



UNIVERSIDADE FEDERAL DE PERNAMBUCO  
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E  
TECNOLOGIAS DA GEOINFORMAÇÃO

MARIA LUCIANA DA SILVA

**CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO UTILIZANDO IMAGENS  
AÉREAS, PRODUTOS LIDAR, ÍNDICES DE VEGETAÇÃO E RAZÃO DE BANDAS**

Recife  
2020

MARIA LUCIANA DA SILVA

**CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO UTILIZANDO IMAGENS  
AÉREAS, PRODUTOS LIDAR, RAZÃO DE BANDAS E ÍNDICES DE VEGETAÇÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

**Área de concentração:** Cartografia e Sistemas de Geoinformação

**Orientador:** Prof<sup>a</sup>. Dr<sup>a</sup> Ana Lúcia Bezerra Candeias

Recife

2020

Catalogação na fonte  
Bibliotecário Gabriel Luz, CRB-4 / 2222

S586c Silva, Maria Luciana da.  
Classificação da cobertura do solo urbano utilizando imagens aéreas, produtos LIDAR, índices de vegetação e razão de bandas / Maria Luciana da Silva – Recife, 2020.  
90 f.: figs., gráfs., abrev. e siglas.  
Orientadora: Profa. Dra. Ana Lúcia Bezerra Candeias.  
Dissertação (Mestrado) – Universidade Federal de Pernambuco.  
CTG. Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, 2020.  
Inclui referências e apêndices.  
1. Ciências Geodésicas. 2. Classificação de imagens. 3. Solo urbano.  
4. Aritmética de bandas. 5. Altimetria. I. Candeias, Ana Lúcia Bezerra (Orientadora). II. Título.

UFPE

526.1 CDD (22. ed.)

BCTG / 2020-116

MARIA LUCIANA DA SILVA

**CLASSIFICAÇÃO DA COBERTURA DO SOLO URBANO UTILIZANDO IMAGENS  
AÉREAS, PRODUTOS LIDAR, RAZÃO DE BANDAS E ÍNDICES DE VEGETAÇÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação, da Universidade Federal de Pernambuco, como requisito parcial para obtenção do grau de Mestre em Ciências Geodésicas e Tecnologias da Geoinformação.

Aprovada em: 18/02/2020

**BANCA EXAMINADORA**

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Ana Lúcia Bezerra Candeias (Orientador)  
Universidade Federal de Pernambuco

---

Prof<sup>o</sup>. Dr. João Rodrigues Tavares Júnior (Examinador Interno)  
Universidade Federal de Pernambuco

---

Prof<sup>a</sup>. Dr<sup>a</sup>. Sylvana Melo dos Santos  
Universidade Federal de Pernambuco (Examinador Externo)

Dedico este trabalho, com todo o meu amor e gratidão, aos meus queridos pais,  
Antônio José e Maria Lúcia, e ao meu amado esposo, Walber Santana.

## AGRADECIMENTOS

A Deus, por me agraciar, mesmo que imerecidamente. Por conduzir as minhas decisões e possibilitar que coisas boas me aconteçam. Por todo o universo que nos foi dado de presente. Pelos perigos dos quais Ele me livra todos os dias. Pelas pessoas com as quais tenho o privilégio de dividir a vida. Em resumo, por todas as ações divinas que me trouxeram até aqui.

Aos meus queridos pais, Maria Lúcia e Antônio José, pelo inestimável apoio durante a realização deste trabalho e em todas as ocasiões da minha vida. Mesmo sem terem escrito sequer uma palavra deste texto e não entenderem do que exatamente ele trata, vocês construíram o alicerce para todas as minhas conquistas, inclusive esta. Nunca conseguirei retribuir integralmente todo o amor e generosidade de vocês por mim. O mérito deste trabalho não é somente meu, mas de vocês também.

Ao meu amado esposo e melhor amigo, Walber Santana, por todo o amor, por acolher os meus projetos de vida e vivê-los junto comigo, por ser o meu maior incentivador e por planejar com tanto zelo o nosso futuro. Obrigada por dividir a vida comigo e me fazer tão feliz. A conclusão deste trabalho é uma conquista nossa.

Aos meus queridos irmãos, Antônio Carlos e Antoniel José, os quais foram os meus primeiros amigos e influenciadores. Tive a sorte de compartilhar com vocês uma infância da qual ainda guardo vestígios. O que sou hoje tem uma parcela de contribuição de cada um. Obrigada por todo amor, cuidado e proteção.

A toda minha família, pela grande torcida e confiança.

À professora Ana Lúcia, pela orientação nesta pesquisa, pelo acréscimo na minha vida profissional, por toda compreensão, carinho e amizade.

Aos professores João Rodrigues, Karoline Paes, Lígia Albuquerque e Sylvana Melo, pelas contribuições durante as participações nas bancas de avaliação desta pesquisa.

À professora Andréa de Seixas, coordenadora do programa de Pós-Graduação, por todo o acolhimento, esclarecimento e amizade.

À funcionária Elizabeth Galdino, pela gentileza e solicitude no atendimento as demandas dos mestrandos.

Ao programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação (PPGCGTG), professores e demais funcionários, pelo aporte durante a realização do mestrado.

À Prefeitura da Cidade do Recife, pela concessão dos dados para a realização desta pesquisa. Em especial ao Analista de Desenvolvimento Urbano, Aurélio Lúcio, pela gentileza e solicitude no atendimento.

Ao Laboratório de Sensoriamento Remoto (LASENSO), pela disponibilidade da estrutura e equipamentos para o desenvolvimento da pesquisa.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo aporte financeiro.

## RESUMO

Os espaços urbanos são compostos, majoritariamente, por objetos de pequena dimensão e com relações complexas entre si, de modo que para a classificação do seu solo é exigido imageamento de alta resolução. Entretanto, os métodos tradicionais de extração de informações em imagens de alta resolução, sejam de nível aéreo ou orbital, ainda apresentam algumas limitações. A fotoanálise acrescida da vetorização em tela, embora seja o método mais adotado para a extração de informações urbanas em imagens de alta resolução, pode ter a sua aplicação prejudicada por objetos com contornos complexos, pela subjetividade da interpretação do analista e pelo tempo de trabalho demandado para grandes áreas. Ademais, os métodos tradicionais de classificação de imagens digitais, embora reduzam ou eliminem os problemas da fotoanálise, também apresentam limitações para a classificação do solo urbano com imagem de alta resolução, devido à informação espectral contida nessas imagens não ser suficiente para discriminar os alvos. Esse problema pode ser contornado utilizando camadas auxiliares com atributos de diferentes fontes, os quais viabilizam a discriminação de classes espectralmente semelhantes. Diante do exposto, este trabalho propõe uma análise conjunta de imagens aéreas, modelos do terreno e imagens provenientes de operações aritméticas, para o reconhecimento de padrões nos dados e classificação do solo urbano. Para a realização dos experimentos, nos softwares QGIS e SPRING, foram utilizados Modelo Digital do Terreno, Modelo Digital de Elevação, bandas espectrais de ortofoto com GSD de 8cm e imagem de intensidade. O desenvolvimento da pesquisa teve início com a aquisição de amostras de classes, a partir da qual iniciou-se o reconhecimento de padrões nos dados para a definição de limiares. Foram investigadas as razões de bandas S1 e S2 e os índices de vegetação GLI, VARI, RGBVI e GRVI, cujas equações utilizam apenas as bandas do visível. Os principais resultados apontaram que: i) a variável intensidade pode revelar propriedades hídricas que subsidiem estudos mais específicos de composição da água; ii) as aritméticas de bandas na faixa do visível, quando aplicadas às imagens de alta resolução, além de realçarem a vegetação, servem para identificar alguns tipos de telhados; iii) as operações S1, GLI e RGBVI são potenciais para classificação da cobertura vegetacional urbana; iv) as operações VARI e GRVI são potenciais para a classificação da cobertura edificacional do tipo telhado de cerâmica, sem fazer distinção quanto ao seu estado de conservação; v) a variável altimetria é potencial

para discriminar classes que possuem respostas espectrais semelhantes; vi) a classificação por máxima verossimilhança, quando aplicada em recortes com classes de sutis variações espectrais, viabiliza a discriminação dessas classes. Por fim, foram classificadas dez classes de alvos, a saber: cobertura vegetacional de baixo porte, cobertura vegetacional de médio porte, cobertura vegetacional de grande porte, telhado cinza claro, telhado cinza escuro, telhado de cerâmica vermelho, telhado de cerâmica marrom, solo exposto, cobertura hídrica e cobertura pavimentada.

**Palavras-chave:** Classificação de imagens. Solo urbano. Aritmética de bandas. Altimetria.

## ABSTRACT

Urban spaces are mostly composed of small objects and with complex relationships with each other, so that the classification of your soil requires high resolution imaging. However, traditional methods of extracting information from high resolution images, whether aerial or orbital, still have some limitations. Photoanalysis plus vectorization on screen, although it is the most adopted method for the extraction of urban information in high resolution images, may have its application impaired by objects with complex contours, by the subjectivity of the analyst's interpretation and by the time required for work for large areas. In addition, traditional methods of classifying digital images, although they reduce or eliminate the problems of photoanalysis, also present limitations for the classification of urban soil with high-resolution images, due to the spectral information contained in these images not being sufficient to discriminate targets. This problem can be overcome by using auxiliary layers with attributes from different sources, which enable the discrimination of spectrally similar classes. Given the above, this work proposes a joint analysis of aerial images, terrain models and images from arithmetic operations, for the recognition of patterns in the data and classification of urban soil. In order to carry out the experiments, using the QGIS and SPRING *software*, Digital Terrain Model, Digital Elevation Model, orthophoto spectral bands with 8 cm GSD and intensity image were used. The development of the research started with the acquisition of samples of classes, from which the recognition of patterns in the data for the definition of thresholds began. The S1 and S2 band ratios and the GLI, VARI, RGBVI and GRVI vegetation indices were investigated, whose equations use only the visible bands. The main results showed that: i) the intensity variable can reveal water properties that support more specific studies of water composition; ii) the band arithmetic in the visible range, when applied to high resolution images, in addition to enhancing vegetation, serve to identify some types of roofs; iii) operations S1, GLI and RGBVI are potential for classifying urban vegetation cover; iv) the VARI and GRVI operations are potential for the classification of the building cover of the ceramic roof type, without making any distinction regarding its state of conservation; v) the altimetry variable is potential to discriminate classes that have similar spectral responses; vi) the classification by maximum likelihood, when applied to cuttings with classes of subtle spectral variations, enables the discrimination of these classes. Finally, ten target classes were classified, namely: low vegetation cover,

medium vegetation cover, large vegetation cover, light gray roof, dark gray roof, red ceramic roof, brown ceramic roof, soil exposed, water cover and paved cover.

**Keywords:** Image classification. Urban soil. Band arithmetic. Altimetry.

## LISTA DE FIGURAS

Figura 1 - Ilustração da classificação pelo método da Distância Euclidiana. ....	24
Figura 2 - Ilustração da definição de limiar na classificação por máxima verossimilhança.....	25
Figura 3 - Componentes básicos de um sistema LSA.....	28
Figura 4 - Processo de reflexão do pulso de laser. ....	29
Figura 5 - Área teste .....	35
Figura 6 - Bandas espectrais da ortofoto.....	36
Figura 7 - Imagem de intensidade.....	37
Figura 8 - Modelos do terreno. ....	37
Figura 9 - Níveis de Classificação. ....	39
Figura 10 - Distribuição das amostras de pontos. ....	41
Figura 11 - Área teste para a validação dos intervalos de univocidade espectral....	44
Figura 12 - Razão de bandas.....	49
Figura 13 - Índices de vegetação. ....	49
Figura 14 - Razão de bandas reclassificada para a forma binária como limiar de vegetação. ....	58
Figura 15 - Índices reclassificados para a forma binária.....	58
Figura 16 - Teste dos limiares espectrais de cobertura vegetacional em outra área de estudo. ....	61
Figura 17 - Teste dos limiares espectrais de cobertura edificacional em outra área de estudo. ....	62
Figura 18 - Rede semântica para a discriminação das classes urbanas (parte 1) ...	64
Figura 19 - Rede semântica para a discriminação das classes urbanas (parte 2) ...	65
Figura 20 - Classificação da cobertura vegetacional. ....	66
Figura 21 - Recorte 1 para análise da classificação da vegetação. ....	67
Figura 22 - Recorte 2 para a análise da classificação da vegetação. ....	68
Figura 23 - Classificação da vegetação em função da altura. ....	69
Figura 24 - Classificação da cobertura hídrica em função do MDE. ....	70
Figura 25 - Classificação da cobertura hídrica em função do MDT. ....	70
Figura 26 - Níveis de classificação da cobertura edificacional.....	72
Figura 27 - Classificação da cobertura pavimentada e do solo exposto. ....	73

Figura 28 - Classificação da cobertura do solo urbano utilizando camadas auxiliares.....	74
Figura 29 - Classificação por distância euclidiana.....	75
Figura 30 - Classificação por Máxima Verossimilhança. ....	76

## LISTA DE GRÁFICOS

Gráfico 1 - Contraste intraclasse da cobertura edificacional.....	46
Gráfico 2 - Contraste intraclasse da cobertura hídrica.....	46
Gráfico 3 - Contraste intraclasse da cobertura pavimentada.....	47
Gráfico 4 - Contraste intraclasse do solo exposto. ....	47
Gráfico 5 - Contraste intraclasse da cobertura vegetacional. ....	48
Gráfico 6 - Contraste intraclasse da cobertura edificacional nos índices de vegetação. ....	50
Gráfico 7 - Contraste intraclasse da cobertura hídrica nos índices de vegetação.....	51
Gráfico 8 - Contraste intraclasse da cobertura edificacional nos índices de vegetação. ....	51
Gráfico 9 - Contraste intraclasse do solo exposto nos índices de vegetação. ....	52
Gráfico 10 - Contraste intraclasse da cobertura vegetacional nos índices de vegetação. ....	52
Gráfico 11 - Dispersão dos pontos no índice S1. ....	53
Gráfico 12 - Dispersão dos pontos no índice RGBVI.....	54
Gráfico 13 - Dispersão dos pontos no índice GLI.....	54
Gráfico 14 - Dispersão dos pontos no índice S2. ....	55
Gráfico 15 - Dispersão dos pontos no índice VARI. ....	56
Gráfico 16 - Dispersão dos pontos no índice GRVI. ....	56

## LISTA DE ABREVIATURAS E SIGLAS

GLI	GREN LEAF INDEX
GPS	GLOBAL POSITION SYSTEM
GRVI	GREEN-RED VEGETATION INDEX
IMU	INERTIAL MEASURE UNIT
LIDAR	LIGHT DETECTION AND RANGING
LSA	LASER SCANNER AEROTRANSPORTADO
MDE	MODELO DIGITAL DE ELEVAÇÃO
MDT	MODELO DIGITAL DO TERRENO
OBIA	OBJECT-BASED IMAGE ANALYSIS
RGBVI	RED GREEN BLUE VEGETATION INDEX
SAM	SPECTRAL ANGLE MAPPER
SMD	STOCHASTIC MINIMUM DISTANCE
SSA2	SETOR DE SUSTENTABILIDADE AMBIENTAL 2
SVM	SUPPORT VECTOR MACHINE
VANT	VEÍCULOS AÉREOS NÃO TRIPULADOS
VARI	VISIBLE ATMOSPHERICALLY RESISTANT

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>17</b>
<b>2</b>	<b>OBJETIVOS.....</b>	<b>20</b>
2.1	OBJETIVO GERAL.....	20
2.2	OBJETIVOS ESPECÍFICOS .....	20
<b>3</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>21</b>
3.1	COMPORTAMENTO ESPECTRAL DOS ALVOS URBANOS .....	21
3.2	PRINCÍPIOS DA CLASSIFICAÇÃO DE IMAGENS DIGITAIS .....	22
3.3	MÉTODOS TRADICIONAIS DE CLASSIFICAÇÃO .....	23
3.3.1	<b>Método da Distância Euclidiana .....</b>	<b>23</b>
3.3.2	<b>Método da Máxima Verossimilhança .....</b>	<b>24</b>
3.4	DESAFIOS NA CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL.....	27
3.5	NOVAS PERSPECTIVAS NA CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL.....	27
3.5.1	<b>Camadas Auxiliares .....</b>	<b>27</b>
3.5.1.1	Informação Altimétrica do LIDAR.....	27
3.5.1.2	Razão de Bandas .....	29
3.5.1.3	Índices de Vegetação .....	30
3.5.	<b>Modernização dos Métodos .....</b>	<b>32</b>
<b>4</b>	<b>METODOLOGIA .....</b>	<b>34</b>
4.1	ÁREA TESTE .....	34
4.2	MATERIAL .....	36
4.2.1	<b>Dados raster .....</b>	<b>36</b>
4.2.2	<b>Softwares .....</b>	<b>37</b>
4.3	EXPERIMENTOS .....	38
4.3.1	<b>Análise da Área de Estudo e Definição dos Níveis de Classificação .....</b>	<b>38</b>
4.3.2	<b>Aquisição das Amostras de Classes e Análise das Variáveis .....</b>	<b>40</b>
4.3.3	<b>Realização da Aritmética de Bandas e Análise dos Intervalos Espectrais .....</b>	<b>41</b>
4.3.4	<b>Inserção da Informação Altimétrica no Processo de Classificação .....</b>	<b>43</b>
4.3.5	<b>Classificação Supervisionada por Distância Euclidiana e por Máxima Verossimilhança.....</b>	<b>44</b>

<b>4.3.6</b>	<b>Validação dos Intervalos de Univocidade Espectral .....</b>	44
<b>5</b>	<b>RESULTADOS E DISCUSSÕES .....</b>	45
5.1	ANÁLISE DO CONTRASTE INTRACLASSE NAS PROPRIEDADES ESPECTRAIS, ALTIMÉTRICAS E DE INTENSIDADE .....	45
5.2	RAZÃO DE BANDAS E ÍNDICES DE VEGETAÇÃO .....	48
5.2.1	Resultados das Operações Aritméticas .....	48
5.2.2	Contraste Intraclass .....	50
5.2.3	Dispersão dos Pontos Amostrais .....	53
5.2.4	Zonas de Mistura Espectral e Zonas de Univocidade Espectral .....	56
5.2.5	Reclassificação da Aritmética de Bandas para a Forma Binária .....	57
5.2.6	Validação dos Intervalos de Univocidade Espectral .....	60
5.2.7	Classificação da Cobertura do Solo Urbano .....	63
5.2.7.1	Rede Semântica para a Discriminação das Classes.....	63
5.2.7.2	Cobertura Vegetacional .....	65
5.2.7.3	Cobertura Hídrica .....	69
5.2.7.4	Cobertura Edificacional.....	71
5.2.7.5	Cobertura Pavimentada e Solo Exposto .....	72
5.2.7.6	Resultado da Classificação Utilizando Camadas Auxiliares.....	73
5.2.7.7	Classificação pelos Métodos Distância Euclidiana e Máxima Verossimilhança .....	74
<b>6</b>	<b>CONCLUSÕES .....</b>	78
	<b>REFERÊNCIAS .....</b>	81
	<b>APÊNDICE A - PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE S1.....</b>	85
	<b>APÊNDICE B - PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE S2.....</b>	86
	<b>APÊNDICE C - PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE VARI .....</b>	87
	<b>APÊNDICE D - PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE RGBVI.....</b>	88
	<b>APÊNDICE E - PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE GRVI .....</b>	89
	<b>APÊNDICE F - PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE GLI .....</b>	90

## 1 INTRODUÇÃO

Os fenômenos urbanos têm impacto de longo alcance nas sociedades e ambientes localizados além dos limites da cidade. Informações precisas e oportunas sobre os ambientes urbanos são essenciais para entender os padrões e a dinâmica da cobertura da terra, subsidiar a tomada de decisão sobre o território e viabilizar pesquisas de cunho local e global (RUIZ, GUASSELLI & CATEN, 2017; LIU *et al.*, 2018).

Devido à pequena dimensão das suas feições, os ambientes urbanos exigem imageamento de alta resolução para o seu mapeamento. Entretanto, os métodos tradicionais de extração de informações em imagens de alta resolução, sejam de nível aéreo ou orbital, ainda apresentam algumas limitações (MYINT *et al.*, 2011).

Os principais fatores que dificultam o mapeamento urbano são: i) a pequena dimensão das feições e a sua disposição complexa no espaço; ii) a diversidade de materiais de que são compostos os objetos e as suas semelhanças espectrais; iii) as regiões de sombra e oclusão em imagens aéreas e; iv) a constante dinâmica territorial. Esses fatores exigem uma combinação de imageamento de alta resolução e mecanismos potenciais de atualização cartográfica, dentre eles os métodos de processamento de imagens digitais.

Segundo Pinho *et al.* (2012), a identificação de mudanças na cobertura e no uso da terra subsidia o planejamento e gerenciamento urbano. Essas informações podem ser usadas, por exemplo, para planejar mudanças nos sistemas de transporte público em áreas onde o número de arranha-céus está aumentando rapidamente. Tais mudanças podem ser avaliadas usando análises multitemporais de mapas de uso e cobertura da terra intraurbanos, que exigem dados continuamente atualizados, detalhados e precisos. O avanço de tecnologias de imageamento de alta resolução, seja em nível aéreo ou orbital, tem demandado técnicas mais robustas de processamento de imagens, de modo a possibilitar mapeamentos automáticos ou semiautomáticos e viabilizar, em menor tempo e custo, a atualização espacial dos fenômenos urbanos.

A fotoanálise e a vetorização em tela ainda são os métodos mais utilizados em mapeamentos urbanos. Entretanto, três fatores principais agregam deficiências a esses métodos, são eles: i) objetos unidos entre si e/ou com contorno complexo, a exemplo da vegetação, cujo delineamento por parte do analista apresenta alto nível

de dificuldade; ii) a área de conhecimento do analista e a área estudada podem interferir no processo de extração da informação, de modo que dois analistas podem chegar a resultados distintos; iii) grandes áreas demandam muito tempo de trabalho, o que pode inviabilizar determinados projetos e retardar a atualização cartográfica.

Sob uma nova perspectiva, a classificação de imagens digitais surgiu como fomento à automatização do processo de extração de informações das imagens, eliminando a subjetividade da interpretação humana e reduzindo o esforço de trabalho do analista (MENESES & ALMEIDA, 2012). Entretanto, a informação espectral utilizada nos métodos tradicionais de classificação não é suficiente para categorizar os *pixels* urbanos integrantes de imagem de alta resolução (ARAKI, 2005).

A classificação *pixel* a *pixel* obtida pelos métodos convencionais do Paralelepípedo, Distância Mínima, Máxima Verossimilhança e também a classificação obtida por regiões como é o caso do ISOSEG e Battacharya, avaliam as classes como agrupamentos de mesma característica espectral, em uma representação bidimensional, e isso não é suficiente para a discriminação das feições urbanas (LU & WENG, 2007; MYINT *et al.*, 2011; MENESES & ALMEIDA, 2012). Esse problema pode ser contornado utilizando camadas auxiliares com atributos de diferentes fontes, os quais viabilizam a discriminação de classes espectralmente semelhantes.

A informação altimétrica proveniente do *Light Detection and Ranging* (LIDAR) e as operações aritméticas com bandas (razão de bandas e índices de vegetação) são exemplos de camadas auxiliares que podem contribuir para a classificação de espaços urbanos.

A informação altimétrica pode resolver questões como: i) perda de informação devido à oclusão; ii) mistura espectral entre classes de alvos, a exemplo de áreas pavimentadas e coberturas edificacionais de concreto, que possuem respostas espetrais semelhantes, mas alturas distintas; iii) segmentar classes em categorias mais específicas, a exemplo da vegetação, que pode ser categorizada em função do seu ciclo de vida ou em função da sua espécie, a depender da altura.

Com relação às operações aritméticas com bandas, essas incrementam informação ao processo de discriminação das classes de alvos, uma vez que consistem em nova camada de dados e podem realçar determinados objetos. Essas operações podem solucionar ou auxiliar uma das etapas de maior complexidade do mapeamento urbano, a saber, a classificação da vegetação. Por estarem, na maioria das vezes, misturadas com outras classes de alvos ou sobrepostas a essas, e

possuírem forma irregular, a vegetação é de difícil extração por vetorização em tela ou por classificação convencional utilizando apenas a informação espectral original.

Diante do exposto, este trabalho propõe uma análise conjunta de imagens aéreas, modelos do terreno e imagens provenientes de operações aritméticas, para o reconhecimento de padrões nos dados e classificação do solo urbano. Para a realização dos experimentos foi escolhida uma área com boa representatividade de alvos urbanos, a saber: edificações com diferentes coberturas, áreas pavimentadas, vegetação de diversos tipos e portes, solo exposto e corpos d'água. Vale salientar que, diferente da maioria das pesquisas, que utilizam as bandas do infravermelho para o estudo da vegetação, neste trabalho as operações utilizam apenas as bandas do visível, o que viabiliza a reprodução da metodologia em diferentes áreas de estudo e com imagens de diferentes sensores, a exemplo das imagens de Veículos Aéreos não Tripulados e drones, às quais ainda têm seus usos limitados devido à falta de métodos de processamento de imagens que explorem todas as suas potencialidades.

