



UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**POTENCIALIDADES E LIMITAÇÕES DAS NOVAS
TECNOLOGIAS DE SENSORIAMENTO REMOTO
APLICADO NO AMBIENTE URBANO DO DISTRITO
FEDERAL**

Felipe Lima Ramos Barbosa

Tese de Doutorado

Brasília/DF, 18 de outubro de 2021

UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

**POTENCIALIDADES E LIMITAÇÕES DAS NOVAS
TECNOLOGIAS DE SENSORIAMENTO REMOTO
APLICADO NO AMBIENTE URBANO DO DISTRITO
FEDERAL**

Felipe Lima Ramos Barbosa

Orientador: Prof. Dr. Renato Fontes Guimarães

Coorientador: Prof. Dr. Osmar Abílio de Carvalho Júnior

Tese de Doutorado

Brasília/DF, 18 de outubro de 2021

UNIVERSIDADE DE BRASÍLIA
INSTITUTO DE CIÊNCIAS HUMANAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

POTENCIALIDADES E LIMITAÇÕES DAS NOVAS TECNOLOGIAS DE SENSORIAMENTO REMOTO APLICADO NO AMBIENTE URBANO DO DISTRITO FEDERAL

Felipe Lima Ramos Barbosa

Tese de Doutorado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Doutor em Geografia, área de concentração Gestão Ambiental e Territorial.

Aprovado por:

Prof. Dr. Renato Fontes Guimarães, Doutor (Universidade de Brasília)
(Orientador)

Prof. Dr. Osmar Abílio de Carvalho Júnior, Doutor (Universidade de Brasília)
(Coorientador)

Prof. Dr. Edilson de Souza Bias, Doutor (Universidade de Brasília)
(Examinador Interno)

Prof. Dr. Claudinei Taborda da Silveira, Doutor (Universidade Federal do Paraná)
(Examinador Externo)

Prof. Dr^a. Carla Bernadete Madureira Cruz, Doutora (Universidade Federal do Rio de Janeiro)
(Examinador Externo)

Prof. Dr. Roberto Arnaldo Trancoso Gomes, Doutor (Universidade de Brasília)
(Suplente)

Brasília/DF, 18 de outubro de 2021

FICHA CATALOGRÁFICA

BARBOSA, FELIPE LIMA RAMOS

Potencialidades e limitações das novas tecnologias de sensoriamento remoto aplicado no ambiente urbano do Distrito Federal, 69 p., (UnB-IH-GEA, Doutor, Gestão Ambiental e Territorial, 2021).

Tese de Doutorado – Universidade de Brasília. Departamento de Geografia.

1. Sensoriamento Remoto

2. Ambiente Urbano

3. LiDAR

4. imageamento SAR

I. UnB-IH-GEA

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

BARBOSA, F. L. R. **Potencialidades e limitações das novas tecnologias de sensoriamento remoto aplicado no ambiente urbano do Distrito Federal.** 2021. 69 p. Tese (Doutorado em Geografia) – Universidade de Brasília, Brasília.

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

Felipe Lima Ramos Barbosa

DEDICATÓRIA

Dedico esse trabalho a minha esposa, a meus filhos e aos meus familiares.

AGRADECIMENTOS

Agradeço a todos que contribuíram para a concretização desse projeto de pesquisa, que aguentaram minhas agonias e ansiedades ao longo desses 4 anos e meio de doutorado

À minha família, principalmente meu pai, minha mãe e meu irmão, que sempre me apoiaram nas minhas aventuras, sejam acadêmicas ou não;

À Nathalia Lira Ramos de Andrade e à Marina pela motivação, apoio nos momentos difíceis de agonia, impaciência e ansiedade durante todo o processo;

Ao meu orientador, Prof. Dr. Renato Fontes Guimarães, pela paciência, confiança, amizade, aprendizado e incentivos;

Ao meu coorientador, Prof. Dr. Osmar Abílio de Carvalho Júnior e ao Prof. Dr. Roberto Arnaldo Trancoso Gomes, pelas contribuições, amizade e aprendizado;

Aos amigos e amigas do LSIE que acompanharam todo o desenvolvimento dessa pesquisa: Hugo, Maria, Diandra, Gabi, Anesmar, Angélica, Nathalia, dentre outros, agradeço pelas discussões e esclarecimentos que enriqueceram o trabalho;

Aos meus amigos de longa data: Renato, Pimenta, Wagner, Pedrinho, Gustavinho, Chicão, Hugo, dentre outros, que me deram apoio e compreensão nos momentos de ausência para a realização dessa pesquisa;

Aos meus amigos do Ministério do Meio Ambiente (MMA): Diego, Pery, Mandalho, Fábio, Will, Salomar, dentre outros, que me apoiaram durante todo o processo e sempre me ajudaram nos momentos de reflexão acerca da temática urbana;

À minha avó Glória (*in memoriam*), vítima da COVID-19, pelo amor e dedicação à família; e

Ao MMA, que me concedeu afastamento para a elaboração e finalização da presente pesquisa.

RESUMO

O Brasil possui aproximadamente 75% de sua população vivendo em ambientes urbanos, conforme estimativas do Censo Demográfico elaborado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), fato que ressalta a necessidade de um planejamento territorial urbano que assegure o equilíbrio quanto ao uso de seus recursos naturais a longo prazo, estratégica central para a agenda da sustentabilidade. Como não existe um consenso global que defina ambiente urbano, são necessários novos conhecimentos que abarquem os complexos desafios inerentes a esse espaço e, assim, contribua no desenvolvimento de sua ciência. O planejamento urbano demanda mais conhecimento relevante e espacialmente explícito que considere sua heterogeneidade espacial e sua dinâmica temporal. Assim, novas soluções de sensoriamento remoto podem ser empregadas no enriquecimento do campo científico urbano, tais como o *Light Detection and Ranging* (LIDAR) e as imagens *Synthetic Aperture Radar* (SAR). Neste sentido, a presente pesquisa contribui com essa discussão ao propor três artigos científicos que consideram a aplicação dessas soluções no Distrito Federal (DF), ambiente que apresenta uma diversidade de arranjos espaciais urbanos. O primeiro artigo classificou o uso e cobertura da terra de parte do DF utilizando informações em série temporal composta de imagens SAR do satélite Sentinel 1 do ano de 2018, aplicando método de aprendizado de máquina, o segundo, analisou as potencialidades e limitações do uso de informações altimétricas provenientes de perfilamento à laser aerotransportado em ambiente urbano, e, por fim, o terceiro artigo estimou o limiar ótimo para a remoção de *outlier* de uma base de dados LiDAR orbital proveniente do *Global Ecosystem Dynamics Investigation* (GEDI) no Distrito Federal e selecionou os dados de elevação de terreno com a maior acurácia altimétrica. Por fim, a presente pesquisa contribui para o desenvolvimento de metodologias que auxiliem o planejamento urbano utilizando dados LiDAR e radar, uma vez que a maioria das pesquisas envolvendo sensoriamento remoto e ambiente urbano foram realizados em cidades na China, Europa e Estados Unidos.

ABSTRACT

Brazil has approximately 75% of its population living in urban environments, according to estimates in the Demographic Census prepared by the Brazilian Institute of Geography and Statistics (IBGE), a fact that highlights the need for urban territorial planning that ensures a balance in the use of its natural resources in the long term, which is central to the sustainability agenda. As there is no global consensus defining the urban environment, new knowledge is needed to address the complex challenges inherent in this space and thus contribute to the development of its science. Urban planning demands more relevant and spatially explicit knowledge that considers its spatial heterogeneity and temporal dynamics. Thus, new remote sensing solutions can be employed in the enrichment of the urban scientific field, such as Light Detection and Ranging (LIDAR), Synthetic Aperture Radar (SAR) images and new methodological approaches involving machine learning. The present research contributes to this discussion by proposing three scientific articles that consider the application of these solutions in the Federal District (DF), an environment that presents a diversity of urban spatial arrangements. The first article classified the land use and coverage of part of the DF using information in time series composed of SAR images from the Sentinel 1 satellite of the year 2018, applying machine learning method, the second, analyzed the potentialities and limitations of the use of altimetric information from airborne laser system (ALS) profiling in urban environment. Finally, the third paper estimated the optimal threshold for outlier removal from an orbital LiDAR database from the Global Ecosystem Dynamics Investigation (GEDI) in the Federal District and selected the terrain elevation data with the highest altimetric accuracy. This research contributes to the development of methodologies to support urban planning using LiDAR and radar data, once most of the research involving remote sensing and urban environment has been conducted in cities in China, Europe and the United States.

SUMÁRIO

LISTA DE FIGURAS	
LISTA DE TABELAS E QUADROS	
LISTA DE ABREVIATURAS E SIGLAS	
LISTA DE SÍMBOLOS	
RESUMO	VI
ABSTRACT	VII
SUMÁRIO	VIII
LISTA DE FIGURAS	X
LISTA DE TABELAS E QUADROS	XIII
LISTA DE ABREVIATURAS E SIGLAS	XIV
LISTA DE SÍMBOLOS	XVI
1. INTRODUÇÃO	1
1.1. OBJETIVOS.....	5
1.1.1. Objetivo Geral	5
1.1.2. Objetivos Específicos	5
1.2. HIPÓTESE.....	5
1.3. APRESENTAÇÃO	6
REFERÊNCIAS	7
2. CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA UTILIZANDO IMAGENS SAR/SENTINEL 1 NO DISTRITO FEDERAL, BRASIL	9
2.1. INTRODUÇÃO	10
2.2. ÁREA DE ESTUDO.....	12
2.3. MATERIAL E MÉTODOS.....	13
2.3.1. Pré-processamento do sinal de radar e construção dos cubos temporais (Etapa 1).....	13
2.3.2. Definição das classes e das amostras de treinamento (Etapa 2)	15
2.3.3. Etapa de classificação (Etapa 3 E).....	16
2.3.4. Avaliação das classificações (Etapa 3 F)	17
2.3.5. Consolidação do mapa de uso e ocupação da terra (Etapa 3 E)	17
2.4. RESULTADOS E DISCUSSÃO	18
2.4.1. Objetos urbanos versus mancha urbana	21
2.4.2. Compilação do mapa de uso e ocupação da terra	22
2.5. CONSIDERAÇÕES FINAIS.....	24
REFERÊNCIAS	25
3. POTENCIALIDADES E LIMITAÇÕES DO USO DE INFORMAÇÕES ALTIMÉTRICAS PROVENIENTES DE PERFILAMENTO À LASER EM AMBIENTE URBANO	27
3.1. INTRODUÇÃO	28
3.2. LEVANTAMENTO TOPOGRÁFICO POR PERFILAMENTO À LASER	28
3.3. MODELO DIGITAL DE ELEVAÇÃO E CONSISTÊNCIA HIDROLÓGICA	30
3.4. ÍNDICE TOPOGRÁFICO DE UMIDADE E ÁREAS DE SENSIBILIDADE HIDROLÓGICA	30
3.5. MATERIAIS E MÉTODOS.....	30
3.5.1. Área de estudo	30
3.5.2. Elaboração do MDE e consistência hidrológica	31
3.5.3. Aplicação do índice ITU e delimitação das ASH	33
3.6. RESULTADOS E DISCUSSÕES	33
3.6.1. Atributos de terreno	33

3.6.2. Distribuição espacial das Áreas de Sensibilidade Hidrológica.....	36
3.6.3. A interferência da cobertura vegetal	39
3.6.4. O efeito da topografia local	41
3.6.5. Análise comparativa com estudos de detecção de ASH em regiões urbanas	41
3.7. CONSIDERAÇÕES FINAIS.....	42
AGRADECIMENTOS	42
REFERÊNCIAS	42
4. ESTIMATING THE OPTIMAL THRESHOLD FOR OUTLIER REMOVAL OF THE GLOBAL ECOSYSTEM DYNAMICS INVESTIGATION (GEDI) DATA.....	47
4.1. INTRODUCTION	47
4.2. MATERIALS AND METHODS	49
4.2.1. Study Area	49
4.2.2. GEDI Data	50
4.2.3. ALS Data.....	51
4.2.4. Methods	51
4.2.4.1. GEDI data preparation.....	51
4.2.4.2. GEDI orthometric height conversion	52
4.2.4.3. GEDI pre-processing	53
4.2.4.4. Statistical analysis.....	53
4.3. RESULTS.....	54
4.3.1. Proposed KS outlier removal method and absolute accuracy assessment	54
4.3.2. Comparison with outlier removal by quality flag parameter and GEDI sensitivity beam data dispersion	59
4.4. DISCUSSION.....	61
4.5. CONCLUSIONS.....	62
REFERENCES	63
5. CONCLUSÕES	66
ANEXO	68

LISTA DE FIGURAS

Figura 2.1 – Esquema da geometria InSAR obtido a partir de duas órbitas.....	11
Figura 2.2 – Diferentes arranjos urbanos no Distrito Federal. (a) Área planejada e amplamente arborizada; (b) Área planejada e menos arborizada; (c) Área de expansão não-planejada recente.....	12
Figura 2.3 – Área de estudo referente à porção do Distrito Federal.....	12
Figura 2.4 – Fluxograma das etapas metodológicas do trabalho.....	13
Figura 2.5 – Fluxograma metodológico de consolidação do mapa de uso e ocupação da terra.....	18
Figura 2.6 – Desempenho das classificações a partir do índice Kappa.....	19
Figura 2.7 – Desempenho das classificações – índice F1, <i>precision</i> e <i>recall</i>	19
Figura 2.8 – Desempenho das classificações por classe temática a partir do índice F1 – (a) Água; (b) Formação campestre; (c) Formação savânica; (d) Formação florestal; (e) Mancha urbana; (f) Edificação e (g) Áreas planas.....	20
Figura 2.9 – Desempenho das classificações por classe temática – índice <i>precision</i> e <i>recall</i> – (a) Água; (b) Formação campestre; (c) Formação savânica; (d) Formação florestal; (e) Mancha urbana; (f) Edificação e (g) Áreas planas.....	20
Figura 2.10 – Desempenho das classes de cobertura vegetal.....	21
Figura 2.11 – Razão entre os valores de VP e as áreas classificadas da classe “edificações”.....	22
Figura 2.12 – Exemplos de refinamento da temática urbana – regiões do (a) Guará e do (b) Plano Piloto.....	23
Figura 2.13 – Mapa compilado de uso e ocupação da terra.....	24
Figura 3.1 – Representação do sinal de retorno em diferentes contextos de alvos.....	29
Figura 3.2 – Localização da área de estudo no Distrito Federal e na Região Administrativa de São Sebastião.....	31
Figura 3.3 – Nuvem de pontos amostrais utilizadas para a geração do MDE.....	32
Figura 3.4 – Modelo Digital de Elevação (MDE) elaborado e corrigido e a localidade das depressões espúrias preenchidas.....	33
Figura 3.5 – Apresenta o modelo de fluxo acumulado estimado para a área de estudo.....	34
Figura 3.6 – Declividade local, estimada em graus, da área de estudo.....	34
Figura 3.7 – Apresenta porção da área de estudo, a estimativa de área de contribuição e sua distribuição de frequência.....	35

Figura 3.8 – Índice ITU estimado para a área de estudo.....	36
Figura 3.9 – ASH estimadas na área de estudo.....	37
Figura 3.10 – Porção da área de estudo representada com sua ortofoto e as respectivas ASH inferidas.....	37
Figura 3.11 – Porção da área de estudo com influência da malha de arruamentos sobre as ASH.....	38
Figura 3.12 – Exemplos de inconsistência introduzida na modelagem devido à densidade da cobertura vegetal.....	39
Figura 3.13 – Exemplo da relação entre declividade, depressão espúria preenchida e ASH em área de vegetação.....	40
Figura 4.1 – Study area located in Federal District. Red line represents center of Brasília city and black dots are GEDI data used in this study.....	50
Figura 4.2 - Methodological flowchart.....	51
Figura 4.3 - Orthometric height conversion procedure in 3 random GEDI footprint samples. Grey line represents the vertical elevation transformation from WGS84 to EGM2008 datum, Red dashed line is the DTM-ALS elevation in each GEDI footprint referred in MAPGEO2015.....	52/53
Figura 4.4 - Comparison between calculated KS (red color), number of GEDI samples (grey color), and RMSE (orange color) curves from absolute dh-DTM thresholds. (a) Calculated KS and RMSE values - 10 m interval from $ dh < 100\text{m}$ and $ dh < 10\text{m}$; (b) Calculated KS value and number of GEDI samples - 10 m interval from $ dh < 100\text{m}$ and $ dh < 10\text{m}$; (c) Calculated KS and RMSE values- 1 m interval from $ dh < 9\text{ m}$ and $ dh < 1\text{ m}$; (d) Calculated KS value and number of GEDI samples - 1 m interval from $ dh < 9\text{ m}$ and $ dh < 1\text{ m}$	56
Figura 4.5 - Optimal threshold of calculated KS (red color), RMSE (red dashed line) values and the number of GEDI samples (grey color).....	56
Figura 4.6 - Histograms showing the dh-DTM distribution: (a) $ dh < 4\text{ m}$; (b) $ dh < 3\text{ m}$; (c) $ dh < 2\text{ m}$; (d) $ dh < 1\text{ m}$. Shaded grey curve is normal distribution.....	57
Figura 4.7 - Quantile-quantile plots showing distributions of: (a) $ dh < 4\text{ m}$; (b) $ dh < 3\text{ m}$; (c) $ dh < 2\text{ m}$; (d) $ dh < 1\text{ m}$. Light grey line indicates the reference of QQ plot.....	58
Figura 4.8 - Location of the GEDI samples excluded from $<100\text{ m}$ to $<3\text{ m}$ thresholds. Yellow dots are the GEDI samples.....	58
Figura 4.9 - Location of the GEDI samples excluded from $<3\text{ m}$ to $<1\text{ m}$ threshold. Where, yellow dots are the GEDI samples.....	59
Figura 4.10 - Boxplots showing the distribution of dh-DTM of total GEDI dataset and of outlier removal method using quality flag parameter. (a) Original distribution of dh-DTM; (b) Resulted distribution of dh-DTM after quality flag applied; (c) Removed outlier distribution of dh-DTM after applying a second step based on IQR thresholds to remove remaining outliers from distribution.....	60

Figura 4.11 - Boxplots showing the distribution of dh-DTM. Data selection with 0.9 sensitivity threshold (a). Useful data along all sensitivity range (b).....60

Figura 4.12 - Location of GEDI footprints groups derived from both removal outlier methods. GEDI footprints from group 1 represented in yellow dots and group 2 in red dots.....61

LISTA DE TABELAS E QUADROS

Tabela 2.1 – Datas das imagens Sentinel 1 adquiridas e processadas.....	14
Quadro 2.1 – Arranjo adotado para a estimativa das coerências interferométricas de 2018...	15
Tabela 3.1 – Valores de média, mediana e desvio padrão da área de contribuição.....	35
Tabela 3.2 – Valores da área das classes de ASH em relação à área total do estudo.....	36
Tabela 3.3 – Valores estatísticos das ASH.....	38
Tabela 4.1 - GEDI metrics used in this study.....	50
Tabela 4.2 - GEDI L2A products downloaded and acquisition dates.....	51/52
Tabela 4.3 - Statistics from pre-defined thresholds of absolute value of dh-DTM.....	55
Tabela 4.4 - Statistics from dh-DTM quality flag to remove outliers and its IQR threshold improvement.....	59
Tabela 4.5 - Statistics from GEDI footprint groups.....	61

LISTA DE ABREVIATURAS E SIGLAS

- ASH** – Área de Sensibilidade Hidrológica
- CART** – *Classification and Regression Trees*
- CNPq** – Conselho Nacional de Desenvolvimento Científico e Tecnológico
- DEM** – *Digital Elevation Model*
- DF** – Distrito Federal
- GEDI** – *Global Ecosystem Dynamics Investigation*
- GNSS** – *Global Navigation Satellite System*
- GRD** – *Ground Range Detected*
- IAF** – Índice de Área Foliar
- IBGE** – Instituto Brasileiro de Geografia e Estatística
- IDW** – Inverso da Distância Ponderada
- InSAR** – *SAR interferométrico*
- INS** – *Inertial Navigation System*
- ITU** – Índice Topográfico de Umidade
- IW** – *Interferometric Wide Swath*
- LiDAR** – *Light Detection and Ranging*
- LSIE** – Laboratório de Sistema de Informações Espaciais
- LULC** – *Land Use and Land Cover*
- MDE** – Modelo Digital de Elevação
- ONU** – Organização das Nações Unidas
- PIB** – Produto Interno Bruto
- RA** – Região Administrativa
- RF** – *Random Forest*
- SAR** – *Synthetic Aperture Radar*
- SICAD** – Sistema Cartográfico do DF
- SIG** – Sistema de Informações Geográficas
- SIRGAS** – Sistema de Referência Geocêntrico para as Américas

SLC – *Single Look Complex*

SRTM – *Shuttle Radar Thematic Mapper*

Terracap – Companhia Imobiliária de Brasília

UN-Habitat – Programa das Nações Unidas para Assentamentos Humanos

UTM – Universal Transversa de Mercator

VH – Polarização Vertical-Horizontal

VV – Polarização Vertical-Vertical

WGS – *World Geodetic System*

ZEE – Zoneamento Ecológico-Econômico

LISTA DE SÍMBOLOS

t – intervalo de tempo

R – distância entre o sensor LIDAR e o alvo

c – velocidade da luz

Y – divergência do feixe de luz laser

Fp – diâmetro da visada instantânea laser

h – altitude da plataforma em relação ao solo

Θ – ângulo de varredura instantâneo

FRP – frequência de repetição de pulso

P_s – espaçamento de pontos perpendiculares à trajetória

α – velocidade de varredura angular instantânea/ área de contribuição a montante

β – declividade local

Φ – fase do sinal SAR

λ – comprimento de onda

γ – coerência interferométrica

db – medida de intensidade SAR em decibéis

σ – medida de intensidade SAR em σ_0

1. INTRODUÇÃO

Atualmente, o Brasil possui uma população estimada de 213 milhões de pessoas, das quais cerca de 160 milhões vivem no ambiente urbano, conforme estimativas provenientes do Censo Demográfico elaborado pelo Instituto Brasileiro de Geografia e Estatística (IBGE) no ano de 2010. Esse fato ressalta a importância e a necessidade de um planejamento urbano que vise garantir o equilíbrio a longo prazo na organização do espaço, estratégia central para a agenda da sustentabilidade. Segundo Zhu et al. (2019), as áreas urbanas garantem mais de 75% do Produto Interno Bruto (PIB) mundial, contribuem com, aproximadamente, 75% das emissões de carbono e produzem, em média, 2 bilhões de toneladas de lixo por ano (HOORNWEG; BHADA-TATA, 2012; SETO et al., 2014).

Segundo relatório produzido pela Organização das Nações Unidas (ONU), estima-se que a população urbana cresceu mais de quatro vezes entre 1950 e 2018, passando de um quantitativo estimado de 0,8 bilhões para 4,2 bilhões de habitantes (ONU, 2018). Esse acelerado crescimento das áreas urbanas demanda soluções que busquem respostas rápidas e objetivas aos tomadores de decisão, principalmente considerando as novas tecnologias de sensoriamento remoto existentes no mercado. Segundo Zhu et al. (2017), essas novas abordagens precisam ser desenvolvidas pela ciência, uma vez que não existe consenso no que se define como ambiente urbano e quais temáticas deveriam ser consideradas a depender da escala do planejamento urbano.

A temática urbana nos planejamentos territoriais varia conforme a escala adotada e as necessidades e particularidades técnicas e políticas de cada país. Normalmente, os países consideram informações populacionais e de infraestrutura como base para a definição das principais questões referentes ao ambiente urbano em seus ritos próprios de planejamento, sendo que um dos principais produtos elaborados em escala regional é o mapeamento da área urbana frente às demais formas de apropriação do espaço, informação estruturante dos mapas de uso e ocupação do solo.

Segundo Acuto et al (2018), são necessários novos conhecimentos que abarquem os complexos desafios inerentes ao mapeamento das áreas urbanas em suas diferentes escalas de análise e, assim, contribua no desenvolvimento de sua ciência. Pesquisadores e especialistas que lidam com o planejamento e a gestão urbana em escala regional expressam a necessidade de mais conhecimento relevante e espacialmente explícito que considere, principalmente, sua

heterogeneidade espacial e sua dinâmica temporal (FELSON et al., 2013; MCGRATH, 2018; STEINER, 2014).

Vários estudos que envolveram técnicas de sensoriamento remoto aplicado a área urbana foram realizados nas últimas décadas, sendo que o primeiro foi executado a partir de uma câmera analógica que operava no infravermelho durante as missões Gemini e Apollo em 1965 (THROWER, 1970). A partir do advento dos satélites orbitais, os estudos se concentraram na análise da diferenciação multiespectral visando segmentar área urbana de área agrícola e florestal (HAACK, 1983; QUATTROCHI, 1985), na discriminação de texturas típicas urbanas e suas diferenciações com demais classes de uso do solo usando dados de radar (HENDERSON; WHARTON; TOLL, 1980; BRYAN, 1975) e na estimativa de densidade e população urbanas (KRAUS; SENGER; RYERSON, 1974; MURAI, 1974).

Neste sentido, e dando continuidade ao legado histórico no sensoriamento remoto de áreas urbanas em escala regional, mais estudos necessitam ser desenvolvidos visando ampliar uma diversidade maior de regiões e tamanhos de áreas urbanas, uma vez que a maioria dos estudos envolvendo sensoriamento remoto em ambiente urbano foram realizados em cidades na China, Europa e Estados Unidos (ZHU et al., 2019). Ademais, e considerando que a maioria dos estudos de sensoriamento remoto em escala regional realizados no ambiente urbano envolvem o uso de sensores óticos e termais, existe um novo conjunto de soluções que podem agregar conhecimento de diferentes características das áreas urbanas, tal como o radar de abertura sintética (SAR) e a utilização de abordagens metodológicas que envolvam o aprendizado de máquina.

As metodologias envolvendo novos sensores orbitais junto ao potencial oferecido pelo aprendizado de máquinas apresentam-se como uma oportunidade em se lidar com objetos terrestres que envolvam uma ampla complexidade de materiais artificiais, tais como casas, ruas, estacionamentos, prédios, dentre outros, e é nesse contexto que a evolução do imageamento SAR tem demonstrado ótimos resultados por não possuir influência direta da atmosfera e da cobertura de nuvens, o que favorece a análise de mudança ao longo do tempo, principalmente na identificação de objetos urbanos. As técnicas interferométricas (InSAR) também auxiliam no estudo do ambiente urbano, cujas aplicações consistem na (i) identificação de movimentos de subsidência a partir da análise de deformações da superfície (CIAMPALINI et al., 2019; HU et al., 2019), ou no (ii) mapeamento do uso e ocupação da terra utilizando-se a coerência interferométrica como métrica auxiliar no processo

classificatório (MIGUEL; SANO, 2019; SICA et al., 2019; ZHANG et al., 2018), especialmente utilizando-se a abordagem *machine learning*.

Devido a sua superioridade frente aos tradicionais algoritmos de classificação, as soluções *machine learning* foram bem-sucedidas em várias abordagens de reconhecimento visual, tais como classificação de objetos de superfície, detecção de objetos e registro de mudança temporal em imagens de sensoriamento remoto. A classificação de imagens SAR utilizando solução *machine learning* contribui no processo de elaboração do mapa de uso e ocupação da terra em ambiente urbano, caracterizando de forma mais fidedigna a área urbana, importante informação para o planejamento urbano em escala regional (ZHANG et al., 2018).

Por outro lado, em escala local, o conhecimento das informações altimétricas são de grande valia para o planejamento urbano, uma vez que importantes inferências espaciais podem auxiliar em tomadas de decisão mais objetivas e assertivas, tais como, as relacionadas a previsão de áreas susceptíveis à escorregamentos rasos (GUIMARÃES et al., 2003; GUIMARÃES et al., 2017).

As informações altimétricas provenientes do relevo são extraídas a partir de fotografias aéreas e técnicas de fotogrametria, que dão origem às curvas de nível presentes nas cartas topográficas em suas mais variadas escalas de detalhamento. Essas são técnicas bastante acuradas, porém dispendiosas com relação ao tempo de levantamento e elaboração dos referidos produtos cartográficos. Segundo Jensen (2011), o levantamento *in situ* utilizando métodos convencionais, por um lado, pode fornecer informações referentes a localização e a altitude precisas (x, y e z), mas, por outro, demandam tempo e têm um alto custo por ponto adquirido. Ademais, geralmente é difícil obter pontos em áreas de vegetação densa, fato que influencia a densidade e a dispersão das amostras obtidas sobre uma determinada área de estudo.

Atualmente, uma das tecnologias que vem ganhando expressividade em processos de levantamento topográfico é a utilização dos sistemas *Light Detection and Ranging* (LiDAR), que permitem a obtenção de dados de elevação com precisão e rapidez, e com aplicabilidade crescente em terrenos inóspitos (MCGLONE, 2004). Segundo Raber (apud JENSEN, 2011), as acurácias ou exatidões vertical e horizontal obtidas pelo LiDAR e seus custos operacionais são, nos dias de hoje, muito similares aos relacionados ao levantamento convencional por fotogrametria.

Segundo Shan e Toth (2018), existem duas tecnologias relacionadas ao perfilamento à laser que são utilizadas em aplicações topográficas, o método referente à medição dos tempos de retorno do sinal e o método de análise da mudança de frequência e da fase do sinal de retorno. A primeira consiste no processo de registro de um conjunto de pontos discretos de elevação, técnica normalmente utilizada em aeronaves (*Airborne Laser System – ALS*) e resultam em nuvens de pontos, distribuídos sistematicamente no tempo, ao longo da linha de voo (HODGSON et al., 2005). Ademais, a disposição funcional do sistema LiDAR não permite ao usuário o controle da localização individual das medidas x, y e z obtidas no levantamento, apesar de, por outro lado, realizar a amostragem de localidades que seriam impossíveis de visitação utilizando-se das técnicas convencionais.

A segunda está relacionada à comparação das fases do sinal de retorno em referência aos emitidos. Nessa técnica, o sinal não é tratado como dado discreto, e sim, como um pulso eletromagnético constante. A técnica LiDAR *waveform* permite um melhor detalhamento entre objetos de terreno e de não-terreno, que, no caso, são identificados a partir da modulação contínua no sinal (SHAN; TOTH, 2018). No âmbito do sensoriamento remoto orbital, a técnica LiDAR *waveform* foi empregada no desenvolvimento da iniciativa *Global Ecosystem Dynamics Investigation* (GEDI), laser altimétrico acoplado à Estação Espacial Internacional cujo objetivo é gerar informações sobre a dinâmica das estruturas florestais em um nível global (DUBAYAH et al., 2020).

Visto o exposto, o objetivo pretendido pela presente pesquisa é analisar as potencialidades e limitações quanto à utilização das novas tecnologias de sensoriamento remoto visando subsidiar o planejamento urbano na escala regional e local, especificamente (i) as imagens de radar SAR e os recentes métodos de aprendizado de máquinas e (ii) as informações altimétricas provenientes de ALS LiDAR e LiDAR *waveform* orbital. A pesquisa vem sendo realizada no contexto urbano do Distrito Federal, ambiente que apresenta uma heterogeneidade de arranjos espaciais urbanos.

Essa pesquisa justifica-se no fato de que a maioria da população brasileira atualmente encontra-se nos ambientes urbanos, fato que demanda uma gestão eficiente dessas áreas nos ritos específicos de planejamento territorial, principalmente visando garantir a sustentabilidade a médio e longo prazo, bem como o bem-estar de seus habitantes cidadãos.

1.1. OBJETIVOS

1.1.1. Objetivo Geral

Analisar as potencialidades e limitações quanto à utilização das novas tecnologias de sensoriamento remoto visando subsidiar o planejamento urbano nas escalas regional e local, considerando as imagens de radar de abertura sintética (SAR) e os recentes métodos de aprendizado de máquinas, bem como as informações altimétricas provenientes de ALS LiDAR e LiDAR *waveform* orbital, no contexto do Distrito Federal.

1.1.2. Objetivos Específicos

A presente seção apresenta os objetivos específicos almejados da pesquisa, sendo eles:

- a) Classificar o uso e cobertura da terra de parte do Distrito Federal utilizando-se informações provenientes de série temporal composta de imagens SAR do satélite Sentinel 1 relativas ao ano de 2018, aplicando método de aprendizado de máquina;
- b) Analisar as potencialidades e limitações do uso de informações altimétricas provenientes de ALS LiDAR em ambiente urbano; e
- c) Propor um método aprimorado de remoção de *outlier* de uma base de dados de elevação GEDI e avaliar sua acurácia absoluta.

1.2. HIPÓTESE

As novas tecnologias de sensoriamento remoto podem contribuir no processo de planejamento urbano em diferentes escalas. Na escala regional, espera-se que aplicação de método de aprendizado de máquina em uma série temporal de dados provenientes de radar SAR, especialmente do satélite Sentinel 1, possuem a potencialidade de mapear o uso e ocupação da terra, tanto de suas classes vegetacionais quanto, especificamente, das classes que representam os arranjos urbanos, por intermédio das características de textura inerentes à tecnologia SAR. Na escala local, a utilização de dados altimétricos de sistemas LiDAR aerotransportado (ALS) e de plataformas orbital (GEDI) possuem potencialidade em representar o relevo de forma acurada e podem ser úteis em diversas aplicações.

1.3. APRESENTAÇÃO

O presente trabalho será dividido da seguinte forma:

- O capítulo 2 apresenta o artigo que visa classificar o uso e cobertura da terra de parte do Distrito Federal utilizando informações provenientes de série temporal composta de imagens SAR do satélite Sentinel 1 relativas ao ano de 2018. Esse artigo foi submetido à revista Sociedade & Natureza da Universidade Federal de Uberlândia (Qualis A1) em 07/07/2020, tendo sido aceito (05/11/2020) e publicado em 02/02/2021;
- O capítulo 3 apresenta o artigo desenvolvido no sentido de analisar as potencialidades e limitações do uso de informações altimétricas provenientes de perfilamento à laser aerotransportado em ambiente urbano do Distrito Federal. Esse artigo foi submetido à revista Caminhos de Geografia da Universidade Federal de Uberlândia (Qualis A2) em 11/09/2020, tendo sido aceito em 09/03/2021 e está aguardando na fila de publicação (termo de aceite em anexo); e
- O capítulo 4 apresenta o artigo que estima o limiar ótimo para a remoção de *outliers* de uma base de dados GEDI adotando o teste não-paramétrico Kolmogorov-Smirnov (KS) e a seleção dos dados de elevação de terreno com a maior acurácia absoluta em uma área urbana do Distrito Federal. Esse artigo foi submetido à revista *Remote Sensing* no dia 02/09/2021 e está na fase de avaliação.

