

UNIVERSIDADE FEDERAL DE MINAS GERAIS
INSTITUTO DE GEOCIÊNCIAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ANÁLISE E
MODELAGEM DE SISTEMAS AMBIENTAIS

Tháisa Santos Faria

CLASSIFICAÇÃO EM ÁREA URBANA APOIADA EM IMAGENS AÉREAS E DADOS LIDAR

BELO HORIZONTE
2017

Tháísa Santos Faria

CLASSIFICAÇÃO EM ÁREA URBANA APOIADA EM IMAGENS AÉREAS E DADOS LIDAR

Defesa de Dissertação apresentada ao Programa de Pós-Graduação em Análise e Modelagem de Sistemas Ambientais da Universidade Federal de Minas Gerais como requisito parcial para obtenção do título de Mestre em Análise e Modelagem de Sistemas Ambientais.

Orientador: Prof. Dr. Marcelo Antônio Nero

Co-orientador: Prof. Dr. Rodrigo Affonso de Albuquerque Nóbrega

BELO HORIZONTE
INSTITUTO DE GEOCIÊNCIAS DA UFMG
MAIO DE 2017

F224c Faria, Tháisa Santos.
2017 Classificação em área urbana apoiada em imagens aéreas e dados LIDAR [manuscrito] / Tháisa Santos Faria. – 2017.
xiv, 94 f., enc.: il. (principalmente color.)

Orientador: Marcelo Antônio Nero.

Coorientador: Rodrigo Affonso de Albuquerque Nóbrega.

Dissertação (mestrado) – Universidade Federal de Minas Gerais, Instituto de Geociências, 2017.

Bibliografia: f. 77-84.

Inclui anexo.

1. Modelagem de dados – Aspectos ambientais – Teses. 2. Solos – Classificação – Teses. 3. Solo urbano – Uso – Belo Horizonte (MG) – Teses. 4. Sensoriamento remoto – Teses. 5. Radar ótico – Teses. I. Nero, Marcelo Antônio. II. Nóbrega, Rodrigo Affonso de Albuquerque. III. Universidade Federal de Minas Gerais. Instituto de Geociências. IV. Título.

CDU: 911.2:519.6(815.1)



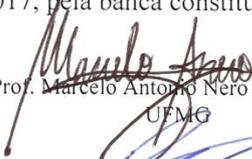
FOLHA DE APROVAÇÃO

PROPOSTA DE CLASSIFICAÇÃO ORIENTADA A OBJETOS EM ÁREA URBANA
COM UTILIZAÇÃO DE DADOS LIDAR E APLICAÇÃO DE VALIDAÇÃO
TEMÁTICA

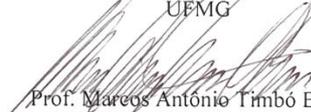
THAÍSA SANTOS FARIA

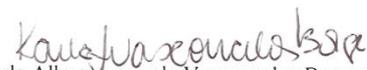
Dissertação submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS, como requisito para obtenção do grau de Mestre em ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS, área de concentração ANÁLISE E MODELAGEM DE SISTEMAS AMBIENTAIS.

Aprovada em 25 de maio de 2017, pela banca constituída pelos membros:


Prof. Marcelo Antonio Nero - Orientador
UFMG


Prof. Rodrigo Affonso de Albuquerque Nobrega
UFMG


Prof. Marcos Antonio Timbó Elmiro
UFMG


Profa. Karla Albuquerque de Vasconcelos Borges
PRODABEL

Belo Horizonte, 25 de maio de 2017.

À minha família, razão da minha existência.

As ideias das pessoas são pedaços de sua felicidade.

(William Shakespeare)

Tão próximas as leis da matemática estejam da realidade,

menos próximas da certeza elas estarão.

E tão próximas elas estejam da certeza,

menos elas se referirão à realidade.

(Albert Einstein)

AGRADECIMENTOS

A Deus.

Aos meus pais, Milza e Antônio, pelo exemplo de caráter, força, dedicação, determinação, criatividade e coragem. Sem vocês absolutamente nada disso seria possível. Agradeço a vocês por tudo, por terem me dado condições para todas as conquistas que já tive ou terei algum dia.