Este estudo justifica-se pela necessidade de métodos que viabilizem o mapeamento automático ou semiautomático de área urbanas, utilizando imagens de alta resolução provenientes de sensores que imageiam apenas as bandas do espectro visível. Isso porque a realidade majoritária dos municípios brasileiros é de negligenciamento com o mapeamento urbano. A complexidade em se extrair informações urbanas de imagens de alta resolução é um problema que faz com que muitas bases cartográficas municipais não contemplem a totalidade do território, se restringindo a informações concernentes apenas à cobrança de impostos. Visto isso, é almejado o desenvolvimento de métodos que possibilitem o mapeamento urbano sistematizado, de modo a subsidiar a tomada de decisão sobre o território.

## 2 OBJETIVOS

Esta seção apresenta os objetivos desta pesquisa.

### 2.1 OBJETIVO GERAL

Gerar uma classificação da cobertura do solo urbano utilizando informações espectrais e altimétricas, razão de bandas e índices de vegetação.

### 2.2 OBJETIVOS ESPECÍFICOS

- Utilizar aritmética de bandas na faixa do visível para discriminar sutis variações de reflectância entre os alvos de interesse;
- Utilizar a informação altimétrica para separar classes espectralmente semelhantes;
- Comparar os resultados da classificação utilizando camadas auxiliares com os resultados das classificações supervisionadas pelos métodos de Distância Euclidiana e Máxima Verossimilhança.

### 3 REFERENCIAL TEÓRICO

Esta seção apresenta o referencial teórico utilizado como embasamento para o desenvolvimento desta pesquisa.

#### 3.1 COMPORTAMENTO ESPECTRAL DOS ALVOS URBANOS

Diversos trabalhos apontam para as dificuldades encontradas na utilização de dados de imageamento no estudo e mapeamento de áreas urbanas. Quanto maior a resolução espacial, maior o nível de detalhamento que se pode extrair da imagem, entretanto, esta não é uma tarefa fácil. Os espaços urbanos são compostos por diferentes materiais, com respostas espectrais muitas vezes semelhantes, o que dificulta o reconhecimento de padrões para a definição de limiares entre classes.

Durán (2014) realizou um estudo da resposta espectral de alvos urbanos com espectroscopia de reflectância e imagens de alta resolução espacial, utilizando a técnica de mapeamento espectral *SAM* (*Spectral Angle Mapper*) e a reamostragem das curvas espectrais utilizando as funções de resposta espectral dos sensores GeoEye-1 e HRG-1/SPOT 5. Os resultados mostraram que: i) em alguns casos a diferença entre alvos foi devida à pequenas diferenças de magnitude nos valores de reflectância; ii) as medições de campo foram realizadas com um espetrorradiômetro cuja faixa espectral atinge o visível e parcialmente o infravermelho próximo, sendo isto um fator limitante na análise de alvos com feições características no infravermelho de ondas curtas; iii) objetos com cobertura colorida mostram uma resposta espectral associada a tinta e não ao material base; iv) objetos como telhas de cerâmica vermelha, estradas de terra e quadras de saibro preservam as propriedades de reflectância do material base; v) objetos fabricados com concreto, telhas de amianto, telhas shingle, asfalto, brita, calçamentos de rochas tipo paralelepípedo e irregulares preto, telha de aço e zinco, sempre que não possuam alguma camada de tinta na superfície, apresentam feições espectrais sem variações definidas que causam confusão no momento da classificação; vi) as ações do intemperismo sobre os alvos urbanos afetam a resposta espectral dos materiais; vii) a técnica *SAM* com algumas limitações possibilitou a identificação de alvos urbanos com exatidão maior a 50%.

Em Ribeiro, Fonseca e Kux (2011) foi avaliado o potencial das imagens do sensor WorldView-II para o mapeamento da cobertura do solo em uma área urbana

na Região Metropolitana de São Paulo, usando o InterIMAGE. Dentre as principais conclusões estão: i) as classes de cobertura vegetacional rasteira e arbórea mostraram resultados espectralmente muito semelhantes, podendo ser separadas por índices de vegetação ou por medidas texturais; ii) foram observadas confusões espectrais entre vegetação rasteira e solo exposto, provavelmente devido a baixa concentração hídrica da vegetação; iii) o solo exposto teve resultado semelhante ao do telhado de cerâmica; iv) a classe vegetação arbórea apresentou confusão com a classe sombra, o que se deve principalmente ao fato de regiões identificadas como sombra serem realçadas na banda do infravermelho próximo, por se tratarem de vegetação; v) As maiores confusões com a classe telha metálica ocorreram com as classes de materiais de cobertura acinzentadas, especialmente com as classes cobertura em cimento claro e médio, isso se deve ao fato dos alvos metálicos serem constituídos de diferentes metais, com cores diferentes, geometrias diferentes (planos ou curvos), e consequentemente, respostas espectrais diferentes.

### 3.2 PRINCÍPIOS DA CLASSIFICAÇÃO DE IMAGENS DIGITAIS

A classificação digital de imagens possibilita a atribuição de um significado real ao *pixel*. Quando esta operação é realizada para todos os *pixels* em uma determinada área, o resultado é um mapa temático com a distribuição geográfica de temas. A classificação pode ser supervisionada, quando o analista poderá definir áreas amostrais das classes contidas na imagem, ou não supervisionada, quando o analista não tem informações relativas à área imageada, sendo as classes definidas automaticamente pelo próprio algoritmo de classificação (IBRAHIN, 2014). Existe ainda a possibilidade de dividir os métodos de classificação segundo outros critérios em: classificação paramétrica e não-paramétrica, classificação espectral e espacial e classificação por *pixel* ou por regiões.

A maioria dos classificadores realiza a classificação por *pixel*, utilizando somente a informação espectral de cada *pixel* para encontrar regiões homogêneas, a partir de medições de distâncias ou de probabilidades de um *pixel* pertencer a uma determinada classe. Na classificação por regiões um agrupamento de *pixels* é usado como unidade de classificação e influencia o processo de decisão (MENEZES & ALMEIDA, 2012; PRUDENTE *et al* 2017; LU & WENG, 2007).

A classificação não supervisionada realizada antes da classificação supervisionada pode ser vista como uma etapa importante para o reconhecimento de padrões espectrais. Entretanto, cuidados especiais devem ser tomados quanto à obtenção do número de classes de *pixels*, a saber: o número de classes espectrais ser maior que o de classes do terreno, havendo necessidade da realização de um reagrupamento; o número de classes espectrais ser muito menor que o de classes no terreno, caracterizando-se a existência de alvos com características espectrais semelhantes e mostrando a necessidade de se utilizar outras formas de discriminações para as classes (FRANÇA *et al.*, 2012).

### 3.3 MÉTODOS TRADICIONAIS DE CLASSIFICAÇÃO

Esta seção discrimina os métodos tradicionais de classificação utilizados nesta pesquisa, a saber: Método da Distância Euclidiana e Método da Máxima Verossimilhança.

#### 3.3.1 Método da Distância Euclidiana

O método de classificação por distância Euclidiana, também chamado de método de classificação por distância mínima, é um procedimento de classificação supervisionada, que utiliza a distância euclidiana (Equação 1) para associar um *pixel* a uma determinada classe. No treinamento supervisionado, definem-se os agrupamentos que representam as classes. Na classificação, cada *pixel* será incorporado a um agrupamento, através da análise da medida de similaridade de distância Euclidiana (CAMARA *et al.*, 1996).

$$D(x, n) = \sqrt{x_i - m_i} \quad (1)$$

Onde,

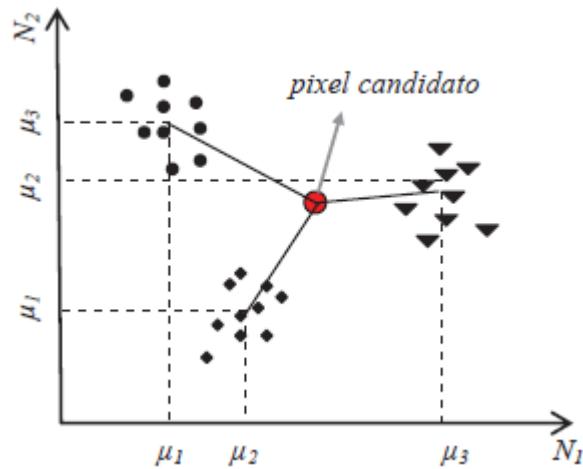
$x_i$  = *pixel* candidato

$m_i$  = média das bandas

$n$  = número de bandas espectrais

A Figura 1 ilustra a medida da distância pelas linhas entre o *pixel* candidato e as médias de três classes. O classificador compara a distância Euclidiana de cada *pixel* à média de cada agrupamento. O *pixel* candidato é designado à classe com média mais próxima, isto é, à classe que apresenta a menor distância Euclidiana.

Figura 1 - Ilustração da classificação pelo método da Distância Euclidiana.



Fonte: Menezes e Almeida (2012).

Segundo Menezes e Almeida (2012), o método de classificação por distância euclidiana apresenta uma série de vantagens e desvantagens. Para os autores as vantagens são: i) todos os *pixels* encontrarão uma média à qual estarão espectralmente mais próximos, e assim, não existirão *pixels* não classificados; ii) é a regra de decisão mais rápida depois do paralelepípedo. Enquanto que no tocante as desvantagens, eles apontam: i) *pixels* que deveriam permanecer não-classificados, isto é, eles não estão espectralmente próximos a nenhuma amostra dentro de limites razoáveis, serão classificados; ii) o método não considera a variabilidade espacial da classe.

### 3.3.2 Método da Máxima Verossimilhança

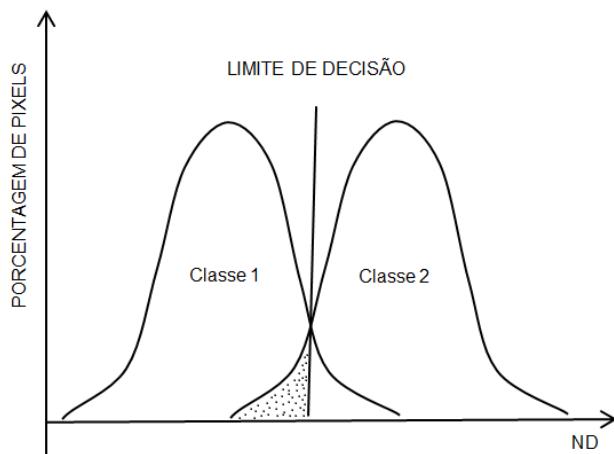
Segundo CAMARA *et al.* (1996), a classificação de imagens pelo método da máxima verossimilhança considera a ponderação das distâncias entre as médias dos níveis digitais das classes, utilizando parâmetros estatísticos. Para que a classificação por este método seja precisa o suficiente, é necessário um número razoavelmente elevado de *pixels*, para cada conjunto de treinamento, os quais definem o diagrama

de dispersão das classes e suas distribuições de probabilidade, considerando a distribuição de probabilidade normal para cada classe de treinamento.

Na Figura 2 apresentam-se duas classes (1 e 2) com distribuição de probabilidade distintas. Estas distribuições de probabilidade representam a probabilidade de um *pixel* pertencer, respectivamente, à classe 1 ou à classe 2, dependendo da posição do *pixel* em relação à esta distribuição.

Um *pixel* contido na região onde as duas curvas se sobrepõem tem igual probabilidade de pertencer à classe 1 e à classe 2. Nessa situação se estabelece um critério de decisão em função de limiares (limite de decisão). A Figura 2 ilustra um limite de decisão de uma classificação, no ponto onde as duas curvas se cruzam, de tal modo que um *pixel* localizado na região pontilhada, apesar de pertencer a uma zona de mistura espectral, será classificado como classe 1. O limiar fornece ao usuário a possibilidade de variar o rigor da classificação. Quanto menor o limiar, mais rigorosa será a classificação (MENEZES & ALMEIDA, 2012).

Figura 2 - Ilustração da definição de limiar na classificação por máxima verossimilhança.



Fonte: Camara *et al.* (1996).

Segundo Menezes e Almeida (2012), o método de classificação por distância euclidiana apresenta uma série de vantagens e desvantagens. No que refere às vantagens, os autores apontam: i) é mais eficiente que o método por distância mínima, pois as classes de treinamento são utilizadas para estimar a forma da distribuição dos *pixels* contidos em cada classe no espaço de  $n$  bandas, como também a localização do centro de cada classe; ii) Possibilidade de variar o rigor da classificação, mediante o estabelecimento de limiares. Já no tocante as desvantagens, os autores apontam:

i) o uso desse classificador exige que as áreas de amostragem das classes de treinamento tenham uma grande quantidade de *pixels*, da ordem de centenas; ii) o resultado pode ser insatisfatório caso haja uma dispersão dos *pixels* em uma classe de treinamento.

### 3.4 DESAFIOS NA CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL

As imagens de alta resolução são muito utilizadas no mapeamento do uso e ocupação do solo. Entretanto, os métodos convencionais de classificação, em áreas urbanas, podem apresentar resultados não satisfatórios, devido à alta heterogeneidade e complexidade destas áreas. Logo, vêm sendo desenvolvidos métodos automáticos e semiautomáticos de extração de informações sobre a cobertura da terra, que melhoram os resultados dos métodos tradicionais e reduzem significativamente o tempo de processamento dos dados e, por conseguinte, reduzem os recursos financeiros durante o processo de produção cartográfica (ARAKI, 2005; LIU & XIA, 2010; ARAÚJO & LUCHIARI, 2016; SANTIAGO & SILVA, 2018).

Como a imagem possui informação bidimensional de algo que é tridimensional, nem sempre o processo de classificação atende à realidade do local. Nas imagens de alta resolução, efeitos de sombra e do terreno podem gerar erros na categorização dos objetos. Deste modo, faz-se necessário incorporar dados auxiliares, não espectrais, à classificação para que se obtenha um resultado mais refinado e que represente melhor a superfície imageada (SILVA, CANDEIAS e TAVARES JUNIOR, 2010).

Segundo Santos *et al.* (2011), os métodos convencionais de extração de informações a partir de imagens de satélite baseiam-se em abordagens *pixel a pixel*. Entretanto, o aumento da resolução dos sensores digitais levou ao surgimento de novos paradigmas de classificação, que pretendem replicar a identificação dos objetos da imagem de forma análoga a interpretação realizada pelo cérebro humano. Esta nova abordagem se deve ao fato da utilização de classificadores ao nível do *pixel*, fazendo uso apenas da informação espectral, ter se revelado ineficaz na extração de informações em imagens de muito alta resolução.

### 3.5 NOVAS PERSPECTIVAS NA CLASSIFICAÇÃO DE IMAGENS DE ALTA RESOLUÇÃO ESPACIAL

Nesta seção é feita uma análise da modernização dos métodos de classificação de imagens de alta resolução.

#### 3.5.1 Camadas Auxiliares

Nesta seção são apresentadas as camadas auxiliares utilizadas no desenvolvimento desta pesquisa.

##### 3.5.1.1 Informação Altimétrica do LIDAR

Dados auxiliares de altimetria podem contribuir na classificação, pois incorporam uma diferenciação dos alvos pelas suas alturas e resgatam a informação tridimensional para a imagem digital (SILVA e ARAKI, 2015; OLIVEIRA, 2016). Sendo assim, uma tecnologia que pode auxiliar no mapeamento de alta resolução ao contribuir para o aprimoramento da classificação de imagens digitais é o Laser Scanner Aerotransportado (LSA), mundialmente conhecido como LIDAR (*Light Detection and Ranging*).

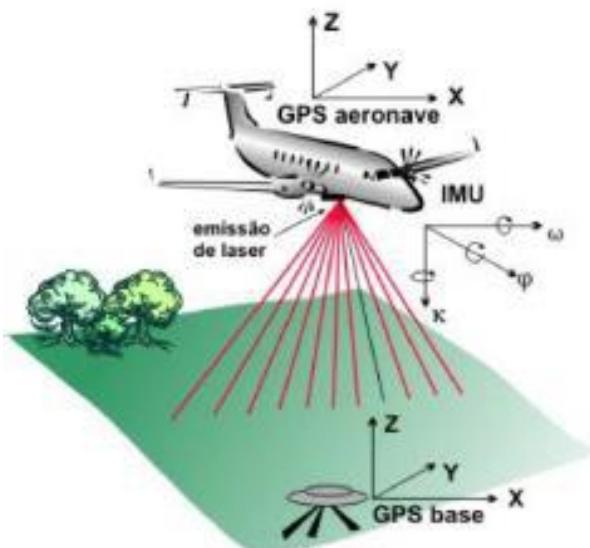
O LIDAR é um sistema de sensoriamento remoto ativo aerotransportado com funcionamento baseado na utilização de um pulso de *laser* que é emitido em direção ao terreno para a obtenção de coordenadas tridimensionais de pontos sobre uma superfície (BALTSAVIAS, 1999). Consiste em uma das mais modernas técnicas para coleta de dados tridimensionais e se difere dos métodos tradicionais de levantamento, dentre outros motivos, pelo pequeno tamanho dos equipamentos que o compõem, pela alta velocidade com que ocorre a varredura e pelo elevado número de pontos levantados. O seu produto consiste em uma nuvem de pontos com coordenadas tridimensionais. Além destas, cada ponto medido retorna também informações do nível de intensidade do alvo refletido, o que permite a geração de imagens de composição entre estas camadas de informação, que facilitam a interpretação e visualização das feições do terreno (CAVALCANTI, 2016).

A maioria dos sistemas LIDAR disponíveis no mercado utiliza o mesmo princípio, a saber: uma aeronave sobrevoa uma região e o equipamento *laser* efetua uma

varredura no chão em direção perpendicular à direção do voo, determinando a distância ao terreno, sendo esta distância calculada em função do tempo exigido pelo raio laser para ir e voltar do equipamento até o terreno, na velocidade da luz (MACHADO, 2006).

Os componentes básicos do sistema LIDAR são os seguintes: Sensor Laser, composto pela fonte do pulso laser; sistema ótico de transmissão e recepção do pulso laser; Unidade de Medição Inercial denominada IMU (*Inertial Measure Unit*); receptor GPS (*Global Position System*); Computadores de bordo com programas para gerenciamento de todo o sistema; Unidade de armazenamento dos dados brutos provenientes do GPS, do IMU e das medições laser. Além destes, é importante salientar a necessidade de um GPS de base para que os dados do *laser* sejam pós processados e corrigidos em relação ao referencial adotado para o mapeamento (SLOBODA, 2005). A Figura 3 demonstra esses componentes.

Figura 3 - Componentes básicos de um sistema LSA.

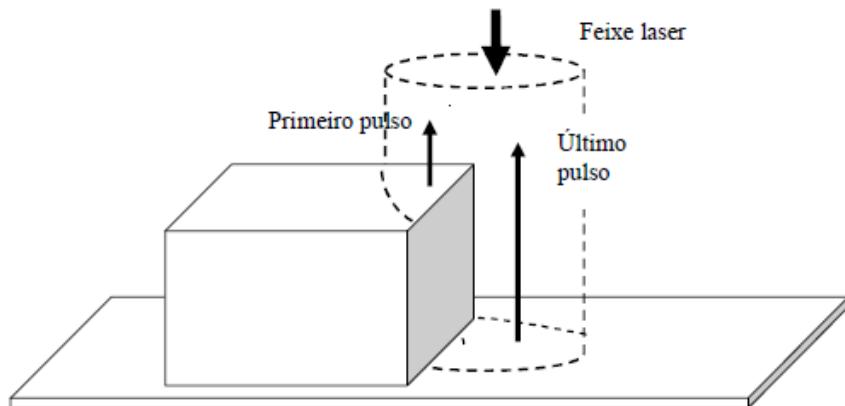


Fonte: Kersting *et al.* (2005).

Ao se propagarem no ar, formando um determinado diâmetro, os pulsos emitidos pelo *laser* apresentam uma característica de divergência. A área de cobertura de cada pulso emitido pelo LSA varia de acordo com a altitude e é possível que uma porção do mesmo pulso *laser* encontre um ou mais objetos antes de atingir o solo. No primeiro pulso tem-se a reflexão do nível mais elevado e no último pulso tem-se a reflexão correspondente ao nível do solo, sendo ambos os retornos registrados pelo sistema

LSA. De posse desses dois tipos de informação é possível obter diferentes modelos digitais (ARAKI, 2005). A Figura 4 ilustra o processo de reflexão do pulso de laser.

Figura 4 - Processo de reflexão do pulso de laser.



Fonte: Araki (2005).

O conjunto de dados oriundos do LSA pode ser tratado como dados vetoriais ou transformados em *raster* para serem processados como uma grade regular. A segunda opção é geralmente mais adotada devida à redução significativa na quantidade de dados de modo a facilitar o armazenamento e o processamento (CENTENO & MITISHITA, 2007).

De acordo com Botelho e Centeno (2005), a altimetria adquirida pelo *laser scanner* pode ser incluída no processo de classificação de imagens digitais, diferenciando os objetos de mesmo comportamento espectral localizados em diferentes elevações, tornando-se assim uma informação auxiliar interessante nesse processo.

### 3.5.1.2 Razão de Bandas

Segundo Menezes e Almeida (2012), no processo de extração de informações em imagens de sensores multiespectrais, quando há o interesse de discriminar sutis variações de reflectância de alvos específicos, como um tipo de litologia, solo, ou tipos de vegetação, buscam-se mecanismos que destaqueem, exclusivamente, as propriedades daquele tipo de alvo, em detrimento a todos os outros presentes na imagem. A operação utilizada para esta finalidade é a razão de bandas, a qual se tornou uma das mais úteis técnicas de transformação de imagem.

Segundo Araújo e Mello (2010), a operação razão de bandas demonstrou eficiência em estudos geoambientais de caracterização, intervenção e recuperação de áreas degradadas. De acordo com os autores, a razão de bandas possibilita o mapeamento de detalhes, mesmo em imagens de alta resolução, pois possibilitam a resolução de semelhanças espectrais.

Como os valores das operações de razão de bandas e índices de vegetação resultam em números pequenos e fracionários, para fins de exposição da imagem no monitor de vídeo eles devem ser multiplicados por um valor escalar (*a*) para recolocá-los ou expandi-los para o intervalo 0 a 255 de uma imagem de 8 bits. Uma constante (*b*) é somada aos valores reescalados para apenas obter um deslocamento (*offset*) do histograma para uma posição mais central entre 0 a 255, a fim de possibilitar um equilíbrio no realce da imagem (MENEZES & ALMEIDA, 2012). Neste trabalho, após realizados vários testes, foi utilizado “*a*” igual a 10 e “*b*” igual a 50, os quais resultaram em um aspecto visual considerado bom para os experimentos. Vale salientar que nas equações 2 a 7, *Blue* representa a faixa do azul, *Green* representa a faixa do verde e *Red* representa a faixa do vermelho.

Neste trabalho foram realizadas as razões de bandas denominadas de S1 (Equação 2) e S2 (Equação 3).

$$S1 = a \left( \frac{Green}{Blue} \right) + b \quad (2)$$

$$S2 = a \left( \frac{Red}{Blue} \right) + b \quad (3)$$

Onde,

$$a = 10$$

$$b = 50$$

### 3.5.1.3 Índices de Vegetação

Diversos índices de vegetação têm sido propostos e investigados na literatura com o objetivo de inspecionar as propriedades espectrais da vegetação, em especial nas regiões do visível e do infravermelho próximo. Esses índices exploram parâmetros biofísicos da cobertura vegetal, a exemplo de biomassa e índice de área foliar, além

de minimizarem efeitos de geometria de aquisição, iluminação da cena e declividade da superfície (PONZONI & SHIMABUKURO, 2007).

Neste trabalho foi realizado um levantamento bibliográfico de quatro índices que utilizam as bandas do visível, foram eles: i) *Green-Red Vegetation Index* (GRVI); ii) *Gren Leaf Index* (GLI); iii) *Visible Atmospherically Resistant* (VARI); iv) *Red Green Blue Vegetation Index* (RGBVI).

A Equação 4 apresenta o índice de vegetação *Green-Red Vegetation Index* (GRVI), o qual teve alguns de seus resultados mais relevantes investigados em Tucker (1979), Falkowsk et. al. (2005) e Motohka et al. (2010).

$$GRVI = a \left[ \frac{(Green-Red)}{(Green+Red)} \right] + b \quad (4)$$

As Equações 5 e 6 apresentam, respectivamente, os índices de vegetação *Gren Leaf Index* (GLI) e *Visible Atmospherically Resistant* (VARI). Alguns de seus resultados foram explorados em Louhaichi, Borman e Johnson (2001), Gitelson et al. (2002) e Hunt et al. (2013).

$$GLI = a \left[ \frac{(2*Green-Red-Blue)}{(2*Green+Red+Blue)} \right] + b \quad (5)$$

$$VARI = a \left[ \frac{(Green-Red)}{(Green+Red-Blue)} \right] + b \quad (6)$$

A Equação 7 apresenta o índice de vegetação *Red Green Blue Vegetation Index* (RGBVI), o qual teve alguns de seus resultados investigados em Bendig et al. (2015) e Lussen et al. (2018).

$$RGBVI = a \left[ \frac{((Green^2 - (Blue*Red)))}{((Green^2 + (Blue*Red)))} \right] + b \quad (7)$$

Os experimentos descritos demonstram a utilização dos índices de vegetação, na faixa do visível, em estudos de realce da vegetação e análise de suas propriedades. Este trabalho analisa a possibilidade do mapeamento da vegetação intraurbana e de outras feições urbanas que sejam realçadas, utilizando índices de vegetação na faixa do visível, assim como a utilização de um desses índices como camada auxiliar no processo de classificação por mineração de dados.

