alvos em diferentes bandas e redes neurais artificiais.

6. Referências bibliográficas

ALEXANDER, C.; KORSTJENS, A. H.; HILL, R. A. Influence of micro-topography and crown characteristics on tree height estimations in tropical forests based on LiDAR canopy height models. **International Journal of Applied Earth Observation and Geoinformation**, v. 65, n. November 2017, p. 105–113, 2018.

ANDERSEN, H. E.; REUTEBUCH, S. E.; MCGAUGHEY, R. J. A rigorous assessment of tree height measurements obtained using airborne lidar and conventional field methods. **Canadian Journal of Remote Sensing**, v. 32, n. 5, p. 355–366, 2006.

- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; DE MORAES GONÇALVES, J. L.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711–728, 2013.
- AVAL, J.; DEMUYNCK, J.; ZENOU, E.; et al. Detection of individual trees in urban alignment from airborne data and contextual information: A marked point process approach. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 146, n. October, p. 197–210, 2018.
- BARNES, C.; BALZTER, H.; BARRETT, K.; et al. Individual tree crown delineation from airborne laser scanning for diseased larch forest stands. **Remote Sensing**, v. 9, n. 3, p. 1–20, 2017.
- BOTTALICO, F.; CHIRICI, G.; GIANNINI, R.; MELE, S.; MURA, M.; PUXEDDU, M.; MCROBERTS, R. E.; VALBUENA, R.; TRAVAGLINI, D. Modeling Mediterranean forest structure using airborne laser scanning data. **International Journal of Applied Earth Observation and Geoinformation**, v. 57, p. 145–153, 2017.
- BRANDO, P. Tree height matters. **Nature Geoscience**, v. 11, n. 6, p. 390–391, 2018.
- GONZÁLEZ-FERREIRO, E.; DIÉGUEZ-ARANDA, U.; BARREIRO-FERNÁNDEZ, L.; BUJÁN, S.; BARBOSA, M.; SUÁREZ, J. C.; BYE, I. J.; MIRANDA, D. A mixed pixel- and region-based approach for using airborne laser scanning data for individual tree crown delineation in *Pinus radiata* D. Don plantations. **International Journal of Remote Sensing**, v. 34, n. 21, p. 7671–7690, 2013.
- CHANG, J.; QU, Z.; XU, R.; et al. Assessing the ecosystem services provided by urban green spaces along urban center-edge gradients. **Scientific Reports**, v. 7, n. 1, p. 1–9, 2017.
- CHEN, Q.; BALDOCCHI, D.; GONG, P.; KELLY, M. Isolating individual trees in a savanna woodland using small footprint LiDAR data. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 8, p. 923–932, 2006.
- CHEN, Z.; XU, B.; GAO, B. Assessing visual green effects of individual urban trees using airborne LiDAR data. **Science of the Total Environment**, v. 536, p. 232–244, 2015.
- CODEPLAN. **Distrito Federal em síntese: informações socioeconômicas e geográficas. Brasília - DF**, 2012.
- CORTE, A. P. D.; SOUZA, D. V.; REX, F. E.; et al. Forest inventory with high-density UAV- LiDAR: Machine learning approaches for predicting individual tree attributes. **Computers and Electronics in Agriculture**, v. 179, n. September, p. 105815, 2020.

- DALAGNOL, R.; PHILLIPS, O. L.; GLOOR, E.; et al. Quantifying canopy tree loss and gap recovery in tropical forests under low-intensity logging using VHR satellite imagery and airborne LiDAR. **Remote Sensing**, v. 11, n. 7, p. 1–20, 2019.
- ERFANIFARD, Y.; STEREŃCZAK, K.; KRASZEWSKI, B.; KAMIŃSKA, A. Development of a robust canopy height model derived from ALS point clouds for predicting individual crown attributes at the species level. **International Journal of Remote Sensing**, v. 39, n. 23, p. 9206–9227, 2018.
- FUJIMOTO, A.; HAGA, C.; MATSUI, T.; et al. An end to end process development for UAV-SfM based forest monitoring: Individual tree detection, species classification and carbon dynamics simulation. **Forests**, v. 10, n. 8, p. 1–27, 2019.
- GARCÍA-MURILLO, D. G.; CAICEDO-ACOSTA, J.; CASTELLANOS-DOMINGUEZ, G. Individual detection of citrus and avocado trees using extended maxima transform summation on digital surface models. **Remote Sensing**, v. 12, n. 10, 2020.
- GOUTTE, C.; GAUSSIER, E. A Probabilistic Interpretation of Precision, Recall and F-Score, with Implication for Evaluation. **Lecture Notes in Computer Science**, v. 3408, p. 345–359, 2005.
- GU, J.; GRYBAS, H.; CONGALTON, R. G. A comparison of forest tree crown delineation from unmanned aerial imagery using canopy height models vs. spectral lightness. **Forests**, v. 11, n. 6, 2020.
- GUO, T.; MORGENROTH, J.; CONWAY, T.; XU, C. City-wide canopy cover decline due to residential property redevelopment in Christchurch, New Zealand. **Science of the Total Environment**, v. 681, p. 202–210, 2019.
- HARTLING, S.; SAGAN, V.; SIDIKE, P.; MAIMAITIJIANG, M.; CARRON, J. Urban tree species classification using a worldview-2/3 and liDAR data fusion approach and deep learning. **Sensors (Switzerland)**, v. 19, n. 6, p. 1–23, 2019.
- HE, C.; CONVERTINO, M.; FENG, Z.; ZHANG, S. Using LiDAR Data to Measure the 3D Green Biomass of Beijing Urban Forest in China. (M. Convertino, Org.) **PLoS ONE**, v. 8, n. 10, p. 1–11, 2013.
- HYYPPÄ, J.; YU, X.; HYYPPÄ, H.; et al. Advances in forest inventory using airborne laser scanning. **Remote Sensing**, v. 4, n. 5, p. 1190–1207, 2012.
- KAARTINEN, H.; HYYPPÄ, J.; YU, X.; et al. An international comparison of individual tree detection and extraction using airborne laser scanning. **Remote Sensing**, v. 4, n. 4, p. 950–974, 2012.
- KARDAN, O.; GOZDYRA, P.; MISIC, B.; et al. Neighborhood greenspace and health in a large urban center. **Scientific Reports**, v. 5, p. 1–14, 2015.
- KHOSRAVIPOUR, A.; SKIDMORE, A. K.; ISENBURG, M.; WANG, T.; HUSSIN, Y. A. Development of an algorithm to generate a LiDAR pit - free canopy height model. Proceedings of Silvilaser 2013: **13th International conference on LiDAR**

- applications for assessing forest ecosystems**, October, 9-11, 2013 Beijing, China, p. Paper SL2013-030, p. 125–128, 2013.
- KHOSRAVIPOUR, A.; SKIDMORE, A. K.; ISENBURG, M.; WANG, T.; HUSSIN, Y. A. Generating pit-free canopy height models from airborne LiDAR. **Photogrammetric Engineering and Remote Sensing**, v. 80, n. 9, p. 863–872, 2014.
- KWONG, I. H. Y.; FUNG, T. Tree height mapping and crown delineation using LiDAR, large format aerial photographs, and unmanned aerial vehicle photogrammetry in subtropical urban forest. **International Journal of Remote Sensing**, v. 41, n. 14, p. 5228–5256, 2020.
- LEITES, L. P.; ROBINSON, A. P.; CROOKSTON, N. L. Accuracy and equivalence testing of crown ratio models and assessment of their impact on diameter growth and basal area increment predictions of two variants of the forest vegetation simulator. **Canadian Journal of Forest Research**, v. 39, n. 3, p. 655–665, 2009.
- LIU, J.; SHEN, J.; ZHAO, R.; XU, S. Extraction of individual tree crowns from airborne LiDAR data in human settlements. **Mathematical and Computer Modelling**, v. 58, n. 3–4, p. 524–535, 2013.
- LIU, L.; LIM, S.; SHEN, X.; YEBRA, M. A hybrid method for segmenting individual trees from airborne LiDAR data. **Computers and Electronics in Agriculture**, v. 163, n. April, p. 104871, 2019.
- MAN, Q.; DONG, P.; YANG, X.; WU, Q.; HAN, R. Automatic Extraction of grasses and individual trees in urban areas based on airborne hyperspectral and LiDAR data. **Remote Sensing**, v. 12, n. 17, p. 1–22, 2020.
- MATASCI, G.; COOPS, N. C.; WILLIAMS, D. A. R.; PAGE, N. Mapping tree canopies in urban environments using airborne laser scanning (ALS): A vancouver case study. **Forest Ecosystems**, v. 5, n. 1, 2018.
- MIELCAREK, M.; STEREŃCZAK, K.; KHOSRAVIPOUR, A. Testing and evaluating different LiDAR-derived canopy height model generation methods for tree height estimation. **International Journal of Applied Earth Observation and Geoinformation**, v. 71, n. May, p. 132–143, 2018.
- MILLIKAN, P. H. K.; SILVA, C. A.; RODRIGUEZ, L. C. E.; et al. Automated individual tree detection in amazon tropical forest from airborne laser scanning data. **Cerne**, v. 25, n. 3, p. 273–282, 2019.
- MOHAN, M.; MENDONÇA, B. A. F. DE; SILVA, C. A.; et al. Optimizing individual tree detection accuracy and measuring forest uniformity in coconut (*Cocos nucifera* L.) plantations using airborne laser scanning. **Ecological Modelling**, v. 409, n. June, p. 108736, 2019.
- MOHAN, M.; SILVA, C. A.; KLAUBERG, C.; et al. Individual tree detection from unmanned aerial vehicle (UAV) derived canopy height model in an open canopy mixed conifer forest. **Forests**, v. 8, n. 9, p. 1–17, 2017.

- NOWAK, D. J.; WALTON, J. T.; STEVENS, J. C.; CRANE, D. E.; HOEHN, R. E. Effect of Plot and Sample Size on Timing and Precision of Urban Forest Assessments. **Arboriculture and Urban Forestry**, v. 34, n. 6, p. 386–390, 2008.
- PLOWRIGHT, A. A.; COOPS, N. C.; ESKELSON, B. N. I.; SHEPPARD, S. R. J.; AVEN, N. W. Assessing urban tree condition using airborne light detection and ranging. **Urban Forestry and Urban Greening**, v. 19, p. 140–150, 2016.
- POPESCU, S. C.; WYNNE, R. H. Seeing the Trees in the Forest: Using LiDAR and Multispectral Data Fusion with Local Filtering and Variable Window Size for Estimating Tree Height. **Photogrammetric Engineering & Remote Sensing**, v. 70, n. 5, p. 589–604, 2004.
- POPESCU, S. C.; WYNNE, R. H.; NELSON, R. F. Estimating plot-level tree heights with LiDAR: Local filtering with a canopy-height based variable window size. **Computers and Electronics in Agriculture**, v. 37, n. 1–3, p. 71–95, 2003.
- SFB, S. F. B. **Inventário Florestal Nacional: principais resultados Distrito Federal**. 2016.
- ROUSSEL, J. R.; AUTY, D.; COOPS, N. C.; TOMPALSKI, P.; GOODBODY, T. R. H.; MEADOR, A. S.; BOURDON, J. F.; BOISSIEU, F. DE; ACHIM, A. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. **Remote Sensing of Environment**, v. 251, n. February, p. 112061, 2020.
- SINGH, M.; EVANS, D.; TAN, B. S.; NIN, C. S. Mapping and characterizing selected canopy tree species at the Angkor world heritage site in Cambodia using aerial data. **PLoS ONE**, v. 10, n. 4, p. 1–26, 2015.
- SONG, C.; DICKINSON, M. B.; SU, L.; ZHANG, S.; YAUSSEY, D. Estimating average tree crown size using spatial information from Ikonos and QuickBird images: Across-sensor and across-site comparisons. **Remote Sensing of Environment**, v. 114, n. 5, p. 1099–1107, 2010.
- STEREŃCZAK, K.; MIELCAREK, M.; WERTZ, B.; BRONISZ, K.; ZAJĄCZKOWSKI, G.; JAGODZIŃSKI, A. M.; OCHAŁ, W.; SKORUPSKI, M. Factors influencing the accuracy of ground-based tree-height measurements for major European tree species. **Journal of Environmental Management**, v. 231, n. September 2018, p. 1284–1292, 2019.
- STEREŃCZAK, K.; KRASZEWSKI, B.; MIELCAREK, M.; et al. Mapping individual trees with airborne laser scanning data in an European lowland forest using a self-calibration algorithm. **International Journal of Applied Earth Observation and Geoinformation**, v. 93, n. June, p. 102191, 2020.
- TANHUANPÄÄ, T.; VASTARANTA, M.; KANKARE, V.; et al. Mapping of urban roadside trees - A case study in the tree register update process in Helsinki City. **Urban Forestry and Urban Greening**, v. 13, n. 3, p. 562–570, 2014.

TEAM, R. C. **R: A Language and Environment for Statistical Computing**, Vienna, Austria R Foundation for Statistical Computing, 2020. Disponível em: <<https://www.r-project.org/>>

UNITED NATIONS. **World Urbanization Prospects: The 2018 Revision**. Disponível em: <<https://population.un.org/wup/publications/Files/WUP2018-KeyFacts.pdf>>.

WAGNER, F. H.; FERREIRA, M. P.; SANCHEZ, A.; et al. Individual tree crown delineation in a highly diverse tropical forest using very high resolution satellite images. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, n. September 2017, p. 362–377, 2018.