REFERÊNCIAS

- ACUTO, M.; PARNELL, S.; SETO, K. C. Building a global urban science. **Nature Sustainability**, v. 1, 2018.
- BRYAN, M. L. Interpretation of an urban scene using multi-channel radar imagery. **Remote Sensing of Environment**. v. 4, n. 1, p. 49-66, 1975.
- CIAMPALINI, A.; SOLARI, L.; GIANNECCHINI, R.; GALANTI, Y.; MORETTI, S. Evaluation of subsidence induced by long-lasting building load using InSAR technique and geotechnical data: The case study of a Freight Terminal (Tuscany, Italy). **International Journal of Applied Earth Observation and Geoinformation**, v. 82, 2019.
- DUBAYAH, R.; BLAIR, J. B.; GOETZ, S.; FATOYINBO, L.; HANSEN, M.; HEALEY, S.; HOFTON M.; HURTT, G.; KELLNER, J.; LUTHCKE, S.; ARMSTON, J.; TANG, H.; DUNCANSON, L.; HANCOCH, S.; JANTZ, P.; MARSELIS, S.; PATTERSON, P. L.; QI, W.; SILVA, C. The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. **Science of Remote Sensing**, v. 1, p. 1 – 14, 2020.
- FELSON, A. J.; BRADFORD, M. A.; TERWAY, T. M. Promoting Earth Stewardship through urban design experiments. **Frontiers in Ecology and the Environment**, v. 11, n. 7, p. 362 – 367, 2013.
- GUIMARÃES, R. F.; FERNANDES, N. F.; GOMES, R. A. T.; CARVALHO JUNIOR, O. A. Fundamentação teórica do modelo matemático para previsão de escorregamentos rasos *Shallow Stability*. **Revista Espaço & Geografia**, v. 06, n. 2, 133 – 150p, 2003.
- GUIMARÃES, R. F.; MACHADO, W. P.; CARVALHO JÚNIOR, O. A; MONTGOMERY, D.R.; GOMES, R. A. T.; GREENBERG, H. M.; CATALDI, M.; MENDONÇA, P. C. Determination of Areas Susceptible to Landsliding Using Spatial Patterns of Rainfall from Tropical Rainfall Measuring Mission Data, Rio de Janeiro, Brazil. **ISPRS International Journal of Geo-Information**, v. 6, n. 10, p. 289, 2017.
- HAACK, B. N. An analysis of thematic mapper simulator data for urban environments. **Remote Sensing of Environment**. v. 13, n. 3, p. 265-275, 1983.
- HENDERSON, F. M.; WHARTON, S. W.; TOLL, D. L. Preliminary results of mapping urban land cover with Seasat SAR Imagery. In: **American Society of Photogrammetry, Annual meeting, 46th, ACSM**. v. 1, p. 310-317, 1980.
- HOORNWEG, D.; BHADA-TATA, P. What a Waste: A Global Review of Solid Waste Management. **Urban Development Series Knowledge Papers**. v. 15, 2012, 116p.
- HU, L.; DAI, K.; XING, C.; LI, Z.; TOMÁS, R.; CLARK, B.; SHI, X.; CHEN, M.; ZHANG, R.; QIU, Q.; LU, Y. Land subsidence in Beijing and its relationship with geological faults revealed by Sentinel 1 InSAR observations. **International Journal of Applied Earth Observation and Geoinformation**, v. 82, 2019.
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São Jose dos Campos, SP: Parênteses, 2011.
- KRAUS, S. P.; SENGER, L. W.; RYERSON, J. M. Estimating population from photographically determined residential land use types. **Remote Sensing of Environment**. v. 3, n. 1, p. 35-42, 1974.
- MCGLONE, J. C. **Manual of Photogrammetry**. Bethesda: ASP&RS, 2004.

- MCGRATH, B. Intersecting disciplinary frameworks: the architecture and ecology of the city. **Ecosystem Health and Sustainability**, v. 4, n. 6, p. 148 – 159, 2018.
- MIGUEL, B. H.; SANO, E. E. Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica. **Revista Brasileira de Geografia Física**, v. 12, n. 2, p. 427-442, 2019.
- MURAI, S. Estimation of population density in Tokyo districts from ERTS-1 DATA. In: **Proceedings of the Symposium on Remote Sensing of Environment**, 9th.v. 1, 1974.
- ORGANIZAÇÃO DAS NAÇÕES UNIDAS. Departamento de Assuntos Econômicos e Sociais. **World Urbanization Prospects: The 2018 Revision**. Nova Iorque, 2018.
- QUATTROCHI, D. A. An Initial Analysis of LANDSAT-4 Thematic Mapper Data for the discrimination of agricultural, forested wetlands, and urban land cover (USA). **Landsat-4 science characterization early results. Vol. 4: applications**. v. 4, p. 131-152, 1985.
- SETO, K.C.; SHOBHAKAR, D.; BIGIO, A.; BLANCO, H.; DELGADO, G.C.; DEWAR, D.; HUANG, L.; INABA, A.; KANSAL, A.; LWASA, S.; MCMAHON, J.; MULLER, D.; MURAKAMI, J.; NAGRENDA, H.; RAMASWAMI, A. Chapter 12 – Human settlements, infrastructure, and spatial planning, climate change 2014: mitigation of climate change. In: **Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change**. 1 ed. Cambridge University Press, 2014. p. 923-1000.
- SHAN, J; TOTH, C. K. **Topographic Laser Ranging and Scanning: Principles and Processing**. Nova Iorque: CRC Press, 2^o ed, 2018.
- SICA, F.; PULELLA, A.; NANNINI, M.; PINHEIRO, M.; RIZZOLI, P. Repeat-pass SAR interferometry for land cover classification: A methodology using Sentinel-1 Short-Time-Series. **Remote Sensing of Environment**, v. 232, 2019.
- STEINER, F. Frontiers in urban ecological design and planning research. **Landscape and Urban Planning**, v. 125, p. 304 – 311, 2014.
- THROWER, N. J. W. Annals map supplement number twelve: Land Use in the southwestern United States – from Gemini and Apollo-Imagery. **Annals of the Association of American Geographers**. v. 60, n.1, p. 208-208, 1970.
- ZHANG, H.; LI, J.; WANG, T.; LIN, H.; ZHENG, Z.; LI, Y.; LU, Y. A manifold learning approach to urban land cover classification with optical and radar data. **Landscape and Urban Planning**, v. 172, p. 11-24, 2018.
- ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G.; ZHANG, L.; XU, F.; FRAUNDORFER, F. Deep Learning in Remote Sensing: A comprehensive review and list of resources. **IEEE Geoscience and Remote Sensing Magazine**. v. 5, n. 4, p. 8-36, 2017.
- ZHU, Z.; ZHOU, Y.; SETO, K. C.; STOKES, E. C.; DENG, C.; PICKETT, S. T. A.; TAUBENBOCK, H. Understanding an urbanizing planet: Strategic directions for remote sensing. **Remote Sensing of Environment**, v. 228, p. 164-182, 2019.

2. Classificação do uso e cobertura da terra utilizando imagens SAR/Sentinel 1 no Distrito Federal, Brasil

Land Use/Land Cover (LULC) classification based on SAR/Sentinel 1 image in Federal District, Brazil

*Felipe Lima Ramos Barbosa*¹ 

*Renato Fontes Guimarães*² 

*Osmar Abílio de Carvalho Júnior*³ 

*Roberto Arnaldo Trancoso Gomes*⁴ 

Palavras-chave:

SAR
Sentinel 1
coerência interferométrica
ambiente urbano
objetos urbanos

Resumo

Os desafios sociais e ambientais estão diretamente relacionados à concentração populacional existente nos ambientes urbanos, que contribuem em mais de 75% do Produto Interno Bruto (PIB) mundial. Assim, é essencial a detecção da dinâmica do uso e cobertura da terra visando à elaboração e efetivação de políticas públicas. Os sistemas SAR, especialmente as técnicas de interferometria, vêm apresentando ótimos resultados frente a esse desafio, uma vez que não possuem influência direta da atmosfera. Limitados estudos foram realizados utilizando-se a coerência interferométrica proveniente do satélite Sentinel-1 em ambiente urbano. Nesse sentido o objetivo desse estudo foi classificar o uso e cobertura da terra de parte do Distrito Federal tendo por base diferentes dimensionalidades considerando as medidas de intensidade e de coerência interferométrica relativas ao ano de 2018. Os resultados mensurados a partir das métricas *Kappa* e F1 indicam que a inserção de uma série temporal de coerências interferométricas melhora o desempenho da classificação, de 0,50 a 0,75 (*Kappa*) e de 0,54 a 0,79 (F1), fato que ficou evidente na melhora de desempenho das classes temáticas relacionadas à cobertura vegetal. Ademais, também constata-se que a identificação dos objetos urbanos é melhor representada pela utilização apenas das intensidades (VV e VH) no processo classificatório.

Keywords:

SAR
Sentinel 1
interferometric coherence
urban environment
urban objects

Abstract

The social and environmental challenges are directly related to the existing population concentration in urban environments, which contribute to more than 75% of the world's Gross Domestic Product (GDP). Thus, it is essential to detect the dynamics of Land Use and Land Cover (LULC) aiming to support public policies elaboration and

¹ Programa de Pós-Graduação em Geografia (UnB). felipelrb@gmail.com

² Departamento de Geografia (UnB)/LSIE. renatofg@unb.br

³ Departamento de Geografia (UnB)/LSIE. osmarjr@unb.br

⁴ Departamento de Geografia (UnB)/LSIE. robertogomes@unb.br

implementation. SAR systems, especially the interferometry techniques, have been shown great results in face of this challenge, since they do not have direct influence from the atmosphere. Limited studies were conducted using interferometric coherence from the Sentinel-1 satellite in an urban environment. In this sense, the objective of this study was to classify the LULC of part of the Federal District, Brazil based on different dimensions considering the measures of intensity and interferometric coherence for the year 2018. The results measured from the *Kappa* and F1 metrics indicate that the insertion of a time series of interferometric coherencies improves the performance of the classification, from 0.50 to 0.75 (*Kappa*) and from 0.54 to 0.79 (F1), a fact that was evident in the improved performance of the thematic classes related to vegetation cover. Furthermore, it is also found that the identification of urban objects is best represented by the use of only the intensities (VV and VH) in the classification process.

2.1. INTRODUÇÃO

Partes significativas dos problemas sociais e ambientais são agravadas pela concentração populacional nas cidades brasileiras, visto que, aproximadamente, 160 milhões de pessoas vivem no ambiente urbano, cerca de 85% da população, conforme estimativas provenientes do Censo Demográfico de 2010 elaborado pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Ademais, segundo Zhu et al. (2019), as áreas urbanas garantem mais de 75% do Produto Interno Bruto (PIB) mundial.

As informações de uso e cobertura da terra são essenciais para a elaboração de políticas públicas relacionadas ao meio ambiente (KHALIL; HAQUE, 2018). A dinâmica do uso e cobertura da terra é uma das mais expressivas áreas de estudo do sensoriamento remoto, sendo reconhecida como um elemento chave na avaliação de impactos ambientais, no monitoramento ecológico, no monitoramento das mudanças globais, no planejamento territorial estadual e local, no desenvolvimento de políticas regulatórias, bem como na identificação e prevenção da expansão irregular da malha urbana.

A evolução do imageamento SAR (Synthetic Aperture Radar) para mapeamento de uso e cobertura da terra tem demonstrado ótimos resultados por não possuir influência direta da atmosfera e da cobertura de nuvens, o que favorece a análise de mudança ao longo do tempo. Os dados obtidos por sistemas ativos vêm contribuindo e popularizando o desenvolvimento de estudos focados na classificação do uso e cobertura da terra (DINIZ; GAMA, 2019; MIGUEL; SANO, 2019), na identificação de objetos considerando a fusão com informações provenientes de sensores óticos (RAJAH et al., 2018; WERNER et al.,

2014), no derramamento de óleo (CHATURVEDI et al., 2019; OZIGIS et al., 2020), nos movimentos gravitacionais de massa (AUBLANC et al., 2018; LI et al., 2020), no mapeamento de áreas agrícolas (PICHIERRI et al., 2018; SEKERTEKIN et al., 2020), dentre outros.

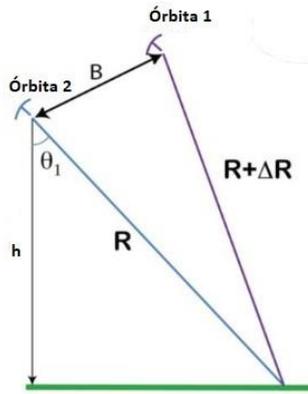
Os sistemas SAR também possuem potencial na identificação de objetos urbanos. O controle quanto à radiação emitida e recebida pelo sensor, permite uma melhor compreensão das estruturas e dos objetos geométricos presentes no terreno, uma vez que suas propriedades dielétricas alteram a polarização da radiação eletromagnética (WERNER et al., 2014). Apesar disso, o sistema SAR apresenta alguns fatores que interferem na qualidade do imageamento das superfícies naturais e artificiais, devido às mudanças abruptas na altura, orientação, forma e tamanho dos objetos, que juntos promovem uma confusão espectral entre as classes de uso e cobertura da terra que serão mapeadas (GRIFFITHS et al., 2010).

A utilização da técnica interferométrica (InSAR) possibilita aprimorar as classificações de uso e cobertura da terra. A fase ondulatória (Φ) presente no sinal SAR representa o momento de retorno da onda eletromagnética e está relacionada com a distância entre a antena do satélite e os alvos, e, por isso, pode ser usada como informação na derivação de distorções no terreno (movimentos de massa, rebaixamentos, Modelos Digitais de Terreno, dentre outros). Essa informação de fase (Φ) pode ser quantificada considerando a seguinte relação matemática (Equação 1), considerando a natureza sinusoidal em relação à um círculo de 2π .

$$\Phi = \frac{2\pi}{\lambda} 2R = \frac{4\pi}{\lambda} R \quad (1)$$

Essa técnica é baseada na mensuração da diferença entre as fases de duas cenas SAR de uma mesma área e obtidas em ângulos diferentes, o que tipifica a mudança de fase, ou fase interferométrica ($\Delta\Phi$). A Figura 2.1 esquematiza a geometria de um sistema InSAR obtido a partir de duas órbitas separadas por uma linha de base interferométrica.

Figura 2.1. Esquema da geometria InSAR obtido a partir de duas órbitas.



Org.: dos Autores, 2020

As medidas apresentadas na figura acima possuem relação direta com a distância percorrida pelo sinal, a baseline interferométrica, os ângulos de visada e o comprimento de onda (λ). As equações 2 e 3 apresentadas a seguir expressam a relação geométrica da definição conceitual do interferograma.

$$\Phi_1 = \frac{4\pi R}{\lambda}, \Phi_2 = \frac{4\pi(R+\Delta R)}{\lambda} \quad (2)$$

$$\Delta\Phi = \Phi_2 - \Phi_1 = \frac{4\pi\Delta R}{\lambda} \quad (3)$$

As técnicas InSAR fornecem informações que auxiliam no estudo do ambiente urbano, principalmente focadas em identificar movimentos de subsidência a partir da análise de deformações da superfície (CIAMPALINI et al., 2019; HU et al., 2019). Portanto, é fundamental garantir uma boa qualidade de ambos os sinais de retorno no sentido de proceder análises de cunho interferométrico.

A coerência (γ) é uma medida interferométrica auxiliar que varia entre 0 e 1 e indica o grau de similaridade das fases de ambos os sinais de retorno em um sistema InSAR. Essa métrica é usada para identificar

as áreas passíveis de estudos interferométricos, resultado direto da combinação de determinado padrão geométrico do sistema utilizado e das condições ambientais da área imageada durante o registro de ambos os sinais. A Equação 4 define a coerência interferométrica entre duas imagens SAR, produto da relação entre os valores reais e esperados das amplitudes $|u_1|$ e $|u_2|$ das duas imagens SAR originais.

$$\gamma = \frac{E[u_1 u_2]}{\sqrt{E[|u_1|^2]} \cdot \sqrt{E[|u_2|^2]}} \quad (4)$$

A coerência interferométrica é uma importante informação complementar para fins de classificação temática da paisagem (OLESK et al., 2016; WEGMULLER et al., 2015), uma vez que seus valores estão associados à características temporais, geométricas, volumétricas e de processamento do sinal. Tal métrica é amplamente utilizada em estudos que envolvem a identificação da cobertura vegetal (DINIZ; GAMA, 2019; MOHAMMADIMANESH et al., 2018), devido seu característico comportamento volumétrico em série temporal. Tais áreas são bastante heterogêneas e apresentam elevadas mudanças em textura ao longo do tempo, fatos ocasionados pelas diferentes condições climáticas ou mesmo pela conversão de uso da terra. A variação dos valores de coerência ocasionada pela decorrelação temporal auxilia na identificação de diferentes curvas de comportamento espectro-temporal desses alvos e servem de informação complementar para sua classificação.

A coerência interferométrica também possui um elevado potencial de aplicação no mapeamento do uso e ocupação da terra em ambiente urbano (MIGUEL; SANO, 2019; SICA et al., 2019; ZHANG et al., 2018). De forma geral, os objetos urbanos (prédios, casas, muros, dentre outros) não possuem uma grande variação de valores de retroespalhamento considerando uma série temporal, o que ocasiona o registro de altos índices de coerência sobre tais áreas. Ademais, limitados estudos foram realizados utilizando-se a coerência interferométrica proveniente do satélite Sentinel-1 em ambiente urbano (KHALIL; HAQUE, 2018).

Desta forma, o objetivo desse estudo é classificar o uso e cobertura da terra de parte do Distrito Federal utilizando-se informações provenientes de série temporal composta de imagens SAR do satélite Sentinel 1 relativas ao ano de 2018. Para tanto, diferentes arranjos

temporais considerando as medidas de intensidade do sinal (db) e da coerência interferométrica foram testados visando identificar a real contribuição de tais métricas no processo de classificação.

2.2. ÁREA DE ESTUDO

O Distrito Federal (DF) possui uma população de, aproximadamente, 3.000.000 habitantes, que se distribui de forma assimétrica entre o ambiente rural (3,38%) e urbano (96,62%), conforme consta em seu Zoneamento Ecológico-Econômico (BRASIL, 2018). O ambiente urbano do Distrito Federal possui diversos arranjos que se materializam, principalmente, em sua porção planejada, com prédios e residências dispostas em áreas arborizadas, variando em densidade, ou não-planejada, no qual tendem a se comportar como arranjos típicos urbanos

encontrados em outras cidades brasileiras. A Figura 2.2 ilustra diferentes arranjos de objetos urbanos que podem ser encontrados no Distrito Federal.

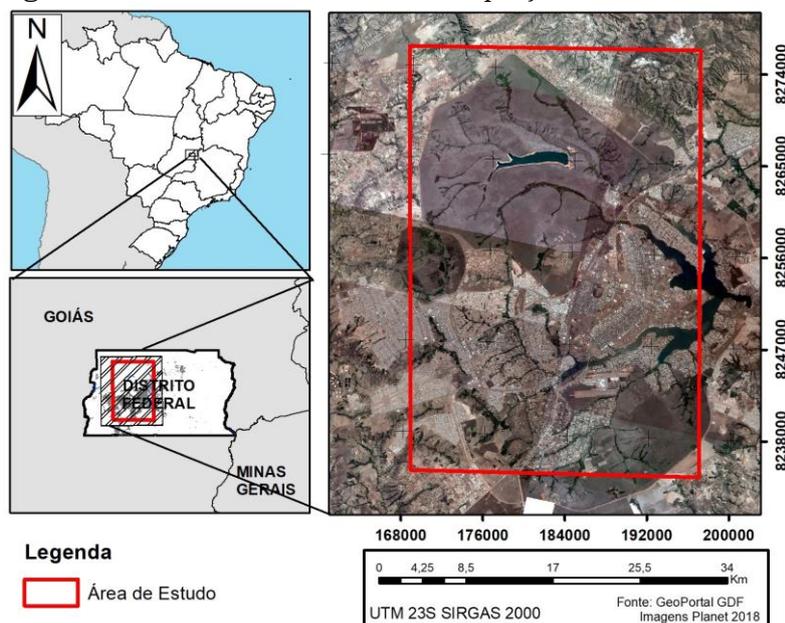
Assim, a área de estudo localiza-se em parte do DF e compreende o perímetro estabelecido entre as coordenadas 48°5'57,31"O 15°34'23,04"S e 47°49'50,10"O 15°57'8,3"S. A escolha dessa área está relacionada (i) a diversificação existente de morfologias urbanas e de cobertura vegetal associada à fitofisionomia de cerrado e (ii) ao limite tecnológico existente, à época de processamento dos dados, relacionado a capacidade computacional disponível e a grande quantidade de dados SAR processados relativos a todo o ano de 2018, especialmente os interferométricos. A Figura 2.3 mostra a porção do Distrito Federal que foi utilizada nas inferências espaciais realizadas pela presente pesquisa.

Figura 2.2. Diferentes arranjos urbanos no Distrito Federal. (a) Área planejada e amplamente arborizada; (b) Área planejada e menos arborizada; (c) Área de expansão não-planejada recente



Org.: dos Autores, 2020

Figura 2.3. Área de estudo referente à porção do Distrito Federal



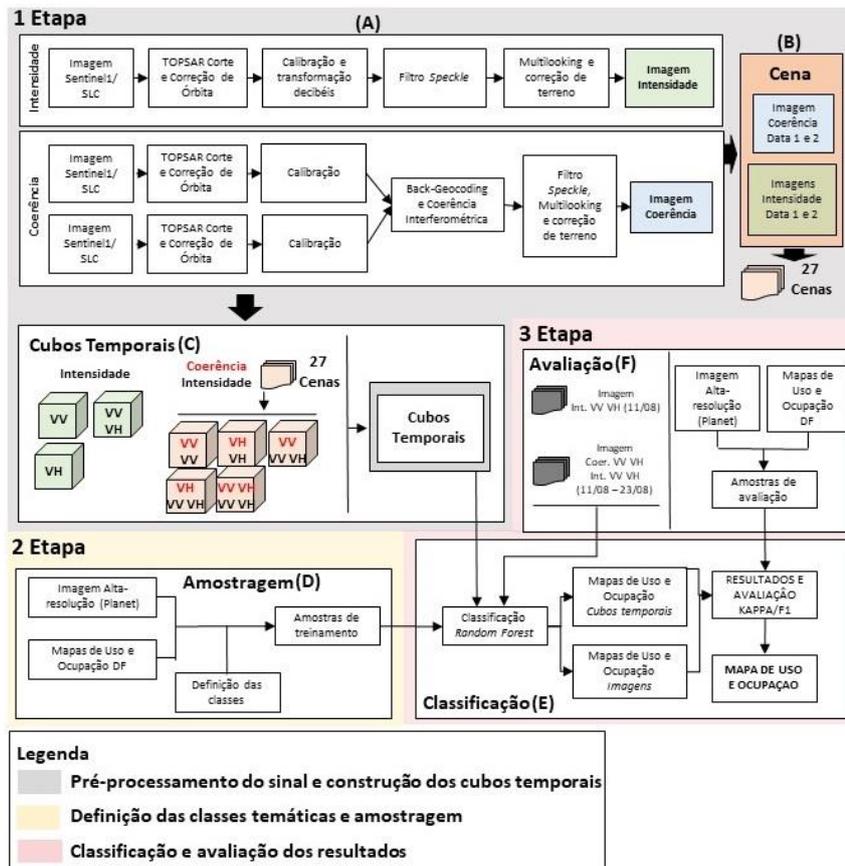
Org.: dos Autores, 2020.

2.3. MATERIAL E MÉTODOS

A metodologia do trabalho foi organizada em 3 etapas (Figura 2.4). A primeira etapa refere-se aos pré-processamentos dos sinais de radar e a construção dos cubos temporais. A segunda

etapa refere-se à definição das classes temáticas e a escolha das amostras de treinamento. A terceira etapa refere-se aos procedimentos de classificação e de avaliação dos resultados.

Figura 2.4. Fluxograma das etapas metodológicas do trabalho.



Org.: dos Autores, 2020

2.3.1. Pré-processamento do sinal de radar e construção dos cubos temporais (Etapa 1)

O Sentinel 1, iniciativa da Comissão Europeia e da Agência Espacial Europeia (ESA), é uma constelação de duas plataformas orbitais operando na banda C (5.405 GHz) do micro-ondas, Sentinel 1A e Sentinel 1B, em duas polarizações (VV e VH), e conta com 4 (quatro) modos de aquisição: (i) *Stripmap* (SM); (ii) *Interferometric Wide Swath* (IW); (iii) *Extra-Wide Swath* (EW); e (iv) *Wave mode* (WV). O modo de aquisição definido foi o IW, que apresenta uma faixa de imageamento de 250 km com uma resolução geométrica moderada (5m por 20m) e estruturada em *Terrain*

Observation with Progressive Scans SAR (TOPSAR), que garante uma qualidade homogênea na imagem e satisfaz a maioria das aplicações em terreno (DE ZAN; GUARNIERI, 2006). Esse modo de aquisição é o mais utilizado para mapeamentos de uso e ocupação da terra.

As imagens do satélite Sentinel 1 podem ser adquiridas em diferentes níveis de processamento, a saber: (i) *Single Look Complex* (SLC); e (ii) *Ground Range Detected* (GRD). Tendo em perspectiva a aplicação interferométrica, foram selecionadas imagens em nível de processamento SLC, relativas ao ano de 2018, uma vez que possuem informações relativas a amplitude e a fase do sinal, registradas em números complexos, e

projetadas na geometria de visada do sensor (*slant-range*). A Tabela 2.1 mostra as datas das 28 imagens Sentinel 1 IW/SLC que foram adquiridas.

Tabela 2.1. Datas das imagens Sentinel 1 adquiridas e processadas.

Datas – Imagens Sentinel 1 (IW SLC)			
07/01/2018	01/04/2018	18/07/2018	10/10/2018
19/01/2018	13/04/2018	30/07/2018	22/10/2018
31/01/2018	25/04/2018	11/08/2018	03/11/2018
12/02/2018	07/05/2018	23/08/2018	15/11/2018
24/02/2018	19/05/2018	04/09/2018	27/11/2018
08/03/2018	12/06/2018	16/09/2018	09/12/2018
20/03/2018	24/06/2018	28/09/2018	21/12/2018

Org.: dos Autores, 2020.

A etapa de pré-processamento do sinal de radar (Figura 2.4A) tem por objetivo reduzir as distorções radiométricas e geométricas e corrigir as imagens SAR. Essa etapa foi realizada considerando as aplicações presentes no programa SNAP, desenvolvido pela Agência Espacial Europeia (ESA), que possui ferramentas específicas para o processamento e a estimativa das métricas de intensidade e de coerência interferométrica do satélite Sentinel 1.

Todas as imagens SAR foram recortadas para a área de interesse e corrigidas considerando suas informações complementares relativas à órbita e a altitude do satélite. No caso da estimativa dos valores de intensidade, o sinal foi calibrado com o objetivo de realizar a transformação dos valores de retroespalhamento, inicialmente, em níveis digitais (ND) para sigma (σ) e, posteriormente, transformado em níveis de decibéis (db), etapa essa que garante uma melhor representação dos valores no intervalo do histograma da imagem, a partir de sua expansão.

Após os ajustes radiométricos, foi necessária a realização de um procedimento de filtragem convolucional, utilizando-se a mediana em uma janela 5x5, no sentido de reduzir o efeito *speckle* inerente a dados SAR. Esse efeito provoca uma diferenciação nos valores de retroespalhamento que podem não estar associados a mudanças reais de objetos na paisagem, causando um padrão granulado do tipo “sal e pimenta”. Posteriormente, realizou-se a transformação das imagens, originalmente, projetada *slant-range* para uma grade regular, processo conhecido como *multilooking*.

Por fim, as imagens foram ortoretificadas e projetadas em UTM, fuso 23S, e datum WGS 1984, tendo como referência o Modelo Digital

de Elevação do Shuttle Radar Topography Mission (SRTM) de 30 metros de resolução espacial, o que resultaram em imagens SAR finais na resolução espacial de 10 metros. Tais correções geométricas de terreno visam reduzir as distorções associadas ao encurtamento de rampa, dentre outros.

Para a estimativa da coerência, o sinal SAR também foi recortado para a área de interesse e calibrado mantendo-se as informações de amplitude e fase, fato que demanda a manutenção dos valores ajustados em números complexos. Como a configuração de um sistema InSAR com imagens Sentinel 1 só é possível de forma monostática, no qual a simulação da linha de base interferométrica é adquirida com a aquisição de duas cenas de tempos distintos sobre uma mesma área, pares de imagens foram agrupados considerando as informações complementares de órbita através do processo *back-geocoding*, visando georeferenciar as informações de amplitude e fase e, assim, permitir o computo da coerência interferométrica conforme a Equação 4. O Quadro 2.1 mostra as 27 imagens de coerência interferométrica calculadas para o ano de 2018.

Uma vez calculadas as coerências interferométricas apresentadas no quadro 2.1, os procedimentos de filtragem, *multilooking* e correção geométrica de terreno adotados foram os mesmos já apresentados acima. Isso se justifica uma vez que os valores de coerência interferométrica são computados na projeção *slant-range* utilizando-se as informações de fase do sinal original, registrado em números complexos, em cada imagem do par, visando à compatibilidade com as métricas de intensidade. As imagens de coerência interferométrica resultantes também foram elaboradas na resolução espacial de 10 metros.

Todas as informações SAR processadas foram transformadas para SIRGAS 2000, observando

a Resolução IBGE 01/2015 (BRASIL, 2015).

Quadro 2.1. Arranjo adotado para a estimativa das coerências interferométrica de 2018.

Data	Coer.	Data	Coer.	Data	Coer.	Data	Coer.
07/01/2018	1	01/04/2018	8	18/07/2018	15	10/10/2018	22
19/01/2018		13/04/2018		30/07/2018		22/10/2018	
19/01/2018	2	13/04/2018	9	30/07/2018	16	22/10/2018	23
31/01/2018		25/04/2018		11/08/2018		03/11/2018	
31/01/2018	3	25/04/2018	10	11/08/2018	17	03/11/2018	24
12/02/2018		07/05/2018		23/08/2018		15/11/2018	
12/02/2018	4	07/05/2018	11	23/08/2018	18	15/11/2018	25
24/02/2018		19/05/2018		04/09/2018		27/11/2018	
24/02/2018	5	19/05/2018	12	04/09/2018	19	27/11/2018	26
08/03/2018		12/06/2018		16/09/2018		09/12/2018	
08/03/2018	6	12/06/2018	13	16/09/2018	20	09/12/2018	27
20/03/2018		24/06/2018		28/09/2018		21/12/2018	
20/03/2018	7	24/06/2018	14	28/09/2018	21		
01/04/2018		18/07/2018		10/10/2018			

Org.: dos Autores, 2020

Uma vez pré-processadas as informações, as imagens de intensidade relativas ao ano de 2018 foram combinadas em diferentes estruturas matriciais contendo toda a informação do interstício analisado (cubos temporais), conforme apresentado na Figura 2.4C. Esse arranjo é específico para a análise espectro-temporal no âmbito do programa Abilius, que possui capacidade de análise quantitativa de um alvo considerando sua variabilidade temporal.

Diferentes combinações de cubos temporais foram estruturados considerando, inicialmente, somente as métricas de intensidade em ambas as polarizações, cuja intenção foi verificar o desempenho no processo de classificação considerando as possíveis combinações das polarizações disponíveis. Ademais, e visando compatibilizar as informações das coerências interferométricas e das intensidades em uma mesma estrutura matricial, foi necessário, inicialmente, estabelecer 27 cenas distintas, cada qual com uma (i) imagem de coerência e (ii) com o valor médio das intensidades relativas as datas das imagens que formaram o respectivo par interferométrico (Figura 2.4B), que, por fim, foram agrupadas observando-se os arranjos temporais já mencionados (Quadro 2.1).

Assim, foi possível estruturar 3 cubos temporais utilizando-se apenas as medidas de intensidade, e 5 cubos temporais considerando as possíveis combinações entre as medidas de

coerência interferométrica e de intensidade, em suas diferentes polarizações (Figura 2.4C). Esse arranjo metodológico permitiu a aquisição de 8 classificações de uso e ocupação da terra para a série temporal de 2018.

2.3.2. Definição das classes e das amostras de treinamento (Etapa 2)

A pesquisa utilizou 7 classes temáticas para o mapeamento do uso e cobertura da terra, sendo elas: (i) água; (ii) cobertura vegetal – formação campestre; (iii) cobertura vegetal – formação savânica; (iv) cobertura vegetal – formação florestal; (v) áreas planas, (vi) mancha urbana e (vii) edificações (Figura 2.4D). As quatro primeiras classes são comumente utilizadas em mapas de uso e ocupação da terra e serviram para registrar as localidades com presença de água e os diferentes arranjos de cobertura vegetal. Por sua vez, a classe “áreas planas” tem por objetivo registrar as localidades que apresentam baixos valores de intensidade, uma vez que são planas em relação às configurações do sistema SAR utilizado, tais como pistas, estacionamentos e solo exposto. Essa classe foi primordial no sentido de evitar possíveis confusões com a classe de água, uma vez que as respostas do retroespalhamento do sinal são muito similares devido à presença dominante do efeito especular.

A temática urbana utilizada nesse trabalho foi estruturada considerando dois focos: (i) a

identificação de áreas contendo o agregado de objetos urbanos (edifícios e construções) e áreas verdes; e (ii) a identificação dos próprios objetos urbanos. Essas áreas possuem dupla ou tripla reflexão do sinal em resultado a sua interação com objetos que possuem superfícies planas e ortogonais inerentes a fachadas de prédios, denominado de efeito de refletor de canto (*double-bounce*), o que favorece a identificação de tais alvos. Para o treinamento da primeira vertente, a classe temática “mancha urbana” foi definida considerando diferentes arranjos quanto à orientação e concentração de objetos urbanos, bem como com relação às áreas verdes circunvizinhas (Figura 2.2). Assim, essa classe temática teve o intuito de servir de transição entre os objetos urbanos e as demais classes presentes no mapeamento, porque o termo “urbano” não possui um sentido único e torna impossível a definição exata de diferentes estruturas físicas e suas propriedades de superfície. A segunda vertente consistiu no treinamento de amostras relativas às construções mapeadas por intermédio do aerolevante cadastral do DF realizado em 2016.

Para cada uma das classes temáticas foram estabelecidas 20 regiões de interesse, que representaram um agrupamento amostral de, aproximadamente, 6.400 *pixels*. O intuito dessa estratégia adotada foi manter a distribuição estratiforme entre as amostras em cada um dos processos de classificação. Esse processo de amostragem contou com o auxílio: (i) de fotointerpretação de imagens do satélite ótico de alta resolução *Planet* do ano de 2018; (ii) mapas de vegetação do Distrito Federal elaborados pelo governo local no âmbito do Zoneamento Ecológico-Econômico do Distrito Federal (BRASIL, 2018); e (iii) mapa de uso e cobertura da terra elaborado em 2019 pelo governo local.

A única exceção foi com relação à classe “edificações”, que foi treinada contando com a seleção aleatória de 100 construções, com mais de 500 m² cada, proveniente das informações cadastrais urbanas do aerolevante realizado em 2016. Esses quantitativos foram definidos visando garantir o mesmo valor de agrupamento amostral das demais classes temáticas de treinamento. Essa etapa foi realizada com o auxílio do programa ENVI 4.3.

2.3.3. Etapa de classificação (Etapa 3 E)

O algoritmo *Random Forest* (RF) foi, inicialmente, desenvolvido por Breiman (2001) e consiste de um processo de predição de

resultados tendo por base o desenvolvimento e a utilização de um conjunto de árvores de decisão criadas aleatoriamente com as informações relevantes para a classificação e são estruturadas tendo por base o melhor arranjo de decisão para a explicação de determinada informação. Para cada k th árvore do conjunto a ser constituído pelo algoritmo, um vetor aleatório Θ_k é gerado, independente dos vetores aleatórios passados $\Theta_1, \dots, \Theta_{k-1}$, mas com a mesma distribuição. Assim, uma árvore é estruturada utilizando-se as amostras de treinamento e Θ_k , resultando na definição do classificador $h(x, \Theta_k)$. Os nós de cada uma das k th árvores são definidos tomando-se por base a natureza dos dados de entrada de forma aleatória, buscando-se sempre garantir a melhor entropia entre um nó e seu subsequente (BELGIU; DRAGUT, 2016; BREIMAN, 2001; WHITCOMB et al., 2009). Após a estruturação de um número elevado de árvores, cada classificador estabelecido é utilizado no processo de votação do algoritmo pela classe com maior probabilidade de ocorrência.

A escolha desse classificador se justifica uma vez que quando as amostras de treinamento são menores, ou mesmo o padrão de qualidade é desconhecido, o algoritmo mais robusto a ser utilizado nessa situação são os associados à conjunto de árvores de decisão (MAXWELL et al., 2018). Resultados satisfatórios referentes à potencialidade do RF frente aos demais algoritmos de *machine learning* foram encontrados nos trabalhos de Miguel e Sano (2019) e Lawrence e Moran (2015).