### 3.5.2 Modernização dos Métodos

Novos métodos de classificação de imagens têm surgido para atender a demanda por mapeamentos automatizados e detalhados da cobertura do solo urbano. Dentre os métodos, há aqueles que fazem uso de camadas auxiliares, de diferentes fontes, para o reconhecimento de padrões de classes intraurbanas, visto que a informação espectral não é suficiente para a discretização dessas classes. Muitos desses métodos modernos também fazem uso de abordagens por regiões, em substituição às abordagens por *pixels*.

Segundo Santiago e Silva (2018), uma forma de realizar a classificação digital de imagens é utilizando abordagem por regiões, método que está sendo utilizado em imagens de alta resolução, em áreas urbanas, como uma alternativa ao método de classificação por *pixel*, na tentativa de melhorar os resultados. Os autores utilizaram os métodos máquina de vetores suporte (*support vector machine* - SVM) e distância estocástica mínima (*stochastic minimum distance* – SMD), e comprovaram que estes métodos produzem melhores resultados que o método de máxima verossimilhança, que possui abordagem por pixel.

Segundo Ruiz, Guasselli e Caten (2017), uma alternativa para coletar imagens com alta resolução espacial é o uso de câmaras não métricas acopladas a Veículos Aéreos Não Tripulados (VANT). Em contrapartida, as imagens com resolução espacial submétrica coletadas por essa tecnologia possuem alta variabilidade espectral, o que dificulta a classificação da cobertura da terra. A redução da variabilidade espectral dessas imagens pode ser alcançada a partir da Análise de Imagens Baseada em Objetos (*Object-Based Image Analysis* - OBIA). Dito isso, os autores desenvolveram uma classificação por árvore de decisão e análise baseada em objetos, utilizando ortoimagem e Modelo Digital de Elevação, e concluíram que os métodos são promissores para a classificação de imagens de alta resolução.

Segundo Araújo e Luchiari (2016), a OBIA significa um avanço em relação às abordagens de classificações tradicionais baseadas no *pixel*, uma vez que necessariamente pressupõe a existência de uma rede semântica vinculada ao processo de interpretação da imagem, aproximando aos processos cognitivos humanos. Dito isso, os autores elaboraram um mapa de cobertura da terra intraurbana com base em análise baseada em objetos, utilizando imagens do sensor imagens do

sensor WorldView-II, para investigar as inferências sobre o uso do solo na cidade de Marília/SP.

## 4 METODOLOGIA

Esta seção descreve a área de estudo escolhida para a realização dos experimentos, o material utilizado durante a pesquisa e o detalhamento dos métodos desenvolvidos.

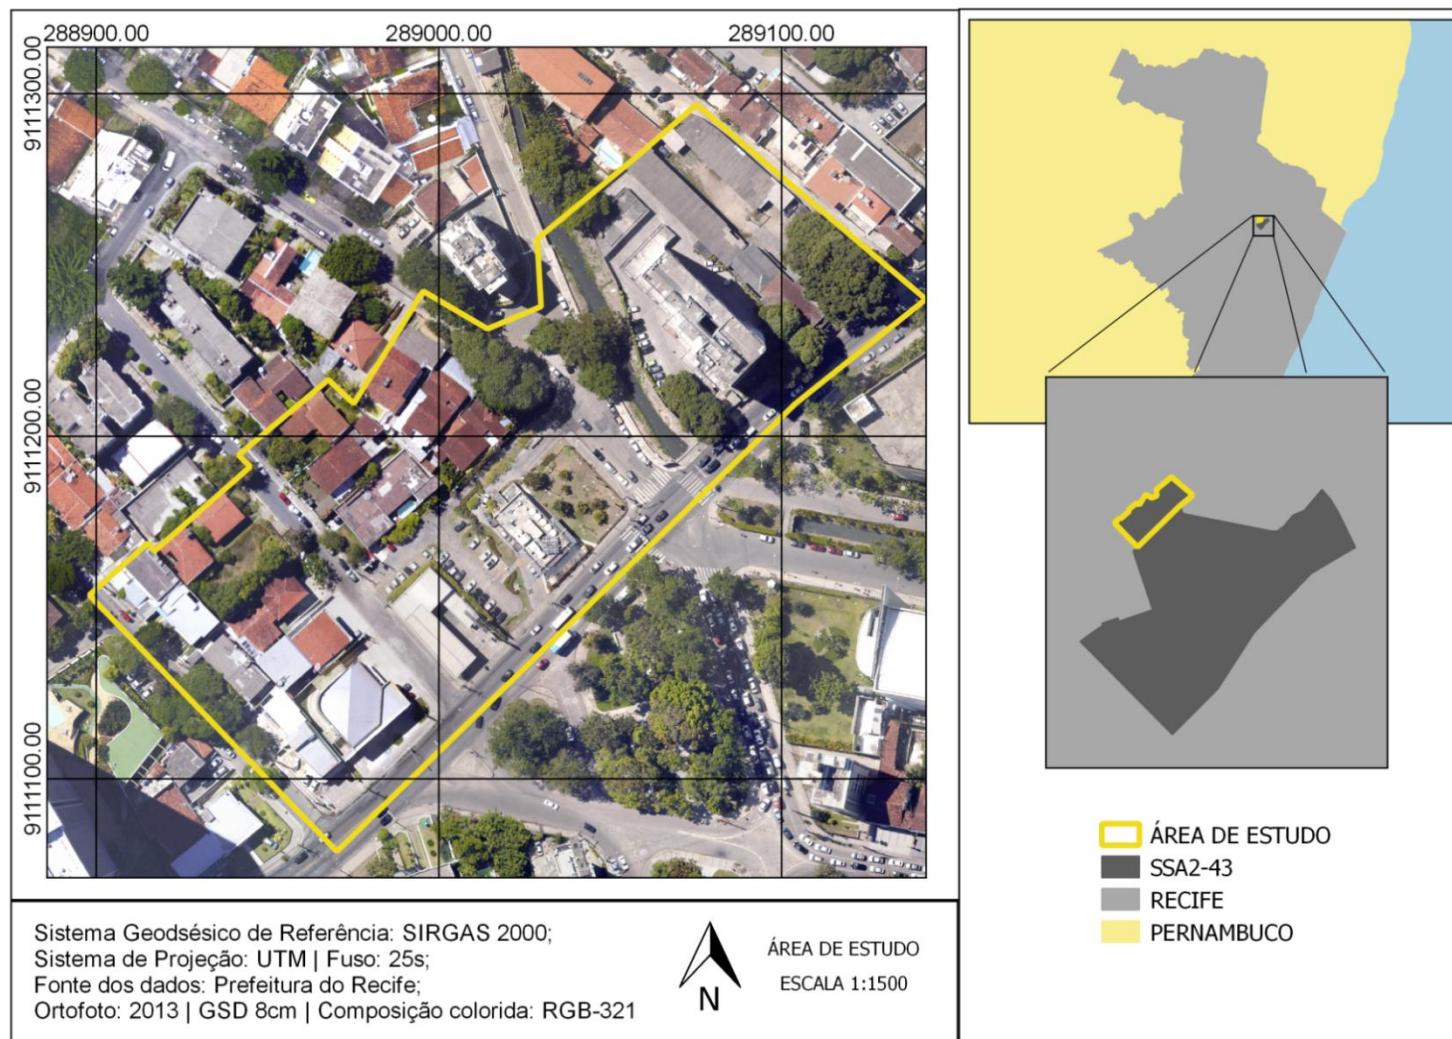
### 4.1 ÁREA TESTE

A área teste (Figura 5) está localizada nas margens do riacho Parnamirim, em Recife, Pernambuco, e consiste em uma parcela do Setor de Sustentabilidade Ambiental 2 (SSA2) de número 43, cujos limites e mecanismos de compensação foram definidos pela Lei nº 18.111, de 12 de janeiro de 2015. A Lei foi criada com o objetivo de aumentar a regulação de questões ambientais e integrar a pauta de educação ambiental do município.

Os SSA2 foram delimitados em função da área e do raio de influência de parques e praças com área maior que 600m<sup>2</sup>. A lei prevê que empreendimentos construídos no entorno desses locais ou em ruas que deem acesso a eles, criem "áreas de amortecimento", as quais são constituídas por uma faixa com vegetação, entre a calçada e o muro da construção.

Os fatores que justificaram a escolha da área teste foram: i) a área estar contemplada por uma medida de desenvolvimento sustentável, para o qual o monitoramento do uso e cobertura do solo é imprescindível; ii) a área possuir diversidade de feições urbanas, fato este que viabiliza a metodologia adotada.

Figura 5 – Área teste



Fonte: A autora (2020).

## 4.2 MATERIAL

Esta seção apresenta o detalhamento do material utilizado durante a pesquisa.

### 4.2.1 Dados *raster*

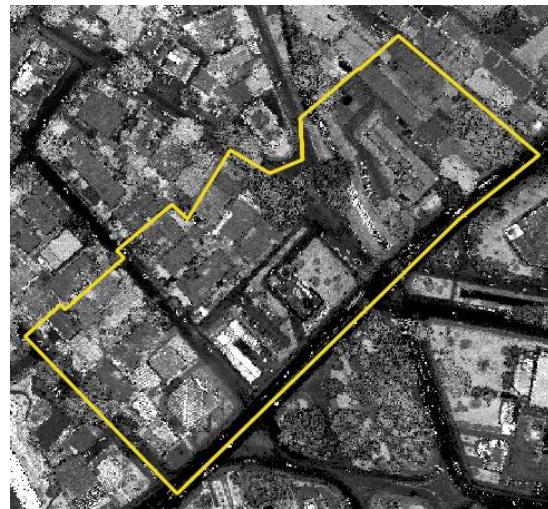
Os dados *raster* utilizados para o desenvolvimento desta pesquisa pertencem ao acervo cartográfico da prefeitura da cidade do Recife e foram disponibilizados mediante ofício prévio e posterior retirada no órgão. O material é oriundo de um projeto financiado pela prefeitura, realizado no ano de 2013 e intitulado: “Serviços de Engenharia para Cobertura Aerofotogramétrica, Perfilamento a Laser Aerotransportado, com Obtenção de Polígonos 2D, 3D e Restituição Estereofotogramétrica”. Os dados disponibilizados foram: ortofotos com GSD de 8 centímetros, Modelos Digitais do Terreno, Modelos Digitais de Elevação e imagens de intensidade. As articulações referentes à área de estudo são 81-80-05, 81-81-00, 81-90-05 e 81-91-00. O mosaico de cada tipo de dado pode ser visto nas Figuras 6,7 e 8.

Figura 6 – Bandas espectrais da ortofoto.



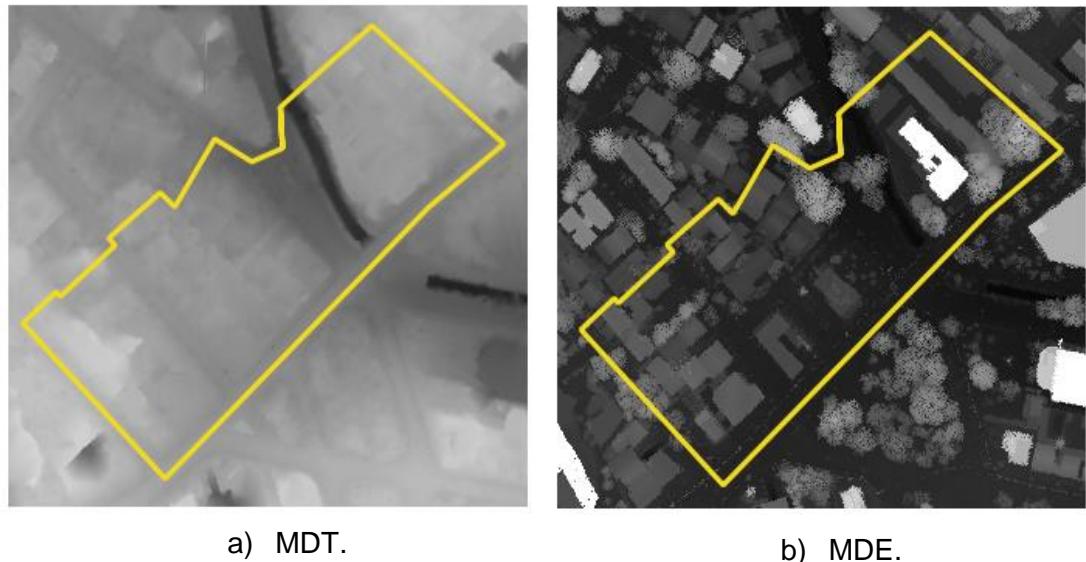
Fonte: Prefeitura do Recife (2019).

Figura 7 – Imagem de intensidade.



Fonte: Prefeitura do Recife (2019).

Figura 8 – Modelos do terreno.



a) MDT.

b) MDE.

Fonte: Prefeitura do Recife (2019).

#### 4.2.2 Softwares

O processamento das imagens foi realizado nos softwares QGIS e SPRING. O software QGIS é um Sistema de Informação Geográfica (SIG) de código aberto licenciado segundo a Licença Pública Geral GNU. Trata-se de um projeto oficial da

Open Source Geospatial Foundation (OSGeo). Seu funcionamento é compatível com os sistemas Linux, Unix, Mac OSX, Windows e Android, suportando inúmeros formatos de vetores, *rasters*, bases de dados e funcionalidades. O *software* SPRING é um Sistema de Informação Geográfica (SIG) no estado-da-arte com funções de processamento de imagens, análise espacial, modelagem numérica de terreno e consulta a bancos de dados espaciais. É um projeto do Instituto Nacional de Pesquisas Espaciais (INPE).

Para a análise estatística dos dados e geração dos gráficos foi utilizado o *software* Microsoft Office Excel.

#### 4.3 EXPERIMENTOS

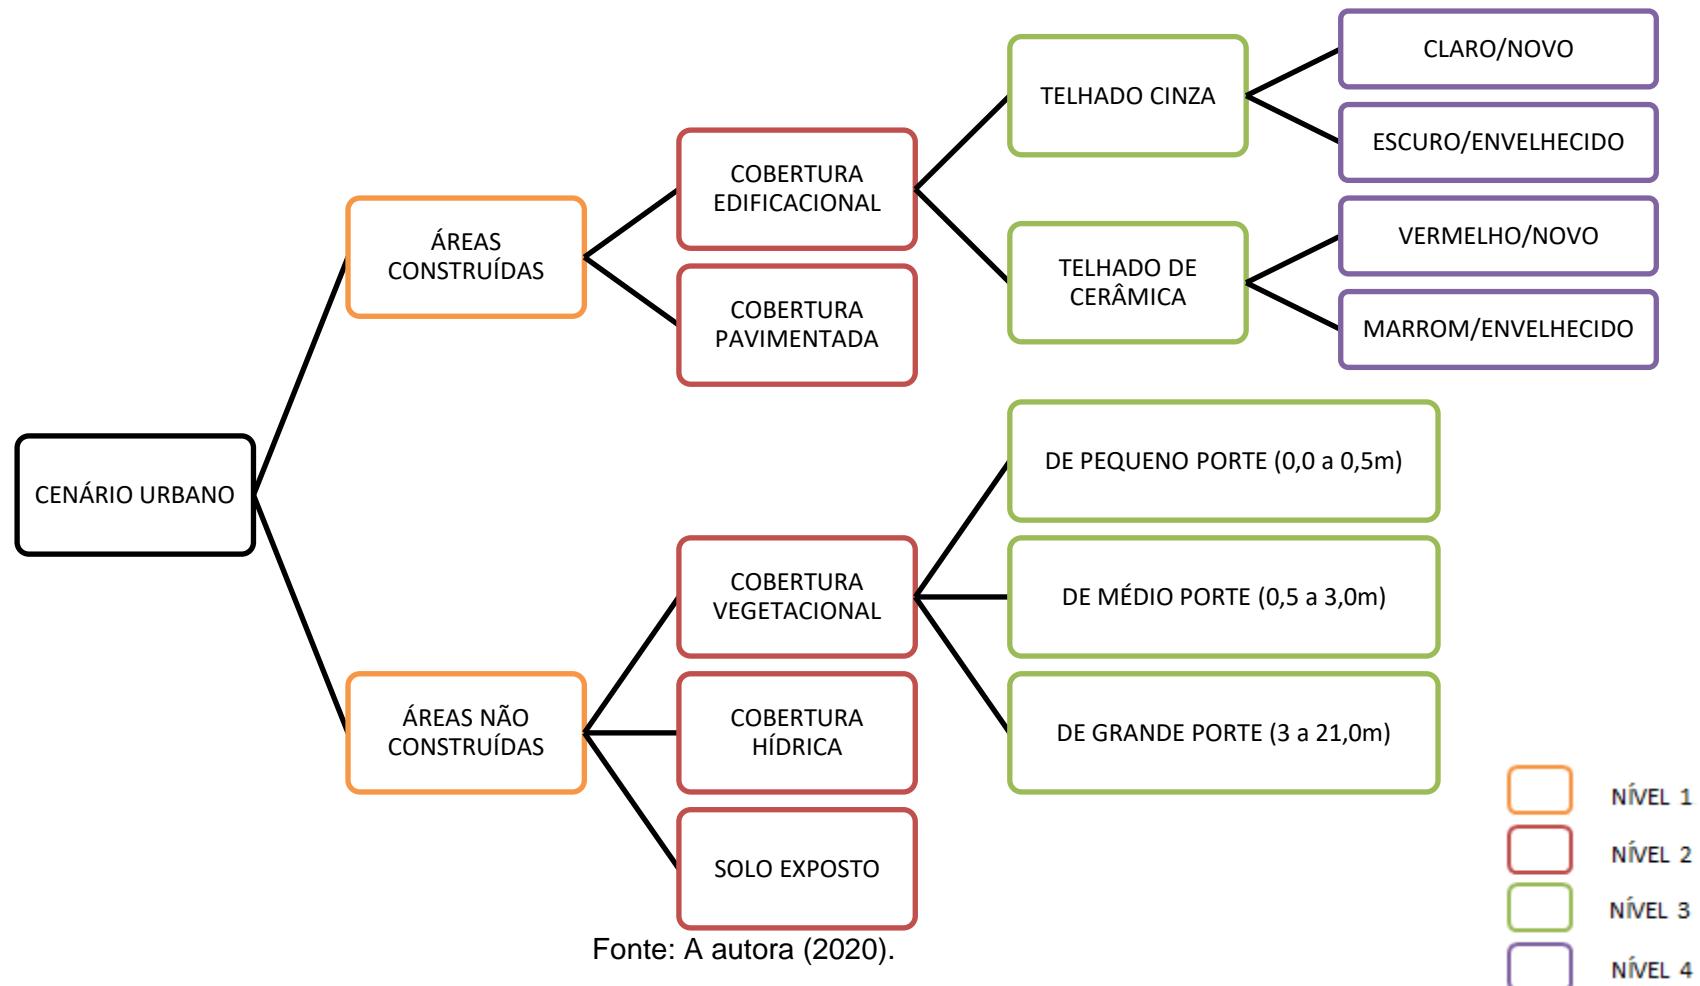
Para o alcance dos resultados, uma série de experimentos foi realizada, a qual é apresentada nesta seção.

##### **4.3.1 Análise da Área de Estudo e Definição dos Níveis de Classificação**

A área de estudo deste trabalho consiste em um típico cenário urbano não planejado, contendo feições que são comuns em boa parte das cidades brasileiras, tanto no quesito existência, como no quesito ordenação. Existem telhados compostos por diferentes materiais e com ordenação arbitrária, vegetação de diferentes portes e com diferentes agrupamentos dentro e fora de lotes residenciais, áreas pavimentadas públicas e privadas e pequenos trechos de água e solo exposto. Além dos componentes móveis, como automóveis e sombras, os quais são comuns em imagens de alta resolução e interferem no mapeamento automático ou semiautomático, pois suas respostas espectrais se confundem com as de outros objetos.

Estabelecido o panorama da área, iniciou-se o processo de discretização, particionando as classes em componentes de menor complexidade, as quais foram chamadas de níveis, como pode ser visto na Figura 9.

Figura 9 - Níveis de Classificação.



No nível 1, tem-se a separação entre áreas construídas e não construídas, as quais são significativamente mais amalgamadas em contextos urbanos, a exemplo das áreas verdes que circundam e permeiam as quadras residenciais.

No nível 2, a classe de áreas construídas foi subdividida em cobertura edificacional e cobertura pavimentada, enquanto que a classe de áreas não construídas foi subdividida em cobertura vegetacional, cobertura hídrica e solo exposto. Neste nível, além das áreas de mistura espectral, comuns em imagens de alta resolução, tem-se um agravante a mais, a saber, a grande semelhança espectral entre as coberturas pavimentada e edificacional. Uma alternativa é utilizar a informação altimétrica para diferenciá-las.

No nível 3 dividiu-se a cobertura edificacional em telhado cinza e telhado de cerâmica, e a cobertura vegetacional em pequeno, médio e grande porte.

No nível 4, a classe telhado foi subdividida em função do estado de conservação. A classe telhado cinza foi subdividida em claro/novo e escuro/envelhecido, e a classe telhado de cerâmica foi subdividida em vermelho/novo e marrom/ envelhecido.

#### **4.3.2 Aquisição das Amostras de Classes e Análise das Variáveis**

A coleta de amostras aconteceu de forma pontual, em quantidade e em aspecto que melhor representassem as classes definidas do nível 2 de classificação. Conforme visto na Figura 9, nesse nível de classificação as diferenças intraclasse, como tipos de telhado e vegetação, não são consideradas. A quantidade de pontos levantados foi 220 de cobertura edificacional, 60 de cobertura hídrica, 200 de cobertura pavimentada, 150 de cobertura vegetacional e 100 de solo exposto. A Figura 10 mostra a distribuição desses pontos.

Cada ponto teve seu valor espectral, de altimetria e de intensidade coletado. De posse desses dados, calculou-se o desvio padrão e analisou-se o contraste intraclasse referente a cada atributo. O contraste intraclasse diz respeito às variações de respostas dentro de cada classe definida, induzindo a uma fragmentação da classe em função de determinada variável.

Figura 10 - Distribuição das amostras de pontos.



Fonte: A autora (2019).

#### 4.3.3 Realização da Aritmética de Bandas e Análise dos Intervalos Espectrais

Nesta etapa do trabalho foi realizado um levantamento bibliográfico de operações aritméticas e índices que utilizam as bandas do visível. Essa seleção deve-se ao fato de que as imagens utilizadas possuem apenas a faixa do visível. Foram selecionados cinco índices de vegetação - GRVI, GLI, VARI, RGBVI e CI - e duas razões de bandas - S1 e S2 - para a realização dos experimentos.

Após a realização das operações aritméticas, cada ponto teve o seu respectivo valor coletado nas imagens geradas. Isso possibilitou a identificação dos mínimos e máximos de cada classe e, por conseguinte, a identificação de intervalos com univocidade espectral, ou seja, intervalos com *pixels* pertencentes a uma única classe. Esses intervalos foram definidos da seguinte forma: i) plotagem dos valores de mínimos e máximos em uma superfície de unidades de medida linear; ii) traçado de circunferências com centro posicionado na média amostral de cada classe e diâmetro igual à amplitude do intervalo; iii) identificação de intervalos onde havia sobreposição de circunferências, ou seja, mistura espectral; iv) identificação de intervalos onde não havia sobreposição de circunferências, ou seja, univocidade espectral. Vale salientar que nenhuma circunferência ficou totalmente contida no intervalo de univocidade espectral.

Para que os valores definidores de um intervalo sejam potenciais na extração de determinada feição, não basta que os seus *pixels* sejam pertencentes a uma única classe (univocidade espectral), mas também que as frequências dentro do intervalo sejam as maiores. Logo, não adiantaria conhecer um intervalo onde só existem *pixels* de vegetação, mas em baixa ocorrência (frequência), estando o restante dos *pixels* de vegetação em um intervalo de mistura espectral com outras classes de alvos.

#### **4.3.4 Reclassificação do Resultado da Aritmética de Bandas para a Forma Binária**

Uma vez conhecidos os intervalos com univocidade espectral, optou-se por reclassificar as imagens, oriundas da aritmética de bandas, para a forma binária. Essa reclassificação reduz a complexidade da imagem e elimina o contraste intraclass à medida que atribui um valor único para todos os *pixels* contidos dentro do intervalo definido. Nesse processo os *pixels* passam a compor duas regiões, são elas: i) a região definida pelo intervalo de *pixels* com univocidade espectral; ii) a região com todos os demais *pixels*.

A reclassificação para a forma binária possibilita a transformação da imagem binária para vetor. É desta forma que a informação sobre determinada classe de alvo compõe uma base cartográfica municipal, de modo que ela possa ser visualizada e analisada em conjunto com as demais informações espaciais do território. Também é em vetor que a informação pode ser quantificada.