Aos meus irmãos, Flávia e Fábio, que admiro e respeito, cujas trajetórias de vida me serviram também de exemplo, para trilhar meu próprio caminho. Orientaram-me e ajudaram a ver com mais clareza as possibilidades da vida.

Sem vocês eu não seria nada!

Ao Haendel, meu companheiro de alma sensível e perspicaz, cujo carinho e compreensão confortaram os dias difíceis.

Aos meus queridos amigos, Ramon e Jean, carinhosamente apelidados de meu cérebro e alma gêmeos. Surpresinhas da vida que nos faz acreditar na lealdade e fidelidade.

À Denise, que nos últimos anos me ajudou a ver a realidade com outros olhos. Me ajudou a recuperar algo que eu precisava para alcançar os meus objetivos.

Aos meus colegas Lorena, Gustavo, Mariana, Toninho, pelas dicas em algumas etapas do trabalho. Compartilhar ideias e sentimentos é algo que torna a trajetória mais leve...

À Karla e ao Eduardo, da PRODABEL, por ouvirem minhas dúvidas e por terem dado sugestões que me ajudaram a traçar os rumos da minha pesquisa. De alguma forma me ajudaram a definir o “norte”.

Aos meus orientadores Marcelo e Rodrigo agradeço as orientações.

A PRODABEL, pela cessão dos dados e pelo apoio para dedicação à essa pesquisa.

RESUMO

Nos grandes centros urbanos, os mapeamentos de uso do solo são amplamente utilizados para planejamento e gestão do território. Para tanto, várias leis foram criadas para indicar diretrizes para que a cobertura e o uso do solo garantam a qualidade de vida dos cidadãos e a permanência dos recursos para futuras gerações. Nesse sentido, desenvolver uma metodologia para o melhor entendimento da paisagem urbana constitui objetivo de grande utilidade para que o poder público tome decisões. Assim, a proposta dessa pesquisa é elaborar uma metodologia de classificação orientada a objetos baseada na modelagem *fuzzy* que considere ainda elementos tridimensionais para melhor categorizar os tipos de cobertura e uso do solo. Adiciona-se a isso a etapa de validação, para analisar a qualidade temática da metodologia proposta. A área de estudo para esta pesquisa compreendeu o Bairro Planalto, no município de Belo Horizonte, pela sua variabilidade de cobertura e uso do solo. Os temas relativos à extração de informação de imagens de alta resolução, aos dados LIDAR, à classificação orientada a objetos, à lógica *fuzzy* e à validação dos dados com base em amostras aleatórias estratificadas são norteadores dessa pesquisa. Com isso, foi elaborada uma segmentação detalhada para a escala de análise; ponderada a utilização dos descritores de classes; consolidada uma metodologia de classificação com consideração de atributos tridimensionais provenientes do LIDAR e bases cartográficas; e realizado um mapeamento da cobertura e uso do solo com possibilidade de aplicação em outras localidades. Dentre os índices globais de validação temática, destaca-se o coeficiente *kappa* de ajuste, cujo valor encontrado foi 62%, resultado considerado substancial. Outros índices por classe foram analisados com o objetivo de avaliar a qualidade da classificação. Comparada à classificação oficial utilizada no município de Belo Horizonte, o resultado da pesquisa apresentou resultados superiores, principalmente em aspectos relacionados ao nível de detalhamento do mapeamento, à metodologia de validação temática aplicada e às classes de cobertura e uso do solo, que permitem observar fenômenos como a verticalização, impermeabilização do solo, entre outros.

PALAVRAS-CHAVE: classificação orientada a objetos, lógica *fuzzy*, imagens de alta resolução, LIDAR, validação temática.