O programa livre Abilius vem sendo desenvolvido no Laboratório de Sistema de Informações Espaciais (LSIE) da Universidade de Brasília (UnB) e possui ferramentas de visualização e processamento digital de imagens e algoritmos de classificação *machine learning*. A principal vantagem da escolha desse software está em sua capacidade de análise em série temporal, no qual as informações são estruturadas em cubos temporais visando permitir a análise quantitativa da dinâmica espectro-temporal dos diferentes alvos da imagem.

O algoritmo RF implementado no Abilius é proveniente da biblioteca *Open Source Vision Library* (OpenCV) e sua parametrização foi estabelecida conforme Prinzie e Van den Poel (2008). Neste sentido, foi definido em 5 o número máximo de divisão das árvores de decisão e em 500 o número máximo do conjunto de árvores (MAXWELL et al., 2018). Esse

algoritmo de classificação já foi utilizado em diversos trabalhos acadêmicos que envolveram a classificação de *commodities* agrícolas (BITENCOURT, 2020; COSTA, 2020), do uso e ocupação da terra (MARQUES et al., 2019; SALGADO, 2019), identificação de áreas inundáveis (FERREIRA, 2018) e de queimada (OLIVEIRA, 2019).

2.3.4. Avaliação das classificações (Etapa 3 F)

A etapa de avaliação foi estabelecida tendo por base a comparação da sequência de classificações temporais junto a um conjunto independente de dados “verdade”, no sentido de viabilizar o cálculo das seguintes métricas de acurácia: (i) índice *Kappa* e (ii) índice F1, amplamente utilizadas em estudos de sensoriamento remoto (CAO et al., 2020; SALGADO et al., 2019).

Tal como o índice *Kappa*, o cálculo da métrica F1 também parte de uma análise que utiliza a distribuição dos elementos da matriz de confusão, contabilizando os verdadeiros positivos (TP), os falsos positivos (FP), os verdadeiros negativos (TN) e os falsos negativos (FN). Para a estimativa de F1 (Equação 5), é necessário a estimativa do *precision* (Equação 6) e do *recall* (Equação 7), métricas complementares que indicam, respectivamente, a precisão do modelo e sua capacidade de representar a classe pretendida.

$$Precision = \frac{\Sigma \text{Verdadeiros positivos (TP)}}{\Sigma \text{Verdadeiros positivos (TP)} + \Sigma \text{Falsos positivos (FP)}} \quad (5)$$

$$Recall = \frac{\Sigma \text{Verdadeiros positivos (TP)}}{\Sigma \text{Verdadeiros positivos (TP)} + \Sigma \text{Falsos negativos (FN)}} \quad (6)$$

$$F1 = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (7)$$

Um resultado que apresente um alto valor de *precision* e um baixo valor de *recall* indica que poucas áreas foram devidamente mapeadas para determinada classe temática, mesmo que

muitas dessas estejam corretas ao se comparar com a “verdade”. Por sua vez, valores altos de *recall* e baixos valores de *precision* indicam que a classe temática foi amplamente classificada e generalizada na área de estudo, contendo muitos erros de comissão. Para cada uma das 7 classes temáticas foram estimados 300 pontos aleatórios de “verdade” independentes das amostras de treinamento (BITENCOURT, 2020; COSTA, 2020). Também para a definição desses pontos aleatórios utilizou-se o mesmo elenco de produtos cartográficos para a definição das classes e das amostras de treinamento (Etapa 2).

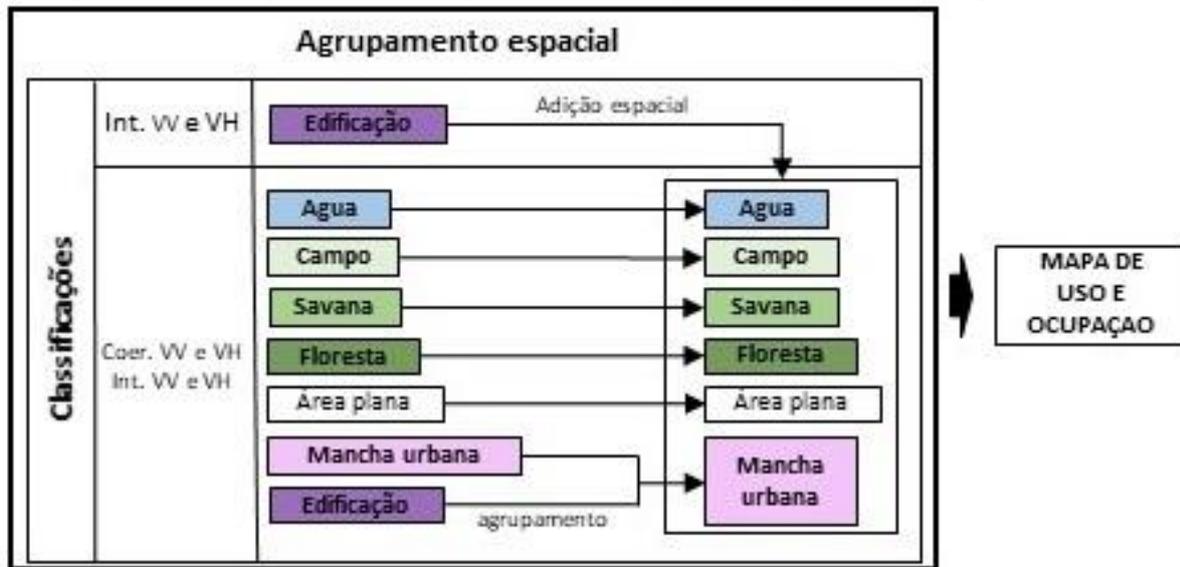
Por fim, e com o objetivo de avaliar o desempenho da análise em série temporal, os resultados classificatórios também foram comparados com classificações realizadas apenas com 2 imagens. A primeira foi estruturada apenas com as métricas de intensidade nas polarizações VV e VH de 11/08/2018. A segunda foi uma imagem contendo as métricas de coerência interferométrica e de intensidade, em ambas as polarizações, referentes às datas de 11/08/2018 e 23/08/2018. Essas etapas estão inseridas na Figura 2.4F.

2.3.5. Consolidação do mapa de uso e ocupação da terra (Etapa 3 E)

A consolidação final do mapa de uso e ocupação da terra é resultado do agrupamento espacial das classes temáticas mapeadas considerando seus melhores desempenhos alcançados nos processos de classificação.

Considerando que a classe temática “edificações” teve sua melhor definição em resultado classificatório diferente das demais classes, sua inserção ao mapeamento final foi realizada conforme o agrupamento espacial apresentada na Figura 2.5, através da aplicação de matrizes de mapas.

Figura 2.5. Fluxograma metodológico de consolidação do mapa de uso e ocupação da terra



Org.: dos Autores, 2020

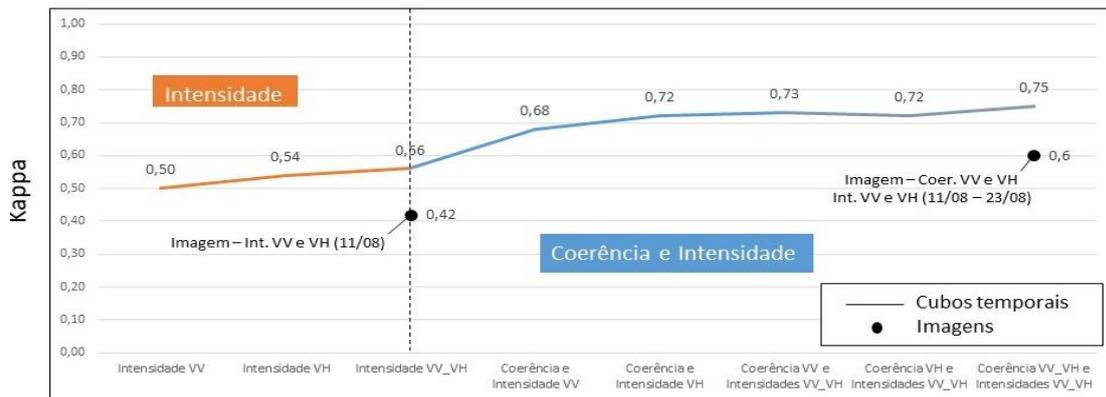
2.4. RESULTADOS E DISCUSSÃO

Essa seção apresenta os resultados e discussões referentes as 8 diferentes classificações temáticas realizadas sobre os cubos temporais. Nas Figuras 2.6 e 2.7 são mostrados os resultados das métricas de acurácia relativas ao índice *Kappa* e ao índice F1, respectivamente, entre as classificações que apresentaram melhor desempenho, tanto considerando (i) apenas a intensidade (VV e VH) (cor marrom) e (ii) a conjugação com a coerência interferométrica (cor azul), e (iii) as classificações resultantes das análises de imagens de 11/08 e 23/08. Os resultados demonstram que as análises em série temporal produzem uma considerável melhoria na classificação, o que representa um aumento de 0,42 a 0,56 (*Kappa*) e 0,49 a 0,59 (F1) na classificação contendo apenas as intensidades em VV e VH, e de 0,6 a 0,75 (*Kappa*) e 0,65 a

0,79 (F1) na classificação contando a conjugação com a coerência interferométrica. O cubo temporal, com as combinações de coerência e intensidade utilizando ambas polarizações, foi o que alcançou os melhores desempenhos com 0,75 (*Kappa*) e 0,79 (F1). Ademais, os resultados também indicam melhores desempenhos das classificações provenientes da série temporal se comparado aos resultados de um único período.

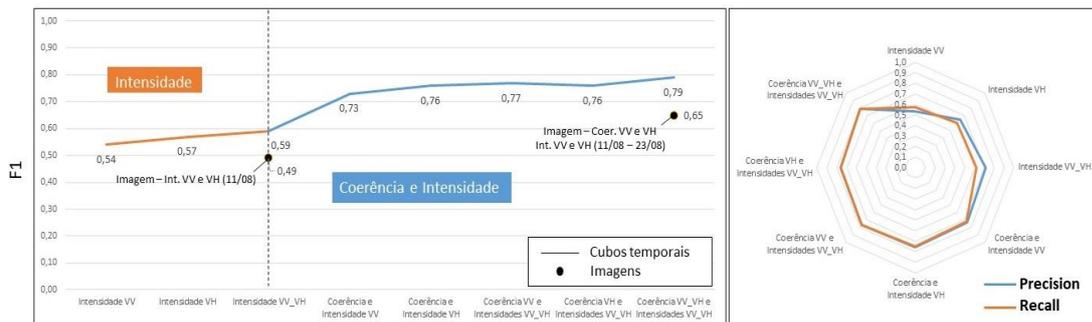
A Figura 2.8 apresenta os resultados referentes ao índice F1 para cada uma das classes temáticas do trabalho, uma vez que se observaram comportamentos distintos na identificação dos alvos com relação à inserção da coerência interferométrica nas análises classificatórias. A Figura 2.9 apresenta as métricas *precision* e *recall* para cada uma das classes temáticas do trabalho.

Figura 2.6. Desempenho das classificações a partir do índice Kappa



Classificações – Cubos temporais
Org.: dos Autores, 2020

Figura 2.7. Desempenho das classificações – índice F1, *precision* e *recall*



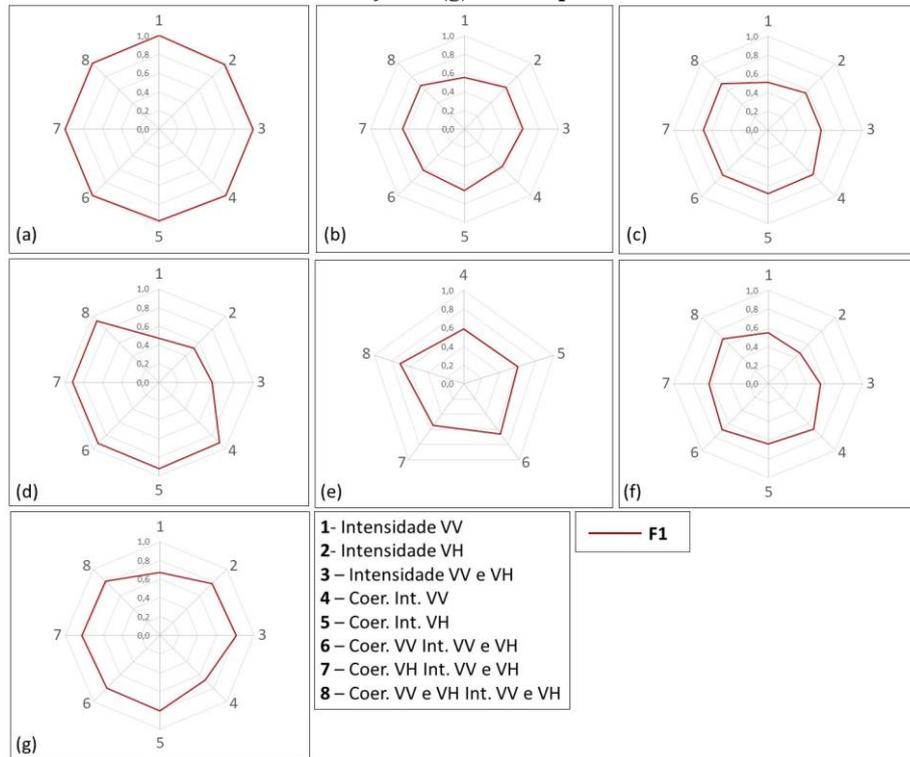
Classificações – Cubos temporais
Org.: dos Autores, 2020

Em linhas gerais, constata-se que os melhores valores de F1 são alcançados pela classificação 8 que considera as intensidades e a coerência interferométrica em VV e VH, fato corroborado pelo melhor balanceamento dos valores de *precision* e *recall* para essa classificação (Figura 2.9).

Ademais, observa-se que os valores de F1 apresentam alterações significativas no desempenho das classes temáticas relacionadas à cobertura vegetal, especificamente nas relativas à formação savânica e florestal (Figura 2.8c e 2.8d). Os resultados indicam um incremento de 0,51 a 0,70 (savana) e de 0,47 a 0,93 (floresta) ao se considerar a coerência interferométrica na classificação, no caso, considerando todas as possíveis combinações das polarizações.

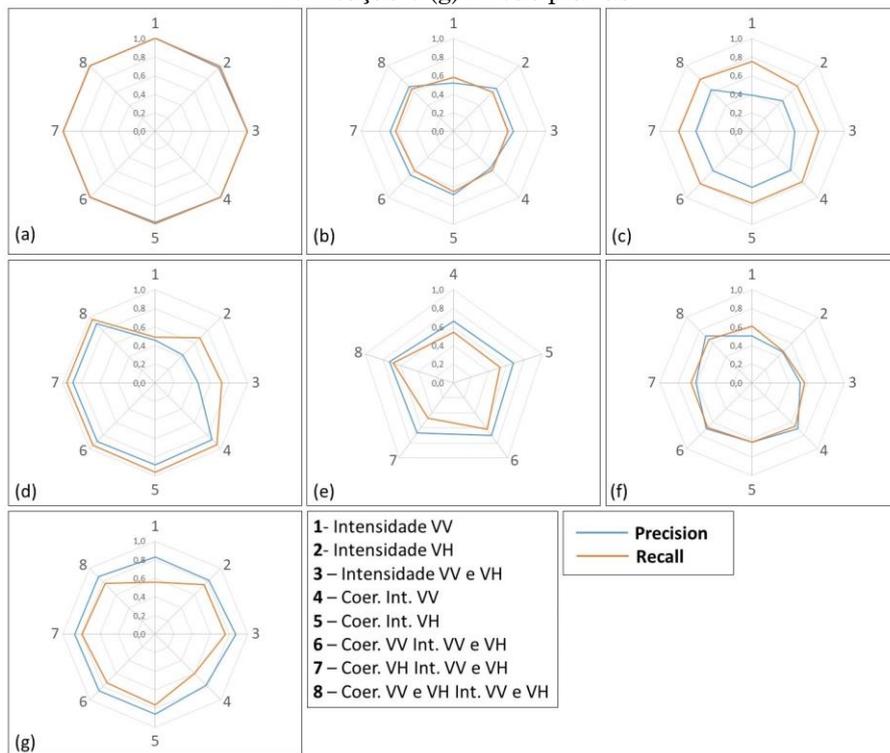
Conforme observa-se na Figura 2.9c, a classe “savana” apresentou pouca variação dos valores de *recall* e uma melhora significativa dos valores de *precision* (0,39 a 0,63), o que indica uma diminuição dos falsos positivos. Por sua vez, na classe “floresta” (Figura 2.9d) a melhora de desempenho fica mais perceptível, no qual ambas as métricas *precision* e *recall* aumentaram, respectivamente, de 0,46 a 0,90 e de 0,49 a 0,96. Esses resultados indicam uma diminuição significativa dos falsos negativos e positivos, e garante, assim, a definição de um modelo mais fidedigno na identificação de classes vegetacionais, principalmente aquelas que possuem menor variação temporal em sua densidade florestal. A Figura 2.10 apresenta a melhora no desempenho da classificação das classes de cobertura vegetal com a inserção da coerência interferométrica em série temporal.

Figura 2.8. Desempenho das classificações por classe temática a partir do índice F1 – (a) Água; (b) Formação campestre; (c) Formação savânica; (d) Formação florestal; (e) Mancha urbana; (f) Edificação e (g) Áreas planas



Org.: dos Autores, 2020

Figura 2.9. Desempenho das classificações por classe temática – índice *precision* e *recall* – (a) Água; (b) Formação campestre; (c) Formação savânica; (d) Formação florestal; (e) Mancha urbana; (f) Edificação e (g) Áreas planas



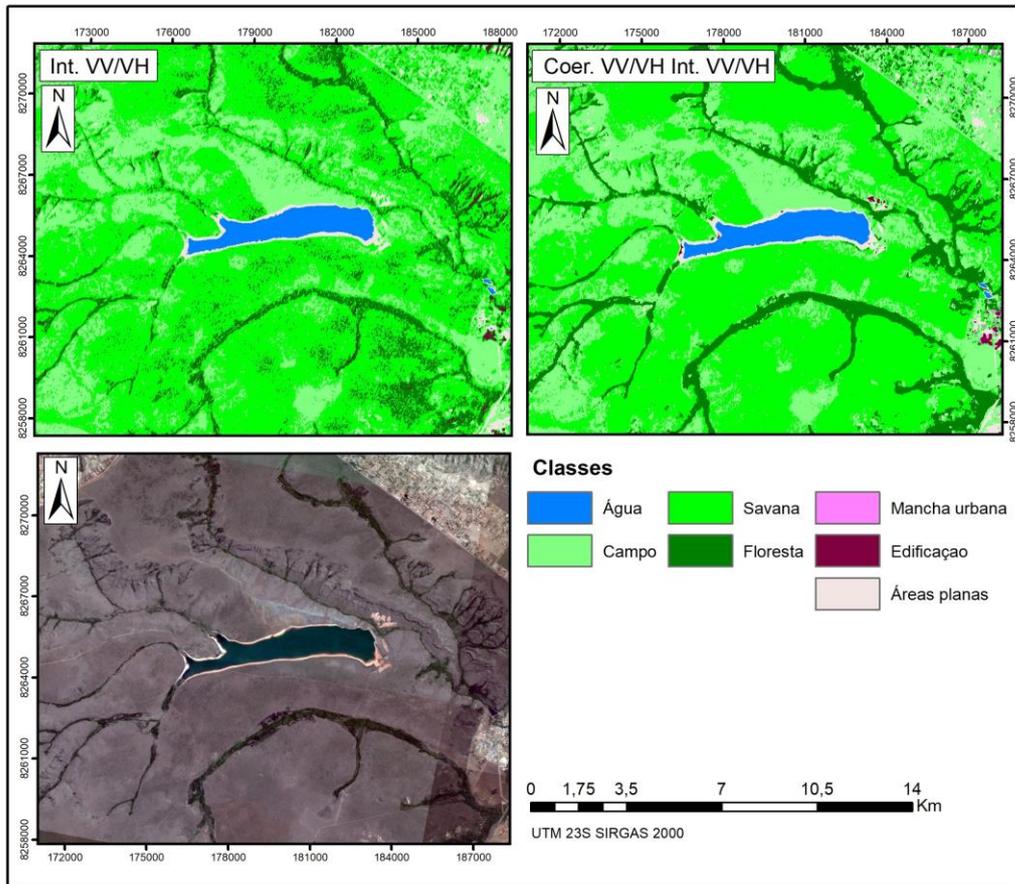
Org.: dos Autores, 2020.

2.4.1. Objetos urbanos versus mancha urbana

As classes temáticas relativas ao ambiente urbano apresentaram comportamentos distintos com a inserção da coerência no processo classificatório. A classe “mancha urbana” somente se materializou como resultado nas classificações quando a coerência foi inserida na dimensionalidade dos dados analisados,

mesmo que seu treinamento tenha sido realizado observando o método adotado. Conforme consta na Figura 2.8e, percebe-se um incremento de 0,59 a 0,71 nos valores de F1 ao se utilizar as intensidades e as coerências em ambas as polarizações no processo de classificação, bem como um melhor balanceamento entre os valores de *precision* e *recall* (Figura 2.9e).

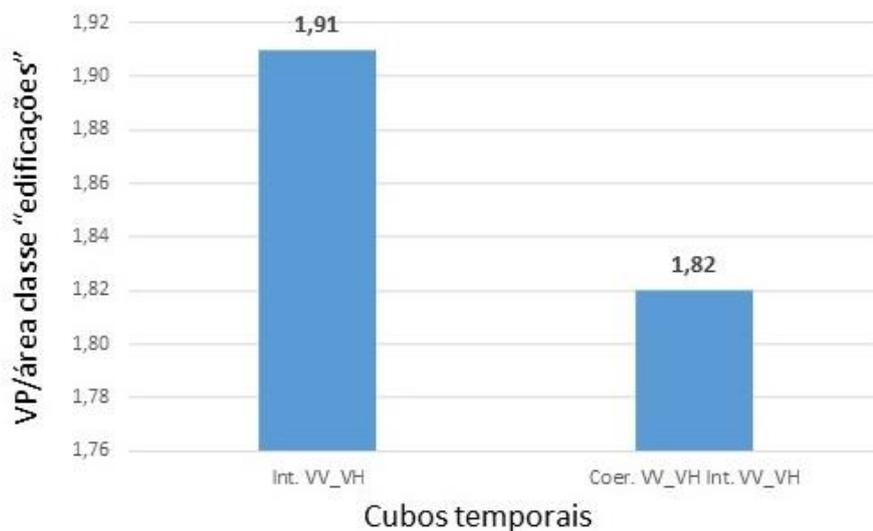
Figura 2.10. Desempenho das classes de cobertura vegetal.



Org.: dos Autores, 2020.

Por sua vez, os resultados apresentados na Figura 2.8f indicam um incremento da classe “edificação” de 0,55 a 0,68 na métrica F1. Conforme a Figura 2.9f, percebe-se que os aumentos dos valores de *precision* (0,50 a 0,71) e de *recall* (0,48 a 0,66) estão associados ao mapeamento de uma classe temática mais genérica na área de estudo, o que não indica, necessariamente, uma melhor definição dos

objetos urbanos. A Figura 2.11 mostra a razão entre os valores de Verdadeiro Positivos (VP) referentes à classe temática “edificação” e as áreas que foram classificadas considerando os resultados (i) utilizando-se apenas as informações de intensidade (VV e VH) e (ii) o agregado de coerências interferométricas e de intensidades em ambas as polarizações.

Figura 2.11. Razão entre os valores de VP e as áreas classificadas da classe “edificações”.

Org.: dos Autores, 2020.

Na Figura 2.11, os resultados indicam que a razão para a respectiva classe temática “edificações” é maior na classificação proveniente da série temporal contendo apenas as métricas de intensidade do que considerando toda a dimensionalidade de dados, o que se mostra mais adequada na identificação das áreas com efeito predominantemente *double bounce*. Também constata-se que a coerência interferométrica, apesar de apresentar melhores índices de acurácia, tende a potencializar o resultado com o aumento de área, ou generalização da classe no processo de classificação do uso e ocupação da terra.

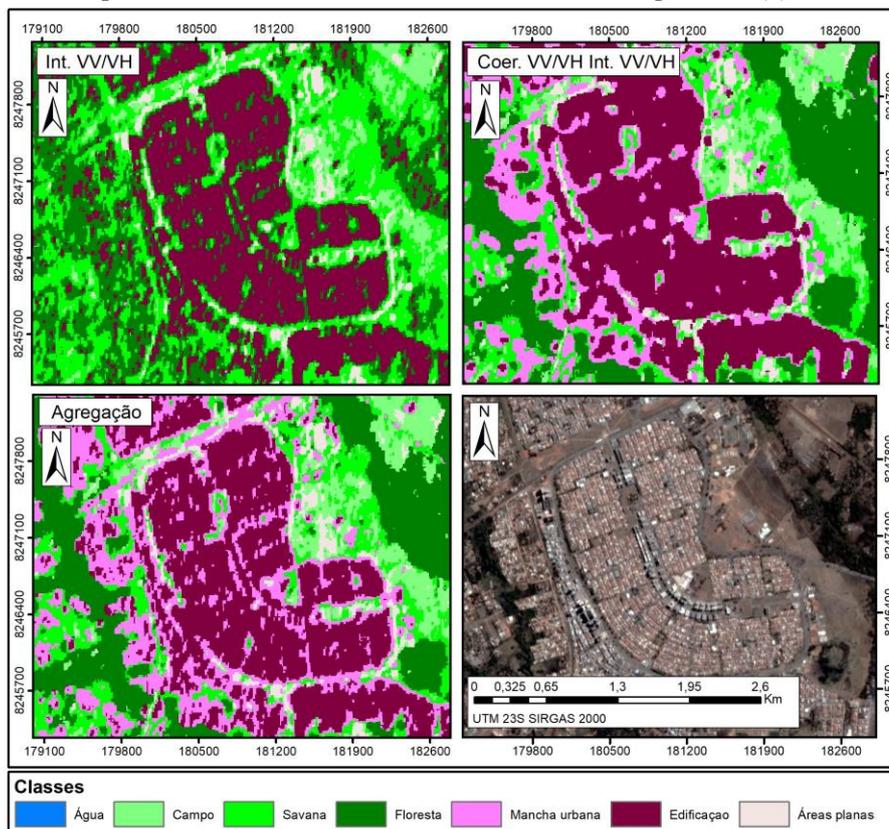
2.4.2. Compilação do mapa de uso e ocupação da terra

A composição do mapa de uso e ocupação da terra foi resultante da agregação espacial das

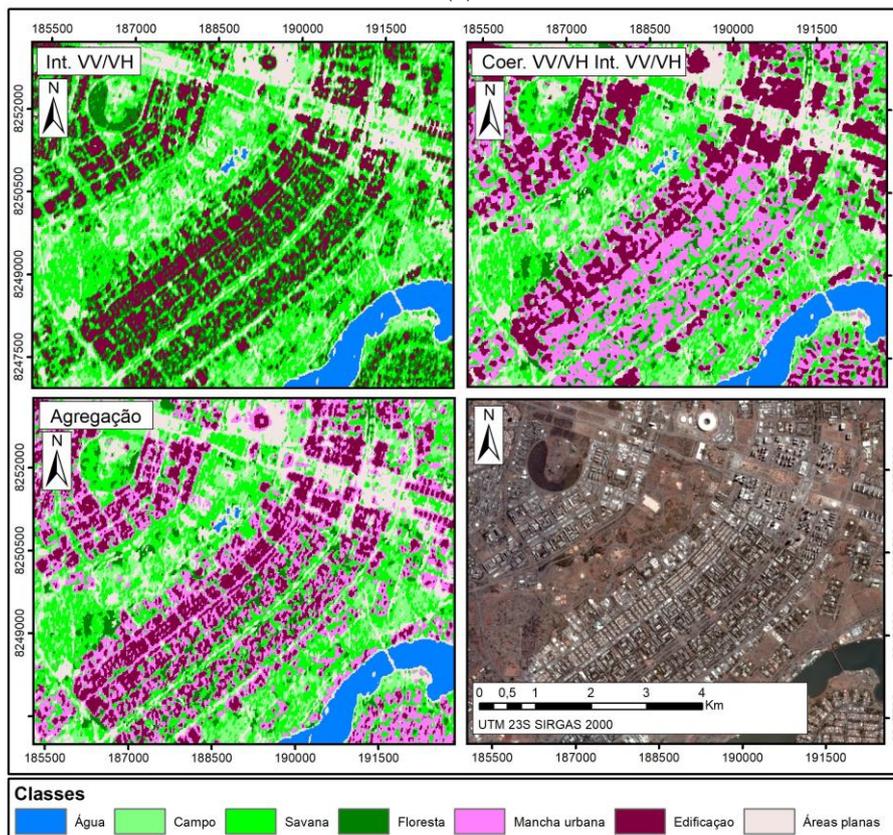
classes temáticas provenientes da classificação que apresentou o melhor desempenho global nos índices *Kappa* e F1. A única exceção foi relativa à classe “edificações”, que foi proveniente da classificação considerando apenas as intensidades em VV e VH. A Figura 2.12 apresenta duas regiões da área de estudo visando exemplificar o refinamento realizado pelo processo de agregação espacial dos melhores desempenhos temáticos identificados.

Percebe-se que o método de composição proposto corrigiu a definição dos objetos urbanos no mapa de uso e ocupação da terra estabelecido, garantindo o registro mais fidedigno das regiões caracterizadas por efeito *double bounce* relacionados com os objetos urbanos. A Figura 2.13 apresentada o mapa resultante de uso e ocupação da terra estabelecido pela metodologia proposta no presente estudo.

Figura 2.12. Exemplos de refinamento da temática urbana – regiões do (a) Guará e do (b) Plano



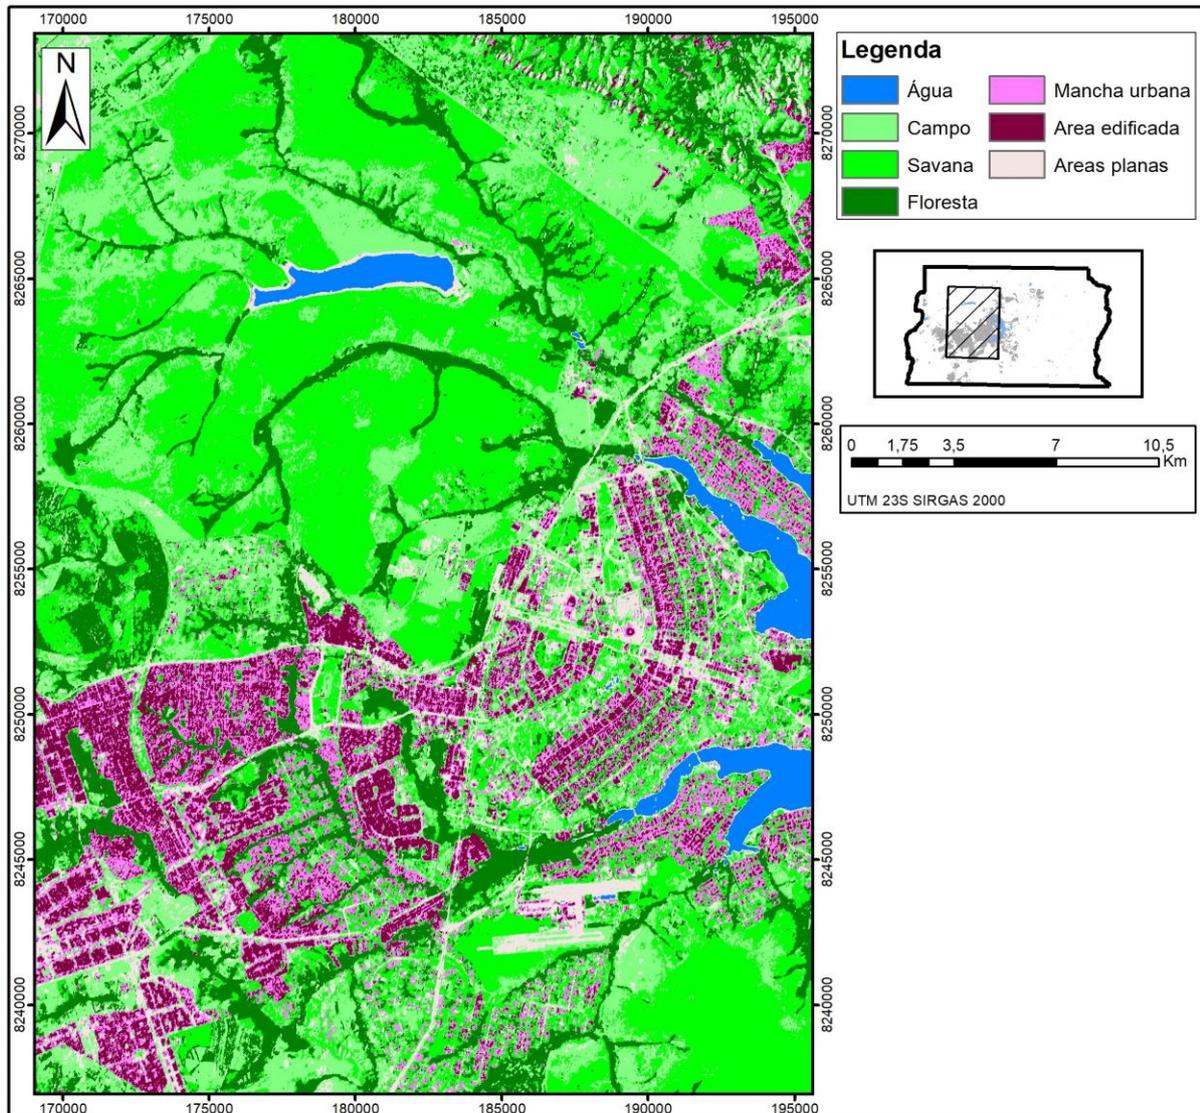
(a)



(b)

Org.: dos Autores, 2020

Figura 2.13. Mapa compilado de uso e ocupação da terra.



Org.: dos Autores, 2020.

2.5. CONSIDERAÇÕES FINAIS

Esse estudo inova ao apresentar uma abordagem metodológica para o mapeamento do uso e cobertura da terra utilizando as métricas da intensidade e da coerência interferométrica provenientes de uma série temporal de imagens Sentinel 1 SLC. As métricas de acurácia consideradas indicam um aprimoramento de 0,50 a 0,75 (*Kappa*) e 0,54 a 0,79 (F1) nas classificações com a inserção da coerência interferométrica em série temporal, apresentando um melhor balanceamento entre as métricas *precision* e *recall*.

Essa melhora é mais presente nas classes temáticas relacionadas à cobertura vegetal, principalmente naquela que possui maior densidade vegetacional (Floresta), cujos índices

variaram de 0,47 a 0,93 (F1), fato que indica a importância dessa informação SAR como complemento na melhora de desempenho da classificação.

Por sua vez, os resultados indicam que tal inserção prejudica a capacidade dos classificadores em identificar especificamente objetos urbanos, porque a coerência produz a suavização dos valores das métricas SAR, o que não é favorável a classificação de alvos geométricos porque estes possuem alta frequência. Dessa forma, essa classe foi determinada utilizando apenas as métricas de intensidade, em ambas as polarizações. Sendo assim, a compilação das metodologias para a elaboração do mapeamento do uso e cobertura da terra identifica com maior precisão tanto às

classes naturais como a definição geométrica dos objetos urbanos.

Demais estudos podem ser desenvolvidos no sentido de aprimorar o processo de classificação utilizando classificadores orientados a objetos, fusão de sensores óticos e de radar, utilização de aprendizado de máquina profunda (*Deep Learning*), a partir de cubos temporais que consideram a variação temporal.