#### **4.3.4 Inserção da Informação Altimétrica no Processo de Classificação**

A informação altimétrica foi inserida nos contextos em que a informação espectral, original ou oriunda da aritmética de bandas, não foi suficiente pra discernir as classes de alvos.

A inserção da informação altimétrica teve início no processo de classificação da cobertura hídrica, visto que o corpo d'água presente na área de estudo, devido ao seu alto nível de poluição, apresentou as mais variadas respostas espetrais, estando inseridas em regiões de mistura espectral com as outras classes de alvos. Para a classificação da cobertura hídrica em função da altimetria foram definidos dois limiares, um para o Modelo Digital de Elevação e outro para o Modelo Digital do Terreno, e realizados testes para averiguar qual dos dois apresentam melhor potencial de classificação da cobertura hídrica.

Outra situação em que foi preciso a utilização da altimetria como delimitadora de classes foi na separação de cobertura pavimentada e telhado cinza, visto que esses possuem grande semelhança espectral, sendo necessário outro atributo que os diferencie. Neste caso foi utilizado o Modelo Digital de Elevação, uma vez que é a altura desses objetos que os diferem.

#### **4.3.5 Classificação Supervisionada por Distância Euclidiana e por Máxima Verossimilhança**

Em algumas situações foram utilizadas classificações supervisionadas por Distância Euclidiana e por Máxima Verossimilhança. Esses algoritmos, quando unicamente utilizados para a classificação da cobertura do solo urbano utilizando imagens de alta resolução, apresentam sérias deficiências e têm os seus resultados invalidados.

A estratégia utilizada neste trabalho foi realizar, quando outra medida não era possível, a classificação por trechos da área de estudo utilizando Máxima Verossimilhança. Isso foi possível através de recortes da ortofoto, reduzindo a área de estudo a pequenas regiões com no máximo três classes de alvos e com respostas espetrais semelhantes. Exemplos deste procedimento são: i) recorte (da ortofoto) de telhados de cerâmica e classificação – por Máxima Verossimilhança – de telhado de

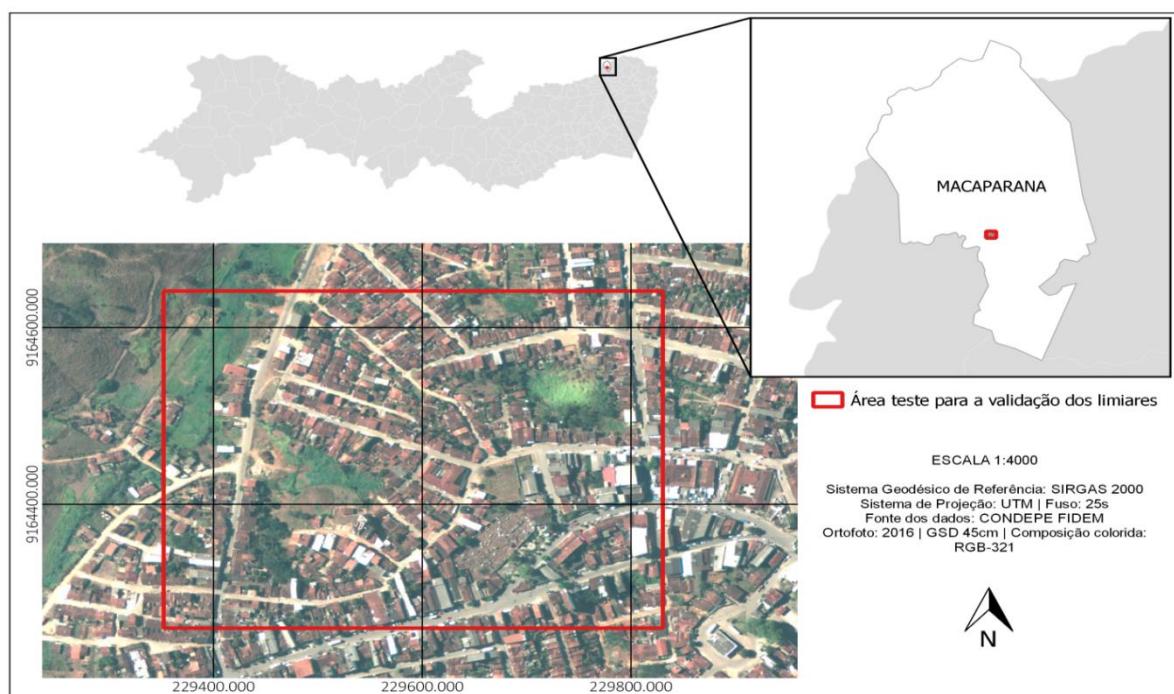
cerâmica vermelho e telhado de cerâmica marrom; ii) recorte (da ortofoto) de cobertura pavimentada unida à solo exposto e separação dessas classes de alvos por classificação por Máxima Verossimilhança.

#### 4.3.6 Validação dos Intervalos de Univocidade Espectral

Para a validação dos intervalos de univocidade espectral definidos a partir da amostra de pontos, foi utilizada uma ortofoto com GSD de 45 cm oriunda de um voo fotogramétrico ocorrido no município de Macaparana, em Pernambuco, conforme ilustra a Figura 11. A escolha desta área se justifica pela existência de material *raster* utilizado em pesquisa anterior a esta.

Para a validação dos intervalos foram realizadas as aritméticas de bandas que obtiveram bons resultados na área de estudo deste trabalho. Para isso foram utilizados os mesmo valores de ganho e *offset*. Após a execução da aritmética, as imagens foram reclassificadas para a forma binária e transformadas para vetor.

Figura 11 – Área teste para a validação dos intervalos de univocidade espectral.



Fonte: A autora (2020).

## 5 RESULTADOS E DISCUSSÕES

Nesta seção são apresentados os resultados obtidos durante o desenvolvimento desta pesquisa, assim como as discussões acerca dos referidos resultados.

### 5.1 ANÁLISE DO CONTRASTE INTRACLASSE NAS PROPRIEDADES ESPECTRAIS, ALTIMÉTRICAS E DE INTENSIDADE

A Tabela 1 apresenta os valores de desvio padrão nas variáveis altura, intensidade e bandas espectrais, para as classes de cobertura edificacional, cobertura hídrica, cobertura pavimentada, cobertura vegetacional e solo exposto. A análise do contraste é importante para identificar quais variáveis podem ser utilizadas para resolver questões de mistura espectral e quais variáveis aumentam a mistura espectral. Esses valores são representados nos gráficos 1, 2, 3, 4 e 5, de modo a facilitar a interpretação. Vale salientar que todos os gráficos foram gerados com os mesmos parâmetros de formatação, de modo a manter a proporcionalidade real dos dados.

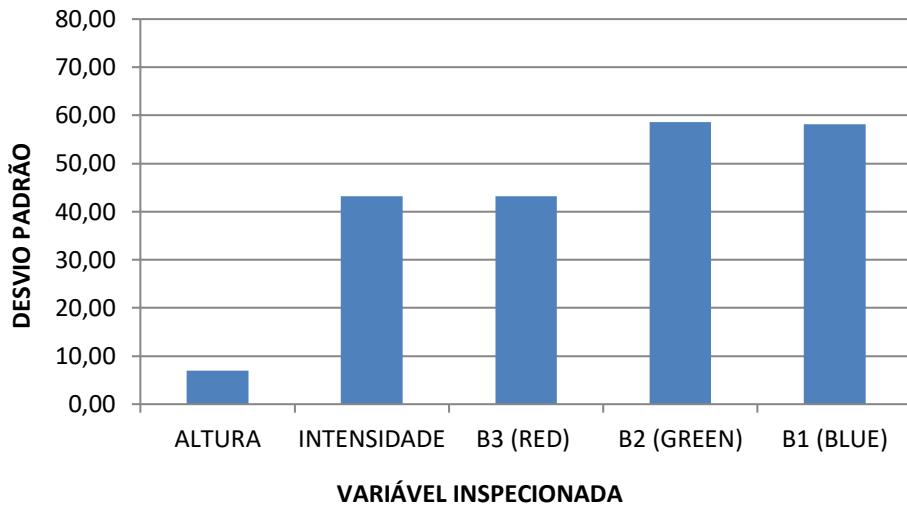
Tabela 1 - Desvio padrão das variáveis altura, intensidade e bandas espectrais.

CLASSE	ALTURA	INTENSIDADE	B3 (RED)	B2 (GREEN)	B1 (BLUE)
COBERTURA EDFICACIONAL	6,94	43,19	43,22	58,65	58,14
COBERTURA HÍDRICA	0,21	74,70	4,94	5,22	4,03
COBERTURA PAVIMENTADA	0,52	25,52	28,40	25,84	21,38
COBERTURA VEGETACIONAL	4,92	40,35	25,79	26,15	17,61
SOLO EXPOSTO	0,37	20,54	12,42	12,43	13,81

Fonte: A autora (2020)

O Gráfico 1 mostra que a cobertura edificacional possui pequeno contraste de altura, o que indica que na área de estudo as alturas das edificações não sofrem grandes variações. Referente à intensidade, esta possui contraste semelhante ao da banda 3 da ortofoto. Nas bandas 1 e 2, a cobertura edificacional possui contrastes equiparados.

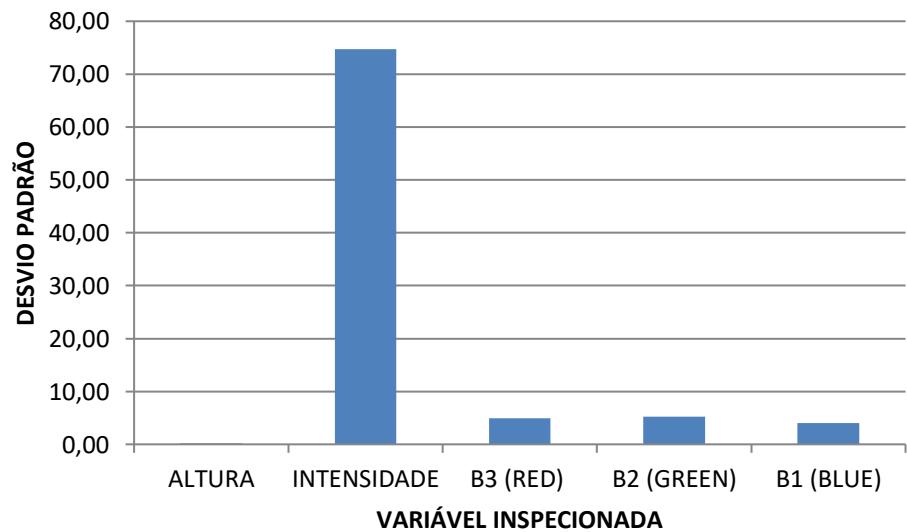
Gráfico 1 - Contraste intraclass da cobertura edificacional.



Fonte: A autora (2020).

No Gráfico 2, ganha destaque o alto contraste de intensidade da cobertura hídrica, provavelmente devido à composição da água poluída. Com relação à altura e às bandas espectrais, a cobertura hídrica possui contrastes equiparados.

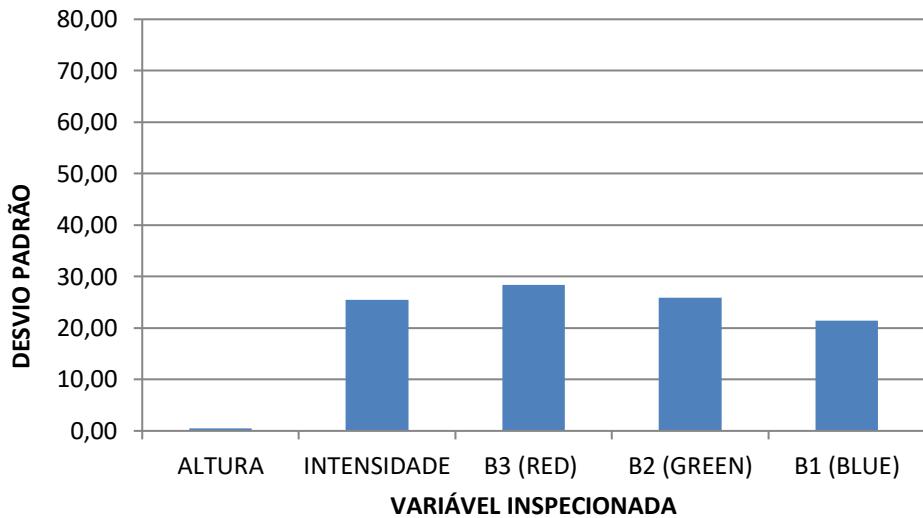
Gráfico 2 - Contraste intraclass da cobertura hídrica.



Fonte: A autora (2020).

O Gráfico 3 mostra que a cobertura pavimentada possui contrastes equiparados em todas as variáveis, com exceção da altura, a qual possui baixo contraste, indicando a não existência de viadutos na área de estudo.

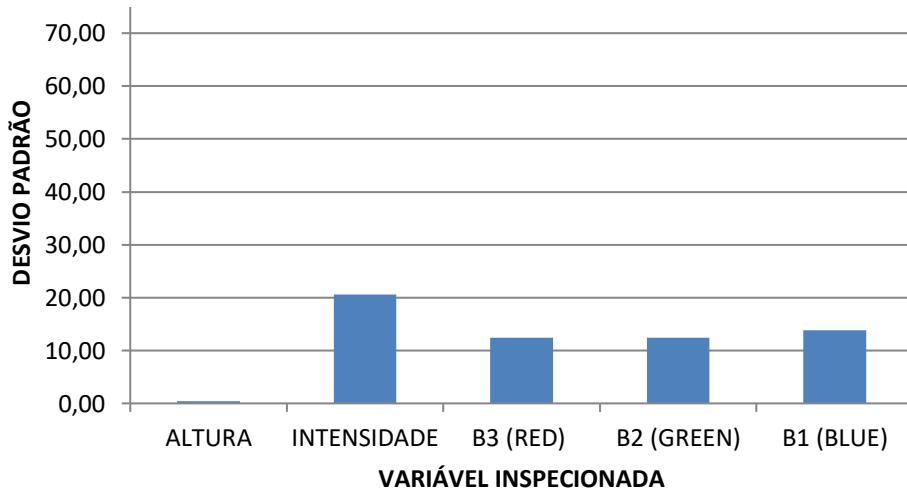
Gráfico 3 - Contraste intraclass da cobertura pavimentada.



Fonte: A autora (2019).

No Gráfico 4 pode ser visto que as variáveis altura, intensidade e bandas espectrais, apresentam baixo contraste na classe de solo exposto, o que indica que a referida classe não é passível de segregação em função dos atributos analisados.

Gráfico 4 - Contraste intraclass do solo exposto.

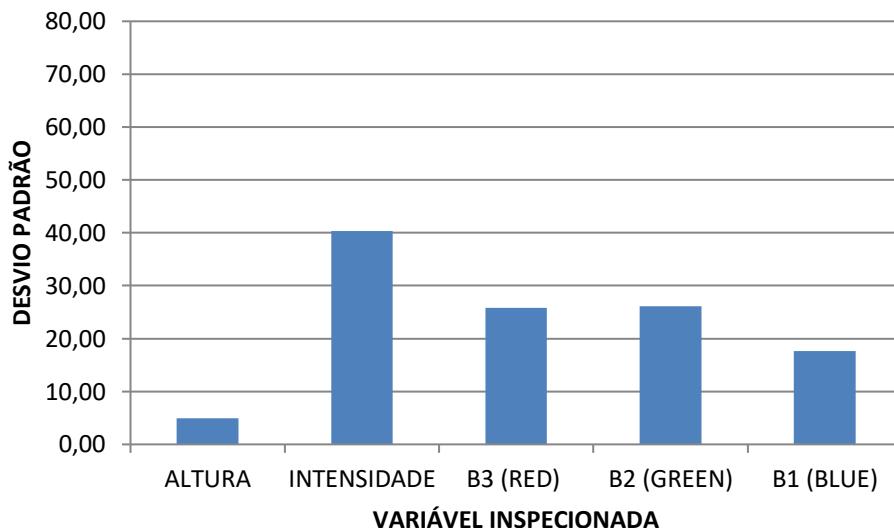


Fonte: A autora (2020).

O Gráfico 5 mostra que a cobertura vegetacional apresenta o maior contraste na variável intensidade, indicando que essa propriedade, a depender do padrão, pode ser utilizada para segmentar subclasses de vegetação. As bandas espectrais também apresentam alto contraste, porém, se a referida classe de alvo possuir semelhanças

espectrais com outras classes, esse alto contraste não será potencial para a segmentação da classe de cobertura vegetacional.

Gráfico 5 - Contraste intraclass da cobertura vegetacional.



Fonte: A autora (2020).

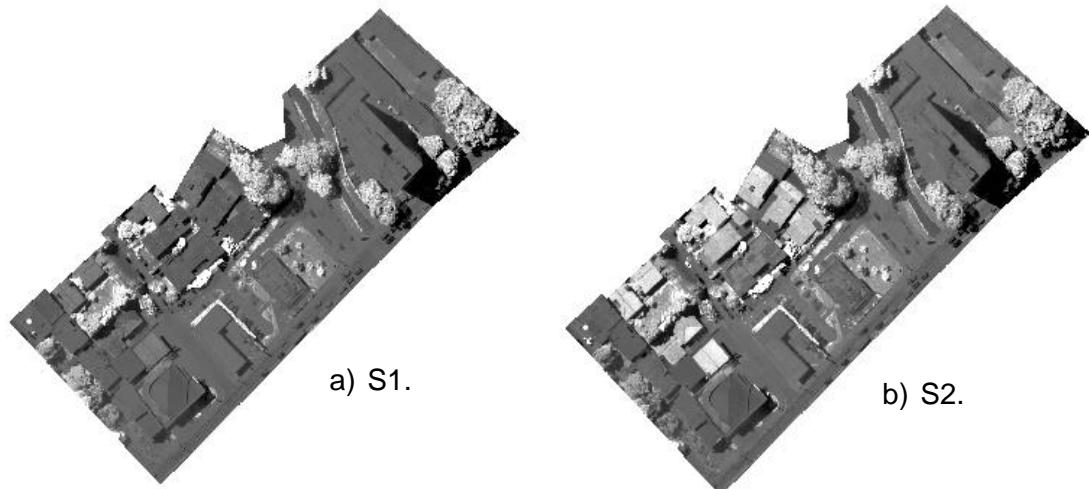
## 5.2 RAZÃO DE BANDAS E ÍNDICES DE VEGETAÇÃO

Nesta seção são apresentados, especificamente, os resultados referentes às operações aritméticas realizadas com as bandas espectrais da imagem aérea ortorretificada.

### 5.2.1 Resultados das Operações Aritméticas

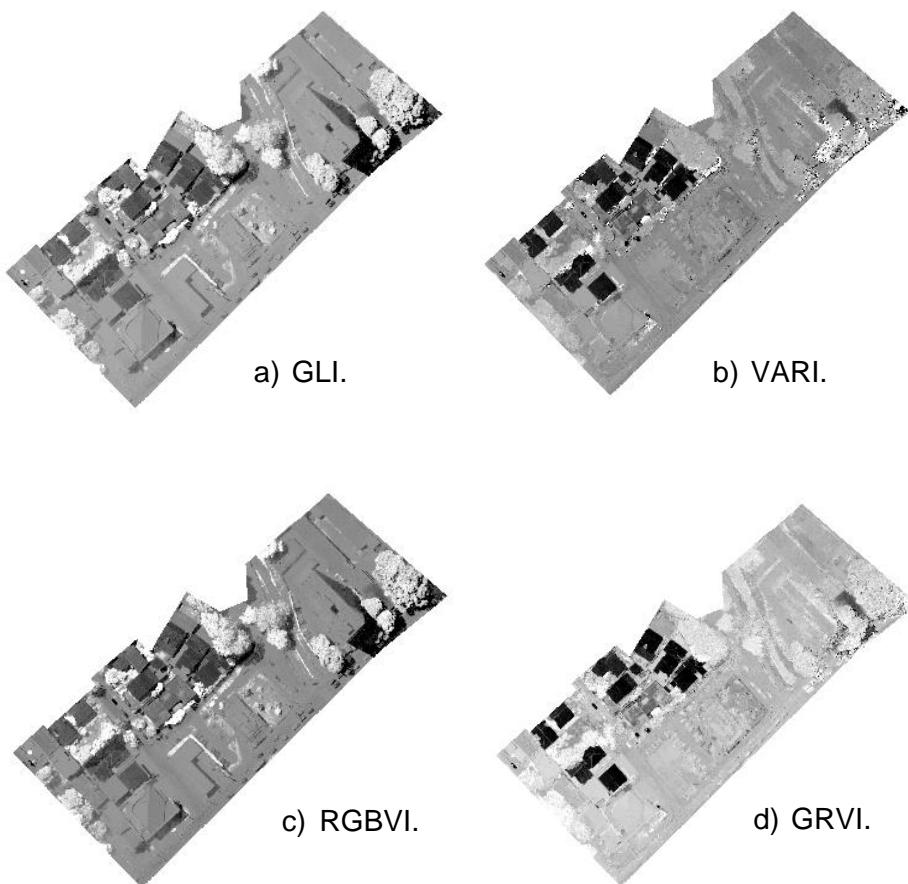
As Figuras 12 e 13 apresentam, respectivamente, os resultados das razões de bandas e dos índices de vegetação. Consegue-se enxergar, previamente, três tipos de fenômenos acontecendo em imagens diferentes, são eles: i) imagem segmentada em cobertura vegetacional e outros; ii) imagem segmentada em (cobertura vegetacional + parcela da cobertura edificacional) e outros; iii) imagem segmentada em cobertura vegetacional, parcela de cobertura edificacional e outros.

Figura 12 - Razão de bandas.



Fonte: A autora (2020).

Figura 13 - Índices de vegetação.



Fonte: A autora (2020).

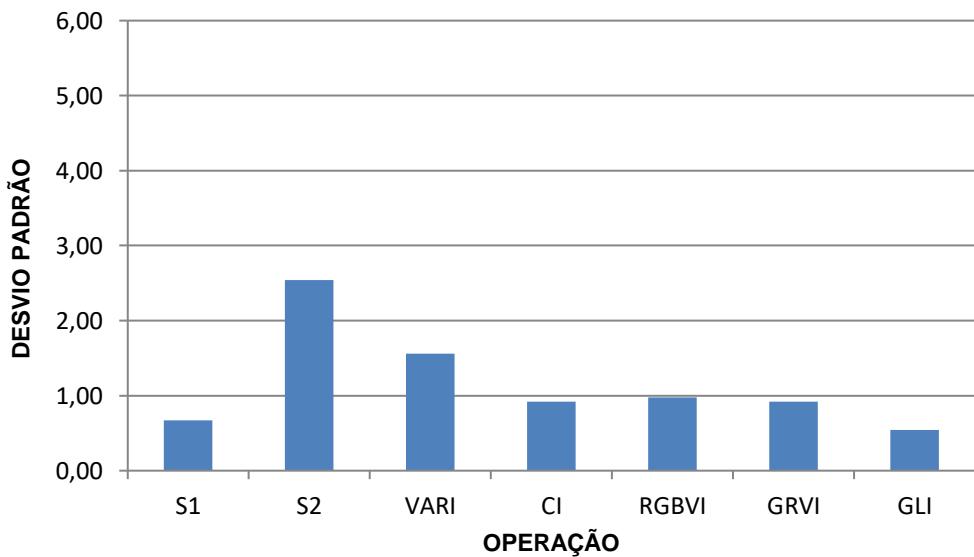
### 5.2.2 Contraste Intraclasses

Os Gráficos 6, 7, 8, 9 e 10, apresentam o contraste intraclasses nas operações aritméticas S1, S2, VARI, RGBVI, GRVI E GLI, para as classes cobertura edificacional, cobertura hídrica, cobertura pavimentada, solo exposto e cobertura vegetacional, respectivamente. Com eles pode-se fazer uma analise de quais índices apresentam um maior grau de uniformização e quais índices apresentam um maior grau de contraste intraclasses.

Vale salientar que o alto contraste intraclasses significa que o índice é potencial para subdivisões da respectiva classe em classes menores. Esse mesmo índice também pode ser potencial para a extração da respectiva classe, pois o contraste pode ser removido na reclassificação para a forma binária.

O Gráfico 6, de cobertura edificacional, mostra que os índices S2 e VARI possuem maior potencialidade de subdivisão da cobertura edificacional, uma vez que possuem o mais alto contraste intraclasses. Enquanto que os índices S1 e GLI apresentam a cobertura edificacional mais uniformizada.

Gráfico 6 - Contraste intraclasses da cobertura edificacional nos índices de vegetação.