WALLACE, L.; SUN, Q. (CHAYN); HALLY, B.; et al. Linking urban tree inventories to remote sensing data for individual tree mapping. **Urban Forestry and Urban Greening**, v. 61, n. November 2020, p. 127106, 2021.

WU, B.; YU, B.; WU, Q.; et al. Individual tree crown delineation using localized contour tree method and airborne LiDAR data in coniferous forests. **International Journal of Applied Earth Observation and Geoinformation**, v. 52, p. 82–94, 2016.

WULDER, M.; NIEMANN, K. O.; GOODENOUGH, D. G. Local maximum filtering for the extraction of tree locations and basal area from high spatial resolution imagery. **Remote Sensing of Environment**, v. 73, n. 1, p. 103–114, 2000.

XU, W.; DENG, S.; LIANG, D.; CHENG, X. A crown morphology-based approach to individual tree detection in subtropical mixed broadleaf urban forests using UAV LiDAR data. **Remote Sensing**, v. 13, n. 7, 2021.

ZHAO, D.; PANG, Y.; LI, Z.; SUN, G. Filling invalid values in a lidar-derived canopy height model with morphological crown control. **International Journal of Remote Sensing**, v. 34, n. 13, p. 4636–4654, 2013.

CAPÍTULO IV

Características tridimensionais da paisagem urbana e sua relação com a temperatura da superfície terrestre

Resumo

A expansão das cidades tem ocasionado no aumento da temperatura da superfície terrestre (TST), ocasionando na formação de ilhas de calor urbano (ICU). Para reduzir os efeitos nocivos das ICU, é importante avaliar os efeitos da morfologia urbano sobre a TST. Esse trabalho teve por objetivo avaliar a relação entre as variáveis tridimensionais da vegetação arbórea urbana e as edificações em relação a sazonalidade da TST. O percentual de cobertura de árvore (PAR_v) e a densidade de borda (DB) das árvores apresentou forte correlação negativa com a TST, indicando que o aumento dessas variáveis contribui para o resfriamento. A altura da árvore e das edificações também contribuíram para redução da temperatura, devido à projeção da sombra, minimizando a incidência de radiação solar. Dentre essas variáveis, a altura dos edifícios e a cobertura de árvores apresentou maior importância na variância do modelo *random forest*. Assim, no manejo da vegetação arbórea urbana pode-se associar árvores de menor porte em regiões com edifícios maiores, enquanto ambientes urbanos com edifícios de menor porte pode ser alocadas árvores de maior porte, em fragmentos de formatos irregulares para aumentar o sombreamento e a evapotranspiração.

Palavras-chave: árvore, edificação, paisagem urbana, ilha de calor urbano.

Three-dimensional urban landscape characteristic and its relationship with the land surface temperature

Abstract

The urban sprawl has been the highest land surface temperature (LST) resulting in urban heat island (UHI). To reduce the negative UHI effects is important evaluate the effects of urban morphology on the LST. The aim of this work was to evaluate the relationship between tridimensional urban tree variables and building in relation to seasonality LST. The percent tree cover (PTree) and edge density (ED) of trees showed negative strong correlation with the LST indicating that increase of these variables contribute to the cooling. The tree and building height contributed to reduce the temperature due to shadow cast, minimizing solar radiation incidence. Between theses variables, the building height and tree cover showed great importance in the random forest model variance. Thus, the smaller tree can be associated in regions with larger buildings, while in urban regions with smaller buildings can be associated with larger trees allocated in patches irregularly shaped to increase shading and evapotranspiration.

Keywords: tree, building, urban landscape, urban heat island.

1. Introdução

O rápido aumento populacional nas cidades tem ocasionado a transformação do espaço, resultando em impactos negativos ao ambiente e consequente redução de serviços ecossistêmicos (Schneiberg *et al.*, 2020). Um dos impactos percebidos é o aumento da temperatura em relação as áreas do entorno, geralmente com cobertura nativa ou com cultura agrícola, ocasionando na formação das ilhas de calor urbano (ICU) (Oke, 1982). As ICU podem resultar em problemas de saúde e bem-estar a população, além de aumentar o consumo de água e energia, o que demonstra a necessidade de estratégias que minimizem esses e outros impactos negativos (Wujeska-Klaue e Pfautsch, 2020).

As ICU podem ser monitoradas a partir de informações de temperatura obtidas de estações meteorológicas. As informações obtidas dessas estações apresentam alta resolução temporal sobre as condições atmosféricas, no entanto é baixa a densidade espacial, tendo pouca aplicabilidade no monitoramento de áreas extensas. Por outro lado, imagens obtidas de sensoriamento remoto podem ser utilizadas para estimar a temperatura de superfície em áreas extensas e com resolução temporal adequada, possibilitando a obtenção da superfície de calor urbano (SCU).

As árvores urbanas são um dos principais componentes responsáveis por minimizar a temperatura do ambiente, devido a projeção das sombras das árvores sobre a superfície e pelo aumento da evapotranspiração (Morakinyo *et al.*, 2017). A composição e configuração das árvores urbanas são variáveis que devem ser consideradas no planejamento urbano, afim de potencializar a produção de serviços ecossistêmicos e contribuir para mitigar os efeitos das ICU. Estudos indicam que o aumento da cobertura de árvores contribui para redução da temperatura de superfície (Maimaitiyiming *et al.*, 2014; Wang *et al.*, 2020; Zhou, Wang e Cadenasso, 2017). Em outros estudos foi observado que a configuração da paisagem deve ser considerada no planejamento e gestão da vegetação urbana, uma vez as áreas urbanas tem limitação de espaços destinados ao aumento da cobertura verde (Du *et al.*, 2016; Maimaitiyiming *et al.*, 2014).

É importante, também, considerar as características tridimensionais das árvores urbanas e dos edifícios no planejamento e manejo da floresta urbana. A altura da árvore é uma das variáveis que influencia no transporte de vapor de água, velocidade do vento e sombreamento da área. Essa variável pode ser manejada por meio de podas e pela seleção de espécies com potencial de desenvolvimento em altura. Alguns estudos demonstram que variáveis relativas a estrutura tridimensional da cobertura de copa contribui para

reduzir a temperatura, porém não consideram a informação ao nível de árvore (Chen, Jin e Du, 2020). Além disso, poucos estudos relacionam a influência da estrutura tridimensional das árvores e das construções sobre o resfriamento do ambiente urbano (Chen, J. *et al.*, 2021; Yu *et al.*, 2018). Isso pode estar relacionado a indisponibilidade de dados ou pela falta de metodologias adequadas para esse tipo de avaliação (Gage e Cooper, 2017a).

O potencial de resfriamento das árvores urbanas é variável em função da densidade e da altura de copa. Isso é possível pela redução da incidência de ondas curtas, por meio do sombreamento da superfície, e pela dissipação de ondas longas durante a noite, ocasionada por correntes de ar abaixo das copas. No entanto, estudos relacionados ainda são incipientes, principalmente quanto aos limiares de altura para ocorrência desse fenômeno por árvore individual (Wujeska-Klause e Pfautsch, 2020).

Esse estudo tem por objetivo avaliar a influência de variáveis relativas composição, configuração e a estrutura vertical dos componentes urbanos em relação a temperatura da superfície terrestre (TST), visando otimizar o manejo de áreas urbanas a partir de métricas de paisagem que auxiliem no planejamento e na tomada de decisão.

2. Material e métodos

2.1 Área de estudo

Esse estudo foi desenvolvido na região urbana de Brasília, capital do Brasil, situada na região Centro-Oeste do Brasil, no Planalto Central. Desde a construção de Brasília, que teve início na segunda metade da década de 1950, a cidade vem passando por transformações na sua divisão política, de forma a facilitar a gestão do seu espaço por meio de Regiões Administrativas. Atualmente, a cidade é composta pelas Regiões Administrativas do Lago Norte, Lago Sul, Varjão, Plano Piloto, Cruzeiro e Sudoeste/Octogonal, perfazendo uma área igual a, aproximadamente, 600 km² entre as latitudes 15,5780° S e 15,9137° S e entre as longitudes 48,0897° W e 47,7839° W. Esse estudo foi desenvolvido em uma região representativa da área urbana de Brasília, situada no Plano Piloto (Figura 1). O Parque Nacional de Brasília não foi considerado como área de estudo por ser área de conservação com vegetação nativa, onde não ocorreu alteração da vegetação durante o desenvolvimento da cidade de Brasília.

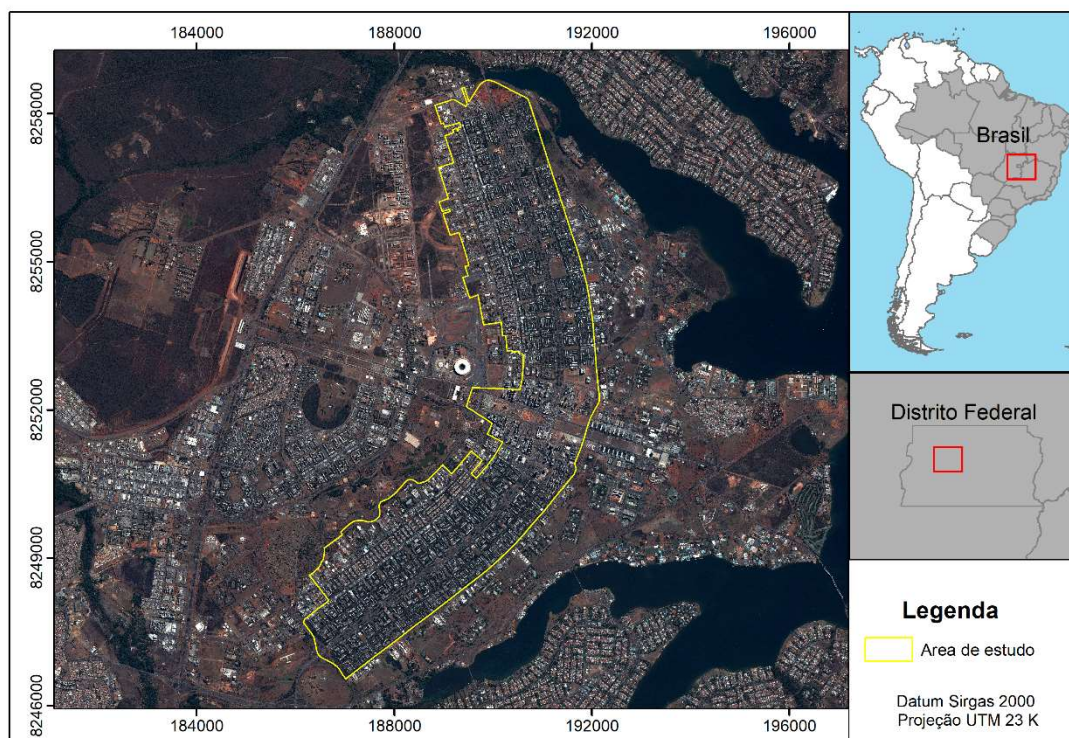


Figura 1. Mapa de localização da cidade de Brasília, Distrito Federal, Brasil.

2.2 Temperatura da Superfície Terrestre (TST)

Foram utilizadas imagens do satélite Landsat 8 *Operational Land Imager* (OLI) e Landsat 8 *Thermal Infrared Sensor* (TIRS) na órbita/ponto 220/71 obtidas em 06 de junho de 2017 (outono), 10 de setembro de 2017 (inverno), 12 de outubro de 2017 (primavera) e 02 de outubro de 2019 (verão). O sensor TIR disponibiliza imagens nas bandas 10 (10,60–11,19 μm) e 11 (11,50–12,51 μm), com resolução espacial original de 100 m e reamostradas para 30 m pelo *United States Geological Survey* (USGS).

Nesse estudo, foi utilizada a banda 10 para calcular a TST. Inicialmente, a imagem na faixa do termal é convertida para temperatura de brilho no sensor, assumindo que a emissividade é uniforme, ou seja, tendo como referência um corpo negro. Como nenhum objeto na natureza tem comportamento termodinâmico similar ao corpo negro, a temperatura de brilho no sensor deve ser corrigida considerando os parâmetros de emissividade e de condições atmosféricas do ambiente. Nesse caso, a temperatura de brilho foi corrigida por meio do algoritmo de janela única (Qin, Karnieli e Berliner, 2001; Wang *et al.*, 2015).

O algoritmo de janela única utiliza a emissividade da superfície para corrigir a temperatura. A emissividade pode ser definida como a diferença da radiância

eletromagnética entre um objeto e um corpo negro. Essa variável não depende apenas da composição química e física do objeto, mas também de sua rugosidade. Nesse estudo, optou-se por estimar a emissividade a partir de aproximações utilizando o índice de vegetação por diferença normalizada (NDVI) para estimar a fração de vegetação, utilizando bandas com reflectância da superfície (Sobrino *et al.*, 2008; Sobrino, Jiménez-Muñoz e Paolini, 2004). Os efeitos atmosféricos da banda termal são corrigidos pela estimativa do conteúdo de vapor de água e pela temperatura do ar no momento de passagem do satélite. Esses dados foram obtidos por meio de estação meteorológica automática do Instituto Nacional de Meteorologia (INMET) situada em Brasília (DF). Essas informações, junto com a emissividade, permitem corrigir os efeitos atmosféricos na imagem e obter a temperatura de superfície (Qin, Karnieli e Berliner, 2001; Wang *et al.*, 2015).