REFERÊNCIAS

- AUBLANC, J.; MOREAU, T.; THIBAUT, P.; BOY, F.; RÉMY, F.; PICOT, N. Evaluation of SAR altimetry over the Antarctic ice sheet from CryoSat-2 acquisitions. *Advances in Space Research*, v. 62, n. 6, p. 1307-1323, 2018. <https://doi.org/10.1016/j.asr.2018.06.043>
- BELGIU, M.; DRAGUT, L. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 114, p. 24-31, 2016. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>
- BITENCOURT, M. D. **Classificação espectral-temporal da cultura de grãos em imagens Sentinel (SAR) utilizando Machine Learning em Luís Eduardo Magalhães, Brasil.** (Dissertação de Mestrado), Curso de Pós-graduação em Geografia, Universidade de Brasília, 2020, 39f. <https://repositorio.unb.br/>
- BRASIL. Governo de Distrito Federal – GDF. **Zoneamento Ecológico-Econômico do Distrito Federal (ZEE/DF).** Brasília, 2018. <http://www.zee.df.gov.br/>
- BRASIL. Instituto Brasileiro de Geografia e Estatística – IBGE. **Resolução n01/2015 que trata da transformação entre os referenciais geodésicos no Brasil.** Rio de Janeiro, 2015. ftp://geoftp.ibge.gov.br/metodos_e_outros_documentos_de_referencia/normas/rpr_01_2015_sirgas2000.pdf
- BREIMAN, L. Random Forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001. <https://doi.org/10.1023/A:1010933404324>
- CAO, R.; TU, W.; YANG, C.; LI, Q.; LIU, J.; ZHU, J.; ZHANG, Q.; LI, Q.; QIU, G. Deep learning-based remote and social sensing data fusion for urban region function recognition. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 163, p. 82-97, 2020. <https://doi.org/10.1016/j.isprsjprs.2020.02.014>
- CHATURVEDI, S. K.; BANERJEE, S.; LELE, S. An assessment of oil spill detection using Sentinel 1 SAR-C images. *Journal of Ocean Engineering and Science*, in press, 2019. <https://doi.org/10.1016/j.joes.2019.09.004>
- CIAMPALINI, A.; SOLARI, L.; GIANNECCHINI, R.; GALANTI, Y.; MORETTI, S. Evaluation of subsidence induced by long-lasting building load using InSAR technique and geotechnical data: The case study of a Freight Terminal (Tuscany, Italy). *International Journal of Applied Earth Observation and Geoinformation*, v. 82, 2019. <https://doi.org/10.1016/j.jag.2019.101925>
- COSTA, D. H. **Uso de séries temporais Sentinel 1 na identificação de culturas agrícolas utilizando modelos de Machine Learning.** (Dissertação de Mestrado), Curso de Pós-graduação em Geografia, Universidade de Brasília, 2020, 51f. <https://repositorio.unb.br/>
- DE ZAN, F.; GUARNIERI, A. M. TOPSAR: Terrain Observation by Progressive Scans. *IEEE Transactions on Geoscience and Remote Sensing*, v. 44, n. 9, p. 2352-2360, 2006. <https://doi.org/10.1109/TGRS.2006.873853>
- DINIZ, J. M. F. S.; GAMA, F. F. Utilização da coerência interferométrica SAR para mapeamento do uso e cobertura da terra na região da Amazônia. In: Simpósio Brasileiro de Sensoriamento Remoto, 2019, Santos/SP. **Anais...** São José dos Campos: INPE, 2019. Disponível em: <https://proceedings.science/sbsr-2019/papers/utilizacao-da-coerencia-interferometrica-sar-para-mapeamento-do-uso-e-cobertura-da-terra-na-regiao-da-amazonia>
- FERREIRA, G. H. S. **Identificação de áreas inundáveis na porção sul de Roraima com auxílio de imagens de radar.** (Dissertação de Mestrado), Curso de Pós-graduação em Geografia, Universidade de Brasília, 2018, 75f. <https://repositorio.unb.br/handle/10482/33928>
- GRIFFITHS, P.; HOSTERT, P.; GRUEBNER, O.; LINDEN, V. Mapping megacity growth with multi-sensor data. *Remote Sensing of Environment*, v. 114, n. 2, p. 426-439, 2010. <https://doi.org/10.1016/j.rse.2009.09.012>
- HU, L.; DAI, K.; XING, C.; LI, Z.; TOMÁS, R.; CLARK, B.; SHI, X.; CHEN, M.; ZHANG, R.; QIU, Q.; LU, Y. Land subsidence in Beijing and its relationship with geological faults revealed by Sentinel 1 InSAR observations. *International Journal of Applied Earth Observation and Geoinformation*, v. 82, 2019. <https://doi.org/10.1016/j.jag.2019.05.019>
- KHALIL, R. Z.; HAQUE, S. InSAR coherence-based land cover classification of Okara, Pakistan. *The Egyptian Journal of Remote Sensing and Space Sciences*, v. 21, p. S23-S28, 2018. <https://doi.org/10.1016/j.ejrs.2017.08.005>
- LAWRENCE, R. L.; MORAN, C. J. The AmericaView Classification Methods Accuracy Project: A Rigorous Approach for Model Selection. *Remote Sensing of Environment*, v. 170, p. 115-120, 2015. <https://doi.org/10.1016/j.rse.2015.09.008>
- LI, M.; ZHANG, L.; DING, C.; LI, W.; LUO, H.; LIAO, M.; XU, Q. Retrieval of historical surface displacements of the Baige landslide from time-series SAR observations for retrospective analysis of the collapse event. *Remote Sensing of Environment*, v. 240, 2020.

- <https://doi.org/10.1016/j.rse.2020.111695>
 MARQUES, J. B.; CARVALHO JÚNIOR, O. A.; CAMPAGNOLI, F.; MESQUITA JÚNIOR, H. N.; GOMES, R. A. T.; GUIMARÃES, R. F. Classificação da cobertura da terra na região da ilha do Bananal usando imagens multitemporais PALSAR-2/ALOS-2. **Revista Franco-Brasileira de Geografia (Confins)**, v. 39, 2019. <https://doi.org/10.4000/confins.17506>
- MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: an applied review. **International Journal of Remote Sensing**, v. 39, n. 9, p. 2784-2817, 2018. <https://doi.org/10.1080/01431161.2018.1433343>
- MIGUEL, B. H.; SANO, E. E. Classificação do uso e cobertura da terra do Distrito Federal, Brasil a partir de dado de coerência interferométrica. **Revista Brasileira de Geografia Física**, v. 12, n. 2, p. 427-442, 2019. <https://doi.org/10.26848/rbgf.v12.2.p427-442>
- MOHAMMADIMANESH, F.; SALEHI, B.; MAHDIANPARI, M.; BRISCO, B.; MOTAGH, M. Multi-temporal, multi-frequency, and multipolarization coherence and SAR backscatter analysis of wetlands. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 142, p. 78-93, 2018. <https://doi.org/10.1016/j.isprsjprs.2018.05.009>
- OLESK, A.; PRAKS, J.; ANTROPOV, O.; ZALITE, K.; ARRUMAE, T.; VOORMANSIK, K. Interferometric SAR Coherence Models for Characterization of Hemiboreal Forests Using TanDEM-X Data. **Remote Sensing**, v. 8, n. 9, 2016. <https://doi.org/10.3390/rs8090700>
- OLIVEIRA, P. D. S. **Uso de aprendizagem de máquina e redes neurais convolucionais profundas para a classificação de áreas queimadas em imagens de alta resolução espacial**. (Dissertação de Mestrado), Curso de Pós-graduação em Geografia, Universidade de Brasília, 2019, 34p. <https://repositorio.unb.br>
- OZIGIS, M. S.; KADUK, J. D.; JARVIS, C. H.; BISPO, P. C.; BALZTER, H. Detection of oil pollution impacts on vegetation using multifrequency SAR, multispectral images with fuzzy forest and random forest methods. **Environmental Pollution**, v. 256, 2020. <https://doi.org/10.1016/j.envpol.2019.113360>
- PICHIERRI, M.; HAJNSEK, I.; ZWIEBACK, S.; RABUS, B. On the potential of Polarimetric SAR Interferometry to characterize the biomass, moisture and structure of agricultural crops at L-, C- and X-Bands. **Remote Sensing of Environment**, v. 204, p. 596-616, 2018. <https://doi.org/10.1016/j.rse.2017.09.039>
- PRINZIE, A.; VAN DEN POEL, D. Random Forests for multiclass classification: Random MultiNomial Logit. **Expert systems with Applications: An International Journal**, v. 34, n. 3, p. 1721-1732, 2008. <https://doi.org/10.1016/j.eswa.2007.01.029>
- RAJAH, P.; ODINDI, J.; MUTANGA, O. Feature level image fusion of optical imagery and Synthetic Aperture Radar (SAR) for invasive alien plant species detection and mapping. **Remote Sensing Applications: Society and Environment**, v. 10, p. 198-208, 2018. <https://doi.org/10.1016/j.rsase.2018.04.007>
- SALGADO, C. B. **Emprego de séries temporais na Amazônia: análise de imagens MODIS e RADAR para mapeamento de uso e ocupação do solo no Estado do Acre**. (Tese de Doutorado), Curso de Pós-graduação em Geografia, Universidade de Brasília, 2019, 113f. <https://repositorio.unb.br/handle/10482/35999>
- SALGADO, C. B.; CARVALHO JÚNIOR, O. A.; GOMES, R. A. T.; GUIMARÃES, R. F. Análise da interferência de nuvens na classificação de séries temporais MODIS-NDVI na região da Amazônia, município de Capixaba, Acre. **Sociedade & Natureza**, v. 31, p. 1-20, 2019. <https://doi.org/10.14393/SN-v31-2019-47062>
- SEKERTEKIN, A.; MARANGOZ, A. M.; ADBIKAN, S. ALOS-2 and Sentinel-1 SAR data sensitivity analysis to surface soil moisture over bare and vegetated agricultural fields. **Computers and Electronics in Agriculture**, v. 171, 2020. <https://doi.org/10.1016/j.compag.2020.105303>
- SICA, F.; PULELLA, A.; NANNINI, M.; PINHEIRO, M.; RIZZOLI, P. Repeat-pass SAR interferometry for land cover classification: A methodology using Sentinel-1 Short-Time-Series. **Remote Sensing of Environment**, v. 232, 2019. <https://doi.org/10.1016/j.rse.2019.111277>
- WEGMULLER, U.; SANTORO, M.; WERNER, C.; CARTUS, O. On the estimation and interpretation of Sentinel 1 TOPS InSAR coherence. In: **Proc. of FRINGE 2015 Workshop**, Frascati, Italia, 23-27 março, ESA, 2015. <http://proceedings.esa.int/files/89.pdf>
- WERNER, A.; STORIE, C. D.; STORIE, J. Evaluating SAR-Optical Image Fusions for Urban LULC Classification in Vancouver Canada. **Canadian Journal of Remote Sensing**, v. 40, n. 4, p. 278-290, 2014. <https://doi.org/10.1080/07038992.2014.976700>
- WHITCOMB, J.; MOGHADDAM, M.; MCDONALD, K.; KELLNDORFER, J.; PODEST, E. Mapping vegetated wetlands of Alaska using L-band radar satellite imagery. **Canadian Journal of Remote Sensing**, v. 35, n. 1, p. 54-72, 2009. <https://doi.org/10.5589/m08-080>
- ZHANG, H.; LI, J.; WANG, T.; LIN, H.; ZHENG, Z.; LI, Y.; LU, Y. A manifold learning approach to urban land cover classification with optical and radar data. **Landscape and Urban Planning**, v. 172, p. 11-24, 2018. <https://doi.org/10.1016/j.landurbplan.2017.12.009>
- ZHU, Z.; ZHOU, Y.; SETO, K. C.; STOKES, E. C.; DENG, C.; PICKETT, S. T. A.; TAUBENBOCK, H. Understanding an urbanizing planet: Strategic directions for remote sensing. **Remote Sensing of Environment**, v. 228, p. 164-182, 2019. <https://doi.org/10.1016/j.rse.2019.04.020>

3. POTENCIALIDADES E LIMITAÇÕES DO USO DE INFORMAÇÕES ALTIMÉTRICAS PROVENIENTES DE PERFILAMENTO À LASER EM AMBIENTE URBANO

Felipe Lima Ramos Barbosa

Universidade de Brasília, Departamento de Geografia, Brasília-DF, Brasil
felipelrb@gmail.com

Renato Fontes Guimarães

Universidade de Brasília, Departamento de Geografia, Brasília-DF, Brasil
renatofg@unb.br

Osmar Abílio de Carvalho Júnior

Universidade de Brasília, Departamento de Geografia, Brasília-DF, Brasil
osmarjr@unb.br

Roberto Arnaldo Trancoso Gomes

Universidade de Brasília, Departamento de Geografia, Brasília-DF, Brasil
robertogomes@unb.br

Erondina Azevedo de Lima

Universidade de Brasília, Instituto de Física, Brasília-DF, Brasil
erondinaazevedo@unb.br

RESUMO

A concentração da população brasileira residindo em ambientes urbanos demandam uma gestão eficiente do território e dos efeitos provenientes do escoamento hídrico, tais como erosão, inundações e movimento de massa. O presente trabalho tem como objetivo adequar para áreas urbanas a delimitação de Áreas de Sensibilidade Hidrológicas (ASH), utilizando o Índice Topográfico de Umidade (ITU). A área de estudo é a Região Administrativa de São Sebastião do Distrito Federal que apresenta expansão urbana recente e problemas de drenagem urbana. A pesquisa discute as potencialidades e limitações quanto à utilização de dados altimétricos provenientes de laser na derivação de Modelos Digitais de Elevação (MDE) e na estimativa do escoamento superficial. A aplicação do índice HSA em áreas urbanas necessita de metodologias específicas: redução da nuvem de pontos amostrais pela seleção de fatores relevantes para o fluxo da água, filtragem de artefatos, manutenção das feições urbanas que condicionam o direcionamento hídrico, eliminação da cobertura vegetal, dentre outros. Os resultados obtidos mostram o potencial de estabelecer áreas sensíveis dentro da rede urbana com alta precisão, considerando as influências da topografia local. Portanto, a pesquisa inova ao apresentar uma solução metodológica de estimativa de HSA para o ambiente urbano na escala local.

Palavras-chave: Modelo Digital de Elevação (MDE). LIDAR. Índice Topográfico de Umidade (ITU). Área Urbana.

CAPABILITIES AND LIMITATIONS OF LASER SCANNING SYSTEM ALTIMETRICS INFORMATIONS APPLIED IN AN URBAN SETTLEMENT

ABSTRACT

The concentration of the Brazilian population living in urban environments requires efficiently manage the territory and the effects of water runoff, such as erosion, floods, and mass movement. This work aims to adapt the delimitation of Hydrological Sensitivity Areas (HSA) to urban areas, using the Topographic Wetness Index (TWI). The study area is the Administrative Region of São Sebastião, in the Federal District, which presents recent problems of urban expansion and urban drainage. The research discusses the potentials and limitations in the use of altimetric data from the laser profile in the derivation of Digital Elevation Models (DEM) and the estimation of surface runoff. The application of the HSA index in urban areas requires specific methodologies: reduction of the sample point cloud by the selection of relevant factors for the flow of water, filtering of artifacts, maintenance of urban features that condition the direction of the water, elimination of vegetation cover, among others. The results obtained show the potential to establish sensitive areas within the urban network with high precision considering the influences of the local topography.

Therefore, the research innovates by presenting a methodological solution to estimate HSA for the urban environment at a local scale.

Keywords: Digital Elevation Model (DEM). LIDAR. Topographic Wetness Index (TWI). Urban areas.

3.1. INTRODUÇÃO

Apresentemente, o Brasil possui satisfatórios valores de disponibilidade hídrica per capita, em comparação com outros países, tais como os europeus e os do Oriente Médio. No entanto, em média cerca de 260.000 m³/s de água não é distribuída homoganeamente no território, dos quais 205.000 m³/s concentram-se na bacia hidrográfica do rio Amazonas e 55.000 m³/s nas demais áreas do território nacional (ANA, 2016). Essa distribuição heterogênea dos recursos hídricos brasileiros demonstra a necessidade de uma gestão sustentável.

Ressalta-se que, dos estimados 191 milhões de pessoas que residem no Brasil, cerca de 161 milhões (84,36% da população) vivem no ambiente urbano (IBGE, 2010). Em 2050, projeções apontam um aumento para mais de 90% (ONU, 2018). Assim, é de suma importância considerar a dinâmica e o impacto da morfologia urbana no escoamento superficial, enchentes, erosões e movimentos de massa. Os modelos de dinâmica de relevo e de escoamento superficial da água são soluções estratégicas para a política pública preventiva (GUIMARÃES et al., 2003, 2017; CARVALHO JÚNIOR et al., 2010; FREITAS et al., 2012).

Grande parte das informações para inferências de modelos espaciais são provenientes da topografia. Diferentes técnicas e dados podem auxiliar na construção de representações digitais da elevação topográfica, conhecidos como Modelos Digitais de Elevação (MDE). A exemplo, podem ser citados os produtos provenientes do *Shuttle Radar Thematic Mapper* (SRTM), os métodos de interpolação de dados altimétricos amostrais provenientes do mapeamento cartográfico nacional, dentre outros.

Uma emergente técnica de levantamento topográfico é o sistema LIDAR (*Light Detection and Ranging*) que permite uma coleta rápida, precisa e densa de grandes volumes de dados georreferenciados na forma de nuvem de pontos tridimensionais. O sistema LIDAR permite diversas aplicações territoriais, tais como estudos dos aspectos biofísicos das árvores (IAF – índice de área foliar), planejamento urbano e levantamento topográfico de informações do terreno. O alto grau de confiabilidade e rapidez torna essa técnica aplicável em terrenos inóspitos (MCGLONE, 2004).

O presente trabalho tem como objetivo adaptar para utilização em áreas urbanas a delimitação de Áreas de Sensibilidade Hidrológica (ASH) (WALTER et al., 2000) a partir do Índice Topográfico de Umidade (ITU). Para tanto, serão utilizados os dados altimétricos de perfilamento à laser (LIDAR) para a derivação de MDEs e a subsequente estimativa do escoamento superficial em áreas de expansão urbana recente no Distrito Federal. As informações são provenientes do aerolevanteamento realizado pela Companhia Imobiliária de Brasília (Terracap) em uma porção da Região Administrativa de São Sebastião.

3.2. LEVANTAMENTO TOPOGRÁFICO POR PERFILAMENTO À LASER

Os sistemas LIDAR utilizados em mapeamentos topográficos são caracterizados como sistemas ativos de aquisição de dados levantamento ativo e utilizam o comportamento de retorno da luz laser na faixa do infravermelho próximo (1.040 nm a 1.600 nm) para obtenção da altimetria, a partir de técnica de varredura ótico-mecânica a bordo de plataformas aerotransportadas ou orbitais (JENSEN, 2011).

As informações altimétricas coletadas são obtidas a partir do intervalo de tempo (t) registrado entre a emissão do pulso laser, sua interação com o alvo e o registro do sinal de retorno, definido pela seguinte Equação (1) (MCGLONE, 2004).

$$t = 2 \frac{R}{c} \quad (1)$$

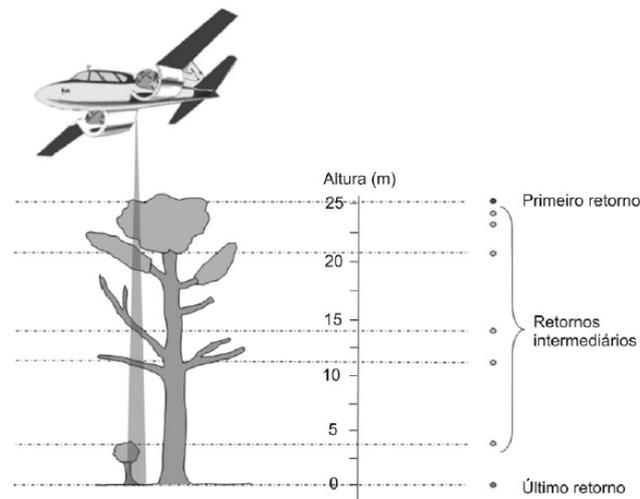
Onde R corresponde a distância entre o sensor LIDAR e o alvo, enquanto que, c é a velocidade da luz. Tendo em perspectiva a distância percorrida pelo pulso em sistemas aerotransportados ou orbitais, a luz laser sofre divergência em formato cônico, o que define a área de cobertura do pulso no terreno em formato circular, variando sua forma a depender do ângulo de varredura e da topografia

local. O diâmetro da visada instantânea laser (F_p) no terreno é calculada pela Equação (2) (BALTSAVIAS, 1999).

$$F_p = \frac{h}{\cos^2(\theta)} \gamma \quad (2)$$

Onde h equivale a altitude da plataforma em relação ao solo, θ ao ângulo de varredura instantâneo e γ a divergência do feixe laser. Outro importante fator é a Frequência de Repetição de Pulso (FRP), que pode apresentar valores superiores a 100.000 pulsos por segundo, o que torna possível o registro de um massivo quantitativo de informações altimétricas. Em sistemas aerotransportados, o levantamento das informações é realizado seguindo uma geometria perpendicular à linha de voo. A Figura 3.1 esquematiza o padrão de retornos esperados no levantamento.

Figura 3.1 – Representação do sinal de retorno em diferentes contextos de alvos.



Fonte: Giongo et al., (2010)

Um dos métodos de perfilamento à laser comumente utilizado em aplicações topográficas consiste no aerolevanteamento de um conjunto de pontos com dados de elevação, normalmente denominados de nuvem de pontos, distribuídos sistematicamente no tempo, ao longo da linha de voo (HODGSON et al., 2005; SHAN e TOTH, 2018). A disposição funcional do sistema LIDAR não permite ao usuário o controle da localização individual das medidas tridimensionais (x , y , z) obtidas no levantamento. Apesar de, por outro lado, realizar a amostragem de localidades que seriam impossíveis de visitação utilizando-se das técnicas convencionais (linhas de crista, vegetação densa, dentre outros).

O espaçamento de pontos perpendiculares à trajetória (P_s) é o parâmetro que define o grau de densidade da nuvem de pontos altimétricos, e depende diretamente da frequência de repetição de pulso, da altitude da plataforma, da velocidade de varredura angular instantânea e do ângulo de varredura instantâneo, conforme a Equação (3) a seguir.

$$P_s = \frac{h}{\cos^2(\theta)} \times \frac{\alpha}{PRF} \quad (3)$$

Onde h equivale a altitude da plataforma em relação ao solo, θ ao ângulo de varredura instantâneo, α a velocidade de varredura angular instantânea, em radianos por segundo, e PRF a frequência de repetição de pulso. A densidade de amostragem para uma área depende, também, da velocidade da plataforma. Assim, o massivo conjunto amostral resultante do perfilamento à laser apresenta múltiplos retornos de determinadas situações (Figura 3.2). Isso permite capturar e estratificar com maior acurácia os alvos sobre a superfície da terra. Essa técnica permite um melhor controle procedimental na elaboração dos MDE e uma melhor adaptabilidade à diferentes aplicações técnicas e científicas (JENSEN, 2011).

3.3. MODELO DIGITAL DE ELEVAÇÃO E CONSISTÊNCIA HIDROLÓGICA

Na modelagem hidrológica, deve-se estabelecer etapas de consistência do MDE, tais como o preenchimento de depressões espúrias. Esse processamento visa garantir a conectividade do escoamento superficial no MDE a fim de assegurar a derivação de informações correlatas à direção preferencial, à acumulação de fluxo, a estimativa de área de contribuição, dentre outras. As depressões espúrias são comumente resultado da etapa de interpolação dos dados amostrais altimétricos durante a geração do MDE e, assim, sua eliminação visa garantir a máxima coincidência entre o trajeto de escoamento superficial da água no modelo, obtido de forma analítica, com a realidade em questão (HUTCHINSON, 1996).

Uma das propostas existentes na literatura, e bastante difundida, é a representação do caminho preferencial de escoamento superficial da água sobre o MDE, identificando o caminho descendente deste fluxo em cada célula do modelo. Exemplos de trabalhos que exploram esta abordagem são descritos pelos autores Quinn et al. (1991); Lea (1992); Costa-Cabral e Burges (1994), entre outros.

Diversas extensões de programas hoje existentes no mercado, tais como o *ArcHydro* (ESRI, 2020) e o *TauDEM* (TARBOTON, 2015), soluções livres que possuem uma coletânea de algoritmos, processados em *workflow*, visando tal consistência hidrológica do MDE, contendo procedimentos de preenchimento de depressões espúrias, estimativas de fluxos direcionais e acumulados, imposição de drenagem, dentre outros.

3.4. ÍNDICE TOPOGRÁFICO DE UMIDADE E ÁREAS DE SENSIBILIDADE HIDROLÓGICA

O ITU proposto por Beven e Kirkby (1979) permite uma rápida inferência de áreas com probabilidade de saturação e posterior ocorrência de escoamento superficial, sendo expresso pela Equação (4).

$$ITU = \ln \left(\frac{\alpha}{\tan \beta} \right) \quad (4)$$

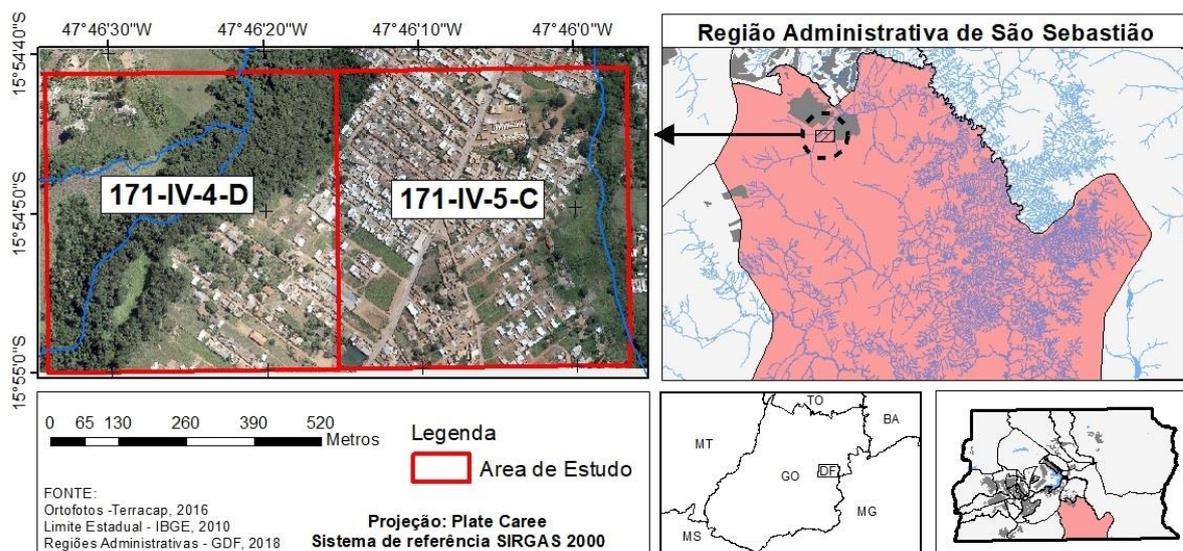
Onde α representa a área de contribuição a montante e β a declividade local. O ITU possibilita quantificar e qualificar o controle da topografia local quanto aos processos hidrológicos, bem como ressaltar as áreas com maior propensão ao escoamento superficial, contendo altos valores de área de contribuição e baixas declividades (LOTTE, ALMEIDA e VALERIANO, 2015). Ademais, esse índice possibilita a delimitação das ASH, contendo maiores susceptibilidades à saturação e geração de escoamento superficial (GRABS et al., 2009; THOMAS et al., 2017). O índice ITU por ser sensível à resolução do MDE evidencia as potencialidades e limitações dos sistemas LIDAR em aplicações topográficas (KIENZLE, 2004; THOMAS et al., 2017).

3.5. MATERIAIS E MÉTODOS

3.5.1. Área de estudo

A área de estudo compreende as articulações 171-IV-4-D e 171-IV-5-C do Mapeamento das Áreas Urbanas e Urbanizáveis do Distrito Federal na escala de 1:1.000, a partir de Levantamento Aerofotogramétrico de uma área aproximada de 1.201,15 km², realizado em 2016 pela Companhia Imobiliária de Brasília - Terracap (TERRACAP, 2016). A área está localizada na Região Administrativa de São Sebastião (RA XIV), especificamente na região conhecida como "Morro da Cruz", entre as coordenadas geográficas 15° 54' 41"S a 15° 55' 0"S em latitude e 47° 45' 56"O a 47° 46' 34"O (Figura 3.2).

Figura 3.2 – Localização da área de estudo no Distrito Federal e na Região Administrativa de São Sebastião.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

O mapeamento da Terracap de 2016 foi sistematizado em 3.729 folhas na escala 1:1.000, referenciadas ao SICAD-SIRGAS. O perfilamento à laser desse aerolevante possui densidade média de 4 pontos/m², cujo produto são nuvens de pontos de terreno (solo) e de superfície (feições localizadas acima do solo), ambas estratificadas em classes temáticas, bem como em número de retornos. Considerando as limitações de *hardware*, as inferências espaciais foram realizadas considerando as informações das articulações 171-IV-4-D e 171-IV-5-C, presentes na denominada “área 2” do referido projeto de levantamento.

Nos anos recentes, a irregular transformação de rural para urbana acarretou diversos impactos ambientais e sociais conforme o Zoneamento Ecológico-Econômico (ZEE) do Distrito Federal (GDF, 2018). Assim, a área de estudo foi escolhida como exemplo desse processo de rápida e desordenada transformação territorial e, principalmente, por se caracterizar como área de alta recorrência de inundações, conforme frequentemente noticiado pelos principais veículos de comunicação do Distrito Federal.

3.5.2. Elaboração do MDE e consistência hidrológica

Para a elaboração do MDE, as informações utilizadas foram: (i) dados de terreno e (ii) dados de superfície classificados como edifícios, ambos produtos derivados no mapeamento das áreas urbanas e urbanizáveis realizado em 2016 pela Terracap (TERRACAP, 2016). A intenção de considerar tais informações foi de garantir a representação das alterações antrópicas no ambiente natural, com influência sobre o escoamento superficial da água.

O trabalho executado no ano de 2016 pela Terracap foi responsável pelo processo de classificação da nuvem de pontos e sua respectiva classificação temática. O processo de filtragem das informações em diferentes elementos temáticos (solo, vegetação, edificações, linhas de transmissão, dentre outros) foi realizado de forma automatizada e contando com a etapa de avaliação assistida dos resultados por parte dos técnicos envolvidos, garantindo a devida qualidade altimétrica das informações de terreno (TERRACAP, 2016). Assim, o presente estudo apenas utilizou os citados pontos altimétricos como dados de entrada para a estimativa do MDE.

No processo de interpolação, existem basicamente dois tipos de métodos, os determinísticos e os probabilísticos. Os primeiros partem de valores pré-definidos e parametrizações que são estimadas tendo por base as informações locais da amostra e, por sua vez, os probabilísticos consideram o comportamento estatístico das amostras como um todo para a parametrização do interpolador.

A interpolação dos dados utilizou o método do Inverso da Distância Ponderada (IDW), escolhido devido sua simplicidade e popularidade, sendo caracterizado como um método de interpolação determinístico que considera a influência de amostras vizinhas imediatas para a estimativa da altimetria, considerando formulações matemáticas (POLAT, UYSAL e TOPRAK, 2015). A Figura 3.3

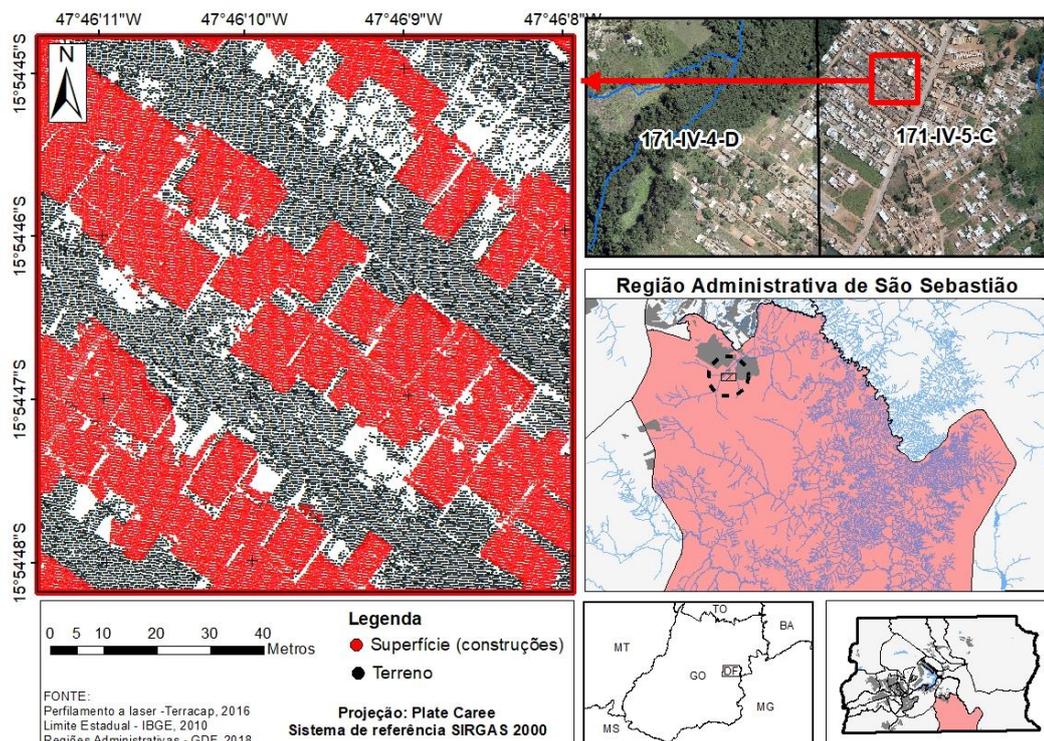
mostra a área de estudo com parte da nuvem de pontos amostrais utilizados no processo de interpolação.

Segundo Lloyd e Atkinson (2002), os métodos de interpolação probabilísticos tendem a apresentar maior acurácia em áreas com menor densidade de pontos amostrais, mas concluíram que nenhum benefício é alcançado utilizando-se métodos sofisticados de interpolação em áreas com densa nuvem amostral proveniente do perfilamento à laser. Outros estudos nesse sentido podem ser consultados na literatura científica dentre os quais Yanalak (2003), Abramov e Mcewan (2004) e Bater e Coops (2009).

Considerando as particularidades das informações provenientes de sistemas LIDAR de aplicação topográfica, não existe uma definição ideal para a resolução espacial de um MDE, mas sim, um conjunto de soluções adequadas que devem ser utilizadas nessa estimativa, relacionadas à (i) conceitos cartográficos e estatísticos; (ii) poder de processamento do hardware; (iii) acurácia posicional; (iv) avaliação da densidade de pontos amostrais; (v) estrutura de autocorrelação espacial; e (vi) complexidade do terreno (JENSEN, 2011). Segundo Hengl (2006), a resolução espacial do modelo para esses casos deve ser, no máximo, a metade do espaçamento médio dos pares de amostras mais próximas. Neste sentido, adotou-se o valor de 0,2 metros como resolução espacial do modelo, uma vez que os dados altimétrico provenientes do LIDAR possuem uma densidade média de 4 pontos/m².