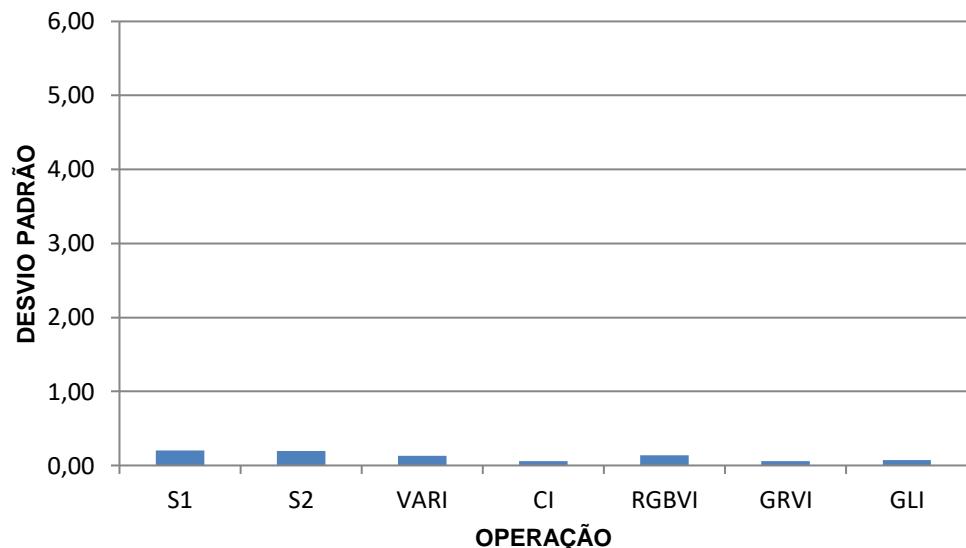


Fonte: A autora (2020).

Os Gráficos 7,8 e 9, de cobertura hídrica, cobertura pavimentada e solo exposto, mostram que, para todos os índices, os alvos foram uniformizados, devido

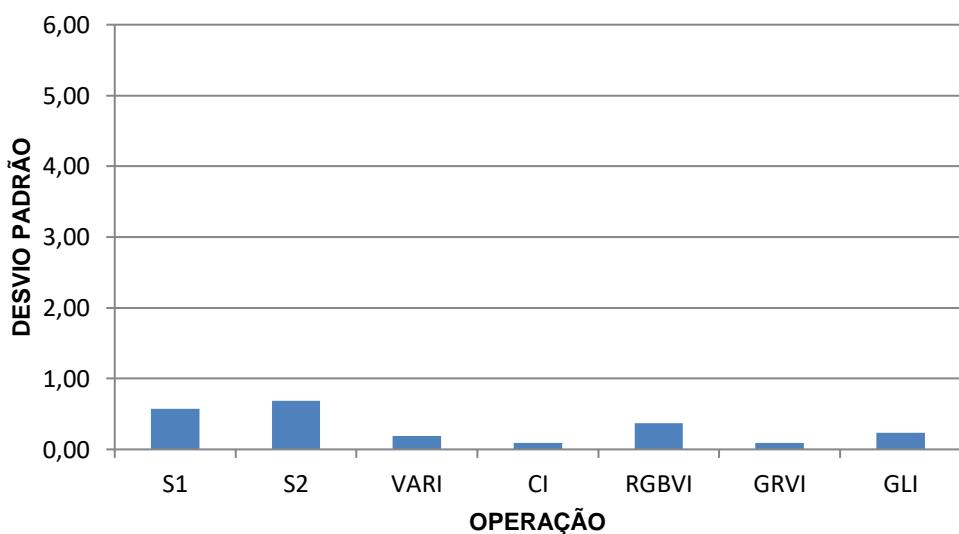
ao baixo contraste intraclasse. As mesmas classes sofreram um acréscimo de contraste intraclasse nos índices S1 e S2.

Gráfico 7 - Contraste intraclasse da cobertura hídrica nos índices de vegetação.



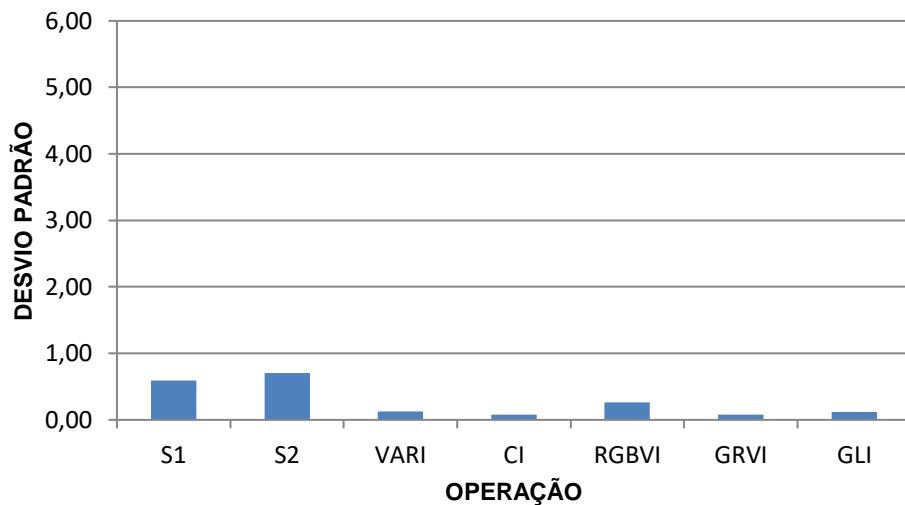
Fonte: A autora (2020)

Gráfico 8 - Contraste intraclasse da cobertura edificacional nos índices de vegetação.



Fonte: A autora (2020).

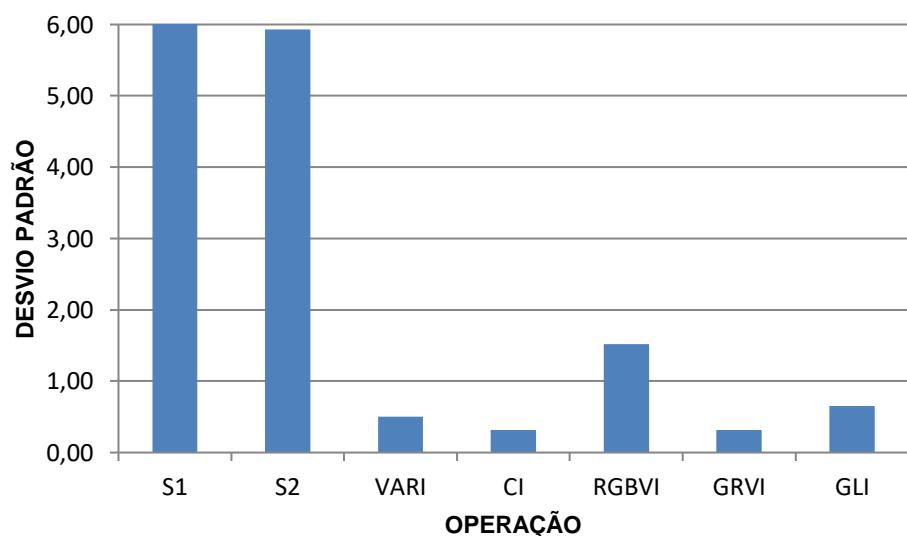
Gráfico 9 - Contraste intraclasse do solo exposto nos índices de vegetação.



Fonte: A autora (2020).

O Gráfico 10, de cobertura vegetacional, mostra a alta discrepância de contraste intraclasse dos índices S1 e S2 para com os demais índices. O RGBVI apresenta o terceiro maior contraste intraclasse, enquanto VARI, CI, GRVI e GLI são equiparados.

Gráfico 10 - Contraste intraclasse da cobertura vegetacional nos índices de vegetação.



Fonte: A autora (2020).

### 5.2.3 Dispersão dos Pontos Amostrais

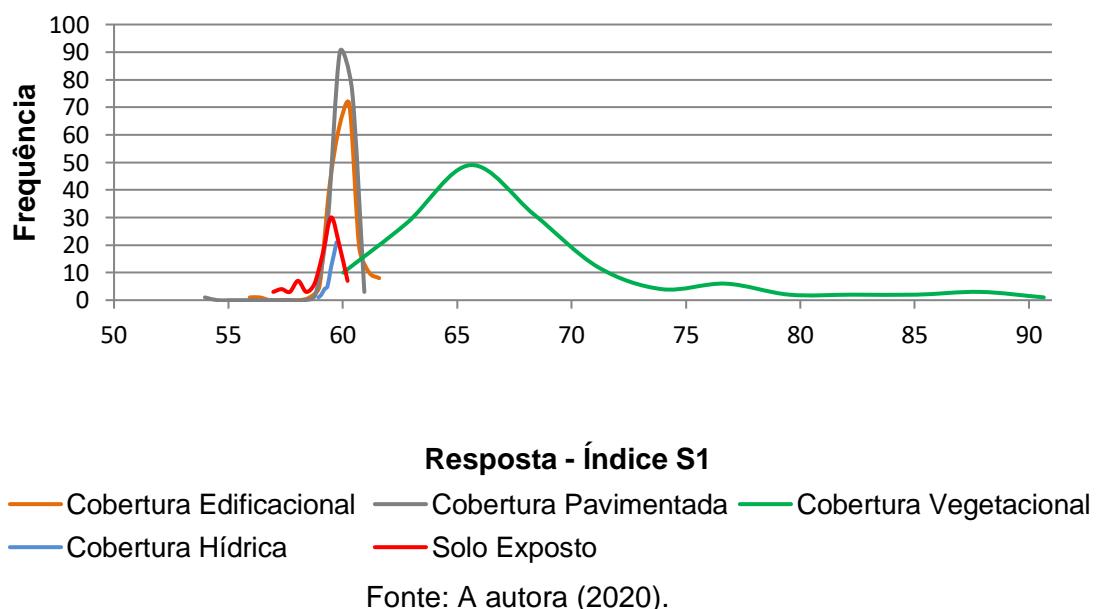
Os gráficos de dispersão dos pontos amostrais permitem uma análise mais pormenorizada do que acontece com as classes de alvos nos índices de vegetação, pois permitem a apreciação conjunta dos contrastes intraclasse e interclasse. Neles podemos observar quais classes se misturam e quais classes se sobressaem, espectralmente.

Vale salientar que os gráficos dos índices S1 (Gráfico 11) e S2 (Gráfico 14) tiveram valores de mínimo e máximo, para os eixos horizontal e vertical, diferentes dos demais gráficos, para melhor adequar as curvas às áreas dos gráficos.

Os Gráficos 11, 12 e 13, dos índices S1, RGBVI e GLI, respectivamente, apresentaram o melhor contraste interclasse entre a cobertura vegetacional e as demais classes.

Percebe-se que, apesar do alto contraste intraclasse da cobertura vegetacional no índice S1 (Gráfico 11), este índice demonstra um alto potencial de definição de limiar entre áreas de vegetação e áreas que não possuem vegetação. Com relação às outras classes, o índice S1 possui alto grau de mistura espectral.

Gráfico 11 - Dispersão dos pontos no índice S1.



Os Gráficos 12 e 13 mostram que os índices RGBVI e GLI realçam uma parcela da cobertura vegetacional, com *pixels* mais claros, e uma parcela da cobertura edificacional, com *pixels* mais escuros. Nesses índices, a cobertura hídrica e o solo exposto possuem alto grau de mistura espectral.

Gráfico 12 - Dispersão dos pontos no índice RGBVI.  
Fonte: A autora (2020).

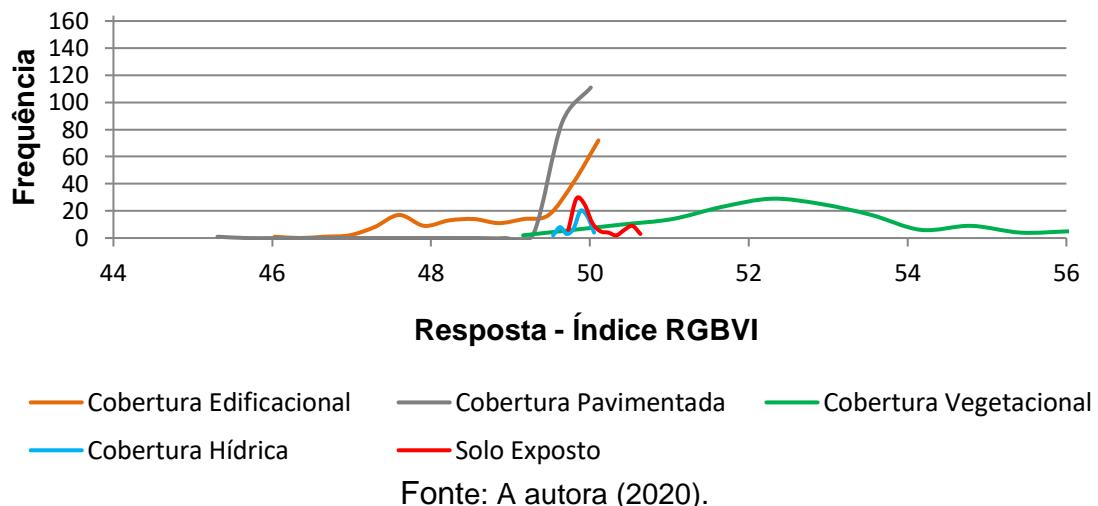
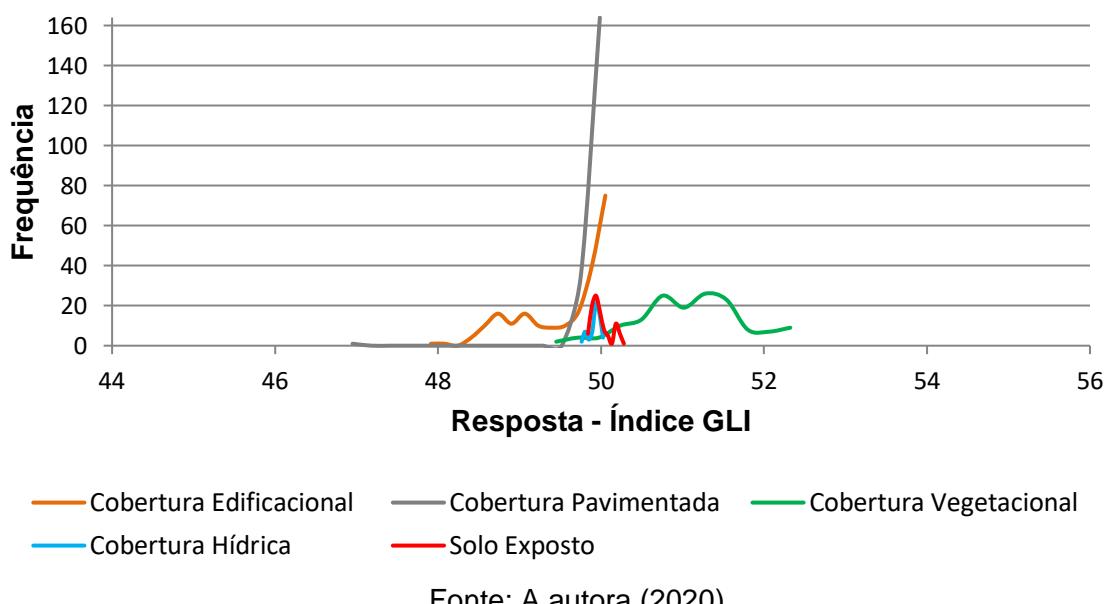


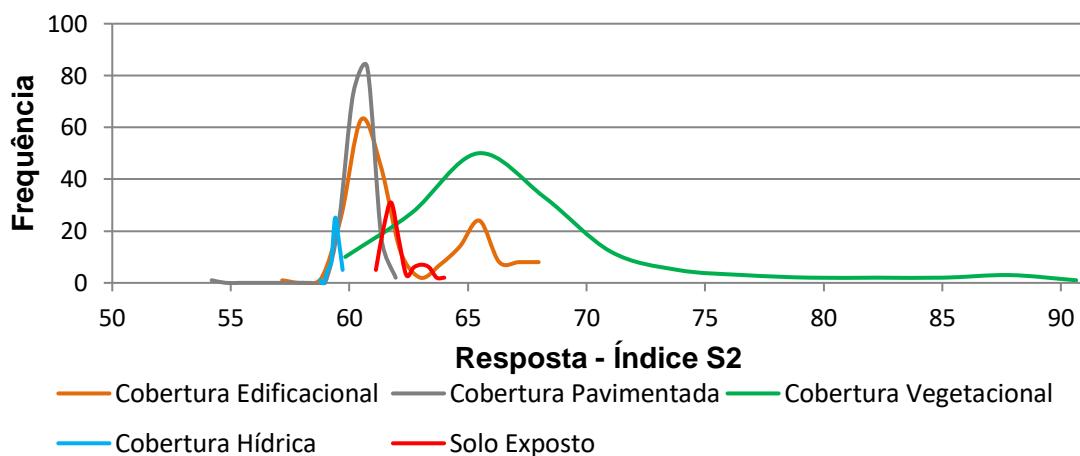
Gráfico 13 - Dispersão dos pontos no índice GLI.



Fonte: A autora (2020)

O Gráfico 14 mostra que há poucas regiões com univocidade espectral no índice S2 e que a parte da vegetação que se sobressai possui baixas frequências, logo, são poucos os *pixels* realçados. Nota-se também um alto grau de correlação entre uma parcela da cobertura edificacional e grande parte da cobertura vegetacional.

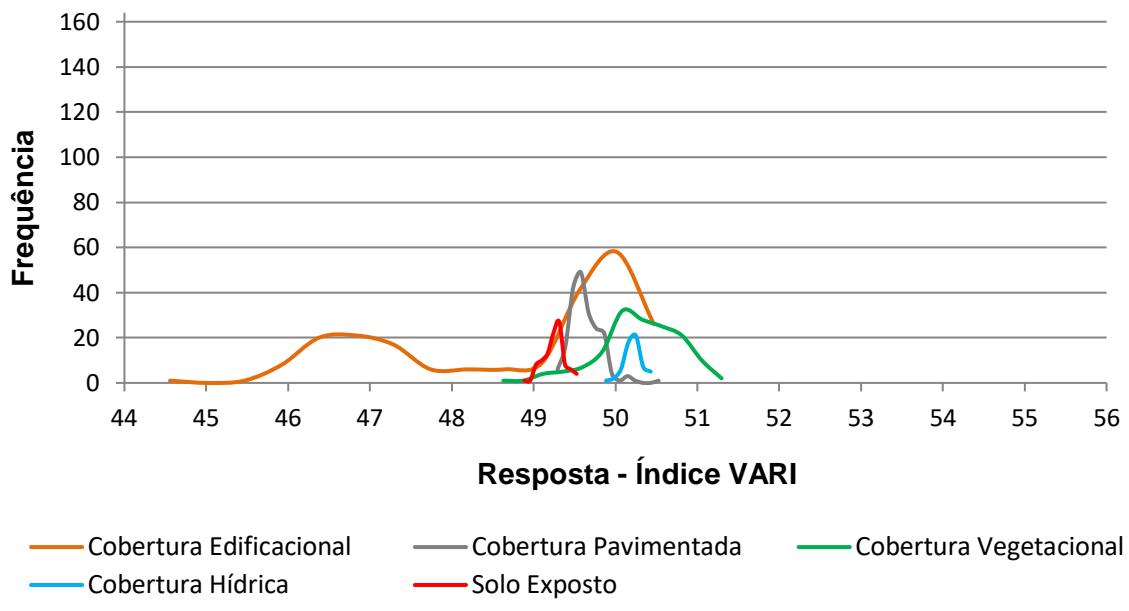
Gráfico 14 - Dispersão dos pontos no índice S2.



Fonte: A autora (2019).

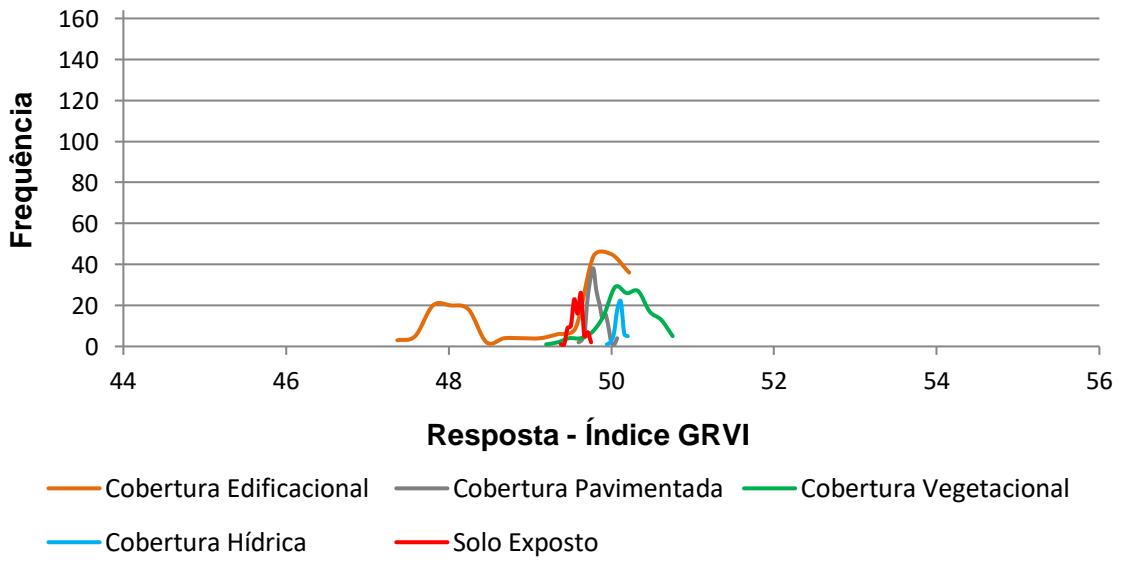
Os Gráficos 15 e 17 demonstram que os índices VARI e GRVI não são potenciais para a identificação da vegetação intraurbana, visto que grande parte dos *pixels* de cobertura vegetacional possuem valores semelhantes aos das outras classes, gerando grande mistura espectral. Entretanto, nos três índices, uma parcela da cobertura edificacional, com frequências baixas e médias, é realçada. No índice CI essa parcela edificacional apresenta *pixels* claros e nos índices VARI e GRVI, *pixels* escuros.

Gráfico 15 - Dispersão dos pontos no índice VARI.



Fonte: A autora (2020).

Gráfico 16 - Dispersão dos pontos no índice GRVI.



Fonte: A autora (2020).

#### 5.2.4 Zonas de Mistura Espectral e Zonas de Univocidade Espectral

As Tabelas 2 e 3 apresentam os intervalos das zonas de univocidade espectral de cobertura edificacional e cobertura vegetacional, respectivamente.

Tabela 2 - Zonas de univocidade espectral de cobertura edificacional.

OPERAÇÃO ARITMÉTICA	MÍNIMO	MÁXIMO
VARI	44,1	48,39
GRVI	47,15	49,06

Fonte: A autora (2020).

Tabela 3 - Zonas de univocidade espectral de cobertura vegetacional.

OPERAÇÃO ARITMÉTICA	MÍNIMO	MÁXIMO
S1	61,591	90,65
S2	67,981	90,65
VARI	50,531	51,3
CI	49,25	49,78
RGBVI	50,111	56,05
GRVI	50,221	50,75
GLI	50,051	52,32

Fonte: A autora (2020).

### 5.2.5 Reclassificação da Aritmética de Bandas para a Forma Binária

As Figuras 14 E 15 mostram os resultados da reclassificação para a forma binária utilizando os limiares das zonas de univocidade espectral de cobertura vegetacional, cujos limites estão descritos da Tabela 3. A razão de bandas S1 e os índices de vegetação GLI e RGBVI tiveram quase que a totalidade dos *pixels* de cobertura vegetacional contidos no intervalo de univocidade, o que indica que poucos *pixels* da referida classe estão em zona de mistura espectral. Em contrapartida, a razão de bandas S2 e os índices GRVI e VARI, tiveram poucas áreas de vegetação detectadas.

Figura 14 - Razão de bandas reclassificada para a forma binária como limiar de vegetação.

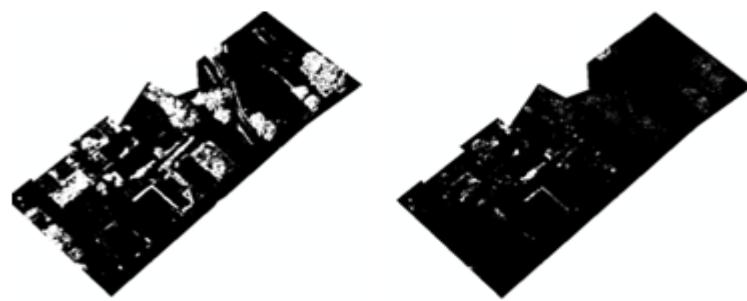


Fonte: A autora (2020).

a) S1.

b) S2.

Figura 15 - Índices reclassificados para a forma binária.



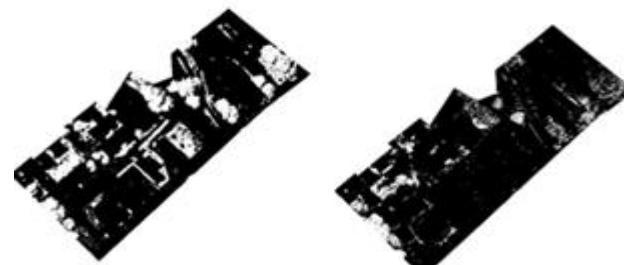
a) S1.

b) S2.



a) GLI

b) VARI



c) RGBVI

d) GRVI

Fonte: A autora (2019).