2.3 Mapeamento de uso e cobertura do solo

O mapeamento de uso e cobertura do solo foi realizado utilizando imagens Pleiades do ano 2017. Essas imagens possuem bandas espectrais na faixa do azul (430-550 μm), verde (500-620 μm), vermelho (590-710 μm), infravermelho próximo (740-940 μm) e pancromática (470-830 μm). A partir da fusão das imagens multiespectrais com a pancromática, foi produzida imagem multiespectral com resolução espacial de 0,50 m e ortorretificada. A alta resolução espacial da imagem permite a discriminação de pequenas feições que compõem o mosaico urbano (Li, Zhou e Ouyang, 2013). A imagem multiespectral foi classificada nas classes (1) vegetação arbórea, que representa fragmentos florestais, parques e a arborização urbana; (2) vegetação rasteira, que engloba vegetação de baixo porte, representada pelas gramíneas e pelas plantas herbáceas e arbustivas de fragmentos florestais, parques e a arborização urbana, em locais públicos e privados; (3) edificação, que engloba áreas comerciais e residenciais; (4) estrada, categoria que representa as vias pavimentadas, como rodovias, avenidas e ruas; (5) solo exposto, que são locais sem cobertura vegetal, destinados a cultivo agrícola ou a construção civil, ou formados devido aos processos erosivos; e (6) água, que representa áreas alagadas, rios, lagos e lagoas.

A identificação das classes foi por algoritmo orientado a objeto que segmenta a imagem em áreas homogêneas. As áreas segmentadas foram classificadas quanto ao uso e cobertura do solo, pelo algoritmo *Support Vector Machine* (SVM), treinado a partir de

amostras das assinaturas espectrais dos alvos. Na pós-classificação foi realizado refinamento da classificação por interpretação visual da imagem e mapeamento dos alvos, visando melhorar a acurácia da classificação. As edificações e estradas foram agrupadas e reclassificadas como superfície impermeável. A acurácia da classificação foi avaliada por 255 pontos aleatórios distribuídos entre as classes de uso e cobertura do solo e interpretados visualmente pela imagem multiespectral com resolução espacial de 0,50 m. A classificação apresentou acurácia global de 0,82. As acurácias de produtor e de usuário variaram de 0,76 a 0,84 e de 0,68 a 0,95, respectivamente.

2.4 Modelo de altura de copa (*Canopy Height Model - CHM*)

Foram utilizados dados LiDAR (*Light Detection and Ranging*) aerotransportado com a emissão de feixes de laser na faixa do infravermelho próximo que escaneia o terreno e a cobertura vegetal, assim como edificações presentes na área. O aerolevanteamento foi realizado em uma altitude que permitiu a obtenção de densidade mínima de 4 pontos/ m², com superposição lateral de 20%. A quantidade de pontos por m² mostra-se adequado de acordo com avaliações realizadas em outros estudos (Singh *et al.*, 2015). O sensor utilizado foi o ALS-60 fabricado pela Leica Geosystems, trabalhando com comprimento de onda $\lambda = 1.064$ nm, amplitude operacional de 200 a 5.000 m e abertura máxima do ângulo de visada de 75°.

Devido a condições meteorológicas, os voos não puderam ser realizados em períodos contínuos, em curto espaço de tempo. Dessa forma, o aerolevanteamento foi realizado no período de 28/06/2016 a 29/08/2016. Para garantir a superposição lateral entre faixas contínuas a 20% de forma a garantir que todos os pontos da área de interesse tenham recobrimento em regiões influenciadas pela variação do relevo. A altura média de voo foi de 575 m, altitude média de 1.575 m, potência do sensor de 360 KHz, velocidade da aeronave de 80 m.s⁻¹ e sensor com ângulo de abertura de (*field of view*) de 60°.

Os dados LiDAR, produzidos no aerolevanteamento, foram classificados em categorias de uso e cobertura do solo. Para produção do modelo de altura de copa (*Canopy Height Model - CHM*) foram utilizados os pontos correspondes à classe vegetação, sendo necessária a remoção dos pontos relativos a construções e edifícios, pois essas informações podem ser utilizadas de forma indevida no processamento e produção do CHM (Man *et al.*, 2020). Dessa forma, a classe construções (classe 6) foi removida do

banco de dados para evitar a interpolação de pontos provenientes de edifícios com a copa das árvores.

O CHM foi obtido pela diferença entre o modelo digital de terreno (MDT) e o modelo digital de superfície (MDS). Esses modelos foram obtidos pela interpolação das elevações dos pontos LiDAR, no entanto, pode correr vazios ou espúrios (pits) no processo de interpolação dos valores de altura, devido à passagem do feixe de laser pelos galhos e folhas antes do primeiro retorno ou pela obtenção de feixes de laser em diferentes ângulos de visada, a partir de diferentes linhas de voo, ocasionando em variação na altura do ponto (Khosravipour *et al.*, 2014). Esses dados espúrios foram suavizados com filtro média móvel ou filtro gaussiano, porém, os valores de altura do CHM podem ser alterados e importantes informações podem ser perdidas.

Para contornar esse problema, o algoritmo pit-free CHM utiliza como metodologia, a produção de diferentes camadas de CHM a diferentes alturas do solo e posterior sobreposição dessas camadas (Khosravipour *et al.*, 2013, 2014). Para isso, os dados de altitude dos pontos de laser foram normalizados, ou seja, os valores dos pontos foram alterados para a altura vertical do ponto em relação ao solo pelo modelo digital de elevação (MDE). A partir de interpretação visual da imagem aérea e da nuvem de pontos em locais com áreas com árvores urbanas, foi possível definir os limiares de 0 m, 5 m, 10 m, 15 m e 20 m para produção das camadas de CHM com a interpolação dos pontos pelo algoritmo TIN (*Triangular Irregular Network*). As camadas de CHM produzidas são sobrepostas de modo a compor o CHM sem dados espúrios (pit-free CHM), onde cada pixel sobreposto terá, como valor, a maior altura entre os pixels das diferentes camadas (Khosravipour *et al.*, 2013). A resolução espacial do CHM foi de 0,5 m, determinado a partir da densidade dos primeiros retornos do LiDAR (Chen *et al.*, 2006). Por meio do CHM foram obtidos os pontos máximos das árvores pelo algoritmo local máximo com janela móvel de 5 x 5 pixels. As métricas das árvores foram obtidas pela segmentação da árvore utilizando o programa R e o pacote lidR (Roussel *et al.*, 2020). Foram consideradas árvores os pontos com altura mínima de 5 m.

2.5 Métricas de paisagem e estrutura vertical da vegetação arbórea urbana

A vegetação arbórea urbana foi caracterizada por meio de métricas de paisagem calculadas a partir do mapeamento da cobertura arbórea urbana e por meio da estrutura vertical das árvores obtidas por dados LiDAR. Essas informações foram utilizadas para

avaliar qual(is) variável(is) está(ão) relacionada(s) com a redução da temperatura da superfície terrestre (TST).

As métricas de paisagem podem ser agrupadas em métricas de composição e de configuração. A composição refere-se à variedade e à abundância de determinada cobertura na paisagem, como a proporção de diferentes tipos de cobertura. A configuração é determinada pelas características espaciais, arranjo, posição ou complexidade geométrica das feições (Du *et al.*, 2016; Hu, Dai e Guldmann, 2021). As métricas para vegetação arbórea foram produzidas no *software* Fragstat 4.2, utilizando a técnica de *moving window*, com regra de 8 células vizinhas (McGarigal, 2015). Como resultados são produzidos dados *rasters* para as métricas desejadas. Foram selecionadas três métricas, considerando a importância teórica e prática, a facilidade de obtenção e a interpretabilidade, baixa redundância e por melhor explicar a variação da TST, como observado no Capítulo 2 (Li *et al.*, 2012). A métrica de composição foi a porcentagem de árvore (PArv) e porcentagem de cobertura de edificações (PEdif) e as métricas de configuração foram densidade de borda (DB), índice de maior fragmento (IMF), forma média dos fragmentos (Forma) e área média dos fragmentos (Area) (McGarigal, 2015) (Tabela 1). A estrutura vertical das árvores foi caracterizada pelas métricas: altura média de árvore (H média), altura máxima da árvore (H max), variância da altura da árvore (H desvpad) e amplitude da altura da árvore (H amp).

Tabela 1. Métricas de paisagem utilizadas para caracterização da vegetação arbórea na área urbana da cidade de Brasília, Brasil.

Métrica de paisagem	Descrição	Fórmula (unidade)
Porcentagem de cobertura (PCob)	Abundância proporcional para cada tipo de fragmento na unidade de análise.	$PCob_i = \frac{\sum_{j=1}^n a_{ij}}{A} * 100 (\%)$
Densidade de borda (DB)	Perímetro da feição da cobertura de copa por hectare na unidade de análise.	$DB_i = \frac{\sum_{j=1}^n p_{ij}}{A} * 10000 (m/ha)$
Índice de maior fragmento (IMF)	Proporção ocupada pelo maior fragmento na unidade de análise.	$IMF_i = \frac{\max(a_{ij})}{A} * 100 (\%)$
Forma média dos fragmentos (Forma)	Relação perímetro/área, corrigido por constante para padrão quadrado. Indica a complexidade da forma.	$Forma = \frac{1}{n_{ij}} \sum_{j=1}^n \frac{0,25 p_{ij}}{\sqrt{a_{ij}}} (\geq 1)$
Área média dos fragmentos (Area)	Média da área de copas de árvores por unidade de área	$Area = \frac{\sum_{i=1}^n a_{ij}}{n} (ha)$

a_{ij} = área da classe i no fragmento j ; A = área da unidade de análise p_{ij} = perímetro da classe i no fragmento j ; n = número de feições por unidade de área.

Tabela 2. Variáveis estruturais das árvores urbanas derivados de dados LiDAR.

Métrica de paisagem	Descrição	Fórmula
Altura média de árvore (H_med)	Média da altura da copa da árvore por unidade de análise	$H_{med_i} = \frac{\sum_{k=1}^n H_k}{n}$
	Altura máxima da copa da árvore por unidade de análise	
Desvio da altura da árvore (H_desvpad)	Desvio padrão da altura da copa da árvore por unidade de área	$H_{desvpad_i} = \sqrt{\frac{\sum_{k=1}^n (H_k - H_{média\ i})^2}{n}}$
	Diferença entre altura máxima e mínima da copa da árvore por unidade de análise	

H_k = altura da copa da árvore k na unidade de análise i; $H_{média\ i}$ = altura média da copa da árvore i; H_{max} e H_{min} = altura máxima e mínima da copa da árvore i, respectivamente; n = número de árvores.

3. Análise estatística

A contribuição das métricas horizontais e verticais sobre a TST foi observado considerando a TST como variável dependente, enquanto as variáveis independentes ou explicativas foram divididas em variável de composição da copa de árvore, configuração da copa de árvore e estrutura vertical da copa de árvore.

A correlação entre as variáveis dependentes e independentes foi obtida pela correlação de Pearson (P). Também foi aplicada a correlação parcial entre a TST e as métricas horizontais e verticais. Essa análise possibilita avaliar o grau de correlação entre as variáveis dependentes e independentes, após o controle dos efeitos mútuos entre elas (Chen, J. *et al.*, 2021).

A relação entre as variáveis tridimensionais das árvores sobre a TST foi avaliada por meio de unidades de análise no formato de grade regular com quadrados de dimensão 120 x 120 m. As variáveis TST, métricas de paisagem e a estrutura vertical das árvores foram convertidas em valores médios por unidade de análise. O modelo *Random Forest* (RF) foi aplicado para avaliar o quanto a variância da TST é explicada em função das variáveis explicativas relacionadas à vegetação arbórea e à edificação. O RF é um algoritmo baseado em árvores de regressão e classificação (*Classification and Regression Tree – CART*). O algoritmo RF produz CART a partir da seleção aleatório subconjunto

de dados por meio de *bootstrapping* de amostras de treinamento para uma árvore e variáveis preditoras para cada nó da árvore. O *bootstrapping* evita problemas encontrados no CART, como sensibilidade às amostras de treinamento e superestimativa (Gage e Cooper, 2017a; Yoo *et al.*, 2018).

O RF foi ajustado a partir de subconjuntos de variáveis explicativas: (1) variáveis de composição, (2) variáveis de configuração (3) variáveis relativas à estrutura vertical, (4) variáveis de composição + estrutura vertical, (5) configuração + estrutura vertical e (6) modelo completo. O algoritmo RF foi executado com 500 árvores e o *mtry* definido por meio da raiz quadrada do número de variáveis e a acurácia da predição dos modelos foi avaliada pelas estimativas dos erros pelo *out-of-bag* (OOB) (Gage e Cooper, 2017a; b; Helletsgruber *et al.*, 2020). O RF ordena as variáveis em função do potencial de predição, sendo possível comparar as variáveis nos modelos por meio do percentual de incremento no erro quadrático médio (%IncMSE) e pelo incremento na impureza do nó (IncNodeImpurity). O %IncMSE é estimado pela permutação do OOB e as variáveis preditoras, a diferença média de todas as árvores e a normalização delas pelo desvio padrão.

4. Resultados

4.1 Caracterização das métricas tridimensionais da paisagem

A região é caracterizada por aglomerados de estruturas urbanas, com construções de diferentes dimensões, pavimentação e intercaladas por áreas com gramado e vegetação arbórea. A vegetação arbórea, em sua maioria, foi implantada em praças, parques, jardins e nas proximidades das vias públicas, proporcionando conforto térmico e beleza cênica à população que reside e/ou trabalha na região. A região apresenta percentual de cobertura de árvore (PArv) variando entre 0,11 a 99,33%, com média de 22,86% de cobertura, enquanto que o percentual de cobertura de edificações (PEdif) variou de 0,11% a 75,44%, com média de cobertura de 21,03%, considerando a média das variáveis em unidades de análise de 120 x 120 m (Tabela 3).