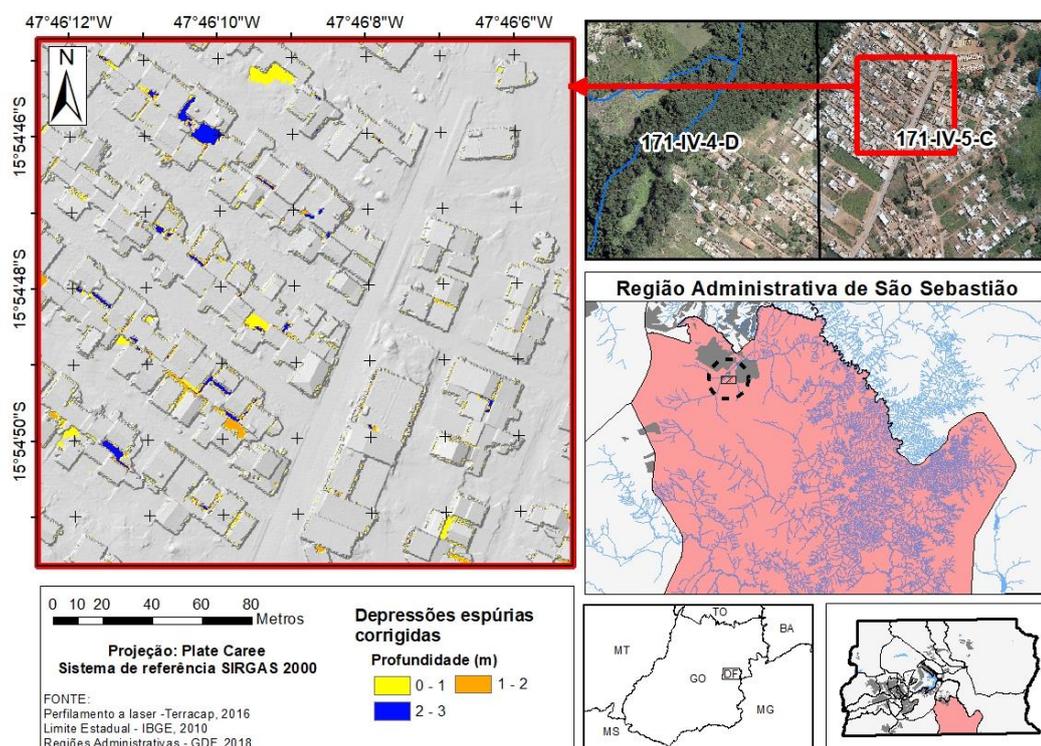
Após a elaboração do MDE, realizou-se o preenchimento das depressões espúrias visando garantir a devida conectividade da superfície do modelo. A Figura 3.4 apresenta o MDE elaborado e corrigido, bem como as localidades que sofreram a respectiva correção.

Figura 3.3 – Nuvem de pontos amostrais utilizadas para a geração do MDE.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

Figura 3.4 – Modelo Digital de Elevação (MDE) elaborado e corrigido e a localidade das depressões espúrias preenchidas.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

3.5.3. Aplicação do índice ITU e delimitação das ASH

Os atributos de terreno utilizados para o cálculo do ITU são: (i) a área de contribuição à montante; e (ii) a declividade local. A área de contribuição à montante foi obtida pelo método de estimativa de fluxo direcional (TARBOTON, 1997). Esse método utiliza um sistema proporcional que pondera o fluxo segundo o ângulo estabelecido entre o escoamento identificado e o caminho preferencial mais próximo a esse, simulando, assim, certa dispersão na modelagem. Uma vez estimado o fluxo direcional, calcula-se para cada pixel o somatório das áreas das células a montante que drenam diretamente para ele (WALLIS et al., 2009). O índice ITU foi processado no *software* Whitebox GAT (LINDSAY, 2016).

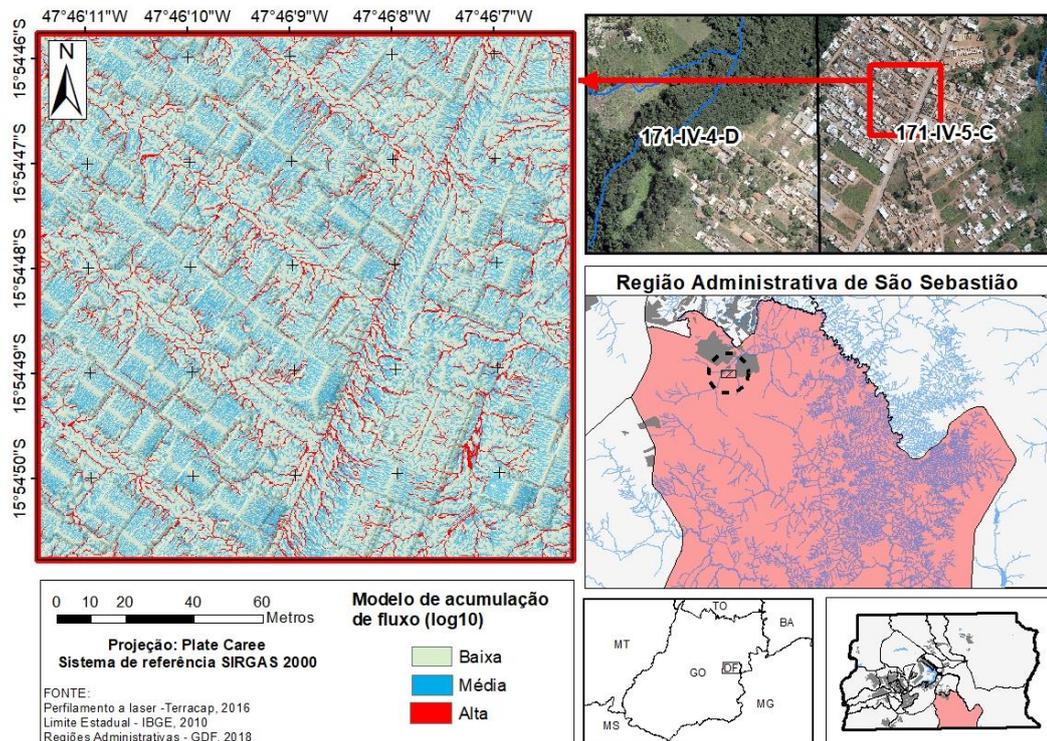
Para a estimativa das HSA adotou-se solução concebida por Thomas et al. (2017), que divide os valores do índice ITU em 100 classes de igual área e, subsequentemente, representa apenas os 15% das regiões de maior propensão ao escoamento superficial do modelo. Portanto, o mapa ASH foi estratificado em três classes de porcentagens de área (5%, 10% e 15%), valores escolhidos de forma aleatória, uma vez que o uso de múltiplos limiares reduz o erro de estimativa dos tamanhos das ASH (THOMAS et al., 2017). Assim, as ASH no presente estudo indicam o agregado dos 15% superiores da área de propensão ao escoamento superficial, considerando seus aspectos topográficos.

3.6. RESULTADOS E DISCUSSÕES

3.6.1. Atributos de terreno

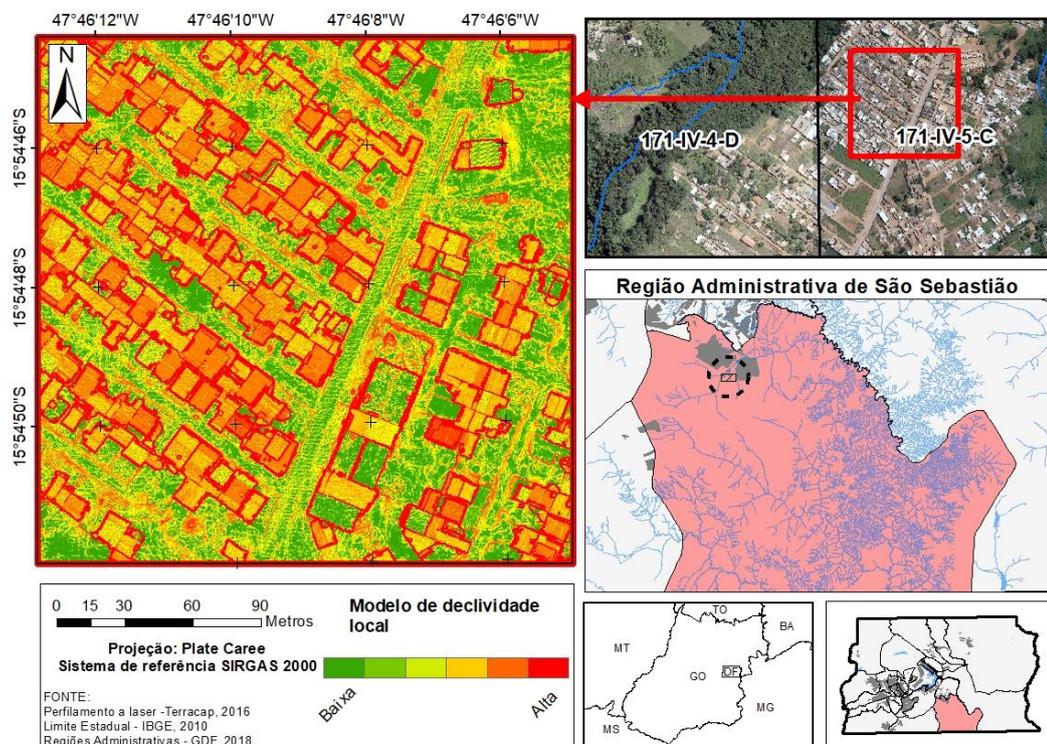
A Figura 3.5 mostra o MDE corrigido e a respectiva área de contribuição à montante, no caso apresentada em função logarítmica para melhor visualização dos resultados. A declividade local da área de estudo foi calculada em graus (Figura 3.6).

Figura 3.5 – Apresenta o modelo de fluxo acumulado estimado para a área de estudo.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

Figura 3.6 – Declividade local, estimada em graus, da área de estudo.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

A Figura 3.7 mostra o histograma de frequências dos valores da área de contribuição em metros quadrados, representado na função \log_{10} , e a Tabela 3.1 apresenta os respectivos valores de média (79,99 m²), mediana (0,15 m²) e desvio padrão - σ (2.339,92 m²) da distribuição. Os resultados indicam um comportamento assimétrico com acúmulo nos baixos valores da distribuição, o que pode

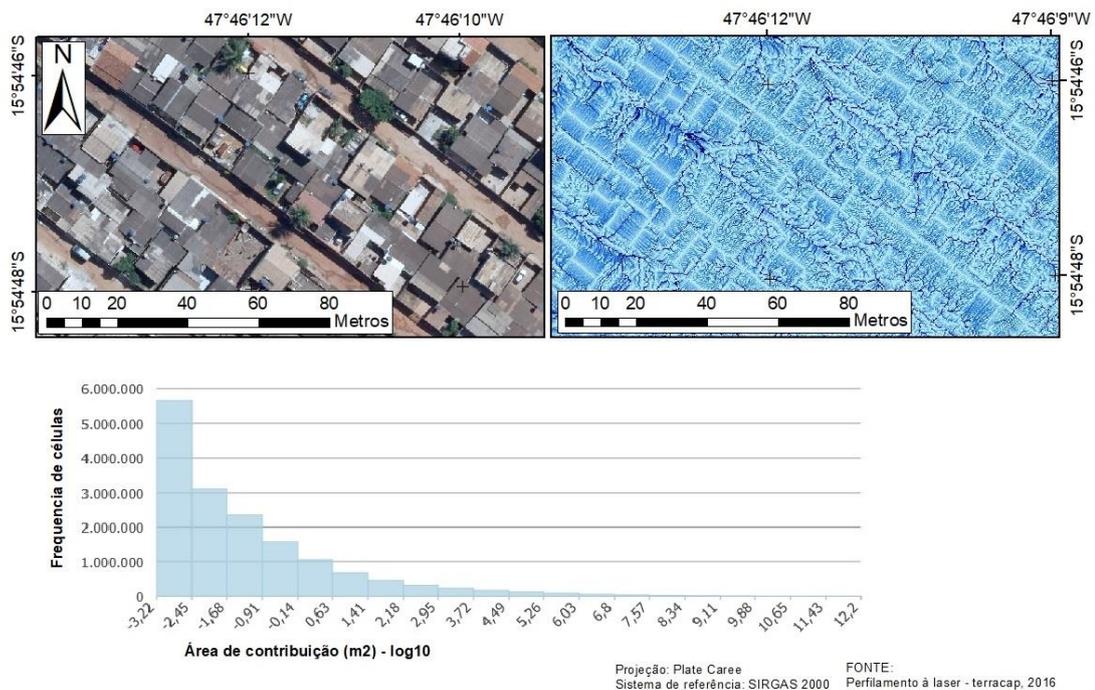
ser constatado, principalmente, pelo valor encontrado de 0,15 m² referente a mediana da distribuição, medida estatística que minimiza o efeito dos *outliers* na análise. Assumindo a distribuição normal dos dados, a um nível de confiança de 99,73%, o limiar é de 7.019,76 m² (3σ), valor relativamente baixo de área de contribuição considerando a totalidade da área de estudo (Tabela 3.1). Os resultados ressaltam a influência da topografia local no comportamento superficial do escoamento de água devido a presença de objetos urbanos que funcionam como divisores d'água artificiais, ou mesmo como obstáculos, assim, reduzindo os valores de área de contribuição e afetando diretamente o índice ITU. Essas constatações também foram exploradas por outros estudos que analisaram os efeitos do uso de LIDAR DEM em aplicações hidrológicas (GILLIN et al., 2015; SORENSEN e SEIBERT, 2007; VAZE, TENG e SPENCER, 2010; THOMAS et al., 2017).

Tabela 3.1 – Valores de média, mediana e desvio padrão da área de contribuição.

Estadística descritiva	Valores (m ²)
Média	79,99
Mediana	0,15
Desvio padrão	2.339,92

Fonte: Org. Autores

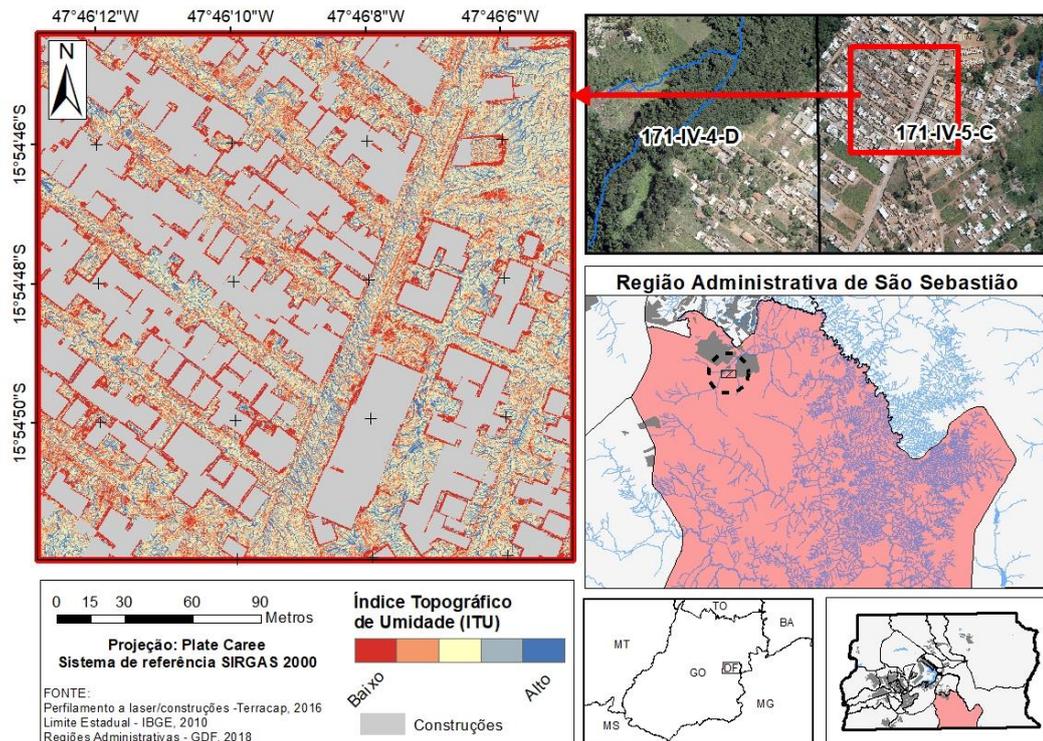
Figura 3.7 – Apresenta porção da área de estudo, a estimativa de área de contribuição e sua distribuição de frequência.



Fonte: Terracap, 2016; Org. Autores

A Figura 3.8 apresenta o índice ITU para a área de estudo, cujos resultados indicam uma baixa concentração de valores próximos às construções e objetos antrópicos no terreno, com concentração do fluxo em pontos específicos da área urbana, caracterizados por depressões e/ou barramentos artificiais que foram criados devido à alteração antrópica do ambiente, pontos estratégicos que merece atenção dos tomadores de decisão.

Figura 3.8 – Índice ITU estimado para a área de estudo.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

3.6.2. Distribuição espacial das Áreas de Sensibilidade Hidrológica

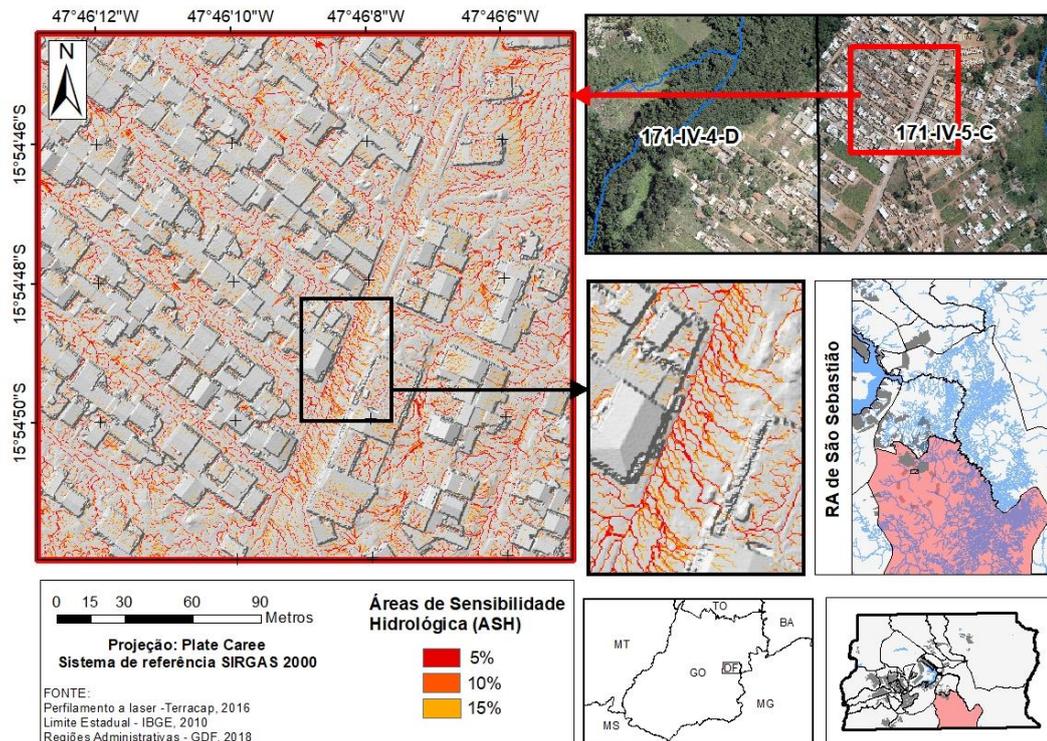
A estimativa das ASH é uma importante informação que auxilia o processo de planejamento e gestão do espaço urbano, que vêm, recentemente, passando por um processo de ocupação acelerado e não planejado. A Tabela 3.2 apresenta as áreas de cada uma das classes de ASH em relação à área total do estudo. A Figura 3.9 mostra a área de estudo com as respectivas classes de ASH estimadas.

Tabela 3.2 – Valores de área das classes de ASH em relação à área total do estudo

Porcentagem	Área (m ²)
5%	32.187,50
10%	64.375,00
15%	96.562,50
Total de área de estudo	643.750.00

Fonte: Org. Autores

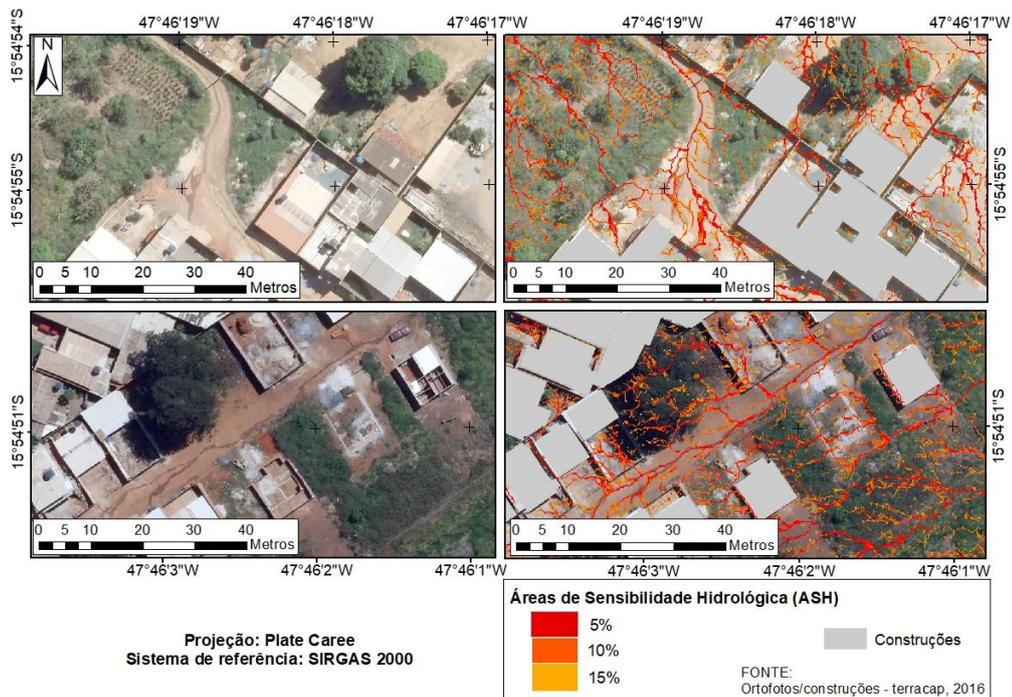
Figura 3.9 – ASH estimadas na área de estudo.



Fonte: Terracap, 2016; IBGE, 2010; GDF, 2018; Org. Autores

A Figura 3.10 apresenta uma porção da área de estudo com a ortofoto e as respectivas ASH estimadas, onde observa-se uma coerência entre a inferência das ASH e o escoamento superficial. A malha urbana local influencia no direcionamento do escoamento superficial da água mesmo com arruamentos não pavimentados, potencializando os impactos ambientais e sociais na região, tais como assoreamentos, erosões e inundações.

Figura 3.10 – Porção da área de estudo representada com sua ortofoto e as respectivas ASH inferidas.



Fonte: Terracap, 2016; Org. Autores

A Tabela 3.3 apresenta as estatísticas das ASH considerando os valores de declividade, área de contribuição e ITU. De forma geral, observam-se baixos valores de declividade, cujas médias variam de 3,02 a 3,51 graus, com σ entre 3,86 a 4,7, o que indicam áreas relativamente planas em locais com maior propensão ao escoamento superficial. O agrupamento assimétrico dos resultados junto a elevada amplitude máxima (74 – 83 graus) indicam poucas áreas com elevada declividade, essas associadas a muros e casas que apresentam elevada variação altimétrica em um MDE de alta resolução espacial. Os resultados referentes as áreas de contribuição das ASH também indicam a alta influência da topografia local. As diferenças encontradas entre os valores de média (1.638,1 – 576,5 m²) e mediana (86,5 – 8,1 m²) ressaltam uma distribuição assimétrica dos resultados e indicam uma alta frequência de baixos valores, com presença de *outliers* elevados (σ – 10.558,3 a 6.280,7 m²). Ademais, os valores estatísticos são decrescentes entre as classes de ASH, o que indica o aumento da influência de obstáculos naturais ou artificiais na estimativa dos caminhos de fluxo superficial, tendência também observada na Tabela 3.1. As distribuições dos valores de ITU se mostraram simétricos, com valores aproximados de média e mediana e baixos valores de σ . Esses resultados ressaltam a escolha quanto a definição das ASH sobre o ITU, que considerou valores limiaries entre classes tendo por base iguais áreas. Segundo Thomas et al., (2017), os mapas de ITU derivados de MDE LIDAR predominantemente capturam a influência das feições de microtopografia na modelagem hidrológica.

Tabela 3.3 – Valores estatísticos das ASH.

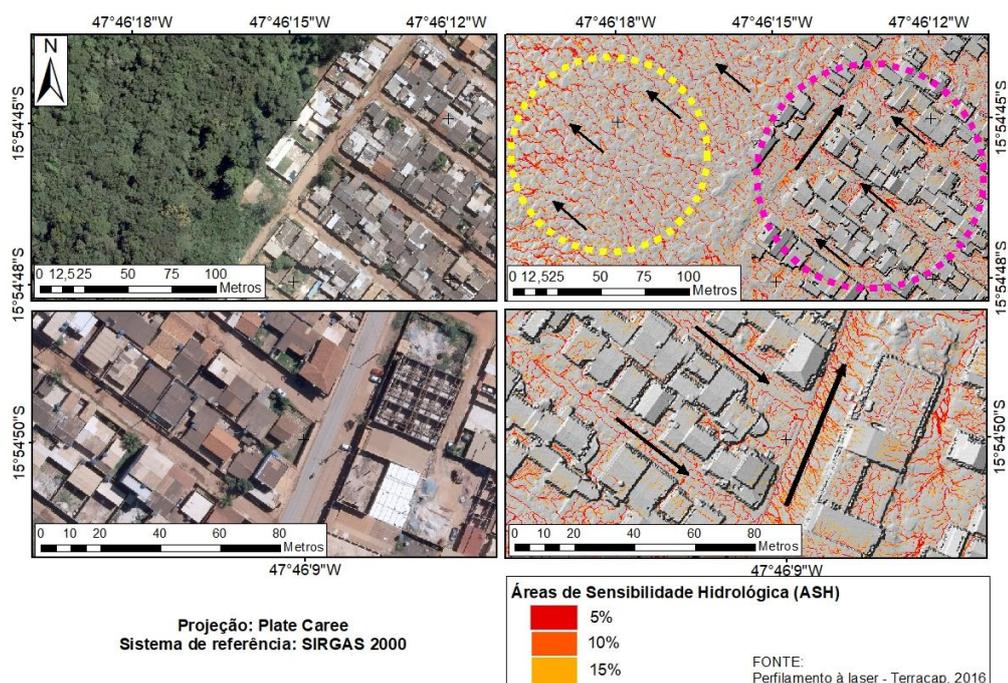
ASH	Declividade (graus)					Área de contribuição (m ²)					Índice Topográfico de Umidade				
	M	Med	DP	i	I	M	Med	DP	i	I	M	Med	DP	i	I
5%	3,0	1,9	3,8	0	74	1.638,1	86,5	10.558,3	0	198.020	9,7	9,3	1,8	7,5	20,6
10%	3,3	2,1	4,3	0	82	848,3	20,4	7.612,2	0	198.020	8,3	7,7	2	5,8	20,6
15%	3,5	2,2	4,7	0	83	576,5	8,1	6.280,7	0	198.020	7,4	6,8	2,1	4,9	20,6

M – Média/ Med – Mediana/ DP – Desvio padrão/ i – Mínimo/ I – Máximo

Fonte: Org. Autores

A Figura 3.11 evidencia a influência da malha urbana sobre o escoamento superficial da água e das ASH em diferentes contextos, destacados por círculos na cor roxo, tendo em vista a elevada variação altimétrica introduzida pela existência de artefatos artificiais (muros, telhados, barreiras, entre outros). São destacadas, ainda, por círculos amarelos as áreas de comportamento natural. Apesar das potencialidades inerentes ao uso de dados altimétricos provenientes de perfilamento à laser (Figura 3.10), algumas limitações necessitam ser ressaltadas.

Figura 3.11 – Porção da área de estudo com influência da malha de arruamentos sobre as ASH.

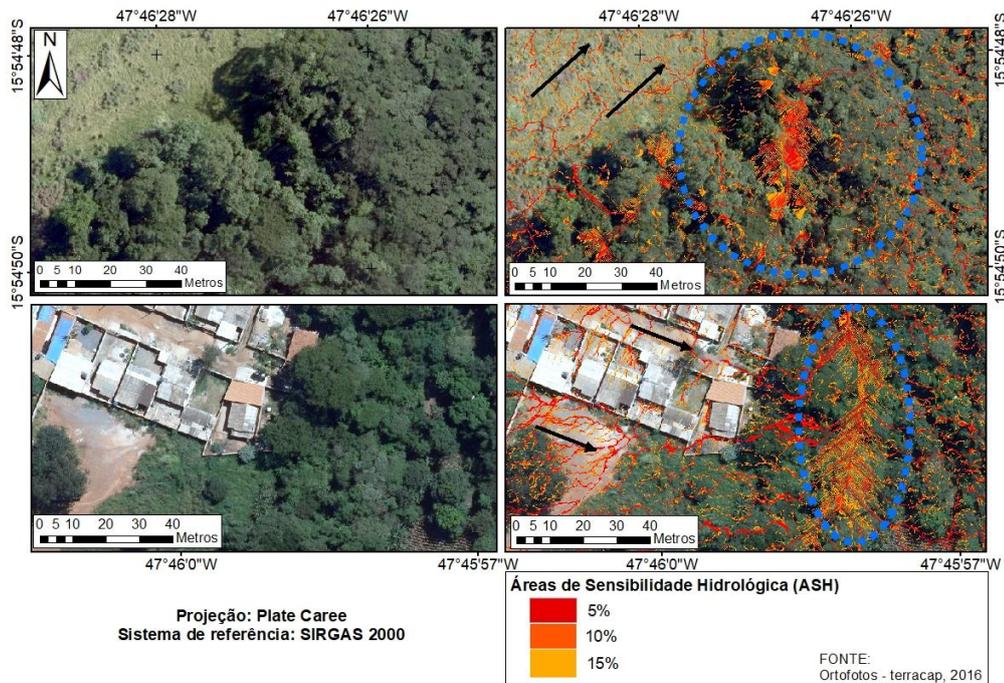


Fonte: Terracap, 2016; Org. Autores

3.6.3. A interferência da cobertura vegetal

A depender da estrutura do dossel e de seus subdosséis, o feixe de laser não consegue registrar com exatidão informações de terreno, o que prejudica as inferências que podem ser extraídas desses produtos. A Figura 3.12 apresenta áreas que sofreram ajuste altimétrico durante o processo de modelagem, o que influencia diretamente o comportamento do escoamento superficial, indicadas por círculos na cor azul.

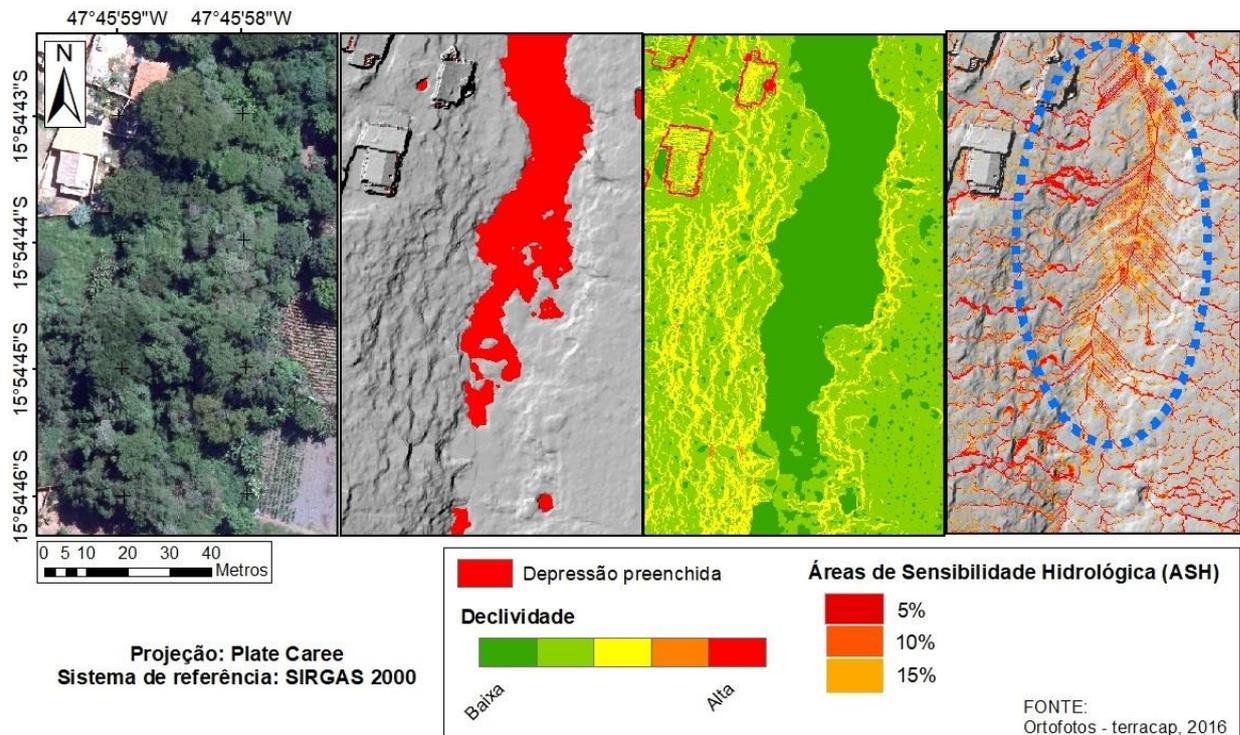
Figura 3.12 – Exemplos de inconsistência introduzida na modelagem devido à densidade da cobertura vegetal.



Fonte: Terracap, 2016; Org. Autores

Percebe-se que as áreas que apresentaram maior alteração altimétrica devido o preenchimento de depressões espúrias resultaram na diminuição dos valores de declividade, fato que influenciou diretamente a definição das ASH. A Figura 3.13 apresenta um exemplo dessa relação e seu efeito no mapeamento das ASH.

Figura 3.13 – Exemplo da relação entre declividade, depressão espúria preenchida e ASH em área de vegetação.



Fonte: Terracap, 2016; Org. Autores

O preenchimento das depressões espúrias ocorreu no processo de modelagem uma vez que a variação das diferentes coberturas de vegetação tem impacto direto na densidade de pontos inferidos como respostas de terreno provenientes dos feixes ópticos emitidos pelo sistema LIDAR. Coberturas de vegetação entre 80 a 90% da área amostrada podem resultar em apenas 10% de respostas de terreno, sendo que neste montante, ainda pode-se identificar “falsos positivos” (COWEN et al., 2000). Segundo Hutson (2015), o tipo de dossel da vegetação parece provocar maior limitação do que sua altura. Mesmo em locais onde se observa uma densa e alta vegetação, pode-se ter bons retornos de solo quando não existem dosséis intermediários entre a vegetação e o terreno. Por outro lado, coberturas de vegetação do tipo arbustivas parecem resultar em uma diminuição do retorno relacionado ao solo, provavelmente vinculados a confusão intra-dossel típicas desse tipo de vegetação, que apresentam baixa variabilidade altimétrica entre seus indivíduos. Resultados nesse sentido foram verificados em diversos estudos científicos que tiveram o caráter de avaliar dados provenientes de sistemas LIDAR visando diversificadas aplicações (HODGSON et al., 2003; CROW et al., 2007; DONEUS et al., 2008; BRUBAKER et al., 2013; HUTSON, 2015).

Percebe-se que a cobertura vegetal é uma questão crítica que deve ser considerada não só nos levantamentos topográficos provenientes de perfilamento à laser, mas em qualquer uso de tecnologia ativa de coleta de dados. As informações confiáveis são provenientes apenas de objetos que interagiram diretamente com o método de coleta. Nas demais áreas de oclusão, as informações altimétricas de terreno acabam sendo estimadas a partir de diferentes técnicas de filtragem, no caso da tecnologia LIDAR, ou mesmo o uso das convencionais técnicas de fotogrametria, fato que acrescenta incerteza nas medições realizadas.