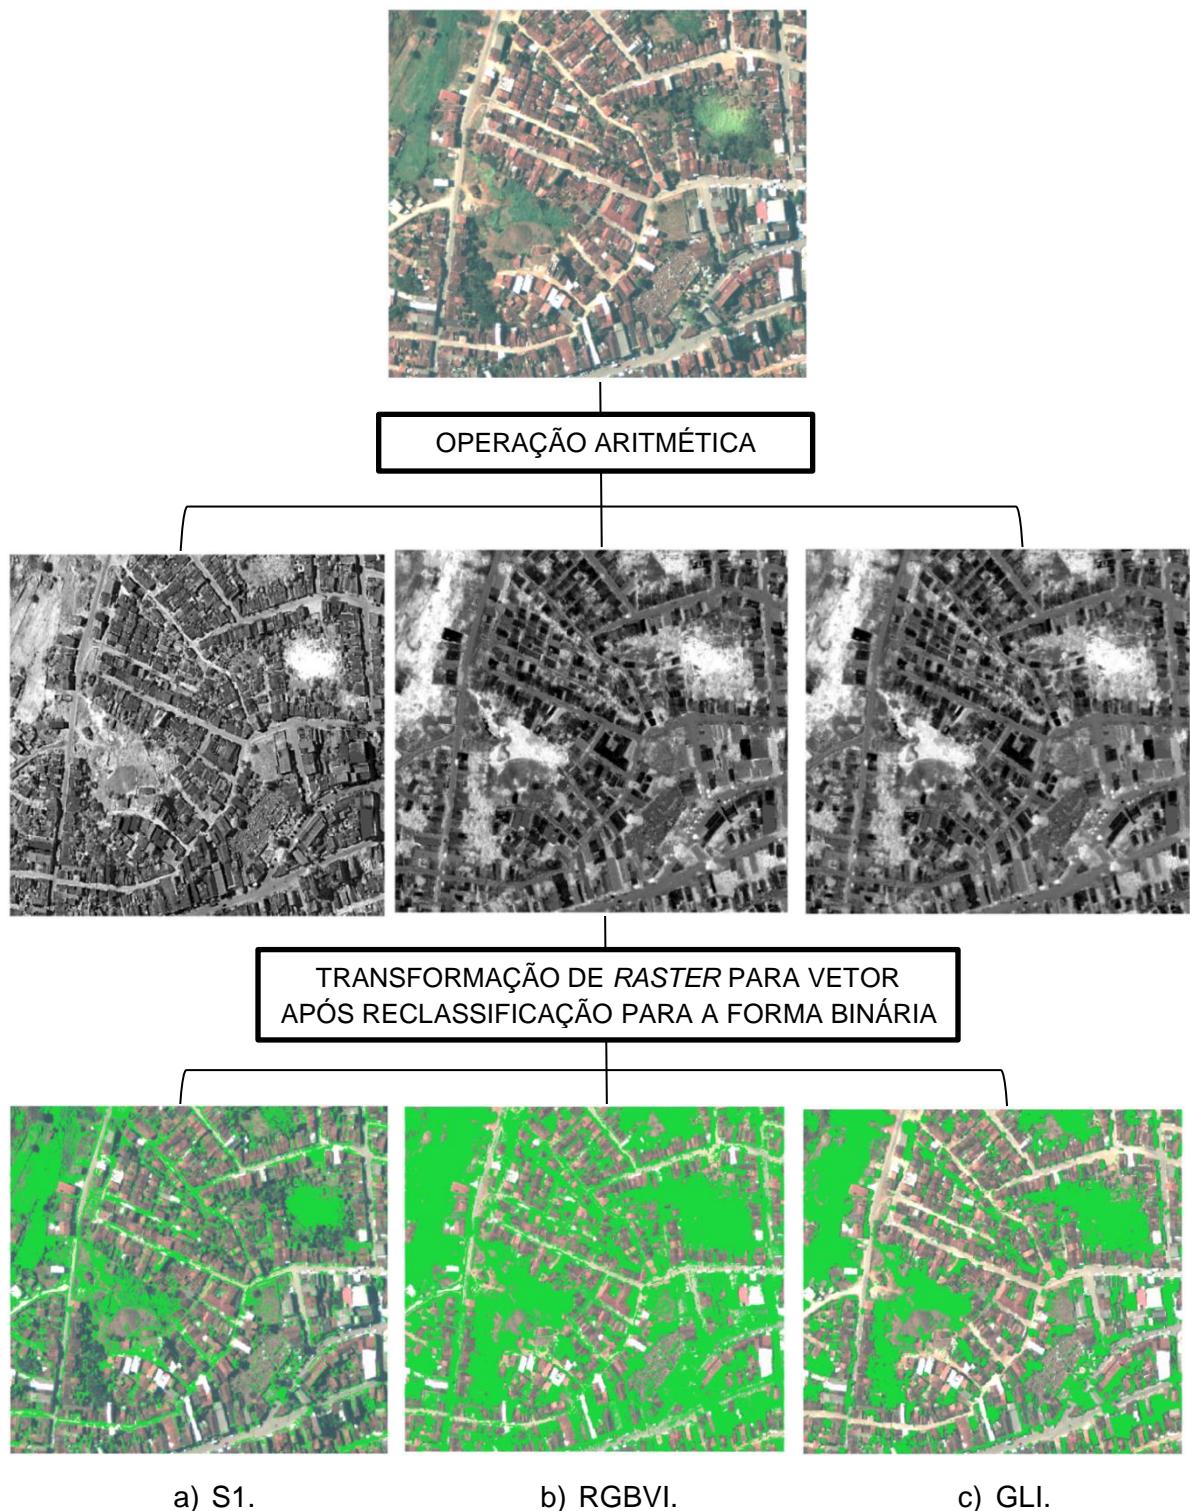


### 5.2.6 Validação dos Intervalos de Univocidade Espectral

As Figuras 16 e 17 apresentam os resultados da aplicação, na área teste de Macaparana, dos limiares de univocidade espectral de cobertura vegetacional e edificacional, respectivamente. Para esse propósito, foram realizadas as operações aritméticas, seguidas das reclassificações para a forma binária e transformação de *rasters* para vetor. Na Figura 16 é possível notar que a operação RGBVI classifica um número maior de *pixels* como sendo de cobertura vegetacional, seguida do GLI e S1. Na Figura 17 é possível notar que a operação GRVI classifica um número maior de *pixels* como sendo de cobertura edificacional do tipo telhado de cerâmica.

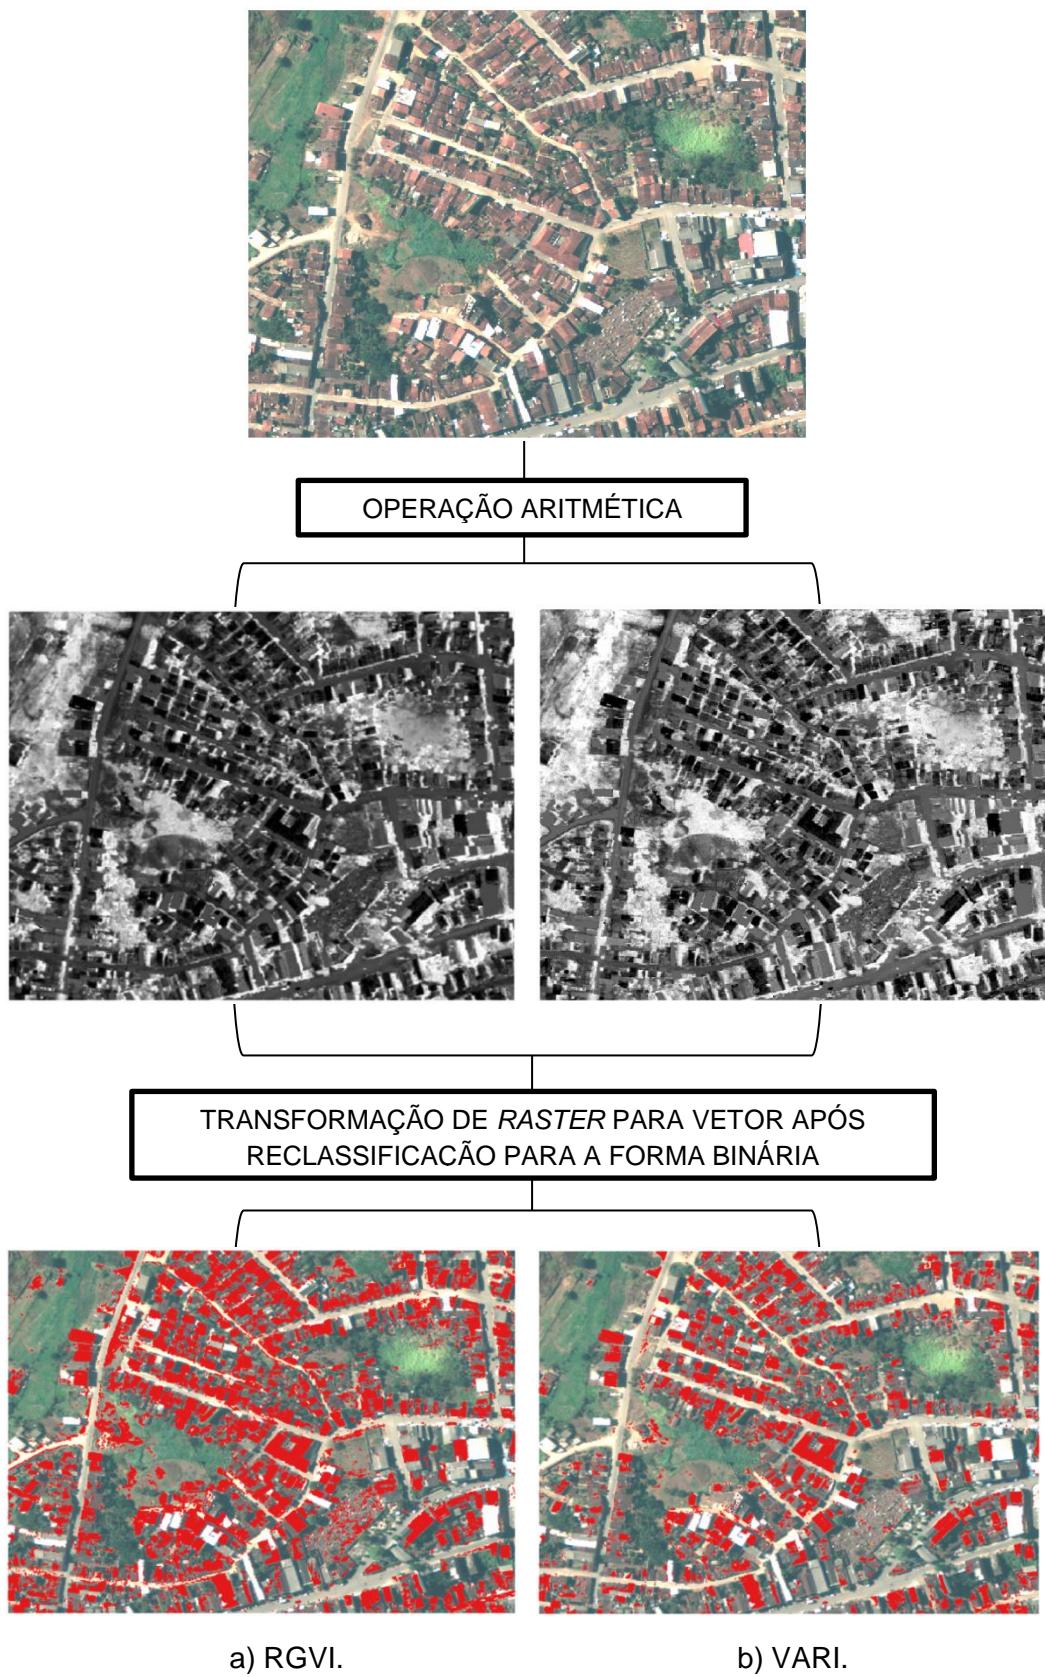
Como a ortofoto de Macaparana tem resolução inferior à ortofoto de Recife, algumas confusões espectrais ocorreram de forma mais acentuada, a exemplo de *pixels* de telhado de cerâmica classificados como cobertura vegetacional, em especial nas operações RGVI e GLI. Com relação à cobertura edificacional do tipo telhado de cerâmica, a operação VARI não classificou telhados ou partes de telhados com tons mais escuros. Esse tipo de validação serve para elencar as operações em função da veracidade com a realidade terrestre, uma vez que na área de estudo em Recife os resultados se mostraram muito semelhantes.

Figura 16 - Teste dos limiares espectrais de cobertura vegetacional em outra área de estudo.



Fonte: A autora (2020).

Figura 17 - Teste dos limiares espectrais de cobertura edificacional em outra área de estudo.



Fonte: A autora (2020).

## 5.2.7 Classificação da Cobertura do Solo Urbano

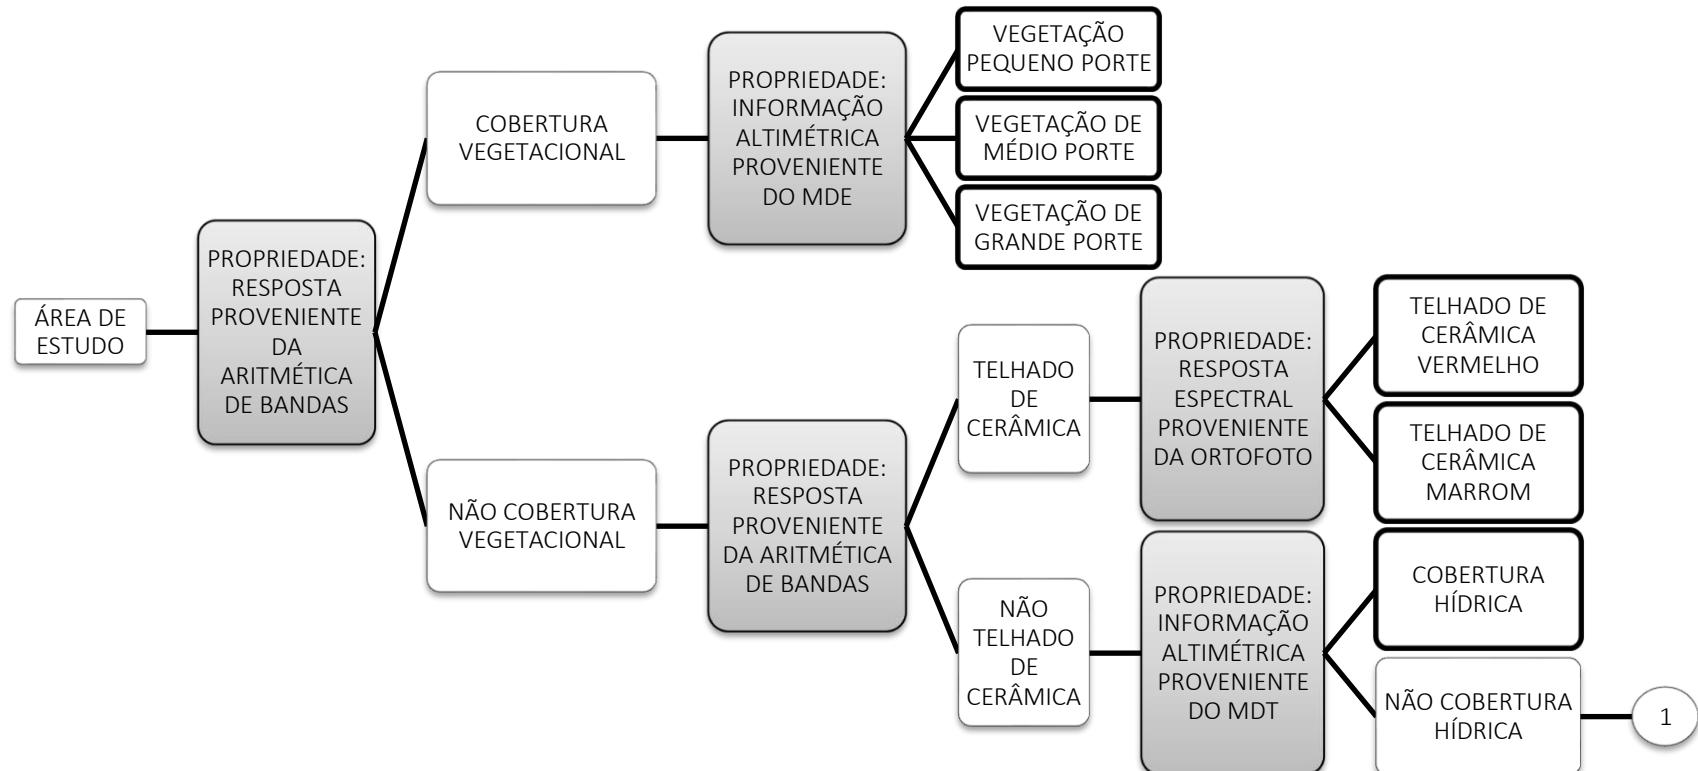
Esta seção apresenta os resultados finais desta pesquisa, desde a rede semântica para a discriminação das classes, até a classificação de cada objeto definido nos níveis de classificação.

### 5.2.7.1 Rede Semântica para a Discriminação das Classes

O processo de classificação do solo urbano seguiu a ordem estabelecida pela rede semântica apresentada nas Figura 18 e 19. O termo propriedade refere-se ao atributo utilizado para a discriminação das classes. Vale salientar que atributos iguais foram utilizados em diferentes fontes, a saber: i) a resposta espectral proveniente das ortofotos e a resposta proveniente das operações aritméticas; ii) a informação altimétrica proveniente do MDT e a informação altimétrica proveniente no MDE.

Nesta etapa do trabalho, foram imprescindíveis as ferramentas de geoprocessamento e de gerenciamento de dados vetoriais e *raster*, dentre as quais pode-se destacar: diferença simétrica entre vetores, recorte de *raster* por máscara, divisão de camada vetorial e reclassificação de *raster*. Essas ferramentas possibilitaram que cada objeto classificado fosse retirado do contexto e não influenciasse as classificações *a posteriori*, e isso, além dos dados auxiliares, também viabilizou a classificação do solo, em especial quando foi realizada a classificação por máxima verossimilhança por trechos, sendo reduzida a variabilidade espectral presente na cena inteira.

Figura 18 - Rede semântica para a discriminação das classes urbanas (parte 1).



Fonte: A autora (2020).

Figura 19 - Rede semântica para a discriminação das classes urbanas (parte 2).



Fonte: A autora (2020).

#### 5.2.7.2 Cobertura Vegetacional

A propriedade utilizada na classificação da cobertura vegetacional foi a resposta proveniente da aritmética de bandas. A Figura 20 mostra o resultado da transformação de *raster* para vetor da razão de bandas S1 e dos índices de vegetação GLI e RGBVI, os quais demonstraram potencial para a classificação da vegetação intraurbana. Com a sobreposição na imagem área ortonretificada e fazendo uma análise visual global dos resultados, pode-se perceber que além de semelhantes, S1, GLI e RGBVI, quando submetidos à reclassificação para a forma binária com o uso dos intervalos de univocidade espectral de cobertura vegetacional, conseguiram classificar as mais altas frequências de vegetação.

Para analisar a diferença em termos quantitativos, a Tabela 4 contém as áreas, em metros quadrados, da cobertura vegetacional na razão de bandas S1 e nos índices GLI e RGBVI. Nota-se que a diferença entre RGBVI e GLI é significativamente menor que a diferença entre ambos os índices e S1.

Figura 20 - Classificação da cobertura vegetacional.



Fonte: A autora (2020).

Tabela 4 - Área da cobertura vegetacional.

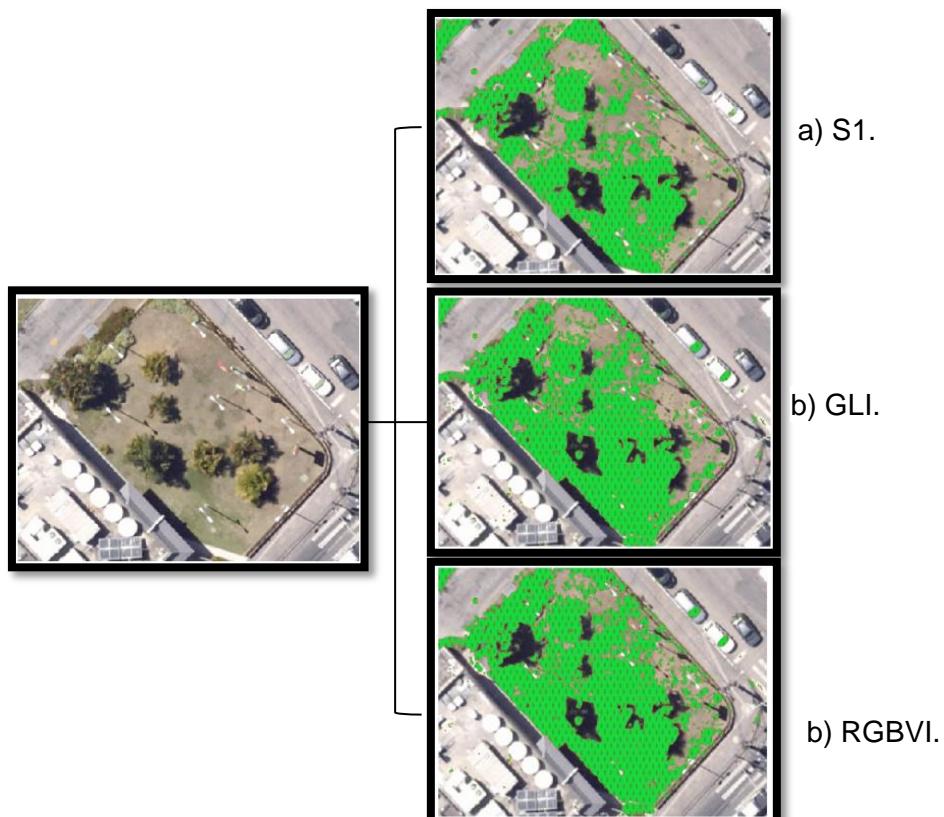
OPERAÇÃO	ÁREA (m <sup>2</sup> )
S1	3502,88
GLI	4367,77
RGBVI	4428,13

Fonte: A autora (2020).

Para analisar no detalhe as diferenças entre S1, GLI e RGBVI, foram feitos dois recortes na área de estudo. A Figura 21 apresenta um trecho da área de estudo onde há vegetação de diferentes alturas, inclusive partes de vegetação rasteira, o que ocasionaria dúvidas no analista, caso o método de extração fosse fotoanálise seguida

de vetorização em tela. A Figura confirma o que mostra a Tabela 4: que S1 considera uma quantidade menor de *pixels* como sendo de vegetação. Também notamos que RGBVI e GLI classificaram a maior parte da vegetação rasteira, se comparados com S1.

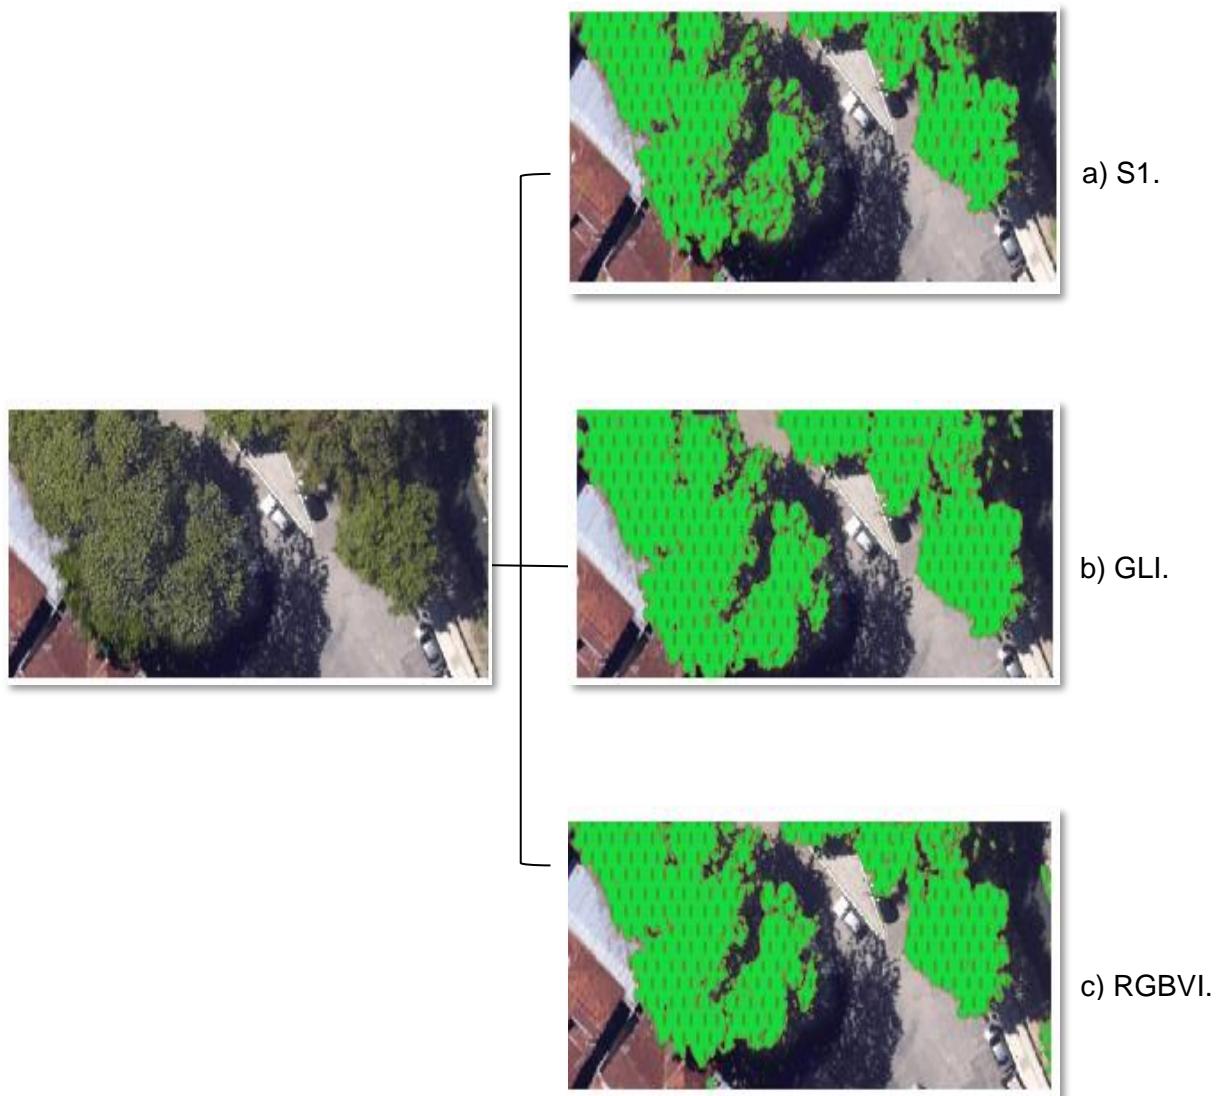
Figura 21 - Recorte 1 para análise da classificação da vegetação.