As unidades de análise de 120 x 120 m apresentaram alta variação na cobertura com vegetação arbórea e edificações. Algumas unidades de análise chegaram a apresentar quase 100% de cobertura, diferente da classe de edificações que apresentou no máximo 75% de cobertura, aproximadamente. Porém, isso não demonstra que todas as unidades de análise apresentam mistura de cobertura florestal com edificações, visto que outros

tipos de cobertura também estão presentes (estradas, gramados, corpos d'água, dentre outros) formando o mosaico urbano.

Tabela 3. Resumo estatístico de métricas de paisagem relativas à composição e configuração das árvores e edificações.

Variável	Arbórea			Edificações		
	Min	Max	Média	Min	Max	Média
Percentual de Cobertura (PCob)	0,11	99,33	22,86	0,11	75,44	21,03
Densidade de Borda (DB)	5,56	963,89	412,98	5,56	1216,67	490,92
Índice de Maior Fragmento (IMF)	0,11	99,33	14,94	0,11	73,89	11,75
Área média (Área)	0,00	1,43	0,08	0,00	0,53	0,05
Formato médio (Forma)	1,00	3,55	1,36	1,00	2,82	1,38

Os fragmentos de vegetação arbórea urbana apresentaram densidade de borda (DB) média de 412,98 m ha⁻¹ e as edificações apresentaram DB de borda média de 490,92 m ha⁻¹, no entanto, os valores máximos de DB da classe edificação foi superior ao observado para vegetação arbórea. O índice de maior fragmento (IMF) representa a relação entre o maior fragmento por classe em relação a uma determinada área que, neste caso, é a unidade de análise. O IMF das árvores apresentou média de 14,94% e o IMF das edificações foi de 11,75%, indicando a predominância média de maiores fragmentos arbóreos em relação aos aglomerados de edificações.

A vegetação arbórea apresentou fragmentos contínuos com área média de 0,08 ha, chegando a 1,43 ha, aproximando-se da área da unidade de análise de 1,44 ha (120 x 120 m). As edificações apresentaram área média semelhante (0,05 ha) aos fragmentos de vegetação arbórea, porém a maior área média foi de 0,53 ha. A complexidade de forma das classes arbórea e edificação é indicada pela variável Forma. Quanto mais próximo de 1, menor a complexidade do fragmento (Tabela 3). A vegetação arbórea apresentou fragmentos com maior complexidade em relação às edificações, quando avaliado com os valores mínimos e máximos. No entanto, os valores médios da variável Forma foram de 1,36 para vegetação arbórea e de 1,38 para edificações, indicando que a vegetação arbórea tem, em média, formas menos complexas que as edificações.

A estrutura vertical das árvores urbanas demonstrou que a média da altura média das árvores (H_med) foi de 7,49 m, com menores valores de 2 m, ocorrendo na região central da área de estudo e chegando a 18,36 m em algumas unidades de análise. A altura máxima (H_max) apresentou valores variando entre 5,39 a 24,38 m, com valor médio de

12,61 m. Essas árvores estão presentes em toda área de estudo, com homogeneidade de ocorrência entre as unidades de análise da região sul. A altura das árvores apresentou desvio padrão de 1,54-9,93 m, com valor médio de 4,15 m. A amplitude de copa (H_amp) indica a variação da altura da copa das árvores, obtida pela diferença entre a maior e a menor altura de copa observada por indivíduo. A menor amplitude foi de 3,67 m, chegando a 22,75 m. As maiores amplitudes de copa foram observadas na região centro-sul da área de estudo. A região centro-norte também apresentou algumas unidades de análise com amplitudes próximas a 22 m, porém com ocorrência espaçada e isolada quando comparada a região centro-sul.

Tabela 4. Caracterização da estrutura vertical das árvores (metros) por indivíduo e por unidade de análise.

Variável	Mínimo	Máximo	Médio
Altura média (H_med)	2,00	18,36	7,49
Altura máxima (H_max)	5,39	24,38	12,61
Desvio padrão da altura (H_desvpad)	1,54	9,93	4,15
Amplitude de copa (H_amp)	3,67	22,75	11,94
Altura de edificação	1,12	114,66	15,33

4.2 Correlação entre a temperatura da superfície e a morfologia urbana

O percentual de cobertura de árvore (PARv) apresentou forte correlação negativa de -0,64 a 0,69 com a TST nas diferentes estações do ano. Quando a influência da configuração e estrutura da vegetação arbórea é controlada, a correlação do PARv tem redução nos valores, porém, ainda indica correlação negativa, demonstrando que o aumento da cobertura de árvores induz a redução da temperatura do ambiente, variando de -0,13 a -0,15.

A correlação entre a temperatura e as variáveis de configuração e de composição apresentaram fortes correlações negativas. Ao controlar os efeitos, a correlação parcial da densidade de borda (DB) foi negativa em todas as estações (-0,22 a -0,32), demonstrando que o aumento da densidade de borda dos fragmentos de vegetação contribuiu para o resfriamento urbano (Tabela 5). O índice de maior fragmento (IMF) contribuiu para a redução da temperatura na primavera e no inverno, porém, após o controle da composição e estrutura vertical, o efeito do IMF no verão e outono foi positivo, indicando que o

aumento do IMF contribui para aumentar a temperatura da superfície. A métrica Area (área média) da vegetação arbórea, calculada por unidade de análise, apresentou efeito positivo sobre a temperatura do ambiente, ou seja, aumentando a área média nas unidades de 120 x 120 m propicia a elevação da temperatura. A complexidade do formato dos fragmentos arbóreos pode ser observada pelos altos valores atribuídos à variável Forma. A correlação parcial demonstrou que a Forma contribuiu para mitigar o aquecimento da superfície apenas na primavera e inverno, enquanto nas demais estações o efeito não foi significativo. Por meio do IMF, Area e Forma, é possível verificar que a presença de grandes fragmentos contínuos contribuiu para o aquecimento do ambiente urbano. Por outro lado, o aumento da frequência de fragmentos arbóreos com formatos complexos contribui para o resfriamento do ambiente urbano (Tabela 5).

As variáveis relativas à estrutura vertical das árvores urbanas apresentaram correlação negativa com a TST em todas as estações. Na primavera e no inverno, a altura média (H_med) teve maior contribuição na redução da temperatura, com correlação de Pearson parcial superior às variáveis de composição e configuração da vegetação arbórea urbana. A altura máxima (H_max) também contribuiu para redução da temperatura na primavera, inverno e no outono, tendo baixa contribuição no verão. A amplitude da copa das árvores (H_amp) também demonstrou forte contribuição na redução do desconforto térmico, apresentando efeito negativo na primavera, outono e inverno. O desvio padrão da altura das árvores apresentou efeito negativo sobre a TST, porém com correlação menor em relação às demais métricas da estrutura vertical da vegetação (Tabela 5). Todas as variáveis relativas à estrutura vertical da vegetação arbórea apresentaram considerável contribuição no resfriamento, diferente da correlação parcial observada para algumas variáveis relativas à configuração das árvores urbanas.

Tabela 5. Correlação entre variáveis tridimensionais da vegetação arbórea e a TST. A correlação parcial está em negrito. Para o PARv a configuração e a estrutura vertical das árvores foram as variáveis de controle. O PARv e a estrutura vertical foram as variáveis de controle para as métricas de configuração. Para as métricas da estrutura vertical das árvores, as variáveis de controle foram PARv e variáveis de configuração. O n foi de 1962.

TST	PARv	DB	IMF	Area	Forma	H_med	H_max	H_desvpad	H_amp
Primavera	-0,69**	-0,69**	-0,49**	-	-0,49**	-0,68**	-0,66**	-0,56**	-0,63**
	-0,16**	-0,29**	-0,32**	0,31**	-0,08**	-0,36**	-0,32**	-0,22**	-0,27**
Verão	-0,66**	-0,60**	-0,55**	-	-0,36**	-0,48**	-0,51**	-0,48**	-0,51**
	-0,15**	-0,22**	0,14**	0,33**	0,05	-0,07**	-0,12**	-0,16**	-0,15**
Outono	-0,70**	-0,70**	-0,56**	-	-0,47**	-0,63**	-0,63**	-0,56**	-0,61**
	-0,15**	-0,32**	0,21**	0,31**	-0,05	-0,27**	-0,27**	-0,23**	-0,25**
Inverno	-0,64**	-0,65**	-0,47**	-	-0,46**	-0,65**	-0,63**	-0,52**	-0,59**
	-0,13**	-0,28**	-0,28**	0,26**	-0,06*	-0,35**	-0,30**	-0,18**	-0,24**

TST = temperatura da superfície terrestre; PARv = percentual de cobertura de árvore; DB = densidade de borda; IMF = índice de maior fragmento; Area = área média; Formato = Relação perímetro/área, indica a complexidade da forma; H_med = altura média da árvore; H_max = altura máxima da árvore; H_desvpad = desvio padrão da altura da árvore; H_amp = amplitude da altura da copa da árvore *p < 0,05; **p < 0,01.

A cobertura de edificações por unidade de área é representada pelo percentual de coberta de edificações (PEdif). Esta variável apresentou correlação parcial negativa com a temperatura da superfície no inverno e correlação parcial positiva com a primavera, verão e outono. O aumento da fragmentação das edificações contribuiu para reduzir a temperatura como demonstrado pela correlação negativa da densidade de borda (DB) das edificações com a temperatura. O IMF da edificação foi negativo no inverno e primavera e positivo no verão e outono, indicando que a predominância de edificações com grandes extensões propicia o resfriamento do ambiente no mês de menor temperatura média (inverno) e no mês de maior temperatura média da superfície (primavera). Isso pode estar relacionado com o manejo de vegetação urbana nos espaços entre as edificações. A área média das edificações (Area) apresentou correlação positiva, indicando que o aumento da área média das edificações tende a aumentar o desconforto térmico. A variável Forma apresentou correlação parcial negativa com a temperatura nas duas estações climáticas, indicando que quanto maior for a complexidade do formato das edificações, menor é a temperatura da superfície. O aumento da altura dos prédios também proporciona redução da temperatura em todas as estações do ano.

Tabela 6. Correlação entre variáveis tridimensionais das edificações e a TST. A correlação parcial está em negrito. Para o PEdif, a configuração e a altura das edificações foram as variáveis de controle. O PEdif e a altura das edificações foram as variáveis de controle para as métricas de configuração. Para a altura das edificações, as variáveis de controle foram PEdif e variáveis de configuração. O n foi de 1962.

TST	PEdif	DB	IMF	Area	Forma	Altura
Inverno	0,01	0,34**	-0,30**	0,06*	-0,20**	-0,27**
	-0,08**	-0,06**	-0,33**	0,10**	-0,22**	-0,26**
Primavera	0,09**	-0,09**	-0,25**	0,12**	-0,16**	-0,18**
	0,12**	-0,31**	-0,33**	0,09**	-0,24**	-0,17**
Verão	0,49**	0,34**	0,46**	0,33**	0,12**	-0,03
	0,21**	-0,15**	0,09**	-0,05	-0,20**	-0,08**
Outono	0,28**	0,09**	0,32**	0,23**	-0,05	-0,15**
	0,15**	-0,27**	0,19**	0,05*	-0,23**	-0,17**

TST = temperatura da superfície terrestre; PEdif = percentual de cobertura por edificação; DB = densidade de borda; IMF = índice de maior fragmento; Area = área média; Formato = Relação perímetro/área, indica a complexidade da forma; *p < 0,05; **p < 0,01.

4.3 Modelagem da TST em relação a variáveis tridimensionais da vegetação arbórea

A análise de variância (ANOVA) entre as variâncias do *Random Forest* por grupo de variáveis explicativas apresentou diferença significativa ($p < 0,05$). Esse resultado demonstra que pelo menos umas das variâncias dos modelos diferiu das demais. As variâncias explicadas pelos modelos para cada uma das estações, apresentou homogeneidade pelo teste de Bartlett e o teste de normalidade de Shapiro-Wilk indicou que os resíduos a ANOVA apresentaram normalidade (Figura 2).

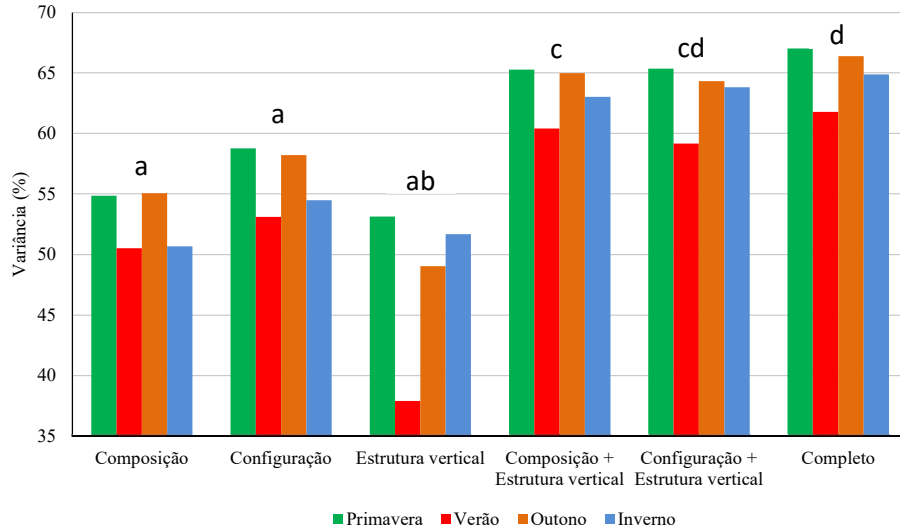


Figura 2. Variância explicativa da temperatura da superfície terrestre (TST) modelo *Random Forest* ajustado com conjuntos de variáveis. Comparação das médias dos conjuntos das variáveis explicativas par-a-par são indicadas por letras; modelos com mesma letra não diferem significativamente um do outro.