Segundo Pfeifer, Gorte e Elberink (2004), a limitação relacionada à densidade de cobertura vegetal não pode ser resolvida com o uso de sistemas convencionais de perfilamento à laser, o que abre um campo novo de discussões a respeito da utilização de sistemas LIDAR que registram todo o comprimento de onda emitido, diferente do sistema discreto apresentado acima, no melhoramento da identificação de retornos de solo em situações de vegetação arbustiva (CROW et al., 2007).

Neste sentido, e tendo por finalidade minimizar ou controlar as incertezas, a utilização de técnicas de fotogrametria conjugadas com as de perfilamento à laser podem ser uma potencialidade visando garantir uma melhor qualidade na derivação de informações altimétricas, tais como curvas de nível, hidrografia e pontos cotados, bem como na geração de MDE.

3.6.4. O efeito da topografia local

Uma limitação do uso de dados LIDAR em aplicações topográficas está principalmente relacionada à influência da topografia local sobre os dados originais, prejudicando estimativas de escoamento superficial.

Segundo Thomas et al. (2017), a definição da resolução espacial do MDE deve considerar a sua aplicação, mesmo que os dados de entrada permitam um melhor refinamento. Essa argumentação vem da constatação de que, por um lado, modelos muito grosseiros podem generalizar em demasia informações primordiais referentes ao comportamento e controle topográfico da região. E, por outro, modelos com elevada resolução espacial podem favorecer a influência da topografia local nas inferências espaciais, essas que, muitas vezes, não estão relacionadas diretamente ao controle exercido pelo relevo sob o comportamento mais regionalizado do escoamento superficial da água. Diversos estudos na literatura constataram a influência da resolução espacial do MDE nos atributos topográficos (declividade, aspecto, área de contribuição à montante, dentre outros). Segundo Gillin et al. (2015), a resolução espacial deve ser estabelecida considerando um balanço entre os efeitos dos fatores regionais que realizam o controle topográfico e a influência desejada, ou não, da topografia local sobre o modelo.

Segundo Carvalho Júnior et al. (2010) e Freitas et al. (2012), um MDE urbano que represente a geometria individual de prédios, blocos e arruamentos permite uma melhor descrição do escoamento superficial da água, as alterações dos fluxos causadas pelas rápidas mudanças morfológicas do ambiente e seu consequente efeito sobre os processos de erosão.

3.6.5. Análise comparativa com estudos de detecção de ASH em regiões urbanas

Os estudos científicos relacionados à identificação das ASH utilizando sistemas LIDAR e o índice ITU estão focados, principalmente, em aplicações agrícolas e em escala regional. Dentre eles, destaca-se o trabalho de Thomas et al. (2016) que desenvolveram uma metodologia para identificar com acurácia as áreas críticas relacionadas à poluição difusa em duas bacias hidrográficas na Irlanda com uso agrícola utilizando LIDAR MDE. Agnew et al. (2006) desenvolveram um estudo visando analisar a performance do índice ITU, adaptado com informações relativas à condutividade hidráulica do solo saturado e sua profundidade, na estimativa das ASH em diferentes contextos agrícolas. Segundo os autores, foi constatado consistente correlação entre as estimativas provenientes do índice ITU e a probabilidade de saturação do solo, fato que auxilia a identificação de áreas críticas quando sobrepostas aos diversos padrões de uso e ocupação da terra.

A identificação das ASH também é objeto de pesquisas realizadas em escala regional, cujas metodologias referentes à sua estimativa variam a depender de cada particularidade, sendo que o ambiente urbano se resume, basicamente, a uma das diversas classes temáticas do uso e ocupação da terra. Wu, Giri e Qiu (2016) analisaram a delimitação das ASH em três diferentes cenários de uso e ocupação da terra e, apesar de não lidar diretamente com o ambiente urbano, seu resultado indica que a estimativa de ASH aumentou em áreas de intenso uso e ocupação da terra, tais como às agrícolas e a urbana. Resultados semelhantes também foram alcançados por Giri, Qiu e Zhang (2017), ao lidar com variações na parametrização da estimativa do índice topográfico de solo visando a estimativa das ASH em diferentes classes de uso e ocupação da terra, na escala de bacia hidrográfica. Qiu et al. (2019) avaliaram o relacionamento entre as alterações do uso e ocupação da terra e a degradação dos ecossistemas aquáticos a partir da perspectiva de ASH, e concluíram que quanto maior a intensidade do grau de urbanização de uma bacia hidrográfica, maior os impactos observados na estimativa das ASH. Os resultados apresentados por tais autores também foram realizados na escala de análise de bacia hidrográfica.

Nesse contexto, a presente pesquisa inova ao adaptar a metodologia para a identificação das ASH a partir do índice ITU em ambientes restritamente urbanos em escala local. Devido à alta acurácia relativa ao relevo extraído de sistema LIDAR foi possível considerar os diferentes arranjos de ruas e edificações do ambiente intraurbano na delimitação das ASH. A abordagem proposta apresenta significativa contribuição uma vez que permite a rápida identificação das ASH, informação de grande valia aos tomadores de decisão na definição das melhores estratégias de intervenção urbana.

3.7. CONSIDERAÇÕES FINAIS

A presente pesquisa apresenta uma abordagem metodológica de estimativa das ASH em escala local no ambiente urbano, baseada em intervalos do índice ITU. Com a tecnologia LIDAR, é possível representar o relevo em alta resolução espacial a partir da utilização de informações altimétricas de alta precisão. O uso dessa tecnologia potencializa o monitoramento de áreas urbanas, uma vez que permite a inferência dos artefatos relacionados à topografia local, importantes para algumas aplicações relacionadas à previsão de possíveis impactos ambientais, bem como na área da engenharia e do planejamento urbano.

A influência dos objetos urbanos no MDE pôde ser constatada, inicialmente, pela diferença encontrada entre os valores de média (79,99 m²), mediana (0,15 m²) e de desvio padrão (2.339,92 m²) relativos à distribuição dos valores de área de contribuição em toda a região de estudo. Esse efeito foi também observado na análise dos resultados do mapeamento das ASH, especialmente considerando a distribuição dos valores de declividade e da área de contribuição. Em linhas gerais, a área de estudo apresenta distribuição assimétrica da declividade, o que indica uma região marcada por baixo gradiente de declividade (3,02 a 3,51 graus) e com a forte influência desses artefatos artificiais, esses que apresentam elevada variação altimétrica em um MDE LIDAR e ocasionam o registro de áreas pontuais com elevada declividade. Por sua vez, os resultados da distribuição da área de contribuição das ASH também indicam a influência urbana no MDE, cujos valores de média (1.638,1 – 576,5 m²) e mediana (86,5 – 8,1 m²) ressaltam uma distribuição assimétrica e indicam uma alta frequência de baixos valores, com presença de *outliers* elevados (σ – 10.558,3 a 6.280,7 m²).

Assim, a depender da finalidade, a expressiva influência dos objetos urbanos nos MDE LIDAR pode ser um obstáculo para a estimativa da convergência do fluxo de água em uma perspectiva mais regional. Nesta escala de trabalho, é necessário garantir um balanço entre a influência da microtopografia no escoamento superficial e a convergência e conectividade de fluxo a montante, o que requer uma reamostragem do MDE LIDAR para resoluções maiores.

Neste sentido, se faz necessário o aperfeiçoamento de uma metodologia específica que contorne, ou suavize, a influência dos artefatos inerente aos dados LIDAR, especificamente considerando as resoluções espaciais indicadas para a estimativa das ASH em escala regional, os procedimentos de filtragem das informações de terreno, as influências da redução da nuvem de pontos amostrais no processo de interpolação e geração do MDE e a incorporação das propriedades hidrológicas de solo na estimativa das ASH, uma vez que o método utilizado na presente pesquisa considerou apenas o controle topográfico.

Ademais, observou-se a influência direta da cobertura vegetal na densidade de pontos amostrais LIDAR, o que ocasionou uma perda de qualidade do MDE gerado nessas áreas e, subsequentemente, a necessidade de preenchimento de depressões visando garantir o escoamento do fluxo no modelo. Esse efeito rebaixou a declividade e influenciou diretamente o traçado das ASH no terreno.

A metodologia permitiu identificar os padrões locais da ocorrência de ASH no ambiente urbano da região administrativa de São Sebastião. Os resultados alcançados indicam que o processo de urbanização sem planejamento altera o escoamento superficial de água, um dos principais fatores topográficos que influencia em inundações e erosões, ao direcionar e concentrar os fluxos em pontos críticos do terreno.

AGRADECIMENTOS

Os autores agradecem o apoio da Terracap no fornecimento da base cartográfica, especificamente o perfilamento à laser, utilizada no presente estudo. Os autores agradecem também ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Apoio e Pesquisa do Distrito Federal (FAP/DF).

REFERÊNCIAS

ABRAMOV, O.; MCEWAN, A. An evaluation of interpolation methods for Mars Orbiter Laser Altimeter (MOLA) data. **International Journal of Remote Sensing**, n. 25, v. 3, p. 669-676, 2004.
<https://doi.org/10.1080/01431160310001599006>

AGNEW, L. J.; LYON, S.; GERARD-MARCHANT, P.; COLLINS, V. B.; LEMBO, A. J.; STEENHUIS, T. S.; WALTER, M. T. Identifying hydrologically sensitive areas: Bridging the gap between science and application. **Journal of Environmental Management**, v. 78, p. 63 – 76, 2006.

<http://doi.org/10.1016/j.jenvman.2005.04.021>

ANA - Agência Nacional de Águas. **Conjuntura dos recursos hídricos no Brasil: Informes 2016**. Brasília, 2016. Disponível em: <<http://www3.snirh.gov.br/portal/snirh/centrais-de-conteudos/conjuntura-dos-recursos-hidricos/informe-conjuntura-2016.pdf/view>>. Acesso em: 21 maio 2020.

BALTSAVIAS, E. P. Airborne Laser Scanning: Basic Relations and Formulas. **Journal of Photogrammetry and Remote Sensing**, v. 54, p. 199 – 214, 1999. Disponível em:

<http://www2.geog.ucl.ac.uk/~mdisney/teaching/teachingNEW/PPRS/papers/Baltsavias_Lidar.pdf>.

Acesso em: 05 jul. 2020.

BATER, C. W.; COOPS, N. C. Evaluating error associated with lidar-derived DEM interpolation. **Computers & Geosciences**, v. 35, p. 289 – 300, 2009. <https://doi.org/10.1016/j.cageo.2008.09.001>

BEVEN, K. J.; KIRKBY, M. J. A Physically Based, Variable Contributing Area Model of Basin Hydrology. **Bulletin of Hydrological Sciences**, v. 24, p. 43 – 69, 1979.

<https://doi.org/10.1080/02626667909491834>

BRUBAKER, K. M.; MYERS, W. L.; DROHAN, P. J.; MILLER, D. A.; BOYER, E. W. The Use of Lidar Terrain Data in Characterizing Surface Roughness and Microtopography. **Applied and Environmental Soil Science**, v. 2013, p. 1 – 14, 2013. <http://dx.doi.org/10.1155/2013/891534>

CARVALHO JÚNIOR, O. A.; GUIMARÃES, R.; FREITAS, L.; GOMES-LOEBMANN, D.; GOMES, R. A.; MARTINS, E.; MONTGOMERY, D. R. Urbanization impacts upon catchment hydrology and gully development using multi-temporal digital elevation data analysis. **Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group**, v. 35, n. 5, p. 611 – 617, 2010. <https://doi.org/10.1002/esp.1917>

COSTA-CABRAL, M.; BURGESS, S. J. Digital elevation model networks (DEMON): A model of flow over hillslopes for computation of contributing and dispersal areas. **Water Resource Res.**, v. 30, n. 6, p. 1681 – 1692, 1994. <https://doi.org/10.1029/93WR03512>

COWEN, D. J.; JENSEN, J. R.; HENDRIX, C.; HODGSON, M. E.; SCHILL, S. R. A GIS-assisted rail construction econometric model that incorporates LIDAR data. **Photogrammetric Engineering and Remote Sensing**, v. 66, n. 11, p. 1323 - 1326, 2000. Disponível em:

<<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.500.5511&rep=rep1&type=pdf>>. Acesso em: 12 jul. 2020.

CROW, P.; BENHAM, S.; DEVEREUX, B. J.; AMABLE, G. S. Woodland vegetation and its implications for archaeological survey using LiDAR. **Forestry**, v. 80, n. 3, p. 241 – 252, 2007.

<https://doi.org/10.1093/forestry/cpm018>

DONEUS, M.; BRIESE, C.; FERA, M.; JANNER, M. Archaeological prospection of forested areas using full-waveform airborne laser scanning. **Journal of Archaeological Science**, v. 35, n. 4, p. 882 – 893, 2008. <https://doi.org/10.1016/j.jas.2007.06.013>

ESRI – Environmental Systems Research Institute. **Archydro 10.8** [S.I.]: ESRI, 2020. Disponível em <<http://downloads.esri.com/archydro/archydro/>> [programa de computador]. Acesso em: 01 maio 2020.

FREITAS, L. F.; GUIMARÃES, R. F.; CARVALHO JÚNIOR, O. A.; GOMES, R. A. T. Relacionamento entre a mudança da rede de drenagem devido à construção de estruturas urbanas e o surgimento de voçorocas e ravinhas no bairro do Jardim Botânico no Distrito Federal. **Revista Brasileira de Geomorfologia**, v. 13, n. 4, p. 419 – 433, 2012. <http://dx.doi.org/10.20502/rbq.v13i4.294>

GDF - Governo do Distrito Federal. **Zoneamento Ecológico-Econômico do Distrito Federal (ZEE/DF)**. Brasília, 2018. Disponível em: <<http://zee.df.gov.br/>>. Acesso em: 10 de junho de 2020.

GILLIN, C. P.; BAILEY, S. W.; MCGUIRE, K. J.; PRISLEY, S. P. Evaluation of Lidar-derived DEMs through Terrain Analysis and Field Comparison. **Photogrammetric Engineering & Remote Sensing**, v. 81, n. 5, p. 387 – 396, 2015. <https://doi.org/10.14358/PERS.81.5.387>

- GIONGO, M.; KOEHLER, H. S.; MACHADO, S. A.; KIRCHNER, F. F.; MARCHETTI, M. LIDAR: princípios e aplicações florestais. **Pesquisa Florestal Brasileira**, v. 30, n. 63, p. 231 - 244, 2010. <https://doi.org/10.4336/2010.pfb.30.63.231>
- GIRI, S.; QIU, Z.; ZHANG, Z. A novel technique for establishing soil topographic index thresholds in defining hydrologically sensitive areas in landscapes. **Journal of Environmental Management**, v. 200, p. 391 – 399, 2017. <https://doi.org/10.1016/j.jenvman.2017.04.080>
- GRABS, T.; SEIBERT, J.; BISHOP, K.; LAUDON, H. Modelling spatial patterns of saturated areas: A comparison of the topographic wetness index and a dynamic distributed model. **Journal of Hydrology**, v. 373, n. 1 - 2, p. 15 - 23, 2009. <https://doi.org/10.1016/j.jhydrol.2009.03.031>
- GUIMARÃES, R. F.; FERNANDES, N. F.; GOMES, R. A. T.; CARVALHO JUNIOR, O. A. Fundamentação teórica do modelo matemático para previsão de escorregamentos rasos Shallow Stability. **Revista Espaço & Geografia**, v. 06, n. 2, p. 133 – 150, 2003.
- GUIMARÃES, R. F.; MACHADO, W. P.; CARVALHO JÚNIOR, O. A.; MONTGOMERY, D. R.; GOMES, R. A. T.; GREENBERG, H. M.; CATALDI, M.; MENDONÇA, P. C. Determination of Areas Susceptible to Landsliding Using Spatial Patterns of Rainfall from Tropical Rainfall Measuring Mission Data, Rio de Janeiro, Brazil. **ISPRS International Journal of Geo-Information**, v. 6, n. 10, p. 289, 2017. <https://doi.org/10.3390/ijgi6100289>
- HENGL, T. Finding the right pixel size. **Computer & Geoscience**, n. 32, p. 1283 – 1298, 2006. <https://doi.org/10.1016/j.cageo.2005.11.008>
- HODGSON, M. E.; JENSEN, J. R.; SCHMIDT, L.; SCHILL, S.; DAVIS, B. An evaluation of LIDAR- and IFSAR-derived digital elevation models in leaf-on conditions with USGS Level 1 and Level 2 DEMs. **Remote Sensing of Environment**, v. 84, n. 2, p. 295 – 308, 2003. [https://doi.org/10.1016/S0034-4257\(02\)00114-1](https://doi.org/10.1016/S0034-4257(02)00114-1)
- HODGSON, M. E.; JENSEN, J. R.; RABER, G.; TULLIS, J.; DAVIS, B. A.; THOMPSON, G.; SCHUCKMAN, K. An Evaluation of Lidar-derived Elevation and Terrain Slope in Leaf-off Conditions. **Photogrammetric Engineering & Remote Sensing**, v. 71, n. 7, p. 817 - 823, 2005. <https://doi.org/10.14358/PERS.71.7.817>
- HUTCHINSON, M. F. A locally adaptive approach to the interpolation of digital elevation models. In: INTERNATIONAL CONFERENCE, 3, Workshop on Integrating GIS and Environmental Modeling. **Proceedings...** Santa Fe, NM: 1996.
- HUTSON, S. R. Adapting LiDAR data for regional variation in the tropics: A case study from the Northern Maya Lowlands. **Journal of Archaeological Science: Reports**, v. 4, p. 252 – 263, 2015. <https://doi.org/10.1016/j.jasrep.2015.09.012>
- IBGE - Instituto Brasileiro de Geografia e Estatística. **Censo Demográfico 2010**. Rio de Janeiro, 2010. Disponível em <<https://censo2010.ibge.gov.br/>>. Acesso em: 10 jul. 2020.
- JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. São Jose dos Campos, SP: Parênteses, 2011.
- KIENZLE, S. The Effect of DEM Raster Resolution on First Order, Second Order and Compound Terrain Derivatives. **Transactions in GIS**, v. 8, n. 1, p. 83 - 111, 2004. <https://doi.org/10.1111/j.1467-9671.2004.00169.x>
- LEA, N. L. An aspect driven kinematic routing algorithm. In: ANDERSON, A. J.; ABRAHAMS, A. D. **Overland Flow: Hydraulics and Erosion Mechanics**, Nova Iorque: Chapman & Hall, 1992.
- LINDSAY, J. B. Whitebox GAT: A case study in geomorphometric analysis. **Computers & Geosciences**, v. 95, p. 75 – 84, 2016. <https://doi.org/10.1016/j.cageo.2016.07.003>
- LLOYD, C. D.; ATKINSON, P. M. Deriving DSMs from LIDAR data with kriging. **International Journal of Remote Sensing**, v. 12, n. 23, p. 2519 – 2524, 2002. <https://doi.org/10.1080/01431160110097998>
- LOTTE, R. G.; ALMEIDA, C. M.; VALERIANO, M. M. Aquisição do Índice de Saturação do Solo (TWI) para a avaliação de suscetibilidade a movimentos de massa na região de São Sebastião-SP. In: Simpósio Brasileiro de Sensoriamento Remoto, 17, 2015. **Anais...** João Pessoa: INPE, 2015. Disponível em: <<http://www.dsr.inpe.br/sbsr2015/files/p1570.pdf>>. Acesso em: 13 jul. 2020.
- MCGLONE, J. C. **Manual of Photogrammetry**. Bethesda: ASP&RS, 2004.

ONU – Organização das Nações Unidas. Departamento de Assuntos Econômicos e Sociais **World Urbanization Prospects – The 2018 Revision**. Nova Iorque, 2019. Disponível em: <<https://population.un.org/wup/Publications/Files/WUP2018-Report.pdf>> Acesso em: 11 jul. 2020.

PFEIFER, N.; GORTE, B.; ELBERINK, S. O. Influences of vegetation on laser altimetry – analysis and correction approaches. In: THIES, M.; KOCH, B.; SPIECKER, H.; WEINACKER, (Eds.), Proceedings of Nascan, Laser-Scanners for Forest and Landscape Assessment – Instruments. Processing Methods and Applications. **International Archives of Photogrammetry and Remote Sensing**, v. 36, p. 283 – 287, 2004. Disponível em: <[https://www.isprs.org/proceedings/XXXVI/8-W2/PFEIFER\(2\).pdf](https://www.isprs.org/proceedings/XXXVI/8-W2/PFEIFER(2).pdf)>. Acesso em: 13 jul. 2020.

POLAT, N.; UYSAL, M.; TOPRAK, A. S. An investigation of DEM generation process based on LIDAR data filtering, decimation, and interpolation methods for an urban area. **Measurement**, v. 75, p. 50 – 56, 2015. <https://doi.org/10.1016/j.measurement.2015.08.008>

QIU, Z.; KENNEN, J. G.; GIRI, S.; WALTER, T.; KANG, Y.; ZHANG, Z. Reassessing the relationship between landscape alteration and aquatic ecosystem degradation from a hydrologically sensitive area perspective. **Science of the Total Environment**, v. 650, p. 2850 – 2862, 2019. <https://doi.org/10.1016/j.scitotenv.2018.10.036>

QUINN, P.; BEVEN, K.; CHEVALLIER, P.; PLANCHON, O. The prediction of hillslope flow paths for distributed hydrological modeling using digital terrain models. **Hydrological processes**, v. 5, p. 59 – 79, 1991. <https://doi.org/10.1002/hyp.3360050106>

SHAN, J.; TOTH, C. K. **Topographic Laser Ranging and Scanning: Principles and Processing**. Nova Iorque: CRC Press, 2º ed, 2018.

SORENSEN, R.; SEIBERT, J. Effects of DEM resolution on the calculation of topographical indices: TWI and its components. **Journal of Hydrology**, v. 347, n. 1-2, p. 79 - 89, 2007. <https://doi.org/10.1016/j.jhydrol.2007.09.001>

TARBOTON, D. G. A new method for the determination of flow directions and upslope areas in the grid digital elevation models. **Water Resources Research**, v. 33, n. 2, p. 309 – 319, 1997. <https://doi.org/10.1029/96WR03137>

TARBOTON, D. G. **Taudem 5.3 – Terrain Analysis Using Digital Elevation Models**. [S.l.]: Utah University, 2015. Disponível em <<https://hydrology.usu.edu/taudem/taudem5/>> [programa de computador]. Acesso em: 15 jul. 2020.

TERRACAP - Agência de Desenvolvimento do Distrito Federal. **Mapeamento Aerofotogramétrico das áreas urbanas do Distrito Federal – Relatório Técnico do produto 2**. Brasília, 2016.

THOMAS, I. A.; JORDAN, P.; MELLANDER, P. E.; FENTON, O.; SHINE, O.; HUALLACHAIN, D. O.; CREAMER, R.; MCDONALD, N. T.; DUNLOP, P.; MURPHY, P. N. C. Improving the identification of hydrologically sensitive areas using LIDAR DEMs for the delineation and mitigation of critical source areas of diffuse pollution. **Science of the Total Environment**, v. 556, p. 276 – 290, 2016. <https://doi.org/10.1016/j.scitotenv.2016.02.183>

THOMAS, I. A.; JORDAN, P.; SHINE, O.; FENTON, O.; MELLANDER, P. E.; DUNLOP, P.; MURPHY, P. N. C. Defining optimal DEM resolutions and point densities for modelling hydrologically sensitive areas in agricultural catchments dominated by microtopography. **International Journal of Applied Earth Observation and Geoinformation**, v. 54, p. 38 – 52, 2017. <https://doi.org/10.1016/j.jag.2016.08.012>

VAZE, J.; TENG, J.; SPENCER, G. Impact of DEM accuracy and resolution on topographic indices. **Environmental Modelling & Software**, v. 25, n. 10, p. 1086 – 1098, 2010. <https://doi.org/10.1016/j.envsoft.2010.03.014>

WALLIS, C.; WATSON, D.; TARBOTON, D.; WALLACE, R. Parallel Flow-Direction and Contributing Area Calculation for Hydrology Analysis in Digital Elevation Models. In: **PDPTA'09 – The 2009 International Conference on Parallel and Distributed Processing Techniques and Applications**, Las Vegas, Nevada, USA, 2009. Disponível em: <https://www.researchgate.net/profile/Robert_Wallace9/publication/221133105_Parallel_Flow-Direction_and_Contributing_Area_Calculation_for_Hydrology_Analysis_in_Digital_Elevation_Models/links/557ed13208aeea18b77952cc/Parallel-Flow-Direction-and-Contributin>. Acesso em: 15 jun. 2020.

WALTER, M. T.; WALTER, M. F.; BROOKS, E. S.; STEENHUIS, T. S.; BOLL, J.; WEILER, K. Hydrologically sensitive areas: variable source area hydrology implications for water quality risk assessment. **J. Soil Water Conserv.** v. 55, p. 277 – 284, 2000. Disponível em: <<https://www.jswnonline.org/content/55/3/277.short>>. Acesso em: 14 jun. 2020.

WU, Y.; GIRI, S.; QIU, Z. Understanding the spatial distribution of hydrologic sensitive areas in the landscape using soil topographic index approach. **International Soil and Water Conservation Research**, v. 4, p. 278 – 283, 2016. <https://doi.org/10.1016/j.iswcr.2016.10.002>

YANALAK, M. Effect of gridding method on digital terrain model profile data based on scattered data. **Journal of Computing in Civil Engineering**, v. 17, n. 1, p. 58-67, 2003. [https://doi.org/10.1061/\(ASCE\)0887-3801\(2003\)17:1\(58\)](https://doi.org/10.1061/(ASCE)0887-3801(2003)17:1(58))

4. Estimating the optimal threshold for outlier removal of the Global Ecosystem Dynamics Investigation (GEDI) data

Felipe Lima Ramos Barbosa¹, Renato Fontes Guimarães^{1,*}, Osmar Abílio de Carvalho Júnior¹, Roberto Arnaldo Trancoso Gomes¹, Osmar Luiz Ferreira de Carvalho² and Thyego Pery Monteiro de Lima³

¹ Departamento de Geografia, Campus Universitário Darcy Ribeiro, Asa Norte, Universidade de Brasília, DF, Brasília 70910-900, Brazil; felipe.barbosa@mma.gov.br (F.L.R.B.); osmarjr@unb.br (O.A.d.C.J.); robertogomes@unb.br (R.A.T.G.);

² Departamento de Ciência da Computação, Campus Universitário Darcy Ribeiro, Asa Norte, Universidade de Brasília, DF, Brasília 70910-900, Brazil; osmarcarvalho@ieee.org (O.L.F.d.C.);

³ Programa de Pós-Graduação em Ciências Ambientais, Campus Planaltina, Universidade de Brasília, DF, Brasília 70910-900; thyego.lima@mma.gov.br (T.P.M.L.)

* Correspondence: renatofg@unb.br

Abstract: Remote Sensing from LiDAR is a great source of altimetric data used in many surveys. The spaceborne handle system, Global Ecosystem Dynamics Investigation (GEDI), provides ground elevation information with high accuracy except for areas with steep slopes. GEDI data have a lot of noise from atmospheric conditions, and therefore filtering procedures are mandatory to select the best dataset. The objective of this work is to identify the best threshold to select the maximum number of samples with low RMSE values. Therefore, we used Kolmogorov-Smirnov (KS) non-parametric test to define the best threshold based on a normal distribution. Our results demonstrated a lower RMSE value with a high number of samples when compared with quality flag threshold parameter even using sensitivity parameters threshold. This method is useful for making the most of altimetric data that is scarce in many areas around the world.

Keywords: spaceborne LiDAR; GEDI; outlier removal; accuracy assessment; digital terrain model; digital surface model

4.1. Introduction

Advances in light detection and ranging (LiDAR) technology have produced accurate terrain altitude with airborne laser scanning (ALS). Many scientific studies use ground elevation and canopy heights in various applications such as urban environment mapping Land Use and Land Cover (LULC) [1–3], extracting objects as buildings [4], estimating urban tree canopy and heights [5,6], detecting road [7], modeling flood and wetlands [8,9], quantifying urban landscape changes under a historical perspective [10], investigating Digital Elevation Model (DEM) generation process and upward fusion with another more generic DEM [11,12]. The key problem is that ALS is expensive, and the survey covers small areas. Therefore, the spaceborne LiDAR has the advantage of providing a global ground elevation and canopy height, filling the lack of accurate data around the world.

There are few experiences in the development of spaceborne LiDAR systems [13]. The first experiences started with Shuttle Laser Altimeter (SLA) [14], followed by ICESat [15]. Currently, ICESat

2 altimeter mission [16] aims to estimate changes in polar ice-sheet volume to evaluate their impact on global sea level. Besides, LiDAR data from space provides biomass quantification by measuring vegetation canopy heights, demonstrating its potential in forest studies.

In this way, the Global Ecosystem Dynamics Investigation (GEDI), launched in 2018, is an advanced spaceborne LiDAR system measuring the returned full waveform. GEDI system comprises 3 lasers producing 8 tracks of data, separated by 600 m in the along-flight track direction, onboard the Japanese Experiment Module-Exposed Facility (JEM-EF) on the International Space Station (ISS). The lasers shoot fires at a frequency of 242 Hz and produce on-ground measures over a 25 m wide footprint. Each track's footprint centers are separated by 60 m along-track direction, producing terrain and canopy information with an estimated accuracy of 10 – 20 m horizontally and about 50 cm vertically [13]. Future post-processing and pointing, ranging, and timing calibration updates improve data accuracy.

The GEDI data provide canopy heights, canopy vertical profile, Relative Heights (RH), and topographic surface elevation. Data availability encourages the scientific community to produce several studies, such as: mapping 3D forest structure in the United States [17], forest stand volume estimation in a mixed forest area of northeast China [18], structural characterization of old-growth forest in the Ukrainian Carpathian Mountains [19], estimation of canopy heights and aboveground biomass (AGB) in Mediterranean forests [20], detection ancient Maya buildings in a forested environment [21], slope-adaptive assessment of GEDI waveforms for AGB estimation over mountainous areas [22] and GEDI geolocation uncertainty impact to estimate tropical forest canopy height [23].

Studies also aim to calculate terrain accuracy of the GEDI dataset, comparing with other reference elevation data. Spracklen and Spracklen [19] use the TanDEM-X 12m as reference data to estimate the relative accuracy of GEDI terrain data. Otherwise, GEDI terrain information was the elevation reference to calculate the accuracy of the sub-canopy estimation from TanDEM-X 12m using ALOS-2 PALSAR-2 InSAR Coherence [24]. In relation to measured elevations there are few studies that assessed absolute accuracy of GEDI elevation data [25,26], mainly using ALS LiDAR.

GEDI is a near-infrared (IR) optical remote sensor and suffers disturbance due to cloud cover, solar illumination, system geometries, atmospheric conditions, among others [13], producing outliers. Most studies used quality flag parameter provided as GEDI ancillary information to assess and remove erroneous data from distribution before their main accuracy assessment issues [18–21,24,27–30]. Other studies optimize the use of the quality flag parameter by adjusting the sensitivity beam value adopted as a complementary analytic threshold. This ancillary information establishes a signal-

to-noise ratio related to the maximum canopy cover throughout the GEDI signal, enabling ground detection [17,31]. These procedures use thresholds that eliminate not only outlier values but also some useful data. Furthermore, they do not consider that the Root Mean Square Error (RMSE) calculation of a non-normalized LiDAR data distribution affects accuracy estimation in high-resolution MDE. Therefore, the data should be as close as possible to a goodness-of-fit distribution [32–36].

Thus, this study aims to obtain the best threshold to select only useful GEDI data with low RMSE values. Therefore, we used a normality paradigm method to remove outliers using the Kolmogorov-Smirnov (KS) non-parametric test, based on a normal distribution trailed in an urban area of Federal District, Brazil.

4.2. Materials and Methods

4.2.1. Study Area

Brasília, the Federal capital of Brazil, has a population of approximately 3,000,000 inhabitants distributed in rural (3,38%) and urban (96,62%) [37]. Brasília's urban environment has buildings and residences arranged in wooded areas, sparse green areas, commercial areas, and political buildings, among others. The study area is the center of Brasília and comprises the perimeter between the coordinates 47°57'19.62" W 15°43'34.62" S and 47°49'9.08" W 15°50'44.56" S (Figure 4.1). The relief is gentle with a mean slope of 3.07 and has ALS data available for absolute accuracy assessment. The vegetation belongs to the Cerrado biome, consisting mainly of grassland formation with sparse savanna and forest areas, normally located in urban conservation parks.

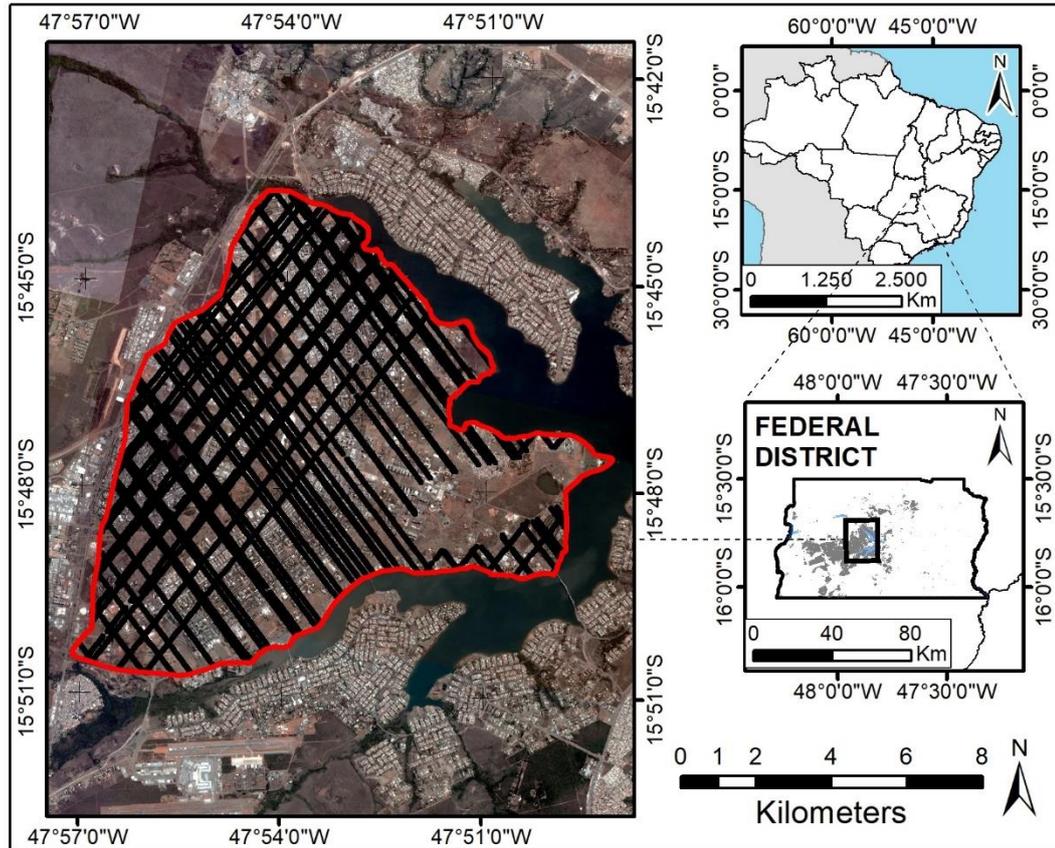


Figure 4.1. Study area located in Federal District. Red line represents center of Brasília city and black dots are GEDI data used in this study.

4.2.2. GEDI Data

GEDI data is available in the Land Processes Distributed Active Archive Center (LP DAAC, <https://lpdaac.usgs.gov/tools/data-pool/> (accessed on 14 April 2021)) in three products, L1B, L2A [27,38], and L2B [39] processed to guarantee the useful part of the waveform after applying smoothing to reduce noise. L1B data product contains geolocated raw transmitted and received waveforms and ancillary information about noise and acquisition time. L2A data product contains elevation data and height metrics of the vertical structures inside the waveform. Other data about the L2B product are vegetation metrics, such as canopy cover, vertical profile metrics, and Leaf Area Index (LAI). We processed data from the L2A considering follow information (Table 4.1).