Fonte: A autora (2020).

A Figura 22 apresenta um recorte de uma área com vegetação de porte maior e mais densa, para analisarmos as diferenças entre S1, GLI e RGBVI. Nota-se mais uma vez que S1 classifica menos *pixels*, de modo que a área de vegetação apresenta-se mais fragmentada que nos índices GLI e RGBVI.

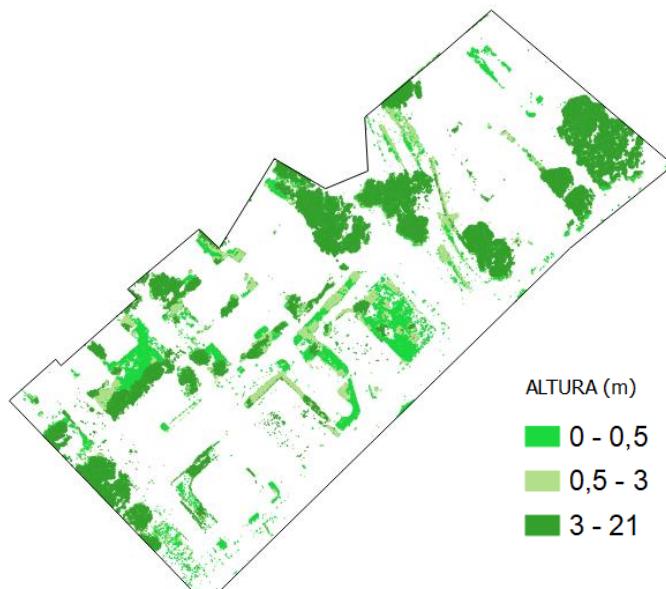
Figura 22 - Recorte 2 para a análise da classificação da vegetação.



Fonte: A autora (2020).

Em função da altimetria proveniente do MDE pode-se classificar a cobertura vegetacional em subclasses, a saber: i) vegetação de pequeno porte; ii) vegetação de médio porte e; iii) vegetação de grande porte. A classificação pode ser vista na Figura 23.

Figura 23 – Classificação da vegetação em função da altura.



Fonte: A autora (2020).

#### 5.2.7.3 Cobertura Hídrica

A cobertura hídrica da área de estudo desse trabalho consiste em um trecho do Riacho Parnamirim, um dos afluentes da margem esquerda do Rio Capibaribe no bairro de Casa Forte em Recife. Ao longo dos anos esse riacho vem sofrendo muitas agressões ambientais deixando-o em situação crítica de poluição. Por se apresentar como uma massa escura e poluída, a resposta espectral dessa água encontra-se numa região de mistura espectral com as outras classes de alvos, inviabilizando a sua classificação em função da informação espectral contida nas ortofotos ou provenientes da aritmética de bandas.

Diante disso, criou-se a alternativa de classificação da cobertura hídrica em função da informação altimétrica. Foram realizados testes com o Modelo Digital do Terreno e com o Modelo Digital de Elevação, cujos resultados podem ser vistos nas Figuras 24 e 25, respectivamente.

Figura 24 - Classificação da cobertura hídrica em função do MDE.



Fonte: A autora (2020).

Figura 25 - Classificação da cobertura hídrica em função do MDT.



Fonte: A autora (2020).

A informação altimétrica proveniente do MDT apresentou maior potencial de classificação da cobertura hídrica. A classificação com o MDE apresentou região de confusão altimétrica com sombra e teve o contorno interrompido devido a sobreposição da vegetação, fatores que tornaram a classificação deficiente.

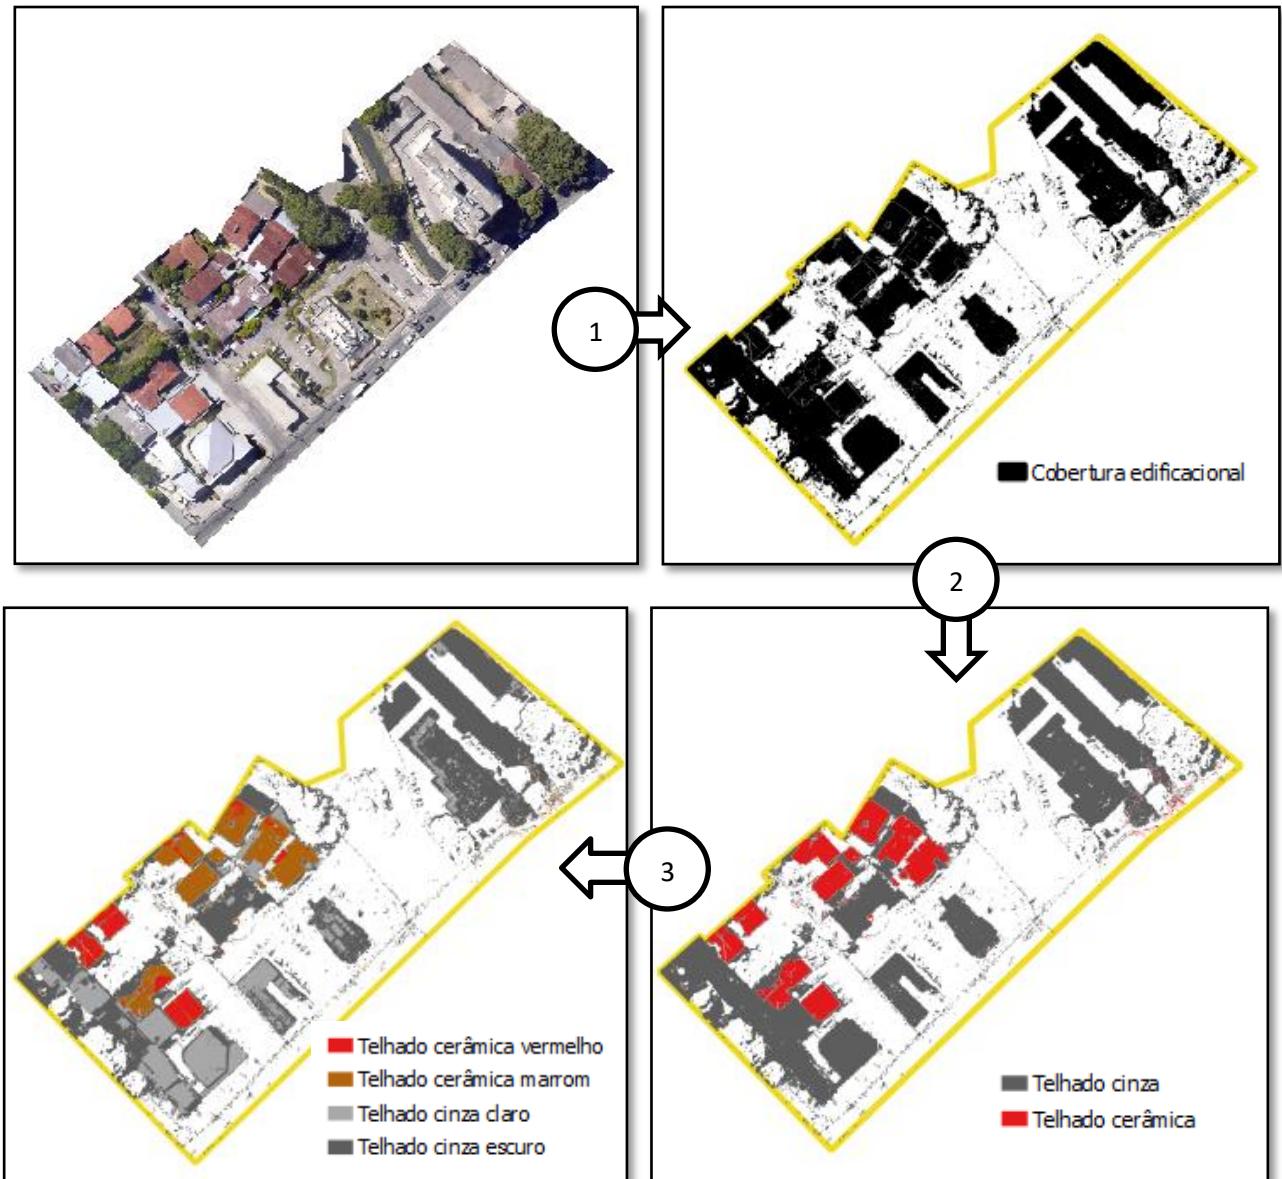
#### 5.2.7.4 Cobertura Edificacional

A classificação da cobertura edificacional (Figura 26) ocorreu em diferentes etapas e com atributos de diferentes fontes. Primeiramente foram classificados os telhados de cerâmica de modo geral, sem haver distinção quanto às nuances de cor proveniente dos diferentes estados de conservação dos telhados. Nessa primeira etapa foi utilizado o resultado da aritmética de bandas.

Na segunda etapa foi gerado um polígono contendo cobertura pavimentada, cobertura edificacional cinza e solo exposto. Isso foi possível realizando-se a operação de diferença simétrica entre o perímetro da área de estudo e o shapefile resultante da união dos shapefiles de cobertura vegetacional, cobertura hídrica, cobertura edificacional de cerâmica e solo exposto. De posse do polígono contendo cobertura pavimentada e cobertura edificacional cinza, pôde-se separar essa duas classes de alvos em função de suas altimetrias.

Na terceira etapa foram feitos dois recortes na ortofoto: i) telhado cerâmica; ii) telhado cinza. Em ambos os recortes foram realizadas a classificação supervisionada por Máxima Verossimilhança, possibilitando as subdivisões em classes mais específicas, a saber: i) telhado cerâmica vermelho e telhado cerâmica marrom; ii) Telhado cinza claro e telhado cinza escuro.

Figura 26 - Níveis de classificação da cobertura edificacional.



Fonte: A autora (2020).

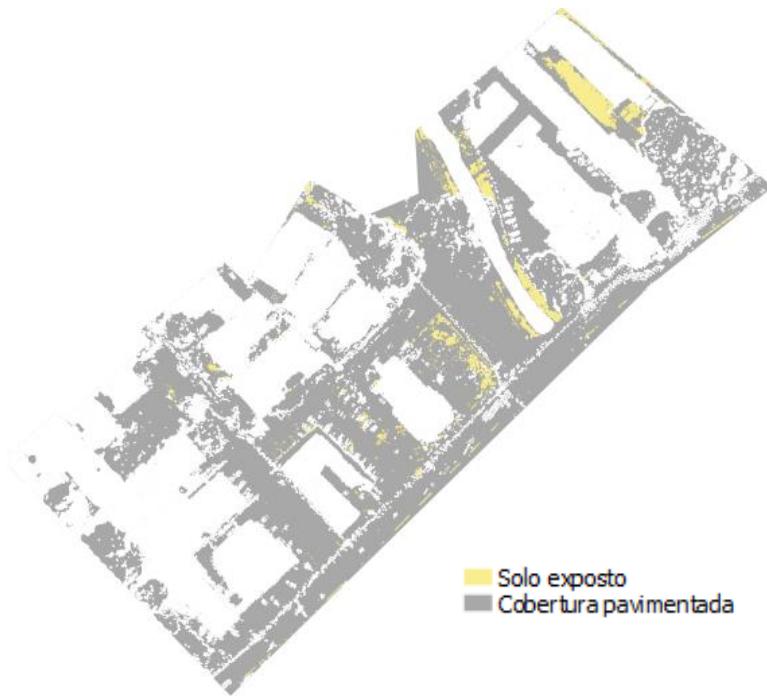
#### 5.2.7.5 Cobertura Pavimentada e Solo Exposto

Como dito no item 5.2.7.3, gerou-se um *shapefile* correspondente à região de cobertura pavimentada, cobertura edificacional cinza e solo exposto. A cobertura edificacional cinza foi extraída em função da informação altimétrica, restando a cobertura pavimentada e o solo exposto.

Devido à sedimentos nas regiões de solo exposto da área de estudo desse trabalho, a resposta espectral do referido alvo apresenta-se muito semelhante à

resposta espectral da cobertura pavimentada. Diante disso, foi realizado um recorte da ortofoto, utilizando o *shapefile* corresponde à apenas essas duas classes de alvos, de modo que todas as outras classes tenham sido excluídas da imagem. Após isso foi realizada a classificação por Máxima verossimilhança e, como o recorte diminuiu a complexidade da imagem, o resultado foi a delimitação de solo exposto e cobertura pavimentada em função de suas respostas espetrais, como apresentado na Figura 27.

Figura 27 - Classificação da cobertura pavimentada e do solo exposto.



Fonte: A autora (2020).

#### 5.2.7.6 Resultado da Classificação Utilizando Camadas Auxiliares

A Figura 28 apresenta o resultado da classificação utilizando informações espetrais e altimétricas, provenientes de imagens aéreas, produtos LIDAR, razões de bandas e índices de vegetação. Foram classificadas dez classes de objetos, a saber: cobertura vegetacional de pequeno porte, cobertura vegetacional de médio porte, cobertura vegetacional de grande porte, telhado cinza claro, telhado cinza escuro, telhado de cerâmica vermelho, telhado de cerâmica marrom, solo exposto, cobertura hídrica e cobertura pavimentada.

Figura 28 - Classificação da cobertura do solo urbano utilizando camadas auxiliares.

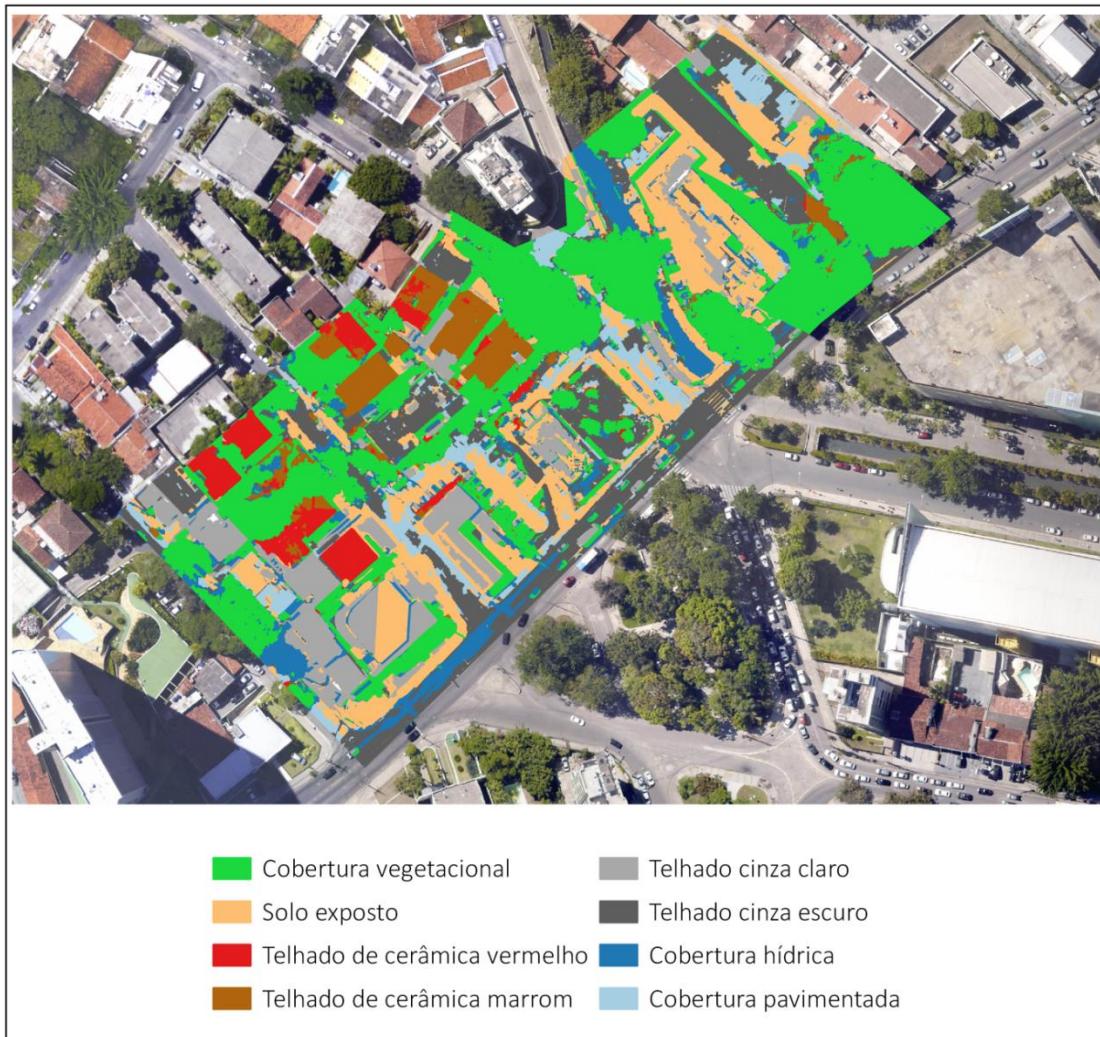


Fonte: A autora (2020).

#### 5.2.7.7 Classificação pelos Métodos Distância Euclidiana e Máxima Verossimilhança

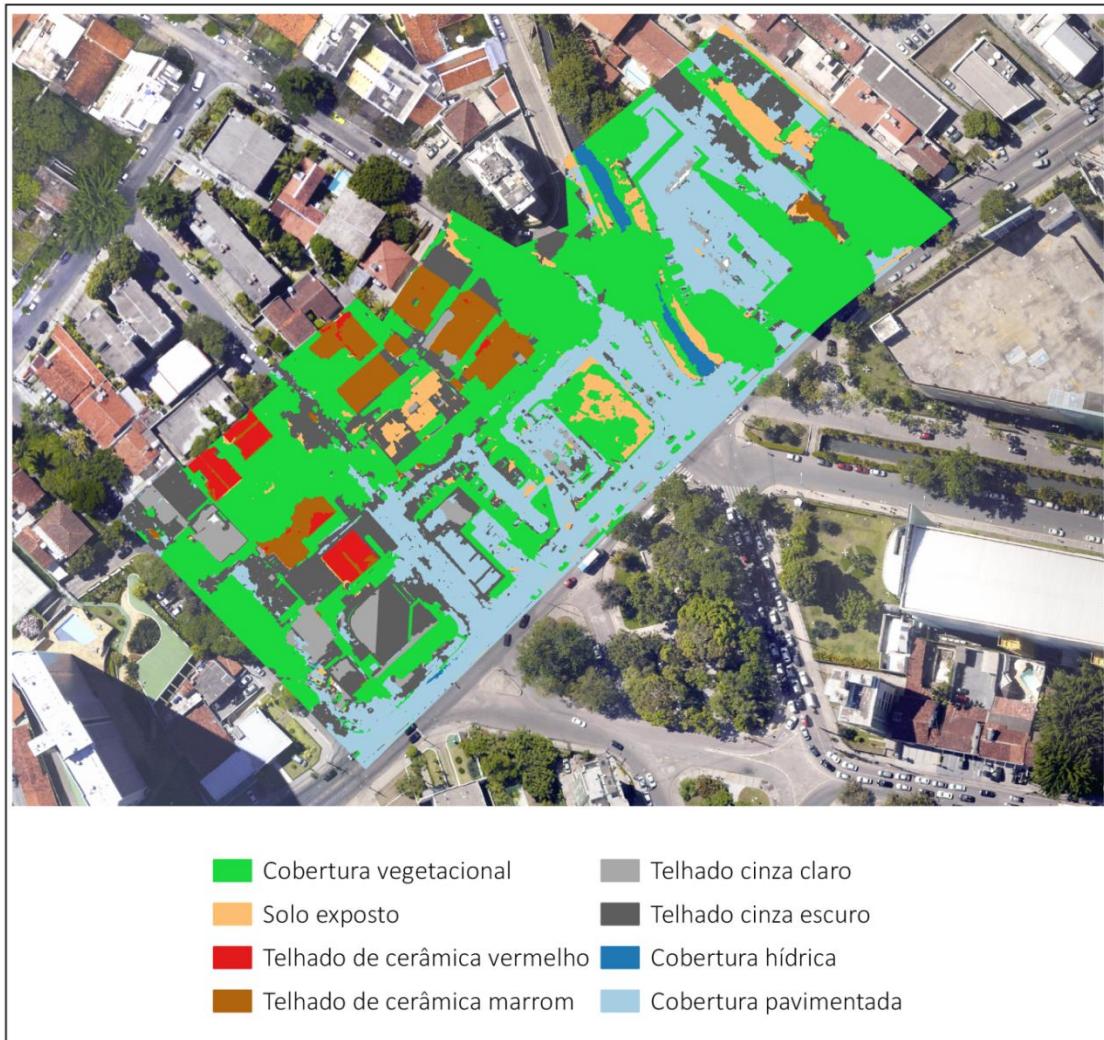
Para a realização das classificações por Distância Euclidiana (Figura 29) e por máxima verossimilhança (Figura 30), foram coletadas amostras de oito classes de alvos, a saber: cobertura vegetacional, solo exposto, telhados de cerâmica vermelho, telhado de cerâmica marrom, telhado cinza claro, telhado cinza escuro, cobertura hídrica e cobertura pavimentada.

Figura 29 - Classificação por distância euclidiana.



Fonte: A autora (2020).

Figura 30 – Classificação por Máxima Verossimilhança.



Fonte: A autora (2020).

É possível notar uma grande fragmentação da área de estudo na classificação por Distância Euclidiana, inviabilizando a definição de classes contínuas. Na classificação por Máxima verossimilhança, embora a fragmentação seja menor, foram classificadas várias regiões de sombra como pertencentes à classe do objeto que está sombreando.

Para ter conhecimento da acurácia das classificações, foram analisadas as suas matrizes de erros. Essas matrizes expressam a concordância entre a imagem classificada (linhas) e o conjunto de amostras de referência (colunas). Os valores da diagonal principal da matriz correspondem ao número de *pixels* que foram corretamente classificados, enquanto os demais valores correspondem às confusões espectrais entre classes.

A Tabela 5 apresenta a matriz de erros da classificação por distância euclidiana. As confusões espectrais mais significativas foram entre as classes: i) telhado cinza escuro e solo exposto; ii) telhado cinza escuro e cobertura pavimentada; iii) solo exposto e cobertura pavimentada; iv) cobertura vegetacional e telhado de cerâmica marrom; v) cobertura pavimentada e cobertura hídrica.

Tabela 5 - Matriz de erros da classificação por distância euclidiana.

VERDADE TERRESTRE \\ IMAGEM CLASSIFICADA	1	2	3	4	5	6	7	8	Soma linhas
1	9583	0	0	0	0	0	0	0	9583
2	0	7645	0	0	1944	0	0	918	10507
3	0	0	7290	0	2	0	0	0	7292
4	0	0	151	11230	0	9	0	0	11390
5	52	102	0	0	7724	0	0	893	8771
6	0	122	536	1069	0	29786	5642	0	37155
7	0	13	0	0	0	0	8490	0	8503
8	23	11262	0	0	8459	0	1461	3653	24858
Soma colunas	9658	19144	7977	12299	18129	29795	15593	5464	118059

(1)Telhado cinza claro; (2) telhado cinza escuro; (3) telhado cerâmica vermelho; (4) telhado cerâmica marrom; (5) solo exposto; (6) cobertura vegetacional; (7)cobertura hídrica; (8) cobertura pavimentada.

Fonte: A autora (2020).

A Tabela 6 apresenta a matriz de erros da classificação por máxima verossimilhança. As confusões espectrais mais significativas foram entre as classes telhado cinza escuro e cobertura pavimentada.

Tabela 6 - Matriz de erros da classificação por máxima verossimilhança.