O modelo com menor potencial explicativo (37,91%) foi o modelo ajustado com variáveis relativas à estrutura vertical das árvores e das edificações no verão, estação caracterizada por alta temperatura e ocorrência de chuvas (Figura 1). A composição da paisagem apresentou baixo efeito de explicação da TST no verão e inverno, com variância próxima a 50%. O modelo completo apresentou variação de explicação de 61,77% a 67,01% da TST nas quatro estações do ano, com explicação de 66,37% e 67,01% no outono e primavera, respectivamente.

Considerando que o modelo completo utilizou 15 variáveis, os modelos utilizando variáveis de configuração e estrutura vertical apresentaram potencial explicativo de 59,15% a 65,36% da TST nas quatro estações, ajustados com 13 variáveis explicativas, variação próxima ao modelo completo que utilizou 15 variáveis. Os modelos sazonais ajustados com variáveis de composição e estrutura vertical apresentaram explicação da variância de 60,41% a 65,28%, utilizando sete variáveis explicativas, menor número de variáveis explicativas em relação ao modelo completo e com alto potencial de explicação da variância da temperatura da superfície (Figura 2).

A explicação dos modelos utilizando as variáveis de composição, configuração e estrutura vertical não apresentou diferença significativa, indicando que o uso de qualquer uma dessas variáveis tem o mesmo potencial de explicação da variação da temperatura

de superfície (Figura 2). A estrutura vertical quando adicionada da composição ou configuração, aumentou o potencial de explicação dos modelos em relação à explicação dessas variáveis separadamente. O modelo completo apresentou alto potencial de explicação da variação da temperatura nas estações do ano, não diferindo significativamente do modelo ajustando com configuração e a estrutura vertical (Figura 2).

Por meio dos modelos sazonais completos é possível estimar a contribuição de cada variável na variância do modelo a partir do incremento no erro médio quadrático (IncMSE%). O ranqueamento das variáveis por meio do IncMSE% demonstra que as variáveis explicativas apresentaram distintas contribuições na explicação da variância do *Random Forest* em função da temperatura por estação climática (Figura 3). O percentual de cobertura de árvore (PARv) apresentou contribuição ligeiramente superior à altura de edificação (H_Edif) na explicação da variância na primavera. Porém, nas demais estações, o H_Edif teve forte contribuição na explicação da variância dos modelos ajustados, sendo a variável com maior valor de IncMSE no verão, outono e inverno. A densidade de borda das árvores (DB_Arv) foi a terceira variável com maior contribuição na primavera (30,71%) e no outono (28,84%). Já no verão e no inverno, o PARv foi a variável com o terceiro maior peso na explicação da variância, com 31,50% e 32,71%, respectivamente (Figura 3).

A forma da árvore (Forma_Arv) foi uma das variáveis que menos contribuíram para o ajuste dos modelos, com valor no IncMSE pouco superior a 10%. A área da edificação (Area_Edif) também foi uma das variáveis que apresentaram menor contribuição na explicação da variância dos modelos (Figura 3).

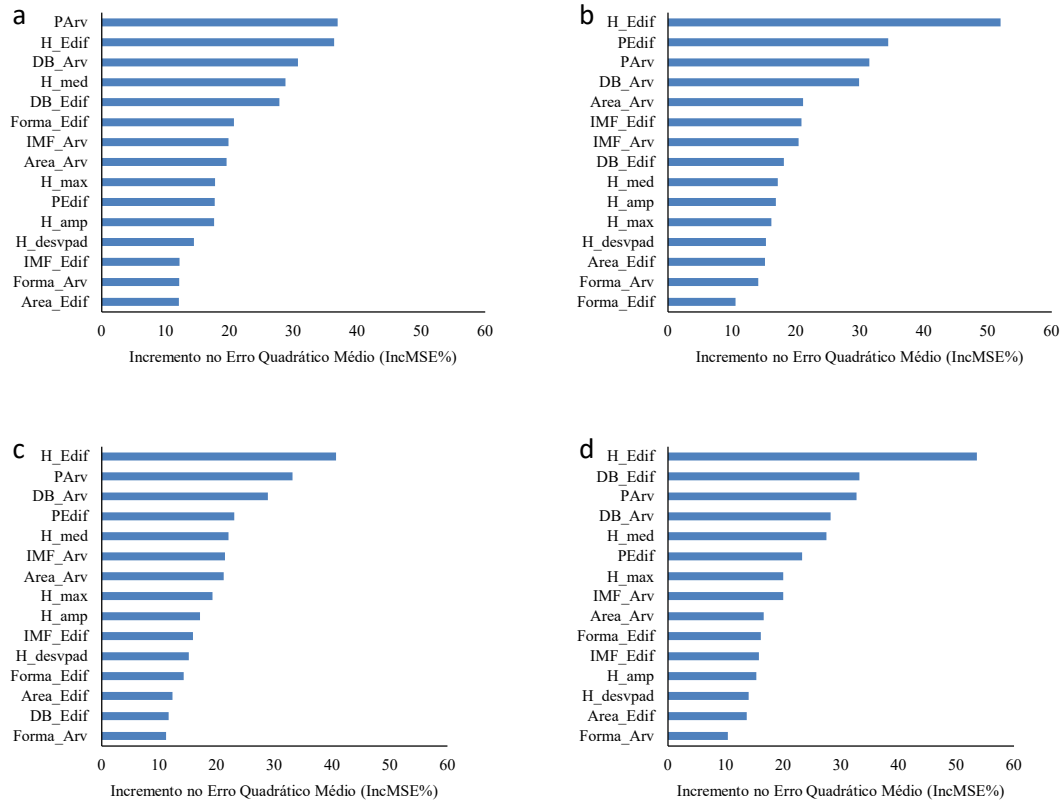


Figura 3. Incremento no Erro Quadrático Médio (IncMSE%) das variáveis explicativas para estimativa da temperatura de superfície terrestre (TST) na a) primavera, b) verão, c) outono e d) inverno.

5. Discussão

5.1 Efeitos das árvores urbanas e edificações sobre a temperatura

Alguns estudos têm utilizado uma imagem ou poucas imagens para avaliar a relação entre a temperatura de superfície terrestre (TST) e a morfologia urbana na perspectiva de compreender quais características da vegetação e construção podem ser consideradas no manejo e planejamento urbano afim de minimizar os efeitos negativos do aumento da temperatura ocasionado pela expansão urbana e pelas mudanças climáticas (Wang, Zhou e Wang, 2019; Zhou, Wang e Cadenasso, 2017). No entanto, pequenas séries temporais da TST podem ocasionar em inferências tendenciosas em relação à identificação dos períodos mais quentes e a identificação de variáveis da vegetação arbórea que contribuem para redução da temperatura (He *et al.*, 2021).

O percentual de cobertura de árvores (PCArv) apresentou forte efeito sobre o resfriamento do ambiente durante as estações avaliadas, apresentando forte correlação negativa com a LST. Após o controle de variáveis relativas à configuração e à estrutura vertical da vegetação, foi observada redução do efeito da PCArv sobre a temperatura, porém ainda apresentou efeito negativo sobre a temperatura. A alta densidade da copa das árvores contribuiu para reduzir a incidência de radiação solar na superfície e por proporcionar aumento na evapotranspiração. Espécies com baixa densidade de copa, que permitem a penetração e incidência da radiação sobre a superfície, tendem a apresentar maior temperatura do ar abaixo da copa (Wujeska-Klaue e Pfautsch, 2020).

As métricas de configuração demonstraram que as áreas analisadas chegaram a apresentar maiores valores de densidade de borda (DB) para edificações em relação à DB da cobertura arbórea. Isso demonstra que, em alguns locais, há alta concentração de edificações ou edificações com formatos irregulares. Para verificar essas possibilidades, pode-se avaliar o índice Forma que determina o grau de complexidade do formato das feições. A vegetação arbórea apresentou valores máximos para o índice Forma, superior ao encontrado para classe edificações, indicando que o valor máximo de DB está relacionado com a complexidade das feições, enquanto para edificação o valor máximo de DB pode estar relacionado à alta densidade de feições em algumas unidades de análise. Por meio de interpretação visual de imagem, é possível observar que a grande parte da vegetação está situada no alinhamento das vias públicas e no entorno das edificações, fazendo com que a vegetação tenha disposição espacial similar às construções. Isso pode ser constatado por meio dos valores médios de DB e Forma para vegetação arbórea e edificação, demonstrando que no geral são feições com formato e densidades similares.

A densidade de borda (DB) dos fragmentos florestais e da edificação foi a variável que apresentou correlação negativa em todas as estações do ano. A fragmentação das árvores e edificações tendem a aumentar o perímetro dessas classes, enquanto a concentração das feições reduz a quantidade de fragmentos e o perímetro. Assim, altos valores de DB indicam alto número de fragmentos ou fragmentos com alta densidade de borda devido à irregularidade do formato (He *et al.*, 2021). Nesse sentido, a variável Forma da classe arbórea apresentou valores não significativos no verão e outono e fraca correlação parcial significativa na primavera e no inverno. Além disso, a Forma apresentou baixa contribuição no IncMESE% dos modelos sazonais de RF, demonstrando a baixa contribuição desta variável para explicação da variação da TST, enquanto a DB de árvore apresentou contribuição sazonal acima de 28%. A partir disso, pode-se inferir

que o aumento da concentração de fragmentos arbóreos contribuiu para o resfriamento do ambiente na região. Isso pode estar relacionado à facilitação do escoamento do vento entre os fragmentos de árvore. A massa de ar que está próxima à superfície aquece por condução de calor entre a superfície e o ar, o que reduz a densidade do ar. O ar quente é trocado por ar denso e frio pelo processo de convecção. Esse processo torna-se dinâmico com a facilitação da passagem do ar entre os fragmentos de vegetação arbórea, promovendo a redução da temperatura da superfície.

As métricas relativas à altura de árvore também apresentaram correlação parcial negativa, demonstrando que elevar os valores dessas variáveis contribuiu para o resfriamento do ambiente. A altura média (H_{med}) e a altura máxima (H_{max}) tiveram forte correlação parcial na primavera, outono e no inverno, enquanto no verão as maiores correlações foram observadas para as variáveis desvio padrão da altura ($H_{desvpad}$). Alguns estudos também observaram que árvores mais altas proporcionaram a redução da temperatura da superfície, decorrente do sombreamento da superfície que possibilitou a redução do aquecimento do ar abaixo e no entorno da copa da árvore (Smithers *et al.*, 2018; Wujeska-Klaue e Pfautsch, 2020). Diferente de árvores mais baixas, onde a projeção da copa é menor e apresenta menor efeito sobre o resfriamento do ar (Wujeska-Klaue e Pfautsch, 2020). Isso não foi observado por Helletsgruber *et al.* (2020), onde foi identificado que altura da base da copa menores proporcionaram maior resfriamento do ambiente.

No caso das edificações, é possível observar que feições com formato complexo e com alta concentração de bordas tendem a reduzir a temperatura do ambiente em todas as estações. A altura das edificações (H_{Edif}) também apresentou correlação negativa e altos valores de IncMSE% na explicação da variação da TST, demonstrando que quanto maior for a edificação maior será o efeito de resfriamento sobre o ambiente (Gage e Cooper, 2017a). O formato irregular das edificações pode estar associado à ocorrência de árvores no entorno das edificações, aumentando a evapotranspiração do ambiente. Além disso, edificações mais altas tendem a ter maior projeção de sombra, o que reduz a incidência direta de radiação solar sobre a superfície (Morakinyo *et al.*, 2017; Nath, Ni-Meister e Özdoğan, 2021). Por outro lado, o aumento da fragmentação de edificações, determinado pela área média ($\bar{Área}$), contribuiu para o aumento da temperatura da superfície nas quatro estações avaliadas, ou seja, para reduzir a temperatura da superfície é interessante que as edificações tenham formatos complexos, baixa fragmentação e alta concentração de borda.

No manejo e implantação da vegetação arbórea urbana, é importante considerar as características das edificações urbanas no planejamento da vegetação. Regiões com ocorrência de prédios podem ocasionar a formação de cânions. Esses locais são caracterizados pelo sombreamento das edificações e pela redução da incidência direta de radiação, que reduz a formação de ilhas de calor durante o dia. A inserção de árvores altas e com copas densas entre grandes edificações impede a dissipação de energia da superfície para atmosfera, ocasionando em desconforto térmico à noite (Morakinyo *et al.*, 2017). Segundo Helletsgruber *et al.* (2020) a vegetação urbana apresentou maior efeito de resfriamento em áreas abertas, onde havia alta incidência de radiação solar. Nos locais com sombreamento de altas edificações, conhecidos como cânions urbanos, a vegetação não apresentou grande contribuição no resfriamento do ambiente, tendo o sombreamento dos prédios maior efeito de resfriamento. Assim, é importante avaliar com mais detalhe a relação da temperatura urbana e as variáveis morfológicas urbanas visando determinar com mais detalhes os parâmetros que viabilizem o manejo da vegetação para resfriamento do ambiente durante o dia e a noite.