Table 4.1. GEDI metrics used in this study

Metrics	GEDI Source	Description
Quality flag	L2A	Quality assessment parameter related to good adjustment between energy, sensitivity, amplitude, and real-time surface tracking. The value "1" means usable information in GEDI data.
Sensitivity	L2A	Maximum canopy cover throughout GEDI signal can detect the ground. This ancillary information is concerned with the signal-to-noise ratio.
Elev_lowestmode	L2A	Elevation of center of lowest mode (ELM) relative to WGS84 ellipsoid.

4.2.3. ALS Data

We used a digital terrain model (DTM) derived from discrete return ALS data to calculate the absolute accuracy of GEDI height estimates. The ALS data is a product of aero photogrammetric elaborated by a government campaign in the urban area, with 4 points per square meter density and 27 cm of vertical accuracy with 50 cm spatial resolution. Original ALS data has a horizontal reference system SIRGAS2000, UTM Zone 23S, ITRF2000-ellipsoid, and it is referred vertically to MAPGEO2015.

4.2.4. Methods

The present research has four methodological sections (Figure 4.2): data preparation, orthometric heights transformation, pre-processing and statistical analysis.

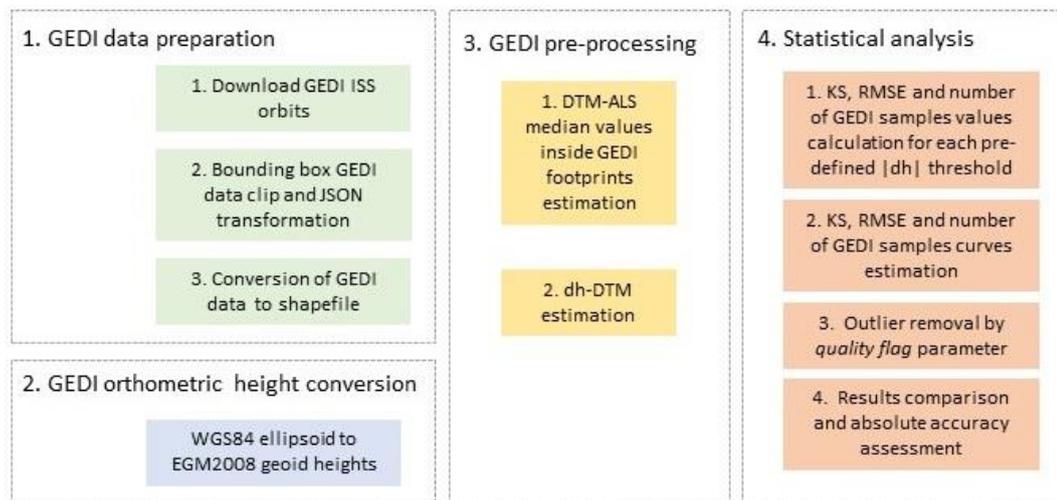


Figure 4.2. Methodological flowchart.

4.2.4.1. GEDI data preparation

The GEDI Finder web service provides all available GEDI L2A products to the study area, totaling 13 orbits files within the boundary box. Table 4.2 lists the GEDI L2A products downloaded and the acquisition dates.

Table 4.2. GEDI L2A products downloaded and acquisition dates

GEDI ISS orbits	Acquisition dates
GEDI02_A_2019153141419_O02667_T05383_02_001_01.h5	06/02/2019
GEDI02_A_2019161000303_O02782_T04978_02_001_01.h5	06/10/2019
GEDI02_A_2019226215413_O03805_T02285_02_001_01.h5	08/14/2019
GEDI02_A_2019268053258_O04446_T02132_02_001_01.h5	09/25/2019
GEDI02_A_2019279121858_O04621_T02690_02_001_01.h5	10/06/2019
GEDI02_A_2019302032210_O04972_T01114_02_001_01.h5	10/29/2019
GEDI02_A_2019317100329_O05209_T00709_02_001_01.h5	11/13/2019
GEDI02_A_2019328165040_O05384_T03960_02_001_01.h5	11/24/2019
GEDI02_A_2020103220644_O07558_T00709_02_001_01.h5	04/12/2020

GEDI02_A_2020123141942_O07863_T03555_02_001_01.h5	05/02/2020
GEDI02_A_2020162101244_O08465_T05536_02_001_01.h5	06/10/2020
GEDI02_A_2020209042759_O09190_T04978_02_001_01.h5	07/27/2020
GEDI02_A_2020217012015_O09312_T02285_02_001_01.h5	08/04/2020

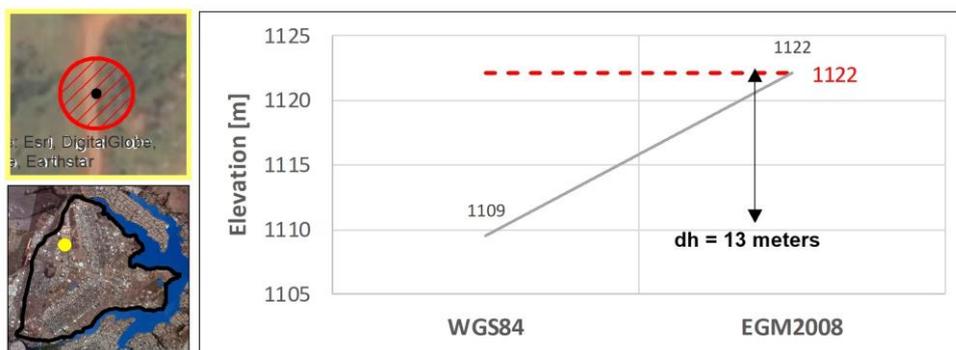
We used a GEDI Subsetter python code to clip the GEDI products spatially and performed the data conversion from GeoJSON format to shapefile using QGIS 3.16. The total of processed footprints in the study area was 7,619 between 02 June 2019 and 04 August 2020.

4.2.4.2. GEDI orthometric height conversion

Analysis between GEDI and reference data elevations requires all heights metrics to be in the same vertical reference system. The original GEDI height data are relative to the WGS 84 ellipsoid, while DTM-ALS is in the MAPGEO2015 geoid system, which has similar characteristics as EGM 2008 [40]. The conversion to orthometric heights of GEDI data used the following equation 1:

$$H_{\text{EGM2008}} = h_{\text{WGS84}} - N_{\text{EGM2008}} \quad (1)$$

where H_{EGM2008} is the derived orthometric height of GEDI data, h_{WGS84} is the original GEDI footprint heights to WGS84 ellipsoid, and N_{EGM2008} are the EGM 2008 gravimetric geoid heights (≈ -12.5 m for study area). We used VDatum 4.2 software developed by the National Oceanic and Atmospheric Administration (NOAA) to convert the vertical datum of GEDI data, ensuring compatibility with the ALS LiDAR reference. Figure 4.3 shows the orthometric height conversion in 3 random GEDI footprint samples as an example.



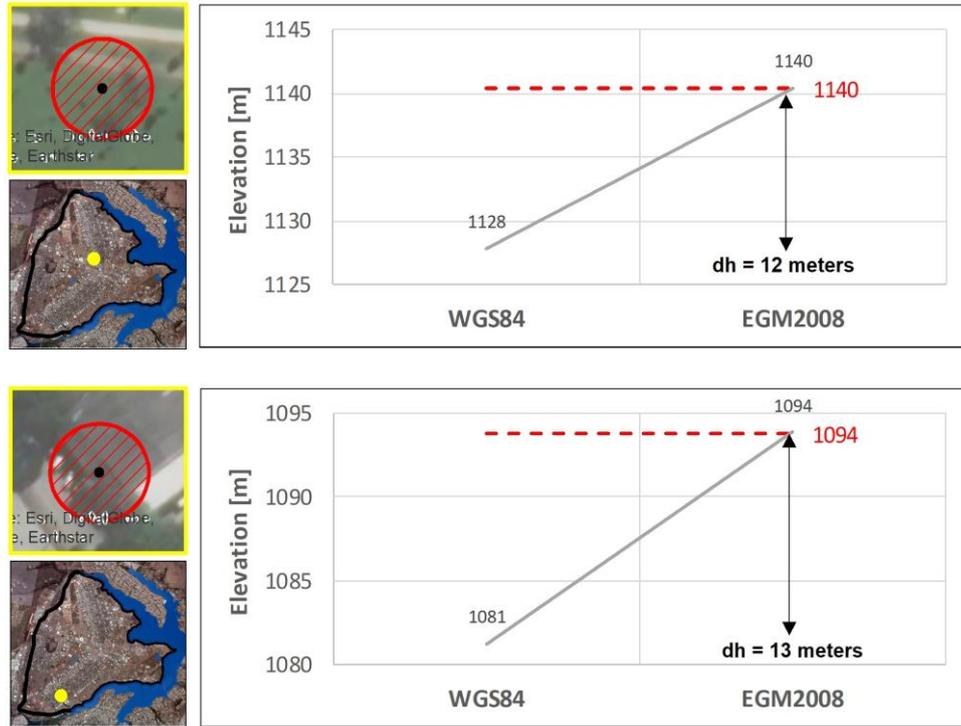


Figure 4.3. Orthometric height conversion procedure in 3 random GEDI footprint samples. Grey line represents the vertical elevation transformation from WGS84 to EGM2008 datum, Red dashed line is the DTM-ALS elevation in each GEDI footprint referred in MAPGEO2015.

4.2.4.3. GEDI pre-processing

Each terrain height of GEDI data is a mean terrain height resulted from the interaction between the signal and the objects within a 25 m footprint, represented by a point-shaped polygon. We extracted to every GEDI footprint attribute table the median of the intercepted cell values from DTM-ALS, regarding the difference between the spatial resolutions of both datasets. The median reduces the influence of potential outliers in the DTM-ALS [25].

For further statistical analysis and absolute accuracy assessment, we defined as error the difference of height (dh) between GEDI elevation of the center of the lowest mode (ELM) value and the DTM-ALS median value (henceforth called “dh-DTM”) within each GEDI footprint.

4.2.4.4. Statistical analysis

The statistical Kolmogorov-Smirnov (KS) non-parametric estimates the normality in the distribution of the error. Applied in many remote sensing studies, the KS test, from two sets of values, compares an observed cumulative frequency distribution based on randomly collected samples and an empirical cumulative frequency distribution based on a normal distribution, expressed as F_{x_i} and S_{x_i} . KS test identifies the point at which these two distributions show the maximum divergence [41], calculated through estimation of absolute divergence values D_1 and D_2 , according to equations 2, 3, and 4:

$$D_1 = |F_{x_i} - S_{x_i}| \quad (2)$$

$$D_2 = |F_{x_i} - S_{x_{i-1}}| \quad (3)$$

$$KS = \sqrt{n} \max(|D_1|, |D_2|) \quad (4)$$

The advantage of the KS test is that it does not need to assume prior normality distribution of the samples [42], and its ability to explain the normality of the data increase significantly with larger sample sizes [43]. The KS curve estimates used dh-DTM distribution according to two groups of pre-defined absolute thresholds. The first group admitted a 10-meter interval (100, 90, 80, 70, 60, 50, 40, 30, 20 and 10 m) and the second more detailed considered a 1-meter interval below 10-meter absolute dh-DTM threshold (9, 8, 7, 6, 5, 4, 3, 2 and 1 m). These interval thresholds allowed us to find the optimal point for data normality with reduced outliers. Around 99.92% of samples above the first absolute threshold (< 100 m) have amplitude errors from 1,668.69 m to 14,709.78 m, indicating coarse data error. So, we decided to start the statistical analysis from this threshold for further accuracy comparison.

The performance analysis of the proposed outlier elimination method considered the RMSE of each pre-selected threshold and the RMSE curve (equation 5) [44]:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n \Delta h_i^2} \quad (5)$$

where Δh_i is the difference between i th values of dh-DTM.

In addition, we also remove outliers from the total GEDI distribution using quality flag indicator with 0 for further comparison and discussion.

4.3. Results

4.3.1. Proposed KS outlier removal method and absolute accuracy assessment

Table 4.3 lists the number of GEDI footprints, calculated KS, and RMSE from each selected threshold. Figure 4.4 shows comparisons between calculated KS, the number of GEDI footprints, and RMSE curves with 10 m and 1 m intervals.

Table 4.3. Statistics from pre-defined thresholds of absolute value of dh-DTM

	Absolute thresholds dh	Number of GEDI footprints	Calculated KS	RMSE [m]
10 m interval	<100 m	3.710	0.3888	8.91
	<90 m	3.710	0.3888	8.91
	<80 m	3.708	0.3869	8.67
	<70 m	3.696	0.3752	7.55
	<60 m	3.684	0.3620	6.60
	<50 m	3.667	0.3381	5.41
	<40 m	3.638	0.2832	3.70
	<30 m	3.613	0.1849	2.33
	<20 m	3.608	0.1607	2.13
	<10 m	3.590	0.1234	1.90
1 m interval	<9 m	3.578	0.1109	1.82
	<8 m	3.564	0.0972	1.75
	<7 m	3.555	0.0891	1.71
	<6 m	3.534	0.0738	1.64
	<5 m	3.504	0.0571	1.56
	<4 m	3.433	0.0373	1.42
	<3 m	3.325	0.0172	1.33
	<2 m	2.907	0.0542	1.09
	<1 m	1.560	0.0737	0.58

Figure 4.4a indicates a decrease in calculated KS and RMSE values between thresholds <100 m and <10 m, around 68.26% and 78.67%, as expected. Instead, figure 4.4b shows a reduction of just 120 GEDI samples, indicating few outliers above 10 m absolute dh-DTM. The KS and RMSE values showed a pronounced reduction between thresholds <100 m and <30 m, registering better goodness-of-fit data distribution with the removal of 97 major outliers that ensured a better absolute accuracy (8.91 m to 2.33 m).

Figures 4.4c and 4.4d show the curves of KS, RMSE, and the number of GEDI samples in more detail considering the 1-meter interval between the <9 m and <1 m absolute dh-DTM thresholds. A function inflection point occurs in <3 m absolute dh-DTM distribution, where the dispersion of data found its optimal normal fit distribution. Calculated KS decreased from 0.1109 to 0.0172 until the identified inflection point, at an approximately constant rate in each 1 m decrease in absolute dh-DTM. Moreover, there is no gain in absolute accuracy (1.82 m to 1.33 m), and the number of GEDI samples decreased by 7.07% with the removal of 253 smaller outliers from the distribution. However, absolute dh-DTM thresholds lower than 3 m have increased KS values, a high reduction in the number of samples, around 53.08% (3,325 to 1,560), and a small gain of approximately 0.75 m in absolute accuracy. Therefore, minor differences in dh-DTM do not produce a better fit to the Gaussian distribution.

Figure 4.5 shows the optimal threshold considering calculated KS, RMSE values, and the number of GEDI samples. The optimal goodness-of-fit threshold converges with the best GEDI sample

arrangement, reaching an RMSE value of 1.33 m. Figure 4.6 shows the histograms of <4 m, <3 m, <2 m, and <1 m absolute thresholds of dh-DTM, where data tends to non-normal distribution in the thresholds below 3 m, as shown by calculated KS values.

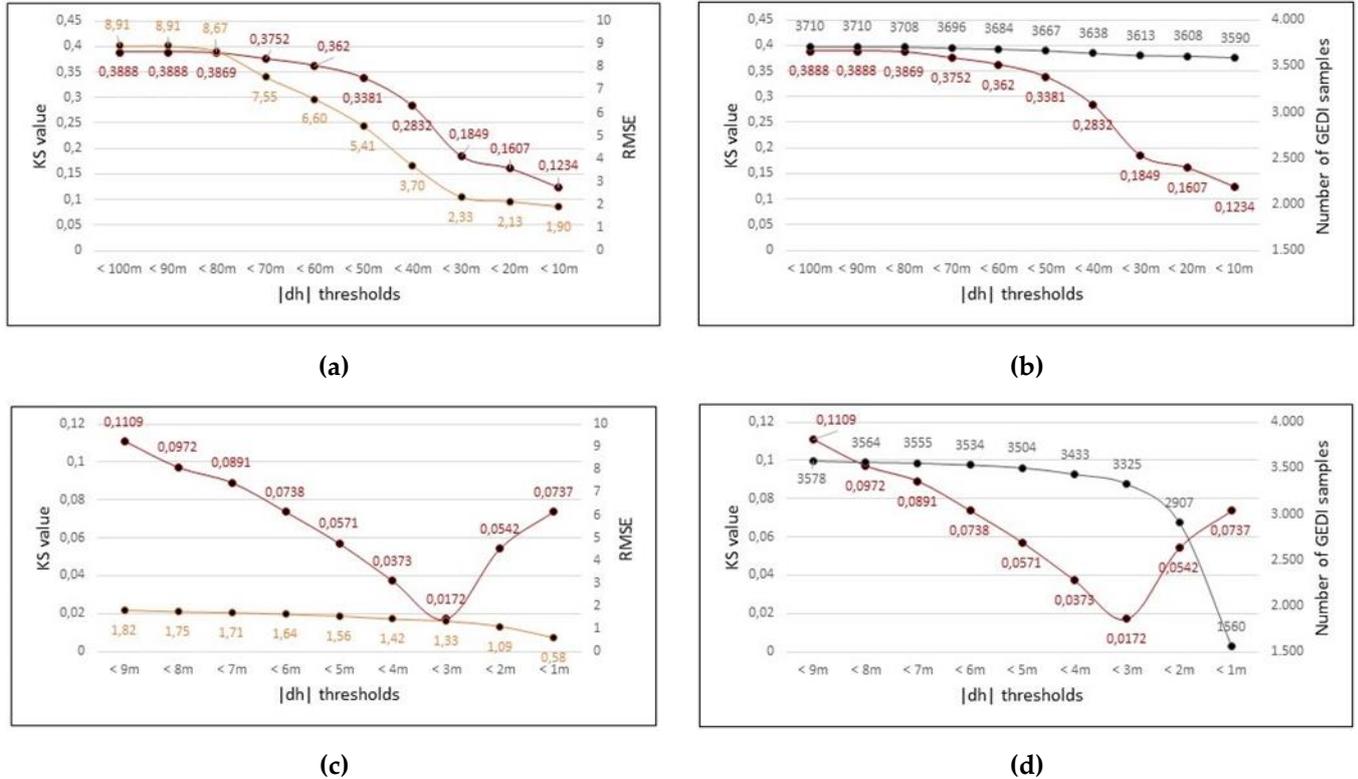


Figure 4.4. Comparison between calculated KS (red color), number of GEDI samples (grey color), and RMSE (orange color) curves from absolute dh-DTM thresholds. **(a)** Calculated KS and RMSE values - 10 m interval from $|dh| < 100$ m and $|dh| < 10$ m; **(b)** Calculated KS value and number of GEDI samples - 10 m interval from $|dh| < 100$ m and $|dh| < 10$ m; **(c)** Calculated KS and RMSE values- 1 m interval from $|dh| < 9$ m and $|dh| < 1$ m; **(d)** Calculated KS value and number of GEDI samples - 1 m interval from $|dh| < 9$ m and $|dh| < 1$ m.

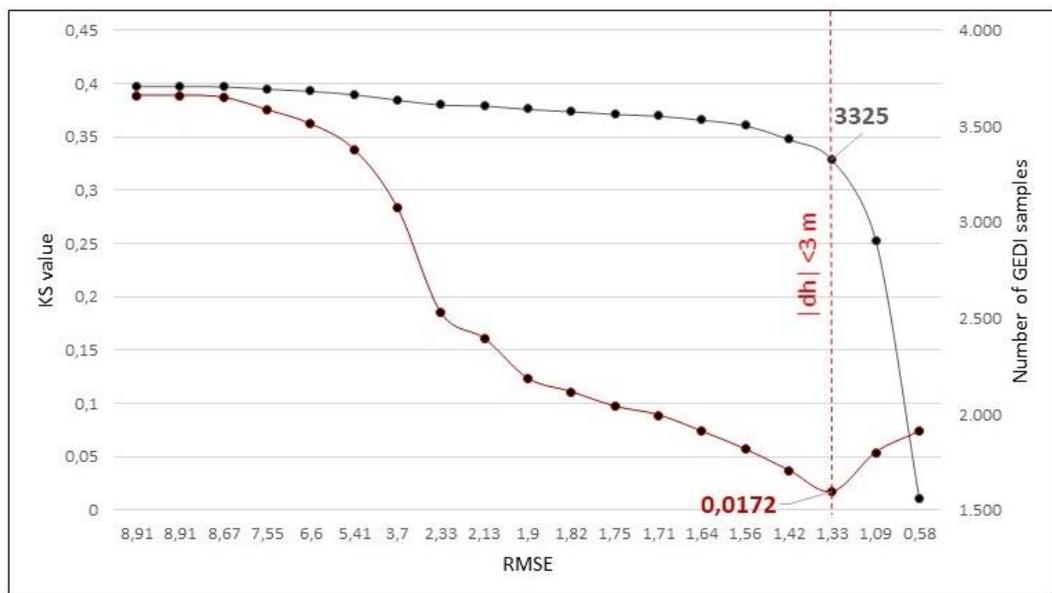


Figure 4.5. Optimal threshold of calculated KS (red color), RMSE (red dashed line) values and the number of GEDI samples (grey color).

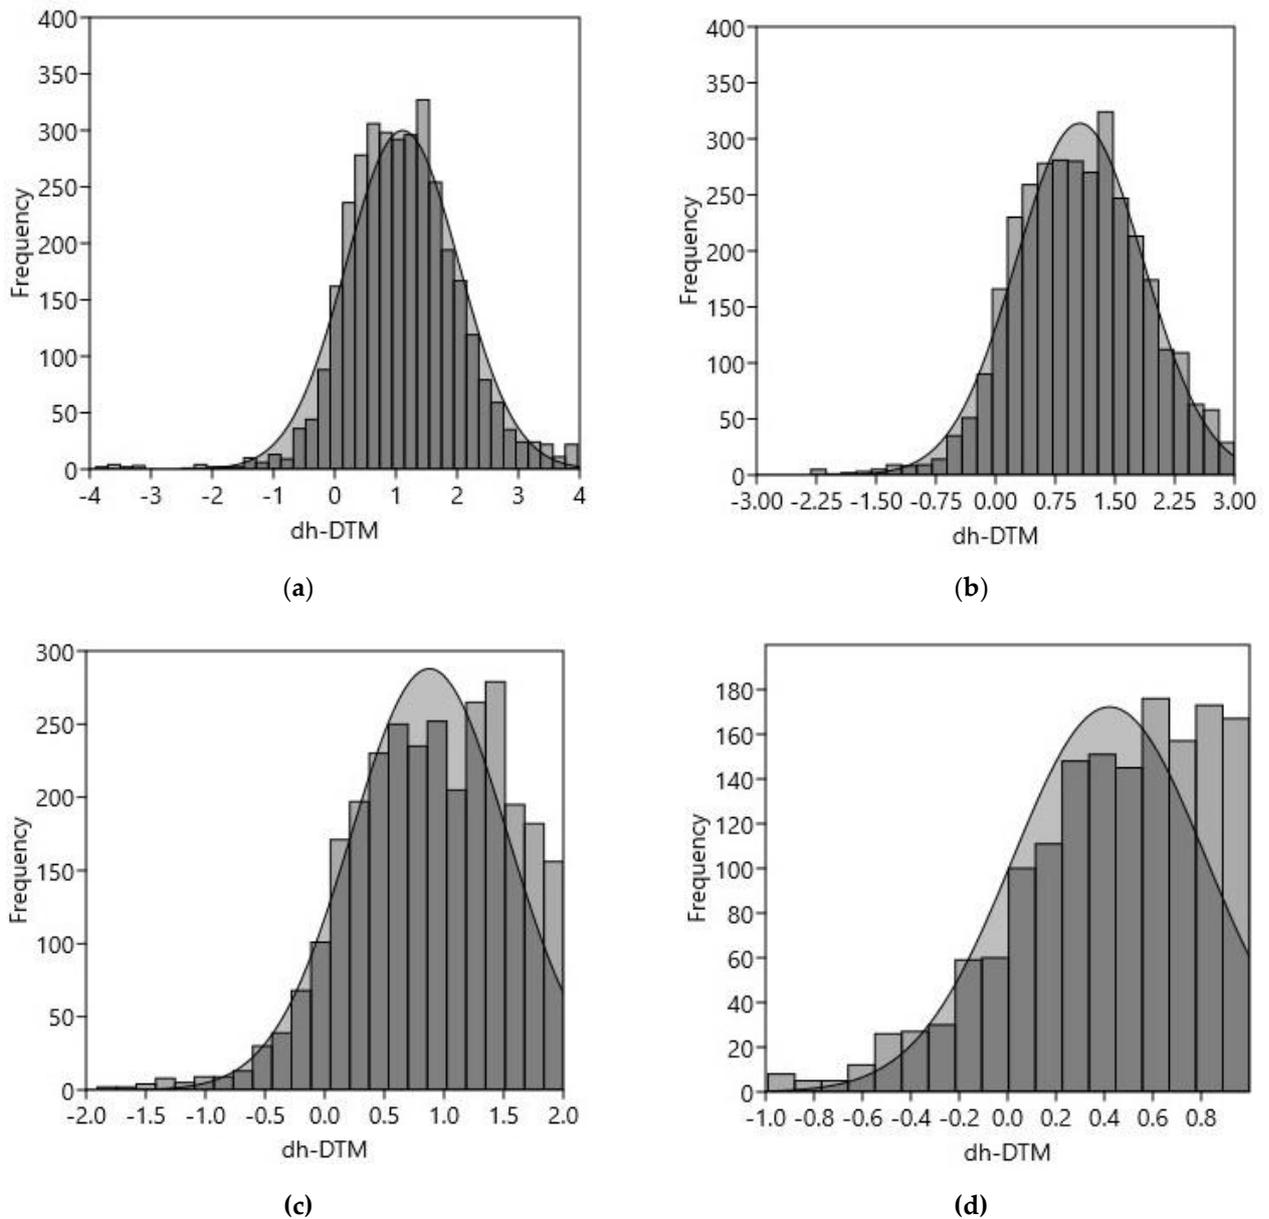


Figure 4.6. Histograms showing the dh-DTM distribution: (a) $|dh| < 4$ m; (b) $|dh| < 3$ m; (c) $|dh| < 2$ m; (d) $|dh| < 1$ m. Shaded grey curve is normal distribution.

Figure 4.7 shows normal quantile-quantile (QQ) plots graphical method for diagnosing differences between the probability distribution of the GEDI dataset and theoretical normal distribution. We observed a slightly sigmoid shape of the empirical distribution compared to the straight line of the normal curve. The analysis of the QQ plots reveals the improvement of goodness fit with reduction of absolute thresholds dh-DTM and the optimal normal behavior of threshold of 3 m. Moreover, absolute dh-DTM distributions lower than 3 m show a non-normal statistical distribution.

Figures 4.8 and 4.9 show the GEDI outlier footprints eliminated above and below the optimal dh-DTM distribution threshold identified. It is possible to observe the spatial distribution of the 385 and 1,765 outlier samples eliminated, respectively, above the inflection point identified on the KS

curve and below it. Although there is no spatial pattern in the eliminated GEDI samples, we can observe a significant loss of accurate data from the GEDI distribution.

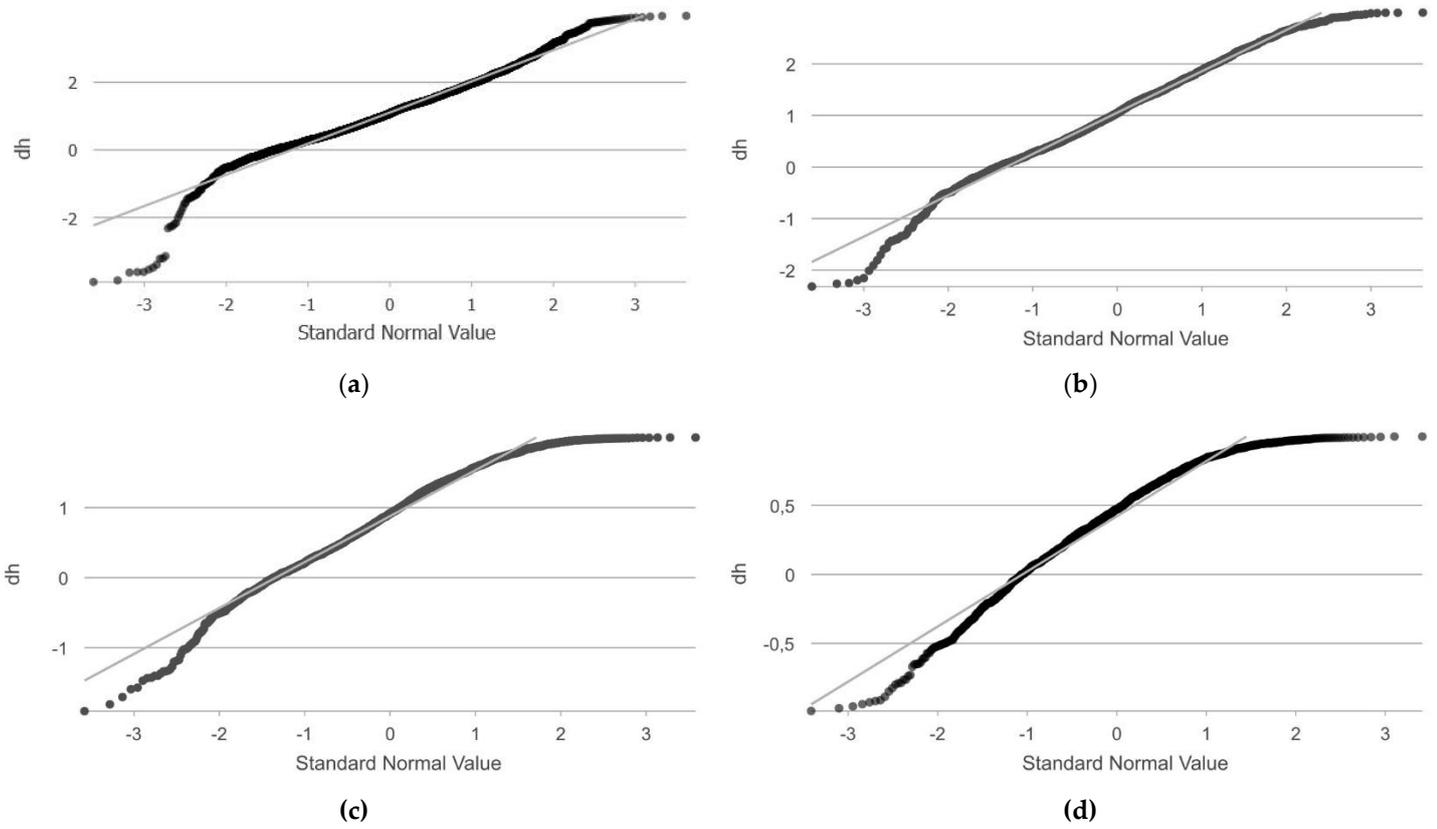


Figure 4.7. Quantile-quantile plots showing distributions of: (a) $|dh| < 4$ m; (b) $|dh| < 3$ m; (c) $|dh| < 2$ m; (d) $|dh| < 1$ m. Light grey line indicates the reference of QQ plot.

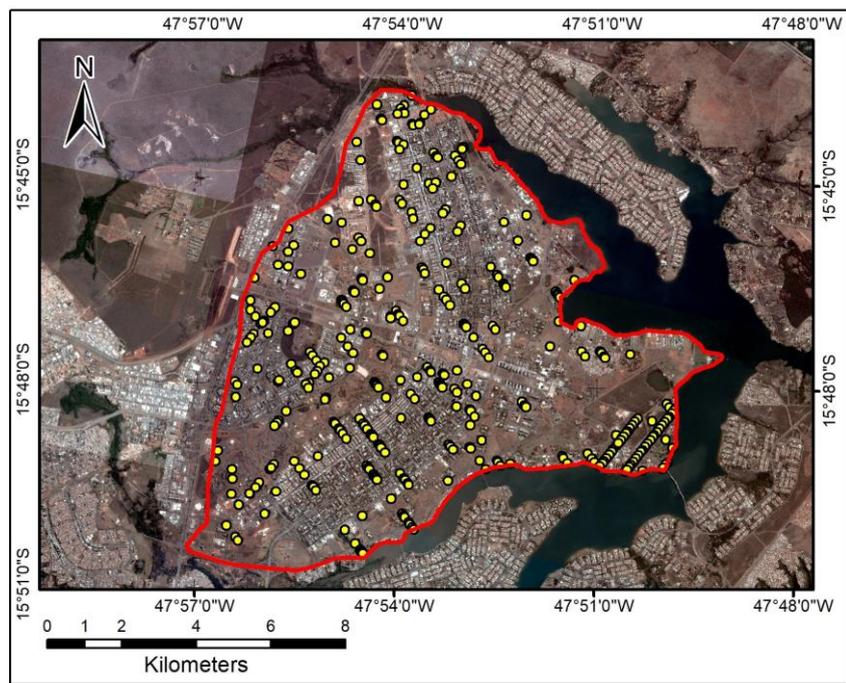


Figure 4.8. Location of the GEDI samples excluded from <100 m to <3 m thresholds. Yellow dots are the GEDI samples.

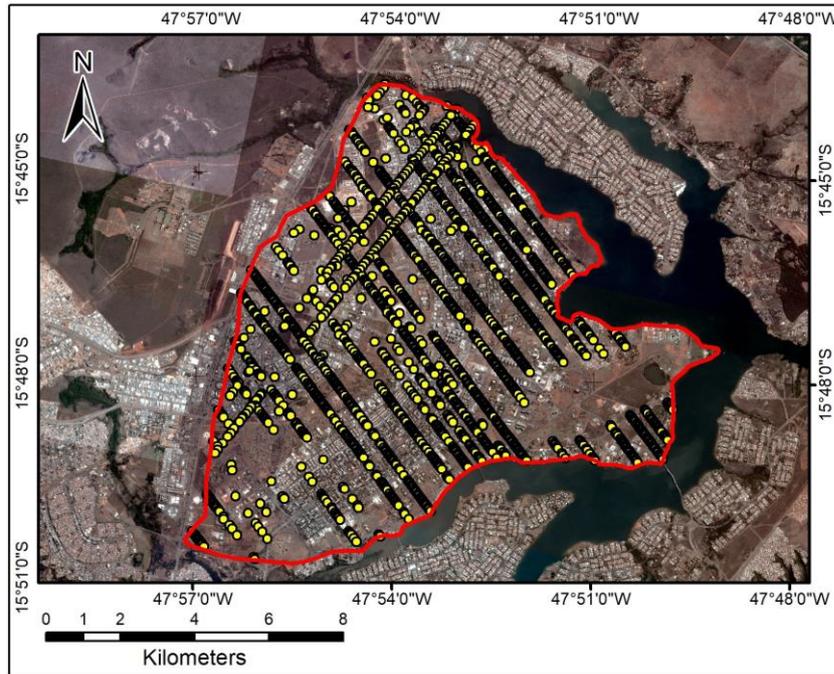


Figure 4.9. Location of the GEDI samples excluded from $<3\text{ m}</math> to $<1\text{ m}</math> threshold. Where, yellow dots are the GEDI samples.$$

4.3.2. Comparison with outlier removal by quality flag parameter and GEDI sensitivity beam data dispersion

Table 4.4 lists the number of GEDI samples, KS, and RMSE values for dh-DTM distribution after removing outliers by quality flag and the IQR threshold approach. Figure 4.10 shows its respective boxplots of dh-DTM outliers.

Table 4.4. Statistics from dh-DTM quality flag to remove outliers and its IQR threshold improvement.