ABSTRACT

In urban centers, land use mappings are widely used for land planning and management. For this, several laws were created to indicate guidelines for land use and occupation to guarantee the quality of life to citizens and the resources maintenance for future generations. In this context, developing a methodology for a better understanding of the urban landscape is an useful tool for government decisions. Therefore, the proposal of this research is to elaborate an object-oriented classification based on fuzzy modeling that still considers three-dimensional elements to better categorize the ground cover types. In addition a validation step was developed to analyze the thematic quality of the proposed methodology. The study area for this research is the Planalto neighborhood, in the city of Belo Horizonte, because its variability of coverage and land use. Topics about the extraction of information from high resolution images, the LIDAR, the object-oriented classification, the fuzzy logic and the data validation based on stratified random samples are the guidelines for this research. With this, a detailed segmentation was elaborated for analysis scale; class descriptors were weighted and a classification methodology considering three-dimensional attributes from lidar and cartographic databases were consolidated. A coverage and use map was created, considering the possibility of application in other locations. Among the overall thematic validation indexes, the kappa coefficient stands out, and the value found was 62%, a result considered substantial. Other indexes by class were analyzed to evaluate the quality of the classification. In comparison to the official classification used in Belo Horizonte city, the research presented better results, mainly in relation to the mapping detail level, the validation methodology and the land cover and use classes, that allows to observe urban phenomena such as verticalization, soil waterproofing, etc.

KEYWORDS: object-oriented classification, fuzzy logic, high resolution images, LIDAR, thematic validation.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	Estrutura do trabalho	2
2	JUSTIFICATIVA	3
3	OBJETIVOS	6
4	REFERENCIAL TEÓRICO	7
4.1	Fontes de dados	7
4.1.1	Fotografias aéreas e subprodutos	7
4.1.2	LIDAR.....	9
4.2	Segmentação	13
4.2.1	Segmentação por crescimento de regiões	15
4.2.2	Descritores de classes.....	16
4.3	Classificação.....	17
4.3.1	Classificação orientada a objetos	19
4.3.2	Classificação por parcelas	20
4.3.3	Lógica <i>Fuzzy</i>	21
4.4	Métodos de validação.....	25
4.4.1	Matriz de confusão	25
4.4.2	Índices globais.....	31
4.4.3	Índices por classe.....	34
5	ÁREA DE ESTUDO	36
6	MATERIAIS E MÉTODOS	38
6.1	Recursos disponíveis.....	38
6.2	Etapas.....	39
6.3	Levantamento de dados	39
6.4	Banda infravermelho próximo	40
6.4.1	Correção do registro da banda NIR	40
6.5	LIDAR.....	41
6.6	Base vetorial	42
6.7	Classificação oficial do uso e cobertura do solo	43
6.8	Segmentação	47

6.9	O modelo conceitual.....	50
6.10	Classificação.....	52
6.11	Consulta espacial	57
6.12	Validação da classificação das imagens	63
7	RESULTADOS.....	67
8	CONSIDERAÇÕES FINAIS	74
	REFERÊNCIAS bibliográficas	77
	ANEXO I.....	85

ÍNDICE DE FIGURAS

Figura 1. Esquema de representação das faixas lateralmente e longitudinalmente sobrepostas durante um voo.....	8
Figura 2. Produtos obtidos no levantamento aerofotogramétrico	8
Figura 3. Base vetorial obtida por meio da interpretação de fotografias aéreas ortorretificadas	9
Figura 4. Esquema de obtenção de dados LIDAR.	9
Figura 5. Primeiro e último retorno dos pulsos <i>laser</i>	10
Figura 6. MDS, obtido pelo primeiro retorno dos pulsos <i>laser</i>	11
Figura 7. MDT, obtido pela interpolação do último retorno dos pulsos <i>laser</i>	11
Figura 8. Segmentação de imagem de satélite.	14
Figura 9. Hierarquia dos objetos na segmentação.	16
Figura 10. Exemplo de imagem de satélite classificada.	18
Figura 11. Etapas da classificação orientada a objeto.....	19
Figura 12. Função de pertinência (hipotética) para classes de vegetação.	22
Figura 13. Funções "padrão" comumente utilizadas em modelagem fuzzy.	23
Figura 14. Sistema de inferência <i>fuzzy</i>	23
Figura 15. Gráfico explicativo da classificação de elementos em "X" e "Y"	27
Figura 16. Tipos de amostragens.....	28
Figura 17. Mapa de localização da área de estudo (Bairro Planalto).....	36
Figura 18. Fluxograma resumo da metodologia da pesquisa	39
Figura 19. Distribuição dos pontos de controle utilizados para registro imagem-imagem no <i>software</i> Envi.	41
Figura 20. Etapas de processamento do LIDAR.	42
Figura 21. Mapa de cobertura e uso do solo da região do Bairro Planalto (nível I).....	44
Figura 22. Mapa de cobertura e uso do solo da região do Bairro Planalto (nível II).....	45
Figura 23. Mapa de cobertura e uso do solo da região do Bairro Planalto (nível III).....	46
Figura 24. Imagens das bandas NIR (a), R (b), G (c) e B (d).	49
Figura 25. Exemplos de testes realizados na segmentação.....	49
Figura 26. Cena após a segmentação.	50
Figura 27. Modelo conceitual de classificação para implementação no eCognition.....	51
Figura 28. Grau de pertinência de dois segmentos em duas classes diferentes	53
Figura 29. Mapa de classificação resultante do processo no <i>software</i> eCognition	54
Figura 30. Mapa de classificação quanto à altura dos objetos acima do nível do solo, informação proveniente dos dados LIDAR.....	55