5.2 Pesquisas futuras

Além das variáveis aqui avaliadas como potenciais responsáveis pelo aquecimento ou resfriamento do ambiente, é importante avaliar outras variáveis que sejam de fácil interpretação e mensuração no ambiente urbano. Alguns estudos têm demonstrado que é possível indicar espécies de árvores que mais contribuem para redução da temperatura durante o dia e a noite, a partir de parâmetros mensurados em campo, como diâmetro de copa e índice de área foliar (Helletsgruber *et al.*, 2020; Morakinyo *et al.*, 2017; Speak *et al.*, 2020). A avaliação sazonal da temperatura em relação à morfologia urbana, mostrou que as variáveis explicativas contribuem de forma diferente sobre a explicação da temperatura ao longo das estações. Além disso, é necessário avaliar os efeitos dessas variáveis na temperatura noturna, uma vez que as variáveis tridimensionais que contribuem para o resfriamento diurno pode contribuir para o aquecimento noturno, aumentando o desconforto térmico à noite.

6. Conclusão

Variáveis tridimensionais relativas à vegetação arbórea urbana e às edificações apresentaram correlação significativa com a temperatura da superfície terrestre, mostrando-se como fatores importantes na formação de ilhas de calor urbano. As variáveis percentuais de cobertura de árvore (PArv), densidade de borda (DB) e altura das árvores devem ser considerados no manejo da vegetação, pois contribuirão para redução da temperatura na área de estudo. Essas variáveis devem ser consideradas juntamente com a DB e a altura dos edifícios, uma vez que proporcionam o sombreamento e consequente resfriamento do ambiente.

7. Referência bibliográficas

CHEN, J.; JIN, S.; DU, P. Roles of horizontal and vertical tree canopy structure in mitigating daytime and nighttime urban heat island effects. **International Journal of Applied Earth Observation and Geoinformation**, v. 89, n. July 2019, p. 102060, 2020.

CHEN, J.; ZHAN, W.; JIN, S.; et al. Separate and combined impacts of building and tree on urban thermal environment from two- and three-dimensional perspectives. **Building and Environment**, v. 194, n. 219, p. 107650, 2021.

CHEN, Q.; BALDOCCHI, D.; GONG, P.; KELLY, M. Isolating individual trees in a savanna woodland using small footprint LiDAR data. **Photogrammetric Engineering and Remote Sensing**, v. 72, n. 8, p. 923–932, 2006.

DU, S.; XIONG, Z.; WANG, Y. C.; GUO, L. Quantifying the multilevel effects of landscape composition and configuration on land surface temperature. **Remote Sensing of Environment**, v. 178, p. 84–92, 2016.

GAGE, E. A.; COOPER, D. J. Urban forest structure and land cover composition effects on land surface temperature in a semi-arid suburban area. **Urban Forestry and Urban Greening**, v. 28, n. September, p. 28–35, 2017a.

GAGE, E. A.; COOPER, D. J. Relationships between landscape pattern metrics, vertical structure and surface urban Heat Island formation in a Colorado suburb. **Urban Ecosystems**, v. 20, n. 6, p. 1229–1238, 2017b.

HE, C.; ZHOU, L.; YAO, Y.; MA, W.; KINNEY, P. L. Cooling effect of urban trees and its spatiotemporal characteristics: A comparative study. **Building and Environment**, v. 204, n. April, p. 108103, 2021.

HELLETSGRUBER, C.; GILLNER, S.; GULYÁS, Á.; et al. Identifying tree traits for cooling urban heat islands—a cross-city empirical analysis. **Forests**, v. 11, n. 10, p. 1–14, 2020.

HU, Y.; DAI, Z.; GULDMANN, J. M. Greenspace configuration impact on the urban heat island in the Olympic Area of Beijing. **Environmental Science and Pollution Research**, n. 2017, 2021. Environmental Science and Pollution Research.

- KHOSRAVIPOUR, A.; SKIDMORE, A. K.; ISENBURG, M.; WANG, T.; HUSSIN, Y. A. Development of an algorithm to generate a LiDAR pit - free canopy height model. *Proceedings of Silvilaser 2013: 13th International conference on LiDAR applications for assessing forest ecosystems*, October, 9-11, 2013 Beijing, China, p. Paper SL2013-030, p. 125–128, 2013.
- KHOSRAVIPOUR, A.; SKIDMORE, A. K.; ISENBURG, M.; WANG, T.; HUSSIN, Y. A. Generating pit-free canopy height models from airborne LiDAR. *Photogrammetric Engineering and Remote Sensing*, v. 80, n. 9, p. 863–872, 2014.
- LI, X.; ZHOU, W.; OUYANG, Z. Relationship between land surface temperature and spatial pattern of greenspace: What are the effects of spatial resolution? *Landscape and Urban Planning*, v. 114, p. 1–8, 2013.
- LI, X.; ZHOU, W.; OUYANG, Z.; XU, W.; ZHENG, H. Spatial pattern of greenspace affects land surface temperature: Evidence from the heavily urbanized Beijing metropolitan area, China. *Landscape Ecology*, v. 27, n. 6, p. 887–898, 2012.
- MAIMAITIYIMING, M.; GHULAM, A.; TIYIP, T.; et al. Effects of green space spatial pattern on land surface temperature: Implications for sustainable urban planning and climate change adaptation. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 89, p. 59–66, 2014.
- MAN, Q.; DONG, P.; YANG, X.; WU, Q.; HAN, R. Automatic Extraction of grasses and individual trees in urban areas based on airborne hyperspectral and LiDAR data. *Remote Sensing*, v. 12, n. 17, p. 1–22, 2020.
- MCGARIGAL, K. Fragstats. *Fragstats*, , n. April, p. 1–182, 2015.
- MORAKINYO, T. E.; KONG, L.; LAU, K. K. L.; YUAN, C.; NG, E. A study on the impact of shadow-cast and tree species on in-canyon and neighborhood's thermal comfort. *Building and Environment*, v. 115, p. 1–17, 2017.
- NATH, B.; NI-MEISTER, W.; ÖZDOĞAN, M. Fine-scale urban heat patterns in New York city measured by ASTER satellite—The role of complex spatial structures. *Remote Sensing*, v. 13, n. 19, p. 1–19, 2021.
- OKE, T. R. The energetic basis of the urban heat island. *Quarterly Journal of the Royal Meteorological Society*, v. 108, n. 455, p. 1–24, 1982.
- QIN, Z.; KARNIELI, A.; BERLINER, P. A mono-window algorithm for retrieving land surface temperature from Landsat TM. *International journal of remote sensing*, v. 22, n. 18, p. 3719–3746, 2001.
- ROUSSEL, J.-R.; AUTY, D.; COOPS, N. C.; et al. lidR: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sensing of Environment*, v. 251, p. 112061, 2020.
- SCHNEIBERG, I.; BOSCOLO, D.; DEVOTO, M.; et al. Urbanization homogenizes the interactions of plant-frugivore bird networks. *Urban Ecosystems*, v. 23, n. 3, p. 457–470, 2020. *Urban Ecosystems*.

- SINGH, M.; EVANS, D.; TAN, B. S.; NIN, C. S. Mapping and characterizing selected canopy tree species at the Angkor world heritage site in Cambodia using aerial data. **PLoS ONE**, v. 10, n. 4, p. 1–26, 2015.
- SMITHERS, R. J.; DOICK, K. J.; BURTON, A.; et al. Comparing the relative abilities of tree species to cool the urban environment. **Urban Ecosystems**, v. 21, n. 5, p. 851–862, 2018. Urban Ecosystems.
- SOBRINO, J. A.; JIMÉNEZ-MUÑOZ, J. C.; PAOLINI, L. Land surface temperature retrieval from LANDSAT TM 5. **Remote Sensing of Environment**, v. 90, n. 4, p. 434–440, 2004.
- SOBRINO, J.; JIMENEZ, J.; SORIA, G.; et al. Land surface emissivity retrieval from different VNIR and TIR sensors. **IEEE Transactions on Geoscience and Remote Sensing**, v. 2, n. 46, p. 316–327, 2008.
- SPEAK, A.; MONTAGNANI, L.; WELLSTEIN, C.; ZERBE, S. The influence of tree traits on urban ground surface shade cooling. **Landscape and Urban Planning**, v. 197, n. January, p. 103748, 2020.
- WANG, F.; QIN, Z.; SONG, C.; et al. An improved mono-window algorithm for land surface temperature retrieval from landsat 8 thermal infrared sensor data. **Remote Sensing**, v. 7, n. 4, p. 4268–4289, 2015.
- WANG, J.; ZHOU, W.; JIAO, M.; et al. Significant effects of ecological context on urban trees' cooling efficiency. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, n. 18, p. 78–89, 2020.
- WANG, JIA; ZHOU, W.; WANG, JING. Time-series analysis reveals intensified urban heat island effects but without significant urban warming. **Remote Sensing**, v. 11, n. 19, 2019.
- WUJESKA-KLAUSE, A.; PFAUTSCH, S. The best Urban trees for daytime cooling leave nights slightly warmer. **Forests**, v. 11, n. 9, 2020.
- YOO, C.; IM, J.; PARK, S.; QUACKENBUSH, L. J. Estimation of daily maximum and minimum air temperatures in urban landscapes using MODIS time series satellite data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 137, p. 149–162, 2018.
- YU, Q.; ACHEAMPONG, M.; PU, R.; et al. Assessing effects of urban vegetation height on land surface temperature in the City of Tampa, Florida, USA. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, n. August, p. 712–720, 2018.
- ZHOU, W.; WANG, J.; CADENASSO, M. L. Effects of the spatial configuration of trees on urban heat mitigation: A comparative study. **Remote Sensing of Environment**, v. 195, p. 1–12, 2017.

Considerações finais

A cidade de Brasília está em constante transformação para atender as demandas da sociedade, porém tem ocasionado o aumento da temperatura em relação as regiões vizinhas, formando as ilhas de calor urbano (ICU), com maior expressão na primavera em relação as demais estações do ano. Para contornar esses efeitos, é importante realizar o manejo adequado da vegetação urbano, sendo que a vegetação arbórea apresentou maior efeito de resfriamento em relação a vegetação rasteira. Aumentar a cobertura de vegetação arbórea, reduz de forma significativa a temperatura do ambiente, porém devido a limitação de espaços para implantação de novas árvores, é importante considerar, também, a implantação de fragmentos de vegetação arbórea com formatos irregulares, para aumentar o sombreamento e a evapotranspiração. Nesse estudo, foi observado que as edificações também desempenham importante função no resfriamento urbano, principalmente pelo sombreamento dos maiores edifícios. Assim, árvores de menor porte podem estar associadas a edifícios maiores, enquanto que em ambientes com edifícios de menor porte, pode-se alocar maiores árvores, de forma a reduzir a temperatura do ambiente urbano.

APÊNDICES

Tabela A1. Cálculo do recall (r) ou revocação para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando combinações de filtro média móvel com variações no tamanho de janela de suavização (TJS) e no tamanho da janela de árvore (TJA) em Brasília (DF).

Recall (r)												
Tamanho de Janela de Suavização (TJS)												
UA	3x3 m				5x5 m				7x7 m			
	Tamanho de Janela de Árvore (TJA)											
	3x3 m	5x5 m	7x7 m	9x9 m	3x3 m	5x5 m	7x7 m	9x9 m	3x3 m	5x5 m	7x7 m	9x9 m
1	1,00	1,00	1,00	0,99	1,00	1,00	1,00	0,93	1,00	1,00	1,00	0,86
2	1,00	1,00	0,86	0,74	1,00	0,94	0,83	0,63	1,00	0,86	0,80	0,63
3	1,00	1,00	1,00	0,85	1,00	1,00	0,94	0,80	1,00	0,93	0,84	0,72
4	1,00	1,00	0,83	0,62	1,00	0,97	0,73	0,57	0,88	0,75	0,64	0,52
5	1,00	1,00	0,69	0,49	1,00	0,82	0,58	0,44	0,76	0,58	0,47	0,41
6	1,00	1,00	0,74	0,54	1,00	0,86	0,64	0,47	0,80	0,64	0,52	0,42
7	1,00	1,00	0,85	0,61	1,00	0,98	0,73	0,56	0,96	0,74	0,61	0,49
8	1,00	1,00	0,86	0,65	1,00	0,93	0,80	0,58	0,89	0,75	0,67	0,56
9	1,00	1,00	0,81	0,67	1,00	0,90	0,72	0,63	0,88	0,74	0,70	0,60
10	1,00	1,00	1,00	0,94	1,00	0,96	0,87	0,71	0,89	0,84	0,79	0,64
11	1,00	1,00	0,72	0,55	1,00	0,81	0,64	0,51	0,78	0,64	0,56	0,49
12	1,00	1,00	0,94	0,70	1,00	1,00	0,83	0,64	1,00	0,89	0,72	0,61
13	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,93	1,00	0,86	0,86	0,71
14	1,00	1,00	0,90	0,68	1,00	1,00	0,81	0,64	0,97	0,81	0,71	0,57
15	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,97	0,89
16	0,93	0,77	0,64	0,55	0,59	0,50	0,45	0,41	0,41	0,39	0,36	0,34
17	1,00	1,00	1,00	0,96	1,00	1,00	0,91	0,78	0,89	0,78	0,72	0,62
18	1,00	1,00	0,86	0,70	1,00	0,99	0,78	0,65	0,94	0,79	0,69	0,61
19	1,00	1,00	0,88	0,66	1,00	0,98	0,83	0,64	0,88	0,76	0,69	0,54
20	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,98	0,89
21	1,00	1,00	0,65	0,45	1,00	0,87	0,64	0,42	0,88	0,74	0,57	0,42
22	1,00	0,68	0,42	0,39	0,81	0,52	0,45	0,39	0,58	0,52	0,45	0,42
23	1,00	0,77	0,64	0,50	0,89	0,72	0,58	0,48	0,72	0,58	0,51	0,44
24	1,00	0,78	0,58	0,51	0,94	0,64	0,55	0,48	0,65	0,53	0,49	0,45
25	1,00	1,00	1,00	0,82	1,00	1,00	1,00	0,78	1,00	1,00	0,92	0,68
26	1,00	0,82	0,68	0,54	0,82	0,71	0,59	0,51	0,65	0,58	0,52	0,47
27	1,00	0,93	0,76	0,61	0,97	0,82	0,70	0,60	0,78	0,73	0,68	0,58
28	1,00	1,00	0,84	0,63	1,00	0,99	0,80	0,56	0,98	0,76	0,65	0,54
29	1,00	1,00	0,88	0,62	1,00	1,00	0,75	0,59	1,00	0,85	0,68	0,55

Tabela A2. Cálculo da precisão (p) para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando combinações de filtro média móvel com variações no tamanho de janela de suavização (TJS) e no tamanho da janela de árvore (TJA) em Brasília (DF).