VERDADE TERRESTRE \\ IMAGEM CLASSIFICADA	1	2	3	4	5	6	7	8	Soma linhas
1	9575	7	0	0	0	0	0	1	9583
2	0	8722	0	0	0	0	0	1785	10507
3	0	0	7288	4	0	0	0	0	7292
4	0	0	0	11387	0	3	0	0	11390
5	0	0	0	0	8722	0	0	49	8771
6	0	0	0	0	1	37118	31	5	37155
7	0	0	0	0	0	42	8423	38	8503
8	1	1553	0	0	48	11	10	23235	24858
Soma colunas	9576	10282	7288	11391	8771	37174	8464	25113	118059

(1) Telhado cinza claro; (2) telhado cinza escuro; (3) telhado cerâmica vermelho; (4) telhado cerâmica marrom; (5) solo exposto; (6) cobertura vegetacional; (7) cobertura hídrica; (8) cobertura pavimentada.

Fonte: A autora (2020).

## 6 CONCLUSÕES E RECOMENDAÇÕES

As informações espectrais presentes nas imagens de alta resolução não são suficientes para o reconhecimento de padrões capazes de definir limiares entre classes de alvos urbanos. As semelhanças espectrais ou as diferenças sutis são fatores que inviabilizam os métodos de classificação que utilizam apenas os valores dos *pixels* contidos nas bandas espectrais dos diferentes sensores. Logo, a discriminação dos alvos urbanos requer a utilização de camadas auxiliares no processo de classificação.

Nesta pesquisa foram estudadas as contribuições do comportamento espectral, altimétrico e de intensidade, provenientes de bandas espectrais de imagens aéreas, razões de bandas, índices de vegetação e produtos LIDAR, para a classificação do solo urbano. Os principais resultados apontaram que: i) a variável intensidade pode revelar propriedades hídricas que subsidiem estudos mais específicos de composição da água; ii) a aritmética de bandas na faixa do visível, quando aplicada à imagens de alta resolução, além de realçarem a vegetação servem para identificar alguns tipos de telhados; iii) as operações S1, GLI e RGBVI são potenciais para classificação da cobertura vegetacional urbana; iv) as operações VARI e GRVI são potenciais para a classificação da cobertura edificacional do tipo telhado de cerâmica, sem fazer distinção quanto ao seu estado de conservação; v) a variável altimetria é potencial para discriminar classes que possuem respostas espectrais semelhantes; vi) a classificação por máxima verossimilhança, quando aplicada em recortes com classes de sutis variações espectrais, viabiliza a discriminação dessas classes.

O uso de camadas auxiliares viabiliza a classificação do solo urbano e, por conseguinte, a atualização cartográfica municipal. A modernização dos métodos de imageamento tem exigido novos métodos de processamento de imagens, que integrem atributos de diferentes fontes e discrimine de modo mais eficaz a diversidade de alvos presentes em contextos urbanos, de modo a subsidiar a tomada de decisão sobre o território.

Por fim, recomenda-se que outros tipos de classes de alvos sejam abrangidos em estudos de reconhecimento de padrões utilizando propriedades de diferentes fontes, assim como foram utilizadas nesta pesquisa. Isso porque os cenários urbanos costumam ter grande variabilidade de objetos, fato este que demanda estudos especializados por grupos de classes, visto que o estudo integral das paisagens

urbanas agregaria alta complexidade. Um exemplo de classe de alvo a ser investigada de forma isolada é a de telhado verde, comum na cidade do Recife devido à Lei Municipal 18.112/2015, que obriga qualquer prédio com mais de quatro pavimentos a ter telhado verde. A classificação desse tipo de telhado encontra limitações quanto a sua resposta espectral e altura, pois essas propriedades podem ser iguais ou semelhantes às das árvores intraurbanas, devendo-se recorrer a uma terceira propriedade para separar essas duas classes de alvos.

## REFERÊNCIAS

- ARAKI,H..**Fusão de informações espectrais, altimétricas e de dados auxiliares na classificação de imagens de alta resolução espacial.** 2005. Tese (Doutorado em Ciências Geodésicas) - Universidade Federal do Paraná, Curitiba, 2005.
- ARAUJO, A. S.; LUCHIARI, A. Elaboração de mapa de cobertura da terra intraurbana com base em análise baseada em objetos (OBIA) para inferências sobre o uso na cidade de Marília/SP. **Geografia**, v. 41, n. 2, p. 241-260, 2016.
- ARAÚJO, T. P.; MELLO, F. M. Procedimento de imagens digitais: razão entre bandas. **Revista Geociências**. v. 29, n. 1, p. 121-131, 2010.
- BALTSAVIAS, E. P. Airborne laser scanning: basic relations and formulas. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 54, p.199–214, 1999.
- BENDIG, J.; YU, K.; AASEN, H.; BOLTEN, A.; BENNERTZ, S.; BROSCHET, J.; GNYP, M.L.; AND BARETH, G. Combining UAV-based plant height from crop surface models, visible, and near infrared vegetation indices for biomass monitoring in barley. **International Journal of Applied Earth Observation and Geoinformation**, v. 39, p. 79-87, 2015.
- BOTELHO, M. F.; CENTENO, J. A. S. Uso integrado de imagem de alta resolução espacial e altura derivada do laser scanner na escolha do classificador orientado a região. **Boletim de Ciências Geodésicas**, v. 1, n. 1, p. 71-87, 2005.
- CAMARA, G.; SOUZA, R. C. M.; FREITAS, U. M.; GARRIDO, J. SPRING: integrating remote sensing and GIS by object-oriented data modelling. **Computers & Graphics**, v. 20, n.3, p.395-403, 1996.
- CAVALCANTI, R. C.; CANDEIAS, A. L.; TAVARES JUNIOR, J. R. metodologia para obtenção de polígonos 3D a partir de nuvem de pontos LIDAR. **Revista Brasileira de Geomática**, v. 4, n. 1, p. 42-48, 2016.
- CENTENO, J. A. S.; MITISHITA, E. A. Laser scanner aerotransportado no estudo de áreas urbanas: a experiência da UFPR. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2007, Florianópolis. **Anais** [...]. Florianópolis: SBSR, 2007. p. 3645-3652.
- DURÁN, G. Y. B. **Estudo da resposta espectral de alvos urbanos com espectroscopia de reflectância e imagens de alta resolução espacial.** 2014. Dissertação (Mestrado em Geografia e Geociências) - Universidade Federal de Santa Maria, Santa Maria, 2014.
- FALKOWSKI, M. J.; GESSLER, P. E.; MORGAN, P.; HUDAQ, A. T.; SMITH, A. M. S. Characterizing and mapping forest fire fuels using ASTER imagery and gradient modeling. **Forest Ecol. Manage.**, v. 217, p. 129-146, 2005.

FRANÇA, A. F.; TAVARES JUNIOR, J. R.; MOREIRA FILHO, J. C. C. Índices NDVI, NDWI e NDBI como ferramentas ao mapeamento temático do entorno da Lagoa Olho D'Água, em Jaboatão dos Guararapes-PE. *In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA GEOINFORMAÇÃO*, 4., 2012, Recife. *Anais [...]*. Recife: SBCGTG, 2012. p. 1-9.

GITELSON, A. A.; KAUFMAN, Y. J.; STARK, R. et alii. Novel algorithms for remote estimation of vegetation fraction. **Remote Sensing of Environment**, v. 80, p. 76-87, 2002.

Hunt, E. Raymond Jr.; Doraiswamy, Paul C.; McMurtrey, James E.; Daughtry, Craig S.T.; Perry, Eileen M.; Akhmedov, B. A visible band index for remote sensing leaf chlorophyll content at the canopy scale. **Publications from USDA-ARS / UNL Faculty**. 1156, 2013.

IBRAHIN, F. I. D. Introdução ao geoprocessamento ambiental. São Paulo: Saraiva, 2014.

LIU, D.; XIA, F. Assessing object-based classification: advantages and limitations. **Remote Sensing Letters**, v. 1, n. 4, p. 187-194, 2010.

LIU, XIAOPING; HU, GUOHUA; CHEN, YIMIN; LI, XIA; XU, XIAOCONG; LI, SHANMIN; PEI, FENGSONG. High-resolution multi-temporal mapping of global urban land using Landsat images based on the Google Earth Engine Platform. **Remote Sensing of Environment**. v. 209. p. 227-238, 2018.

LOUHAICHI, M.; BORMAN, M. M.; JOHNSON, D. E. Spatially Located Platform and Aerial Photography for Documentation of Grazing Impacts on Wheat. **Geocarto International**, v. 16, n. 1, p. 65–70, 2001.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. **International Journal of Remote Sensing**. v. 28, n.5, 2007.

LUSSEM, U.; BOLTEN, A.; GNYP, M.; JASPER, J.; BARETH, G. Evaluation of RGB-BASED vegetation indices from UAV imagery to estimate forage yield in grassland. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. v. 42-3, p. 1215-1219, 2018.

MACHADO, A. M. L. **Extração automática de contornos de edificações utilizando imagem gerada por câmera digital de pequeno formato e dados LIDAR**. 2006. Tese (Doutorado - em Ciências Geodésicas) - Universidade Federal do Paraná. Curitiba, 2006.

MENEZES, P. R.; ALMEIDA, T. Processamento de imagens de sensoriamento remoto. Brasília: Editora da Universidade de Brasília, 2012.

MOTOHKA, T.; NASAHARA, K. N.; OGUMA, H.; TSUCHIDA, S. Applicability of green-red vegetation index for remote sensing of vegetation phenology. **Remote Sensing**, v. 2, p. 2369-2387, 2010.

MYINT, S. W.; GOBER, P.; BRAZEL, A.; GROSSMAN-CLARKE, S.; WENG, Q. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. **Remote Sensing of Environment**, v. 115, n. 5, p. 1145-1161, 2011.

OLIVEIRA, G. R. K. **Uso integrado de dados LIDAR e imagens aéreas aplicado na extração de contornos de telhados de edificações**. 2016. Dissertação (Mestrado em Ciências Geodésicas) - Universidade Estadual Paulista, São Paulo, 2016.

PINHO, C. M. D.; FONSECA, L. M. G.; KORTING, T. S.; ALMEIDA, C.M.; KUX, H. J. H. Land-cover classification of an intra-urban environment using high-resolution images and object-based image analysis. **International Journal of Remote Sensing**. v. 33, n. 19, p. 5973-5995, 2012.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento remoto no estudo da vegetação. São José dos Campos: Parêntese, 2007. 136 p.

PRUDENTE, V. H. R.; SILVA, B. B.; JOHANN, J. A.; MERCANTE, E.; OLDONI, L. V. Comparative assessment between per-pixel and object-oriented for mapping land cover and use. **Eng. Agríc.**, v.37, n.5, 2017.

RIBEIRO, B. M. G.; FONSECA, L. M. G.; KUX, H. J. H. Mapeamento da cobertura do solo urbano utilizando imagens WOR- LDVIEW II e o sistema InterIMAGE. **Revista Brasileira de Cartografia**, n. 63, 2011. Edição especial.

RUIZ, L. F. C.; GUASSELLI, L. A.; CATEN, A. T. Árvore de decisão e análise baseada em objetos na classificação de imagens com resolução espacial submétrica adquiridas por VANT. **Boletim de Ciências Geodésicas**, v. 23, n. 2, p.252 - 267, 2017.

SANTIAGO, L. F. P.; SILVA, W. B. Avaliação de métodos de classificação por regiões em imagens de alta resolução do sensor Rapideye. **Revista Militar de Ciência e Tecnologia**, v. 35, n. 2, p. 22-26, 2018.

SANTOS, T.; FREIRE, S.; TENEDÓRIO, J. A.; FONSECA, A. Classificação de imagens de satélite de alta resolução com introdução de dados LIDAR, aplicação à cidade de Lisboa. Coimbra: Impressa na Universidade de Coimbra, 2011.

SILVA, A. A.; CANDEIAS, A. L. B.; TAVARES JUNIOR, J. R. Inserção de dados altimétricos na diferenciação de tipos florestais em brejos de altitude. **Revista Brasileira de Cartografia**, n. 62, p. 247-260, 2010. Edição especial.

SILVA, F. M. M.; ARAKI H. Integração de dados de imagens orbitais de alta resolução e ALS para detecção semi-automática de edificações em áreas urbanas. **Boletim Ciências Geodésicas**, v. 21, n. 3, p. 548-571, 2015.

SLOBODA, L. **Proposta metodológica para confecção de base cartográfica a partir de dados oriundos do sistema laser scanner**. 2005. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Santa Catarina, Florianópolis, 2005.

TUCKER, C.J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sens. Environ.** v. 8, p. 127-150, 1979.

## APÊNDICE A – PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE S1

Tabela 1A – Parâmetros básicos para o gráfico de dispersão dos pontos no índice S1

PARÂMETROS	EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
Mínimo	55,50	58,80	53,44	57,23	56,60
Máximo	61,59	59,73	60,94	90,65	60,21
Média	59,83	59,47	59,69	66,31	58,98
Tamanho (n)	220,00	60,00	200,00	150,00	100,00
Est. Classes	14,83	7,75	14,14	12,25	10,00
Classes	14,00	7,00	14,00	12,00	10,00
Incremento	0,44	0,13	0,54	2,78	0,36
Desvio Padrão	0,67	0,20	0,57	6,02	0,83

Fonte: A autora (2020).

Tabela 2A – Valores de corte para o gráfico de dispersão dos pontos no índice S1

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
55,94	58,93	53,97	60,02	56,96
56,37	59,07	54,51	62,80	57,32
56,81	59,20	55,05	65,59	57,68
57,24	59,33	55,58	68,37	58,04
57,68	59,46	56,12	71,16	58,41
58,11	59,60	56,65	73,94	58,77
58,55	59,73	57,19	76,72	59,13
58,98		57,73	79,51	59,49
59,42		58,26	82,29	59,85
59,85		58,80	85,08	60,21
60,29		59,33	87,86	
60,72		59,87	90,65	
61,16		60,41		
61,59		60,94		

Fonte: A autora (2020).

Tabela 3A – Valores de frequência para o gráfico de dispersão dos pontos no índice S1

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
1,00	1,00	1,00	10,00	3,00
1,00	2,00	0,00	28,00	4,00
0,00	4,00	0,00	49,00	3,00
0,00	5,00	0,00	31,00	7,00
0,00	11,00	0,00	12,00	3,00
0,00	16,00	0,00	4,00	6,00
1,00	21,00	0,00	6,00	17,00
5,00		0,00	2,00	30,00
41,00		0,00	2,00	20,00
63,00		2,00	2,00	7,00
71,00		28,00	3,00	
19,00		90,00	1,00	
10,00		76,00		
8,00		3,00		

Fonte: A autora (2020).

## APÊNDICE B – PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE S2

Tabela 1B – Parâmetros básicos para o gráfico de dispersão dos pontos no índice S2

PARÂMETROS	EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
Mínimo	56,33	58,60	53,59	57,02	60,80
Máximo	67,98	59,71	61,95	90,65	64,00
Média	61,88	59,32	60,12	65,97	61,91
Tamanho (n)	220,00	60,00	200,00	150,00	100,00
Est. Classes	14,83	7,75	14,14	12,25	10,00
Classes	14,00	7,00	14,00	12,00	10,00
Incremento	0,83	0,16	0,60	2,80	0,32
Desvio Padrão	2,54	0,19	0,68	5,93	0,71

Fonte: A autora (2020).

Tabela 2B – Valores de corte para o gráfico de dispersão dos pontos no índice S2

CORTE				
EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
57,17	58,76	54,19	59,82	61,12
58,00	58,92	54,79	62,63	61,44
58,83	59,08	55,38	65,43	61,76
59,66	59,24	55,98	68,23	62,08
60,49	59,40	56,58	71,03	62,40
61,33	59,56	57,17	73,83	62,72
62,16	59,71	57,77	76,64	63,04
62,99		58,37	79,44	63,36
63,82		58,97	82,24	63,68
64,65		59,56	85,04	64,00
65,48		60,16	87,84	
66,32		60,76	90,65	
67,15		61,35		
67,98		61,95		

Fonte: A autora (2020).

Tabela 3B – Valores de frequência para o gráfico de dispersão dos pontos no índice S2

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
1,00	1,00	1,00	10,00	5,00
0,00	0,00	0,00	27,00	21,00
2,00	5,00	0,00	50,00	31,00
26,00	8,00	0,00	33,00	17,00
63,00	25,00	0,00	12,00	3,00
45,00	16,00	0,00	5,00	6,00
12,00	5,00	0,00	3,00	7,00
2,00		0,00	2,00	6,00
7,00		0,00	2,00	2,00
14,00		24,00	2,00	2,00
24,00		73,00	3,00	
8,00		83,00	1,00	
8,00		17,00		
8,00		2,00		

Fonte: A autora (2020).

## APÊNDICE C – PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE VARI

Tabela 1C – Parâmetros básicos para o gráfico de dispersão dos pontos no índice VARI

PARÂMETROS	EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
Mínimo	44,10	49,79	49,20	48,39	48,82
Máximo	50,47	50,43	50,53	51,30	49,53
Média	48,53	50,17	49,58	50,16	49,22
Tamanho (n)	220,00	60,00	200,00	150,00	100,00
Est. Classes	14,83	7,75	14,14	12,25	10,00
Classes	14,00	7,00	14,00	12,00	10,00
Incremento	0,45	0,09	0,09	0,24	0,07
Desvio Padrão	1,56	0,13	0,19	0,50	0,13

Fonte: A autora (2020).

Tabela 2C – Valores de corte para o gráfico de dispersão dos pontos no índice VARI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
44,56	49,88	49,29	48,63	48,89
45,01	49,98	49,39	48,87	48,96
45,47	50,07	49,48	49,11	49,03
45,92	50,16	49,58	49,36	49,10
46,38	50,25	49,67	49,60	49,17
46,83	50,34	49,77	49,84	49,24
47,29	50,43	49,86	50,08	49,31
47,74		49,96	50,33	49,38
48,20		50,05	50,57	49,45
48,65		50,15	50,81	49,53
49,11		50,24	51,05	
49,56		50,34	51,30	
50,01		50,43		
50,47		50,53		

Fonte: A autora (2020).

Tabela 3C – Valores de frequência para o gráfico de dispersão dos pontos no índice VARI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
1,00	1,00	6,00	1,00	1,00
0,00	2,00	16,00	1,00	1,00
1,00	6,00	42,00	4,00	8,00
8,00	18,00	49,00	5,00	10,00
20,00	21,00	31,00	7,00	13,00
21,00	7,00	24,00	14,00	22,00
17,00	5,00	22,00	32,00	27,00
6,00		4,00	28,00	8,00
6,00		1,00	25,00	6,00
6,00		3,00	21,00	4,00
9,00		1,00	10,00	
41,00		0,00	2,00	
58,00		0,00		
26,00		1,00		

Fonte: A autora (2020).

## APÊNDICE D – PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE RGBVI

Tabela 1D – Parâmetros básicos para o gráfico de dispersão dos pontos no índice RGBVI

PARÂMETROS	EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
Mínimo	45,72	49,45	44,95	48,53	49,63
Máximo	50,11	50,05	50,01	56,05	50,64
Média	49,06	49,81	49,62	52,18	49,99
Tamanho (n)	220,00	60,00	200,00	150,00	100,00
Est. Classes	14,83	7,75	14,14	12,25	10,00
Classes	14,00	7,00	14,00	12,00	10,00
Incremento	0,31	0,09	0,36	0,63	0,10
Desvio Padrão	0,98	0,14	0,37	1,52	0,26

Fonte: A autora (2020).

Tabela 2D – Valores de corte para o gráfico de dispersão dos pontos no índice RGBVI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
46,03	49,54	45,31	49,16	49,73
46,34	49,62	45,67	49,79	49,83
46,66	49,71	46,03	50,41	49,93
46,97	49,80	46,40	51,04	50,03
47,28	49,88	46,76	51,67	50,13
47,60	49,97	47,12	52,29	50,23
47,91	50,05	47,48	52,92	50,33
48,23		47,84	53,54	50,43
48,54		48,20	54,17	50,53
48,85		48,56	54,80	50,64
49,17		48,93	55,42	
49,48		49,29	56,05	
49,79		49,65		
50,11		50,01		

Fonte: A autora (2020).

Tabela 3D – Valores de frequência para o gráfico de dispersão dos pontos no índice RGBVI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
1,00	2,00	1,00	2,00	6,00
0,00	8,00	0,00	6,00	29,00
1,00	3,00	0,00	10,00	25,00
2,00	7,00	0,00	14,00	11,00
8,00	20,00	0,00	23,00	5,00
17,00	16,00	0,00	29,00	4,00
9,00	4,00	0,00	25,00	2,00
13,00		0,00	17,00	6,00
14,00		0,00	6,00	9,00
11,00		0,00	9,00	3,00
14,00		0,00	4,00	
17,00		3,00	5,00	
41,00		85,00		
72,00		111,00		

Fonte: A autora (2020).

## APÊNDICE E – PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE GRVI

Tabela 1E – Parâmetros básicos para o gráfico de dispersão dos pontos no índice GRVI

PARÂMETROS	EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
Mínimo	47,15	49,90	49,56	49,06	49,34
Máximo	50,22	50,20	50,07	50,75	49,75
Média	49,16	50,08	49,79	50,11	49,56
Tamanho (n)	220,00	60,00	200,00	150,00	100,00
Est. Classes	14,83	7,75	14,14	12,25	10,00
Classes	14,00	7,00	14,00	12,00	10,00
Incremento	0,22	0,04	0,04	0,14	0,04
Desvio Padrão	0,92	0,06	0,09	0,32	0,08

Fonte: A autora (2020).

Tabela 2E – Valores de corte para o gráfico de dispersão dos pontos no índice GRVI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
47,37	49,94	49,60	49,20	49,38
47,59	49,99	49,63	49,34	49,42
47,81	50,03	49,67	49,48	49,46
48,03	50,07	49,71	49,62	49,50
48,25	50,12	49,74	49,76	49,54
48,46	50,16	49,78	49,91	49,59
48,68	50,20	49,82	50,05	49,63
48,90		49,85	50,19	49,67
49,12		49,89	50,33	49,71
49,34		49,93	50,47	49,75
49,56		49,96	50,61	
49,78		50,00	50,75	
50,00		50,03		
50,22		50,07		

Fonte: A autora (2020).

Tabela 3E – Valores de frequência para o gráfico de dispersão dos pontos no índice GRVI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
3,00	1,00	2,00	1,00	1,00
5,00	2,00	3,00	2,00	1,00
20,00	6,00	6,00	4,00	9,00
20,00	18,00	23,00	4,00	10,00
18,00	22,00	33,00	7,00	23,00
2,00	6,00	38,00	15,00	16,00
4,00	5,00	27,00	29,00	26,00
4,00		21,00	26,00	5,00
4,00		14,00	27,00	7,00
6,00		16,00	17,00	2,00
9,00		10,00	13,00	
44,00		2,00	5,00	
45,00		1,00		
36,00		4,00		

Fonte: A autora (2020).

## APÊNDICE F – PARÂMETROS DO GRÁFICO DE DISPERSÃO DOS PONTOS NO ÍNDICE GLI

Tabela 1F – Parâmetros básicos para o gráfico de dispersão dos pontos no índice GLI

PARÂMETROS	EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
Mínimo	47,75	49,72	46,72	49,19	49,79
Máximo	50,05	50,02	49,99	52,32	50,28
Média	49,49	49,90	49,81	50,97	49,97
Tamanho (n)	220,00	60,00	200,00	150,00	100,00
Est. Classes	14,83	7,75	14,14	12,25	10,00
Classes	14,00	7,00	14,00	12,00	10,00
Incremento	0,16	0,04	0,23	0,26	0,05
Desvio Padrão	0,54	0,07	0,23	0,65	0,12

Fonte: A autora (2020).

Tabela 2F – Valores de corte para o gráfico de dispersão dos pontos no índice GLI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
47,91	49,76	46,95	49,45	49,84
48,08	49,81	47,18	49,71	49,89
48,24	49,85	47,42	49,97	49,94
48,41	49,89	47,65	50,23	49,99
48,57	49,94	47,88	50,49	50,04
48,74	49,98	48,12	50,76	50,08
48,90	50,02	48,35	51,02	50,13
49,07		48,59	51,28	50,18
49,23		48,82	51,54	50,23
49,39		49,05	51,80	50,28
49,56		49,29	52,06	
49,72		49,52	52,32	
49,89		49,75		
50,05		49,99		

Fonte: A autora (2020).

Tabela 3F – Valores de frequência para o gráfico de dispersão dos pontos no índice GLI

EDIFICAÇÃO	ÁGUA	PAVIMENTAÇÃO	VEGETAÇÃO	SOLO
1,00	2,00	1,00	2,00	6,00
1,00	7,00	0,00	4,00	20,00
0,00	3,00	0,00	4,00	25,00
4,00	7,00	0,00	10,00	17,00
10,00	21,00	0,00	13,00	8,00
16,00	16,00	0,00	25,00	5,00
11,00	4,00	0,00	19,00	1,00
16,00		0,00	26,00	11,00
10,00		0,00	23,00	6,00
9,00		0,00	8,00	1,00
10,00		0,00	7,00	
17,00		0,00	9,00	
40,00		35,00		
75,00		164,00		

Fonte: A autora (2020).