	Number of GEDI footprints	Calculated KS	RMSE [m]
Total GEDI dataset	7.619	0.3098	5.946.73
Outlier removal method by quality flag	3.090	0.4965	260.46
Outlier removal method by quality flag after IQR threshold	2.883	0.0320	1.40

For the total GEDI dataset (7,619 samples), the absolute accuracy is 5,946.73 m. Even after removing all data with quality flag value "0", the RMSE value is 260.46 m, indicating high GEDI dh-DTM distribution errors (Table 4.4). Thus, we applied another step to remove remaining outliers using thresholds of 1.5 times interquartile range (IQR) minus first quartile plus third quartile, establishing a benchmark. Results indicated a better dh-DTM distribution with RMSE of 1.40 m considering 2,883 GEDI footprints (Table 4.4). The proposed outlier removal method reached 1.33 m of RMSE selecting 3,325 GEDI footprints. This result is 15.33% higher than the quality flag method benchmark in dh-DTM distribution with an absolute difference $<3\text{ m}</math>.$

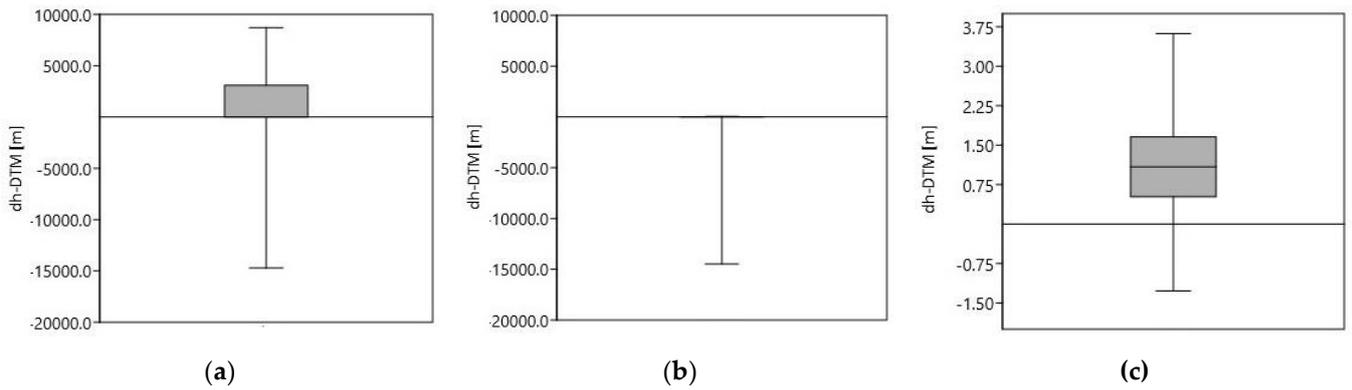


Figure 4.10. Boxplots showing the distribution of dh-DTM of total GEDI dataset and of outlier removal method using quality flag parameter. **(a)** Original distribution of dh-DTM; **(b)** Resulted distribution of dh-DTM after quality flag applied; **(c)** Removed outlier distribution of dh-DTM after applying a second step based on IQR thresholds to remove remaining outliers from distribution.

The boxplot in Figure 4.11a shows data selection using 0.9 sensitivity threshold. Figure 4.11b shows dh-DTM <3 meters in all sensitivity ranges. Those data are useful and should not be disregarded.

We divided into 2 groups the differences between GEDI footprints derived from both outlier removal methods for analysis. Group 1 represents GEDI samples present in our method but not in the dataset from the quality flat removal method (with a value equal to 1). Group 2 is the opposite. Table 4.5 lists the number of samples and RMSE from both GEDI groups. Figure 4.12 presents the spatial distribution of these GEDI groups in the study area.

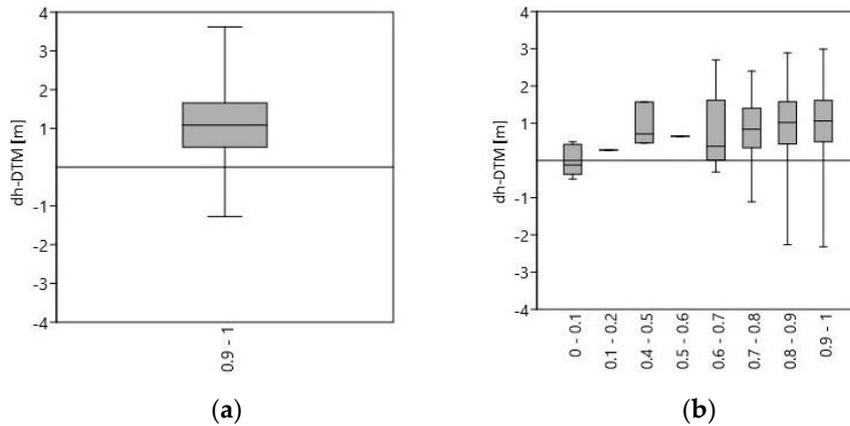


Figure 4.11. Boxplots showing the distribution of dh-DTM. Data selection with 0.9 sensitivity threshold **(a)**. Useful data along all sensitivity range **(b)**.

The results indicate that 502 GEDI samples remain when applying our method to remove outliers, reaching an RMSE value of 1.32 m suitable for use. In contrast, the quality flag removal method keeps only 60 samples (RMSE of 3.28 m). Furthermore, the proposed method did not select the 60 GEDI samples captured by the quality flag removal method because the absolute dh-DTM is greater than 3 m. As shown in Figure 4.12, the increase in useful GEDI samples can assist in the MDE

interpolation processes or even as reference points to support other terrain applications in the study area. These results reinforce the importance of statistical analysis of the Gaussian distribution before removing outliers, evidencing that the use of the quality flag parameter alone may not be sufficient to select the appropriate GEDI data. This is because the quality flag parameter disregards error distribution analysis but considers the energy, sensitivity, amplitude, and real-time surface tracking for each GEDI sample separately [27].

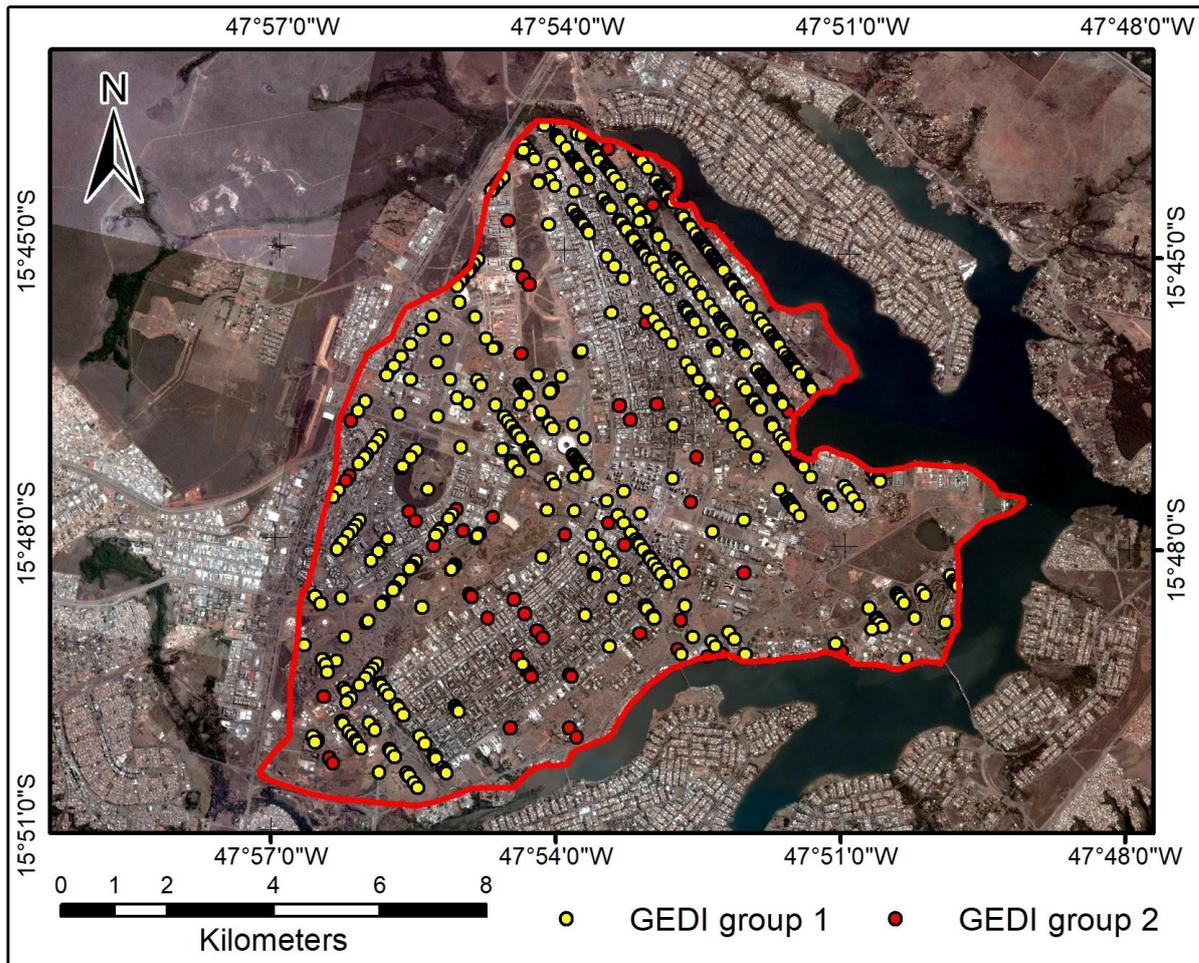


Figure 4.12. Location of GEDI footprints groups derived from both removal outlier methods. GEDI footprints from group 1 represented in yellow dots and group 2 in red dots.

Table 4.5. Statistics from GEDI footprint groups

	Number of GEDI footprints	RMSE [m]
GEDI group 1	502	1.32
GEDI group 2	60	3.28

4.4. Discussion

Atmospheric conditions and system geometries influence the GEDI data and affect its quality flag measurements [13]. Thus, all related GEDI studies have an outlier removal approach. The challenge is to find the best threshold that can separate the signal from the noise. Articles using GEDI

data determine this threshold based on the quality flag parameter. However, this procedure does not adequately consider points with low RMSE that could be used, especially in the interpolation process.

Using a quality flag threshold, Quiros et al. [28] compared GEDI data with airborne LiDAR in ten different areas with a mean slope varying between 3.4 to 25.5 degrees and found a global RMSE of 6.05 m and 1.25 in gentle relief. Guerra-Hernández and Pascual [30] applied the quality flag parameter to remove outliers and reached a total of 3,566 valid observations to assess height growth dynamics in fast-growing species in Spain. They found an RMSE value of 4.48 m, compatible with a higher canopy cover in their GEDI samples.

Spracklen and Spracklen [19] filtered outliers in data distribution in old-growth forests in Ukraine using the quality flag parameter. In addition, the authors had to apply a second step to remove outliers based on field data, establishing a threshold over 50 m in canopy heights to remove remaining outliers. Our study also had to apply a second step based on the IQR threshold to guarantee a useful dataset without extreme outlier after quality flag filtering. Kokalj and Mast [21] used GEDI data for archaeological exploration in a forest area, considering two steps to eliminate outliers: (a) visual inspection and (b) quality flag parameter followed by IQR threshold filtering. Despite obtaining an RMSE of 0.98 m, the procedure removed many GEDI samples, creating a significant data gap. Differently, our results showed similar absolute precision with a larger number of GEDI samples.

Sensitivity is an ancillary GEDI information used to optimize the outlier removal data approach, where studies use a conservative threshold equal or higher than 0.9 [17,45]. Boucher et al. [46] analyzed different sensitivity thresholds to identify ground information in various forest canopies and found that values higher than 0.95 guaranteed that 60-80% of waveform could detect true ground heights. Our results show that it is not sufficient to establish an empirical sensitivity threshold to remove GEDI outliers. The KS test has been widely used in remote sensing studies to verify data normality [42,47–52]. Especially in error removal, few studies used the KS test, but these have demonstrated improvements in different sensors [53–57]. Our approach innovates by using KS testing to analyze the error distribution and improve outlier removal, leveraging all valid GEDI data.

4.5. Conclusions

GEDI data are an important source of altimetry data used in several areas of knowledge. This study innovates by presenting an improved method to remove outliers from GEDI elevation data distribution using KS non-parametric test and absolute accuracy assessment with a reference terrain elevation derived from ALS-DTM in an urban area of Federal District, Brazil. The proposed outlier removal method was better than the method using quality flag threshold, with wide application in

GEDI-related studies. Results indicate a better absolute accuracy (RMSE of 1.33) with a reduction of 56.36% (3,325) of the total GEDI dataset, 15.33% higher than the sample reduction from the quality flag benchmark (2,883). In addition, this procedure removed low RMSE data and selected data with RMSE that would have to be discarded. Calculating KS curves according to pre-defined absolute thresholds allows us to find the optimal inflection point where the dh-DTM distribution has a normal behavior, which occurred in < 3 m. This methodology is useful for defining a threshold capable of selecting the maximum GEDI data with a low RMSE value, which is essential to overcome the global lack of altimetric data.

References

1. Ghaseminik, F.; Aghamohammadi, H.; Azadbakht, M. Land cover mapping of urban environments using multispectral LiDAR data under data imbalance. *Remote Sens. Appl. Soc. Environ.* **2021**, *21*, 100449, doi:10.1016/j.rsase.2020.100449.
2. Azadbakht, M.; Fraser, C.S.; Zhang, C. Separability of targets in urban areas using features from fullwave LiDARA data. In Proceedings of the IEEE International Geoscience and Remote Sensing Symposium (IGARSS) 2015; IEEE: Milan, Italy, 2015; pp. 5367–5370, doi: 10.1109/IGARSS.2015.7327048.
3. Yan, W.Y.; Shaker, A.; El-Ashmawy, N. Urban land cover classification using airborne LiDAR data: A review. *Remote Sens. Environ.* **2015**, *158*, 295–310, doi:10.1016/j.rse.2014.11.001.
4. Awrangjeb, M.; Fraser, C.S. Automatic segmentation of raw LiDAR data for extraction of building roofs. *Remote Sens.* **2014**, *6*, 3716–3751, doi:10.3390/rs6053716.
5. Parmehr, E.G.; Amati, M.; Taylor, E.J.; Livesley, S.J. Estimation of urban tree canopy cover using random point sampling and remote sensing methods. *Urban For. Urban Green.* **2016**, *20*, 160–171, doi:10.1016/j.ufug.2016.08.011.
6. da Cunha Neto, E.M.; Rex, F.E.; Veras, H.F.P.; Moura, M.M.; Sanquetta, C.R.; Käfer, P.S.; Sanquetta, M.N.I.; Zambrano, A.M.A.; Broadbent, E.N.; Corte, A.P.D. Using high-density UAV-LiDAR for deriving tree height of *Araucaria Angustifolia* in an Urban Atlantic Rain Forest. *Urban For. Urban Green.* **2021**, *63*, 127197, doi:10.1016/j.ufug.2021.127197.
7. Matkan, A.A.; Hajeb, M.; Sadeghian, S. Road extraction from LiDAR data using support vector machine classification. *Photogramm. Eng. Remote Sensing* **2014**, *80*, 409–422, doi:10.14358/PERS.80.5.409.
8. Li, B.; Hou, J.; Li, D.; Yang, D.; Han, H.; Bi, X.; Wang, X.; Hinkelmann, R.; Xia, J. Application of LiDAR UAV for High-Resolution Flood Modelling. *Water Resour. Manag.* **2021**, *35*, 1433–1447, doi:10.1007/s11269-021-02783-w.
9. Mahdianpari, M.; Granger, J.E.; Mohammadimanesh, F.; Warren, S.; Puestow, T.; Salehi, B.; Brisco, B. Smart solutions for smart cities: Urban wetland mapping using very-high resolution satellite imagery and airborne LiDAR data in the City of St. John's, NL, Canada. *J. Environ. Manage.* **2021**, *280*, 111676, doi:10.1016/j.jenvman.2020.111676.
10. Terrone M.; Paliaga G.; Piana P.; Faccini F. Coupling historical maps and LiDAR data to recognize man-made landforms in urban areas. *ISPRS Int. J. Geo-Information* **2021**, *10*, 1–17, doi:10.3390/ijgi10050349.
11. Chen, Z.; Devereux, B.; Gao, B.; Amable, G. Upward-fusion urban DTM generating method using airborne LiDAR data. *ISPRS J. Photogramm. Remote Sens.* **2012**, *72*, 121–130, doi:10.1016/j.isprsjprs.2012.07.001.
12. Polat, N.; Uysal, M.; Toprak, A.S. An investigation of DEM generation process based on LiDAR data filtering, decimation, and interpolation methods for an urban area. *Measurement* **2015**, doi:10.1016/j.measurement.2015.08.008.
13. Dubayah, R.; Blair, J.B.; Goetz, S.; Fatoyinbo, L.; Hansen, M.; Healey, S.; Hofton, M.; Hurtt, G.; Kellner, J.; Luthcke, S.; et al. The Global Ecosystem Dynamics Investigation: High-resolution laser ranging of the Earth's forests and topography. *Sci. Remote Sens.* **2020**, *1*, 100002, doi:10.1016/j.srs.2020.100002.
14. Garvin, J.; Bufton, J.; Blair, J.; Harding, D.; Luthcke, S.; Frawley, J.; Rowlands, D. Observations of the earth's topography from the Shuttle Laser Altimeter (SLA): Laser-pulse echo-recovery measurements of terrestrial surfaces. *Phys. Chem. Earth* **1998**, *23*, 1053–1068, doi:10.1016/S0079-1946(98)00145-1.
15. Schutz, B.E.; Zwally, H.J.; Shuman, C.A.; Hancock, D.; DiMarzio, J.P. Overview of the ICESat mission.

- Geophys. Res. Lett.* **2005**, *32*, 1–4, doi:10.1029/2005GL024009.
16. Abdalati, W.; Zwally, H.J.; Bindschadler, R.; Csatho, B.; Farrell, S.L.; Fricker, H.A.; Harding, D.; Kwok, R.; Lefsky, M.; Markus, T.; et al. The ICESat-2 laser altimetry mission. *Proc. IEEE* **2010**, *98*, 735–751, doi:10.1109/JPROC.2009.2034765.
 17. Rishmawi, K.; Huang, C.; Zhan, X. Monitoring key forest structure attributes across the conterminous United States by integrating GEDI LiDAR measurements and VIIRS data. *Remote Sens.* **2021**, *13*, 1–23, doi:10.3390/rs13030442.
 18. Chen, L.; Ren, C.; Zhang, B.; Wang, Z.; Liu, M.; Man, W.; Liu, J. Improved estimation of forest stand volume by the integration of GEDI LiDAR data and multi-sensor imagery in the Changbai Mountains Mixed forests Ecoregion (CMMFE), northeast China. *Int. J. Appl. Earth Obs. Geoinf.* **2021**, *100*, 102326, doi:10.1016/j.jag.2021.102326.
 19. Spracklen, B.; Spracklen, D. V Determination of Structural Characteristics of Old-Growth Forest in Ukraine Using Spaceborne LiDAR. *Remote Sens.* **2021**, *13*, 1–21, doi:10.3390/rs13071233.
 20. Dorado-rodá, I.; Godinho, S.; Silva, C.A.; Botequim, B.; Rodriguez-Gonzalez, P.; Gonzalez-Ferreiro, E.; Guerra-Hernandez, J. Assessing the Accuracy of GEDI Data for Canopy Height and Aboveground Biomass Estimates in Mediterranean Forests. *Remote Sens.* **2021**, *13*, 1–20, doi:10.3390/rs13122279.
 21. Kokalj, Ž.; Mast, J. Space LiDAR for archaeology? Reanalyzing GEDI data for detection of ancient Maya buildings. *J. Archaeol. Sci. Reports* **2021**, *36*, doi:10.1016/j.jasrep.2021.102811.
 22. Ni, W.; Zhang, Z.; Sun, G. Assessment of slope-adaptive metrics of GEDI waveforms for estimations of forest aboveground biomass over mountainous areas. *J. Remote Sens.* **2021**, *2021*, 1–17, doi:10.34133/2021/9805364.
 23. Roy, D.P.; Kashongwe, H.B.; Armston, J. The impact of geolocation uncertainty on GEDI tropical forest canopy height estimation and change monitoring. *Sci. Remote Sens.* **2021**, *4*, 100024, doi:10.1016/j.srs.2021.100024.
 24. Tan, P.; Zhu, J.; Fu, H.; Wang, C.; Liu, Z.; Zhang, C. Sub-Canopy Topography Estimation from TanDEM-X DEM by Fusing ALOS-2 PALSAR-2 InSAR Coherence and GEDI Data. *Sensors* **2020**, *20*, 1–15, doi:10.3390/s20247304.
 25. Adam, M.; Urbazaev, M.; Dubois, C.; Schmillius, C. Accuracy assessment of GEDI terrain elevation and canopy height estimates in European temperate forests: Influence of environmental and acquisition parameters. *Remote Sens.* **2020**, *12*, 1–28, doi:10.3390/rs12233948.
 26. Fayad, I.; Baghdadi, N.; Bailly, J.S.; Frappart, F.; Zribi, M. Analysis of GEDI elevation data accuracy for inland waterbodies altimetry. *Remote Sens.* **2020**, *12*, doi:10.3390/RS12172714.
 27. Hofton, M.; Blair, B.; Story, S.; Yi, D. *Algorithm Theoretical Basis Document (ATBD) for GEDI Transmit and Receive Waveform Processing for L1 and L2 Products*; Goddard Space Flight Center: Greenbelt, MD, USA, 2019; Available online: <https://gedi.umd.edu/data/documents/> (accessed on 01 September 2019).
 28. Quiros, E.; Polo, M.-E.; Fragoso-Campon, L. GEDI Elevation Accuracy Assessment: A Case Study of Southwest Spain. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.* **2021**, 1–17, doi:10.1109/jstars.2021.3080711.
 29. Liu, A.; Cheng, X.; Chen, Z. Performance evaluation of GEDI and ICESat-2 laser altimeter data for terrain and canopy height retrievals. *Remote Sens. Environ.* **2021**, *264*, 112571, doi:10.1016/j.rse.2021.112571.
 30. Guerra-Hernández, J.; Pascual, A. Using GEDI LiDAR data and airborne laser scanning to assess height growth dynamics in fast-growing species: a showcase in Spain. *For. Ecosyst.* **2021**, *8*, doi:10.1186/s40663-021-00291-2.
 31. Hancock, S.; Armston, J.; Hofton, M.; Sun, X.; Tang, H.; Duncanson, L.I.; Kellner, J.R.; Dubayah, R. The GEDI Simulator: A Large-Footprint Waveform LiDAR Simulator for Calibration and Validation of Spaceborne Missions. *Earth Sp. Sci.* **2019**, *6*, 294–310, doi:10.1029/2018EA000506.
 32. Zandbergen, P.A. Characterizing the error distribution of LiDAR elevation data for North Carolina. *Int. J. Remote Sens.* **2011**, *32*, 409–430, doi:10.1080/01431160903474939.
 33. Oksanen, J.; Sarjakoski, T. Uncovering the statistical and spatial characteristics of fine toposcale DEM error. *Int. J. Geogr. Inf. Sci.* **2006**, *20*, 345–369, doi:10.1080/13658810500433891.
 34. Fisher, P. Improved modeling of elevation error with Geostatistics. *Geoinformatica* **1998**, *2*, 215–233, doi:10.1023/A:1009717704255.
 35. Lopez, C. Improving the elevation accuracy of digital elevation models: A comparison of some error detection procedures. *Trans. GIS* **2000**, *4*, 43–64, doi:10.1111/1467-9671.00037.
 36. Bonin, O.; Rousseaux, F. Digital terrain model computation from contour lines: How to derive quality information from artifact analysis. *Geoinformatica* **2005**, *9*, 253–268, doi:10.1007/s10707-005-1284-2.
 37. Governo do Distrito Federal (GDF) *Zoneamento Ecológico-Econômico do Distrito Federal (ZEE/DF): Matriz Socioeconômica*; GDF: Brasília-DF, 2017; Available online: <http://www.zee.df.gov.br/> (accessed on 01

- September 2019).
38. Luthcke, S.B.; Rebold, T.; Thomas, T.; Pennington, T. *Algorithm Theoretical Basis Document (ATBD) for GEDI Waveform Geolocation for L1 and L2 Products*; Goddard Space Center: Greenbelt, MD, USA, 2019; Available online: https://lpdaac.usgs.gov/documents/579/GEDI_WFGEO_ATBD_v1.0.pdf (accessed on 01 September 2019)
 39. Tang, H.; Armston, J. *Algorithm Theoretical Basis Document (ATBD) for GEDI L2B Footprint Canopy Cover and Vertical Profile Metrics*; Goddard Space Flight Center: Greenbelt, MD, USA, 2019; Available online: https://lpdaac.usgs.gov/documents/588/GEDI_FCCVPM_ATBD_v1.0.pdf (accessed on 01 September 2019).
 40. Blitzkow, D.; de Matos, A.C.O.C.; Machado, W.C.; Nunes, M.A.; Lengrubler, N.V.; Xavier, E.M.L.; Fortes, L.P.S. MAPGEO2015: the New Geoidal Undulation Model of Brazil. *Rev. Bras. Cartogr.* **2016**, *68*, 1873–1884.
 41. Corder, G.W.; Foreman, D.I. *Nonparametric Statistics for Non-statisticians: A Step-by-Step Approach*; John Wiley & Sons, 2011; ISBN 9780470454619.
 42. Czajlik, Z.; Árvai, M.; Mészáros, J.; Nagy, B.; Rupnik, L.; Pásztor, L. Cropmarks in aerial archaeology: New lessons from an old story. *Remote Sens.* **2021**, *13*, 1–17, doi:10.3390/rs13061126.
 43. Razali, N.M.; Wah, Y.B. Power comparisons of Shapiro-Wilk, Kolmogorov-Smirnov, Lilliefors and Anderson-Darling tests. *J. Stat. Model. Anal.* **2011**, *2*, 13–14.
 44. Gdulová, K.; Marešová, J.; Moudrý, V. Accuracy assessment of the global TanDEM-X digital elevation model in a mountain environment. *Remote Sens. Environ.* **2020**, *241*, 111724, doi:10.1016/j.rse.2020.111724.
 45. Potapov, P.; Li, X.; Hernandez-Serna, A.; Tyukavina, A.; Hansen, M.C.; Kommareddy, A.; Pickens, A.; Turubanova, S.; Tang, H.; Silva, C.E.; et al. Mapping global forest canopy height through integration of GEDI and Landsat data. *Remote Sens. Environ.* **2021**, *253*, 112165, doi:10.1016/j.rse.2020.112165.
 46. Boucher, P.B.; Hancock, S.; Orwig, D.A.; Duncanson, L.; Armston, J.; Tang, H.; Krause, K.; Cook, B.; Paynter, I.; Li, Z.; et al. Detecting change in forest structure with simulated GEDI LiDAR waveforms: A case study of the hemlock woolly adelgid (HWA; adelges tsugae) infestation. *Remote Sens.* **2020**, *12*, 1304, doi:10.3390/RS12081304.
 47. Dial, R.; Chaussé, P.; Allgeier, M.; Smeltz, S.; Golden, T.; Day, T.; Wong, R.; Andersen, H.E. Estimating net primary productivity (Npp) and debris-fall in forests using lidar time series. *Remote Sens.* **2021**, *13*, 1–17, doi:10.3390/rs13050891.
 48. Silva Junior, J.A.; Pacheco, A.D.P. Avaliação de incêndio em ambiente de Caatinga a partir de imagens Landsat-8, índice de vegetação realçado e análise por componentes principais. *Ciência Florest.* **2021**, *31*, 417–439, doi:10.5902/1980509843818.
 49. Wang, T.; Yu, P.; Wu, Z.; Lu, W.; Liu, X.; Li, Q.P.; Huang, B. Revisiting the Intraseasonal Variability of Chlorophyll-a in the Adjacent Luzon Strait With a New Gap-Filled Remote Sensing Data Set. *IEEE Trans. Geosci. Remote Sens.* **2021**, 1–11, doi:10.1109/TGRS.2021.3067646.
 50. Contador, T.M.; Alcântara, E.; Rodrigues, T.; Park, E. Remote sensing of water transparency variability in the Ibitinga reservoir during COVID-19 lockdown. *Remote Sens. Appl. Soc. Environ.* **2021**, *22*, doi:10.1016/j.rsase.2021.100511.
 51. Luiz, A.J.B.; Lima, M.A. de Application of the Kolmogorov-Smirnov Test To Compare Greenhouse Gas Emissions Over Time. *Rev. Bras. Biometria* **2021**, *39*, 60–70, doi:10.28951/rbb.v39i1.498.
 52. Tariq, A.; Shu, H.; Kuriqi, A.; Siddiqui, S.; Gagnon, A.S.; Lu, L.; Thi, N.; Linh, T.; Pham, Q.B. Characterization of the 2014 Indus River Flood Using Hydraulic Simulations and Satellite Images. *Remote Sens.* **2021**, *13*, 2053, doi:https://doi.org/10.3390/rs13112053.
 53. Baier, G.; He, W.; Yokoya, N. Robust Nonlocal Low-Rank SAR Time Series Despeckling Considering Speckle Correlation by Total Variation Regularization. *IEEE Trans. Geosci. Remote Sens.* **2020**, *58*, 7942–7954, doi:10.1109/TGRS.2020.2985400.
 54. Broadwater, J.B.; Chellappa, R. Adaptive threshold estimation via extreme value theory. *IEEE Trans. Signal Process.* **2010**, *58*, 490–500, doi:10.1109/TSP.2009.2031285.
 55. Lakshmanan, V.; DeBrunner, V.; Rabin, R. Texture-based segmentation of satellite weather imagery. *IEEE Int. Conf. Image Process.* **2000**, *2*, 732–735, doi:10.1109/icip.2000.899813.
 56. Aguilar, F.J.; Mills, J.P. Accuracy Assessment of LiDAR-Derived Digital. *Photogrammetric Rec.* **2008**, *23*, 148–169, doi:10.1111/j.1477-9730.2008.00476.x.
 57. Gómez Giménez, M.; de Jong, R.; Della Peruta, R.; Keller, A.; Schaepman, M.E. Determination of grassland use intensity based on multi-temporal remote sensing data and ecological indicators. *Remote Sens. Environ.* **2017**, *198*, 126–139, doi:10.1016/j.rse.2017.06.003.

5. CONCLUSÕES

A importância de um planejamento urbano mais dinâmico e sustentável demanda o uso das novas tecnologias disponíveis na área do sensoriamento remoto, observando as diferentes escalas de análise.

Inicialmente, os resultados da presente pesquisa permitiram aprofundar o conhecimento sobre a aplicação de série temporal de imagens SAR para a elaboração de mapa de uso e cobertura da terra, especialmente considerando os objetos urbanos. Foi apresentada uma abordagem metodológica utilizando a intensidade e a coerência interferométrica de imagens SAR/Sentinel 1 em série temporal. Os resultados indicaram uma melhora nas métricas de acurácia Kappa (0,50 a 0,75) e F1 (0,54 a 0,79), principalmente na identificação das classes relacionadas à cobertura vegetal e a área urbana. Constatou-se que a coerência interferométrica utilizada em série temporal garantiu uma melhor estratificação de diferentes níveis de densidade vegetacional e, especialmente, da classe urbana, no qual foi possível mapear a mancha urbana e os objetos urbanos. A coerência interferométrica analisada em série temporal permitiu detalhar o mapeamento da classe urbana devido a identificação do efeito *double bounce* no sinal SAR de retorno, comum em áreas com predomínio de ângulos diedrais. Assim, o método proposto refina o mapeamento dessa importante classe temática presente nos mais diversos mapeamentos de uso e ocupação da terra em ambiente urbano e contribui diretamente no enriquecimento do processo de planejamento urbano realizado em escala regional.

Porém cabe ressaltar que, apesar das potencialidades identificadas e da facilidade e gratuidade de acesso às imagens SAR do satélite Sentinel 1, a capacidade de armazenamento e processamento da infraestrutura informacional utilizada é um limitador para a aplicação do método proposto. Para tanto, novas soluções devem ser desenvolvidas no intuito de garantir o aprimoramento e otimização das etapas metodológicas realizadas.

Por sua vez, e considerando a escala local do planejamento urbano, a pesquisa apresentou potencialidades e limitações do uso de informações provenientes de LiDAR aerotransportado e orbital em aplicações altimétricas (discreta e *waveform*). Foi apresentada uma abordagem metodológica para a estimativa das ASH em escala local no ambiente urbano a partir de intervalos do índice ITU, derivado de um modelo ALS LiDAR. Constatou-se que, a depender da finalidade, a influência dos objetos urbanos na microtopografia pode ser um obstáculo para a estimativa da convergência do fluxo de água, principalmente em uma escala

mais regional. Ademais, observou-se também a influência da cobertura vegetal na densidade de pontos amostrais ALS LiDAR, o que ocasionou uma perda de qualidade do MDE gerado e, subsequentemente, a necessidade de preenchimento de depressões visando garantir o escoamento de fluxo no modelo. Esse efeito alterou a declividade nessas áreas e influenciou diretamente a delimitação das ASH no terreno. Assim, novas metodologias necessitam ser aperfeiçoadas visando suavizar a influência dos objetos urbanos e da cobertura vegetal no levantamento e na modelagem de dados ALS LiDAR. Para tanto, pode ser necessário a aplicação de filtros específicos, o estudo da influência da redução da nuvem de pontos amostrais no processo de interpolação e geração do MDE, ou mesmo, a incorporação das propriedades hidrológicas de solo na estimativa das ASH, uma vez que o método utilizado considerou apenas o controle topográfico.

Também foi apresentado uma avaliação da acurácia altimétrica nos dados orbitais GEDI recém lançados e propôs um método aprimorado de remoção de *outlier* utilizando a curva de distribuição normal. Os resultados apresentaram uma acurácia RMSE de 1,33 m considerando uma redução de 56,36% do total de dados GEDI disponíveis, 15,33% maior que a redução considerando o indicador *quality flag* sugerido pela literatura correlata. Ademais, o procedimento de eliminação de *outliers* adotando o indicador *quality flag* removeu dados úteis da amostra. A metodologia proposta é útil em definir o limiar ótimo capaz de selecionar o maior quantitativo de dados de terreno GEDI com os maiores valores de acurácia altimétrica absoluta.

O planejamento urbano demanda soluções tecnológicas e informacionais que variam de acordo com sua escala de elaboração. Nesse sentido, os resultados indicaram que na escala regional, para o qual o foco é a elaboração dos mapas de uso e ocupação da terra, a análise em série temporal de imagens SAR/Sentinel 1 são um importante ferramental que podem auxiliar no entendimento e nas decisões sobre o espaço urbano. Na escala local, por sua vez, os resultados indicam que as novas informações dos sistemas LiDAR disponíveis no mercado garantem informações mais acuradas do relevo e de sua topografia local. Esse combinado de possibilidades permite aos ritos de planejamento territorial um maior e mais fidedigno conhecimento da realidade local urbana de forma rápida e, no caso das informações GEDI, gratuita. Porém, suas limitações devem ser consideradas caso a caso e novas metodologias devem ser desenvolvidas com o objetivo de garantir sua utilização de forma mais eficiente possível.

ANEXO



Caminhos de Geografia

EDUFU

ISSN: 1678-6343

*Revista do Programa de Pós-graduação em Geografia da
Universidade Federal de Uberlândia - UFU*

DECLARAÇÃO

Declaramos que o artigo "**POTENCIALIDADES E LIMITAÇÕES DO USO DE INFORMAÇÕES ALTIMÉTRICAS PROVENIENTES DE PERFILAMENTO À LASER EM AMBIENTE URBANO**" de autoria de Felipe Lima Ramos Barbosa, Renato Fontes Guimarães, Osmar Abílio de Carvalho Júnior, Roberto Arnaldo Trancoso Gomes e Erondina Azevedo de Lima foi aceito para publicação na Revista Caminhos de Geografia (ISSN 1678-6343).

Por ser verdade, firmamos abaixo.

Uberlândia, 02 de setembro de 2021.

Prof. Dr. Paulo Cezar Mendes
Caminhos de Geografia
Editor Chefe