UA	Precisão (P)											
	Tamanho de Janela de Suavização (TJS)											
	3x3 m			5x5 m			7x7 m			7x7 m		
	Tamanho de Janela de Árvore (TJA)											
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	0,30	0,53	0,75	1,00	0,48	0,65	0,82	1,00	0,66	0,83	0,96	1,00
2	0,60	0,92	1,00	1,00	0,83	1,00	1,00	1,00	1,00	1,00	1,00	1,00
3	0,39	0,67	0,94	1,00	0,64	0,85	1,00	1,00	0,89	1,00	1,00	1,00
4	0,46	0,79	1,00	1,00	0,78	1,00	1,00	1,00	1,00	1,00	1,00	1,00
5	0,47	0,97	1,00	1,00	0,85	1,00	1,00	1,00	1,00	1,00	1,00	1,00
6	0,52	0,95	1,00	1,00	0,85	1,00	1,00	1,00	1,00	1,00	1,00	1,00
7	0,41	0,75	1,00	1,00	0,70	1,00	1,00	1,00	1,00	1,00	1,00	1,00
8	0,52	0,84	1,00	1,00	0,83	1,00	1,00	1,00	1,00	1,00	1,00	1,00
9	0,55	0,92	1,00	1,00	0,84	1,00	1,00	1,00	1,00	1,00	1,00	1,00
10	0,58	0,75	0,89	1,00	0,95	1,00	1,00	1,00	1,00	1,00	1,00	1,00
11	0,52	0,97	1,00	1,00	0,90	1,00	1,00	1,00	1,00	1,00	1,00	1,00
12	0,41	0,73	1,00	1,00	0,70	0,95	1,00	1,00	0,96	1,00	1,00	1,00
13	0,27	0,50	0,67	0,82	0,54	0,78	0,82	1,00	0,88	1,00	1,00	1,00
14	0,48	0,83	1,00	1,00	0,77	1,00	1,00	1,00	1,00	1,00	1,00	1,00
15	0,42	0,62	0,79	0,90	0,61	0,73	0,83	0,97	0,79	0,91	1,00	1,00
16	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
17	0,55	0,75	0,89	1,00	0,83	0,95	1,00	1,00	1,00	1,00	1,00	1,00
18	0,44	0,79	1,00	1,00	0,79	1,00	1,00	1,00	1,00	1,00	1,00	1,00
19	0,52	0,86	1,00	1,00	0,81	1,00	1,00	1,00	1,00	1,00	1,00	1,00
20	0,46	0,62	0,74	0,86	0,73	0,80	0,90	0,99	0,89	1,00	1,00	1,00
21	0,37	0,86	1,00	1,00	0,67	1,00	1,00	1,00	1,00	1,00	1,00	1,00
22	0,91	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
23	0,85	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
24	0,66	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
25	0,29	0,52	0,81	1,00	0,47	0,68	0,93	1,00	0,70	0,91	1,00	1,00
26	0,93	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
27	0,71	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
28	0,46	0,79	1,00	1,00	0,78	1,00	1,00	1,00	1,00	1,00	1,00	1,00
29	0,41	0,77	1,00	1,00	0,73	0,94	1,00	1,00	0,96	1,00	1,00	1,00

Tabela A3. Cálculo do F-Score (F) ou Mensuração-F para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando combinações de filtro média com variações no tamanho de janela de suavização (TJS) e no tamanho da janela de árvore (TJA) em Brasília (DF).

F-Score (F)												
Tamanho de Janela de Suavização (TJS)												
UA	3x3 m			5x5 m			7x7 m			7x7 m		
	Tamanho de Janela de Árvore (TJA)											
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	0,46	0,69	0,86	0,99	0,65	0,79	0,90	0,96	0,80	0,91	0,98	0,93
2	0,75	0,96	0,92	0,85	0,91	0,97	0,91	0,77	1,00	0,92	0,89	0,77
3	0,57	0,80	0,97	0,92	0,78	0,92	0,97	0,89	0,94	0,96	0,91	0,83
4	0,63	0,88	0,91	0,76	0,88	0,99	0,85	0,73	0,94	0,86	0,78	0,69
5	0,64	0,99	0,82	0,66	0,92	0,90	0,73	0,61	0,87	0,74	0,64	0,58
6	0,68	0,98	0,85	0,70	0,92	0,92	0,78	0,64	0,89	0,78	0,69	0,59
7	0,59	0,86	0,92	0,76	0,82	0,99	0,84	0,72	0,98	0,85	0,76	0,66
8	0,68	0,91	0,92	0,79	0,91	0,96	0,89	0,74	0,94	0,86	0,80	0,72
9	0,71	0,96	0,90	0,80	0,91	0,95	0,84	0,77	0,94	0,85	0,82	0,75
10	0,73	0,86	0,94	0,97	0,97	0,98	0,93	0,83	0,94	0,91	0,88	0,78
11	0,68	0,99	0,84	0,71	0,95	0,90	0,78	0,68	0,88	0,78	0,72	0,66
12	0,58	0,85	0,97	0,82	0,82	0,98	0,91	0,78	0,98	0,94	0,84	0,76
13	0,42	0,67	0,80	0,90	0,70	0,88	0,90	0,96	0,93	0,92	0,92	0,83
14	0,65	0,91	0,95	0,81	0,87	1,00	0,90	0,78	0,98	0,89	0,83	0,72
15	0,59	0,76	0,88	0,95	0,76	0,84	0,91	0,98	0,88	0,96	0,98	0,94
16	0,96	0,87	0,78	0,71	0,74	0,67	0,63	0,58	0,58	0,56	0,53	0,51
17	0,71	0,85	0,94	0,98	0,91	0,98	0,95	0,88	0,94	0,88	0,83	0,76
18	0,61	0,89	0,93	0,82	0,88	0,99	0,88	0,79	0,97	0,88	0,81	0,75
19	0,68	0,93	0,94	0,80	0,90	0,99	0,91	0,78	0,94	0,86	0,81	0,70
20	0,63	0,77	0,85	0,92	0,84	0,89	0,95	1,00	0,94	1,00	0,99	0,94
21	0,54	0,92	0,79	0,62	0,80	0,93	0,78	0,59	0,94	0,85	0,73	0,59
22	0,95	0,81	0,59	0,56	0,89	0,68	0,62	0,56	0,73	0,68	0,62	0,59
23	0,92	0,87	0,78	0,67	0,94	0,84	0,73	0,65	0,84	0,73	0,68	0,61
24	0,80	0,88	0,73	0,67	0,97	0,78	0,71	0,65	0,79	0,69	0,66	0,62
25	0,45	0,68	0,89	0,90	0,64	0,81	0,96	0,88	0,83	0,95	0,96	0,81
26	0,96	0,90	0,81	0,70	0,90	0,83	0,75	0,67	0,78	0,74	0,68	0,64
27	0,83	0,96	0,87	0,76	0,99	0,90	0,82	0,75	0,88	0,84	0,81	0,74
28	0,63	0,88	0,91	0,77	0,88	1,00	0,89	0,71	0,99	0,87	0,79	0,70
29	0,58	0,87	0,94	0,77	0,85	0,97	0,85	0,74	0,98	0,92	0,81	0,71

Tabela A4. Cálculo do recall (r) ou revocação para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando combinações de filtro gaussiano com variações no tamanho de janela de suavização (TJS) e no tamanho da janela de árvore (TJA) em Brasília (DF).

Recall (r)												
Tamanho de Janela de Suavização (TJS)												
UA	3x3 m			5x5 m			7x7 m			7x7 m		
	Tamanho de Janela de Árvore (TJA)											
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
2	1,00	1,00	1,00	0,49	1,00	1,00	0,91	0,57	1,00	0,94	0,86	0,74
3	1,00	1,00	1,00	0,88	1,00	1,00	1,00	0,87	1,00	1,00	1,00	0,80
4	1,00	1,00	1,00	0,84	1,00	1,00	1,00	0,79	1,00	0,94	0,80	0,67
5	1,00	1,00	1,00	0,84	1,00	1,00	0,93	0,66	1,00	0,91	0,68	0,56
6	1,00	1,00	1,00	0,66	1,00	1,00	0,91	0,63	1,00	0,86	0,71	0,54
7	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,90	1,00	1,00	0,96	0,75
8	1,00	1,00	1,00	0,67	1,00	1,00	1,00	0,69	1,00	0,96	0,81	0,65
9	1,00	1,00	1,00	0,75	1,00	1,00	1,00	0,75	1,00	0,92	0,80	0,73
10	1,00	1,00	0,75	0,45	1,00	1,00	0,74	0,44	0,95	0,88	0,74	0,44
11	1,00	1,00	1,00	0,72	1,00	1,00	0,90	0,65	1,00	0,84	0,69	0,59
12	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,88	1,00	1,00	0,91	0,76
13	1,00	1,00	1,00	1,00	1,00	1,00	1,00	0,93	1,00	1,00	0,86	0,79
14	1,00	1,00	1,00	0,67	1,00	1,00	0,94	0,67	1,00	1,00	0,82	0,64
15	1,00	1,00	1,00	0,89	1,00	1,00	1,00	0,94	1,00	1,00	1,00	0,86
16	1,00	0,55	0,18	0,02	0,73	0,48	0,23	0,02	0,52	0,41	0,27	0,09
17	1,00	1,00	0,44	0,23	1,00	0,92	0,55	0,28	1,00	0,80	0,52	0,30
18	1,00	1,00	1,00	0,72	1,00	1,00	1,00	0,70	1,00	1,00	0,82	0,68
19	1,00	1,00	0,90	0,48	1,00	1,00	0,76	0,52	1,00	0,89	0,69	0,48
20	1,00	1,00	0,69	0,26	1,00	1,00	0,83	0,40	1,00	1,00	0,87	0,50
21	1,00	1,00	1,00	0,97	1,00	1,00	1,00	0,73	1,00	0,97	0,79	0,64
22	1,00	1,00	0,71	0,42	0,97	0,84	0,61	0,39	0,74	0,58	0,45	0,39
23	1,00	1,00	0,77	0,48	1,00	0,89	0,76	0,52	0,83	0,72	0,67	0,52
24	1,00	1,00	0,99	0,48	1,00	1,00	0,72	0,45	0,78	0,70	0,65	0,46
25	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
26	1,00	0,92	0,56	0,29	0,95	0,79	0,58	0,34	0,73	0,65	0,55	0,41
27	1,00	1,00	0,84	0,53	1,00	1,00	0,81	0,56	0,89	0,82	0,75	0,62
28	1,00	1,00	1,00	0,81	1,00	1,00	1,00	0,73	1,00	1,00	0,87	0,72
29	1,00	1,00	1,00	0,94	1,00	1,00	1,00	0,85	1,00	1,00	0,92	0,75

Tabela A5. Cálculo da precisão (p) para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando combinações de filtro gaussiano com variações no tamanho de janela de suavização (TJS) e no tamanho da janela de árvore (TJA) em Brasília (DF).

Precisão (P)												
Tamanho de Janela de Suavização (TJS)												
UA	3x3 m			5x5 m			7x7 m			7x7 m		
	Tamanho de Janela de Árvore (TJA)											
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	0,18	0,30	0,53	0,91	0,36	0,47	0,61	0,90	0,53	0,62	0,75	0,98
2	0,46	0,67	0,90	1,00	0,71	0,88	1,00	1,00	0,88	1,00	1,00	1,00
3	0,26	0,40	0,72	1,00	0,48	0,62	0,80	1,00	0,74	0,82	0,97	1,00
4	0,28	0,46	0,74	1,00	0,56	0,71	0,96	1,00	0,87	1,00	1,00	1,00
5	0,27	0,47	0,75	1,00	0,59	0,84	1,00	1,00	0,91	1,00	1,00	1,00
6	0,32	0,53	0,91	1,00	0,62	0,82	1,00	1,00	0,95	1,00	1,00	1,00
7	0,26	0,39	0,60	0,95	0,52	0,64	0,80	1,00	0,80	0,94	1,00	1,00
8	0,31	0,52	0,81	1,00	0,62	0,81	1,00	1,00	0,87	1,00	1,00	1,00
9	0,31	0,51	0,82	1,00	0,63	0,79	0,99	1,00	0,93	1,00	1,00	1,00
10	0,49	0,79	1,00	1,00	0,81	0,96	1,00	1,00	1,00	1,00	1,00	1,00
11	0,31	0,51	0,87	1,00	0,65	0,85	1,00	1,00	1,00	1,00	1,00	1,00
12	0,25	0,41	0,64	0,93	0,51	0,69	0,89	1,00	0,80	0,95	1,00	1,00
13	0,16	0,31	0,58	0,82	0,38	0,58	0,88	1,00	0,74	0,82	1,00	1,00
14	0,30	0,51	0,90	1,00	0,57	0,79	1,00	1,00	0,87	1,00	1,00	1,00
15	0,27	0,44	0,74	1,00	0,49	0,64	0,83	1,00	0,73	0,85	0,98	1,00
16	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
17	0,41	0,91	1,00	1,00	0,68	1,00	1,00	1,00	0,85	1,00	1,00	1,00
18	0,29	0,46	0,80	1,00	0,56	0,75	0,99	1,00	0,83	0,98	1,00	1,00
19	0,33	0,59	1,00	1,00	0,62	0,80	1,00	1,00	0,90	1,00	1,00	1,00
20	0,36	0,65	1,00	1,00	0,58	0,78	1,00	1,00	0,76	0,88	1,00	1,00
21	0,21	0,34	0,56	1,00	0,45	0,59	0,93	1,00	0,83	1,00	1,00	1,00
22	0,52	0,97	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
23	0,56	0,83	1,00	1,00	0,92	1,00	1,00	1,00	1,00	1,00	1,00	1,00
24	0,42	0,65	1,00	1,00	0,73	0,99	1,00	1,00	1,00	1,00	1,00	1,00
25	0,18	0,28	0,46	0,76	0,34	0,45	0,57	0,87	0,54	0,65	0,78	0,97
26	0,63	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
27	0,48	0,73	1,00	1,00	0,85	0,99	1,00	1,00	1,00	1,00	1,00	1,00
28	0,30	0,46	0,77	1,00	0,57	0,73	0,95	1,00	0,84	0,98	1,00	1,00
29	0,25	0,39	0,67	1,00	0,51	0,68	0,91	1,00	0,79	0,92	1,00	1,00

Tabela A6. Cálculo do F-Score (F) ou Mensuração-F para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando combinações de filtro gaussiano com variações no tamanho de janela de suavização (TJS) e no tamanho da janela de árvore (TJA) em Brasília (DF).

F-Score (F)												
Tamanho de Janela de Suavização (TJS)												
UA	3x3 m			5x5 m			7x7 m			7x7 m		
	Tamanho de Janela de Árvore (TJA)											
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	0,31	0,46	0,70	0,95	0,53	0,64	0,76	0,95	0,69	0,76	0,86	0,99
2	0,63	0,80	0,95	0,65	0,83	0,93	0,96	0,73	0,93	0,97	0,92	0,85
3	0,42	0,57	0,83	0,94	0,65	0,77	0,89	0,93	0,85	0,90	0,98	0,89
4	0,43	0,63	0,85	0,91	0,72	0,83	0,98	0,88	0,93	0,97	0,89	0,80
5	0,43	0,64	0,85	0,91	0,74	0,91	0,97	0,80	0,95	0,95	0,81	0,72
6	0,49	0,70	0,95	0,80	0,77	0,90	0,95	0,78	0,97	0,93	0,83	0,70
7	0,42	0,56	0,75	0,97	0,68	0,78	0,89	0,95	0,89	0,97	0,98	0,86
8	0,47	0,69	0,89	0,80	0,76	0,89	1,00	0,82	0,93	0,98	0,89	0,79
9	0,47	0,67	0,90	0,86	0,78	0,88	1,00	0,86	0,96	0,96	0,89	0,84
10	0,66	0,88	0,86	0,62	0,89	0,98	0,85	0,61	0,97	0,94	0,85	0,61
11	0,48	0,67	0,93	0,84	0,79	0,92	0,95	0,79	1,00	0,92	0,82	0,74
12	0,41	0,58	0,78	0,96	0,68	0,81	0,94	0,93	0,89	0,98	0,95	0,87
13	0,28	0,47	0,74	0,90	0,55	0,74	0,93	0,96	0,85	0,90	0,92	0,88
14	0,46	0,67	0,95	0,80	0,73	0,88	0,97	0,80	0,93	1,00	0,90	0,78
15	0,43	0,61	0,85	0,94	0,66	0,78	0,91	0,97	0,84	0,92	0,99	0,92
16	1,00	0,71	0,31	0,04	0,84	0,65	0,37	0,04	0,69	0,58	0,43	0,17
17	0,58	0,95	0,62	0,37	0,81	0,96	0,71	0,43	0,92	0,89	0,68	0,46
18	0,45	0,63	0,89	0,84	0,71	0,86	1,00	0,82	0,91	0,99	0,90	0,81
19	0,50	0,74	0,95	0,65	0,76	0,89	0,86	0,68	0,95	0,94	0,81	0,65
20	0,53	0,78	0,82	0,41	0,74	0,88	0,91	0,58	0,87	0,94	0,93	0,67
21	0,35	0,51	0,72	0,98	0,62	0,74	0,97	0,85	0,91	0,98	0,88	0,78
22	0,68	0,98	0,83	0,59	0,98	0,91	0,76	0,56	0,85	0,73	0,62	0,56
23	0,71	0,91	0,87	0,65	0,96	0,94	0,86	0,69	0,91	0,84	0,80	0,69
24	0,59	0,79	0,99	0,65	0,85	0,99	0,84	0,62	0,88	0,82	0,79	0,63
25	0,31	0,44	0,63	0,87	0,51	0,62	0,73	0,93	0,70	0,79	0,88	0,98
26	0,77	0,96	0,71	0,45	0,97	0,88	0,73	0,50	0,84	0,79	0,71	0,58
27	0,65	0,84	0,91	0,69	0,92	1,00	0,89	0,72	0,94	0,90	0,86	0,76
28	0,47	0,63	0,87	0,90	0,73	0,85	0,97	0,85	0,91	0,99	0,93	0,84
29	0,40	0,56	0,80	0,97	0,67	0,81	0,95	0,92	0,88	0,96	0,96	0,86

Tabela A7. Cálculo do recall (r) ou revocação para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando os filtros média móvel e gaussiano com variações no tamanho de janela de suavização (TJS) e tamanho de janela de árvore (TJA) variável em função da altura das árvores em Brasília (DF).

UA	Filtro de Suavização					
	Média Móvel			Gaussiano		
	Tamanho de Janela de Suavização (TJS)					
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	0,88	0,83	0,76	0,88	0,83	0,78
2	0,83	0,69	0,74	0,83	0,71	0,71
3	0,76	0,73	0,66	0,75	0,71	0,68
4	0,59	0,56	0,50	0,59	0,57	0,51
5	0,34	0,35	0,33	0,34	0,35	0,33
6	0,47	0,43	0,38	0,46	0,44	0,39
7	0,43	0,41	0,39	0,43	0,42	0,40
8	0,60	0,55	0,50	0,60	0,56	0,51
9	0,61	0,56	0,54	0,61	0,57	0,53
10	1,00	0,76	0,69	1,00	0,76	0,69
11	0,47	0,47	0,43	0,47	0,46	0,44
12	0,48	0,45	0,43	0,48	0,45	0,42
13	1,00	0,93	0,79	1,00	0,93	0,86
14	0,69	0,66	0,58	0,69	0,65	0,61
15	0,88	0,84	0,78	0,88	0,84	0,77
16	0,66	0,48	0,39	0,66	0,48	0,41
17	1,00	0,85	0,67	1,00	0,87	0,74
18	0,67	0,59	0,54	0,67	0,60	0,54
19	0,73	0,70	0,60	0,73	0,72	0,65
20	1,00	1,00	0,93	1,00	1,00	0,95
21	0,29	0,27	0,26	0,29	0,28	0,26
22	0,42	0,39	0,29	0,42	0,39	0,29
23	0,50	0,49	0,47	0,50	0,48	0,48
24	0,47	0,47	0,43	0,47	0,46	0,43
25	0,55	0,56	0,55	0,55	0,56	0,54
26	0,61	0,57	0,51	0,60	0,58	0,55
27	0,67	0,64	0,62	0,66	0,64	0,64
28	0,53	0,54	0,51	0,53	0,54	0,52
29	0,55	0,49	0,48	0,55	0,51	0,49

Tabela A8. Cálculo da precisão (p) para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando os filtros média móvel e gaussiano com variações no tamanho de janela de suavização (TJS) e tamanho de janela de árvore (TJA) variável em função da altura das árvores em Brasília (DF).

UA	Precisão (P)					
	Filtro de Suavização					
	Média Móvel			Gaussiano		
	Tamanho de Janela de Suavização (TJS)					
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	1,00	1,00	1,00	1,00	1,00	1,00
2	1,00	1,00	1,00	1,00	1,00	1,00
3	1,00	1,00	1,00	1,00	1,00	1,00
4	1,00	1,00	1,00	1,00	1,00	1,00
5	1,00	1,00	1,00	1,00	1,00	1,00
6	1,00	1,00	1,00	1,00	1,00	1,00
7	1,00	1,00	1,00	1,00	1,00	1,00
8	1,00	1,00	1,00	1,00	1,00	1,00
9	1,00	1,00	1,00	1,00	1,00	1,00
10	0,94	1,00	1,00	0,95	1,00	1,00
11	1,00	1,00	1,00	1,00	1,00	1,00
12	1,00	1,00	1,00	1,00	1,00	1,00
13	0,82	1,00	1,00	0,82	1,00	1,00
14	1,00	1,00	1,00	1,00	1,00	1,00
15	1,00	1,00	1,00	1,00	1,00	1,00
16	1,00	1,00	1,00	1,00	1,00	1,00
17	0,91	1,00	1,00	0,91	1,00	1,00
18	1,00	1,00	1,00	1,00	1,00	1,00
19	1,00	1,00	1,00	1,00	1,00	1,00
20	0,76	0,91	1,00	0,76	0,90	1,00
21	1,00	1,00	1,00	1,00	1,00	1,00
22	1,00	1,00	1,00	1,00	1,00	1,00
23	1,00	1,00	1,00	1,00	1,00	1,00
24	1,00	1,00	1,00	1,00	1,00	1,00
25	1,00	1,00	1,00	1,00	1,00	1,00
26	1,00	1,00	1,00	1,00	1,00	1,00
27	1,00	1,00	1,00	1,00	1,00	1,00
28	1,00	1,00	1,00	1,00	1,00	1,00
29	1,00	1,00	1,00	1,00	1,00	1,00

Tabela A9. Cálculo do F-Score (F) ou Mensuração-F para identificação de árvores individuais (IAI) em unidades amostrais (UA) urbana utilizando os filtros média móvel e gaussiano com variações no tamanho de janela de suavização (TJS) e tamanho de janela de árvore (TJA) variável em função da altura das árvores em Brasília (DF).

UA	F-Score (F)					
	Filtro de Suavização					
	Média Móvel			Gaussiano		
	Tamanho de Janela de Suavização (TJS)					
	3x3 m	5x5 m	7x7 m	3x3 m	5x5 m	7x7 m
1	0,93	0,91	0,87	0,93	0,91	0,87
2	0,91	0,81	0,85	0,91	0,83	0,83
3	0,86	0,84	0,79	0,86	0,83	0,81
4	0,74	0,72	0,66	0,74	0,73	0,68
5	0,51	0,52	0,50	0,51	0,52	0,50
6	0,64	0,61	0,55	0,63	0,61	0,56
7	0,60	0,59	0,56	0,60	0,59	0,57
8	0,75	0,71	0,67	0,75	0,72	0,68
9	0,76	0,72	0,70	0,76	0,73	0,69
10	0,97	0,86	0,82	0,97	0,86	0,82
11	0,64	0,64	0,60	0,64	0,63	0,62
12	0,65	0,62	0,60	0,65	0,62	0,59
13	0,90	0,96	0,88	0,90	0,96	0,92
14	0,81	0,79	0,74	0,81	0,79	0,76
15	0,93	0,92	0,88	0,93	0,92	0,87
16	0,79	0,65	0,56	0,79	0,65	0,58
17	0,95	0,92	0,80	0,95	0,93	0,85
18	0,80	0,74	0,70	0,80	0,75	0,70
19	0,85	0,82	0,75	0,85	0,84	0,79
20	0,86	0,95	0,97	0,86	0,95	0,98
21	0,45	0,42	0,41	0,45	0,44	0,41
22	0,59	0,56	0,45	0,59	0,56	0,45
23	0,67	0,65	0,64	0,67	0,65	0,65
24	0,64	0,64	0,61	0,64	0,63	0,61
25	0,71	0,72	0,71	0,71	0,72	0,70
26	0,75	0,73	0,68	0,75	0,73	0,71
27	0,80	0,78	0,77	0,80	0,78	0,78
28	0,69	0,70	0,68	0,69	0,70	0,68
29	0,71	0,66	0,64	0,71	0,67	0,65