Figura 31. Representação tridimensional da altura dos objetos acima do nível do solo	56
Figura 32. Detalhe das inconsistências topológicas entre os segmentos e os vetores	57
Figura 33. Consulta espacial para obtenção das classes “calçada impermeável” e “calçada permeável”	58
Figura 34. Consulta espacial para obtenção da classe “lote vago”	59
Figura 35. Consulta espacial para obtenção das classes “área impermeável no interior dos lotes” e “área permeável no interior dos lotes”	60
Figura 36. Consulta espacial para obtenção da classe “vias”	60
Figura 37. Mapa resultante da classificação x consulta espacial.....	62
Figura 38. Representação tridimensional da classificação x consulta espacial.	63
Figura 39. Exemplo de segmentos pequenos, inferiores a 1m ²	64
Figura 40. Exemplos de grades regulares e total de indivíduos de duas classes na população de objetos.....	66

ÍNDICE DE TABELAS

Tabela 1. Exemplo hipotético de matriz de confusão.....	27
Tabela 2. Siglas das variáveis relacionadas aos índices globais de qualidade temática.....	31
Tabela 3. Número de amostras por estrato, conforme o tamanho populacional por classe .	65
Tabela 4. Matriz de confusão obtida na validação das amostras classificadas.....	67
Tabela 5. Índices globais obtidos com base na matriz de confusão da tabela 3.....	68
Tabela 6. Nível de exatidão de uma classificação de acordo com o valor do coeficiente Kappa.....	69
Tabela 7. Índices por classe obtidos com base na matriz de confusão da tabela 3.	69
Tabela 8. Comparativo entre a classificação de cobertura e uso do solo oficial x proposta .	72

LISTA DE SIGLAS

LIDAR – *Light Detection and Ranging*

MDE – Modelo Digital de Elevação

MDSn – Modelo Digital de Superfície Normalizado

MDT – Modelo Digital de Terreno

NDVI – *Normalized Difference Vegetation Index* ou Índice Normalizado de Vegetação

NIR – Near Infrared ou Infravermelho Próximo

PBH – Prefeitura de Belo Horizonte

PRODABEL – Empresa de Informática e Informação do Município de Belo Horizonte

SIG – Sistema de Informações Geográficas

SIRGAS2000 – Sistema de Referência Geocêntrico para as Américas

UFMG – Universidade Federal de Minas Gerais

USP – Universidade de São Paulo

1 INTRODUÇÃO

Nos grandes centros urbanos, os mapeamentos de uso do solo são amplamente utilizados para planejamento e gestão do território. Algumas leis sobre uso e ocupação do solo foram elaboradas para determinar, com base no reconhecimento da ocupação das cidades, temas como a hierarquização de vias para fins de escoamento de tráfego, a permissividade do uso do solo urbano para determinadas atividades específicas, a definição de áreas prioritárias para investimentos do poder público, entre outros (BELO HORIZONTE, 1996; BELO HORIZONTE, 2010). Dessa maneira, tais mapeamentos são utilizados para organizar e sistematizar a ocupação dos centros urbanos.

Dentre as diversas ferramentas que podem ser utilizadas para o planejamento e gestão de território, destacam-se a Cartografia, a Geodésia, a Fotogrametria, entre outros, integrados ao Cadastro Multifinalitário¹. Isso é mais evidente nos cenários urbanos, onde existe a necessidade da Cartografia de alta precisão, por meio dos levantamentos aerofotogramétricos e de campo em escala equivalente ou superior a 1:2.000, entre outros. Com a incorporação de tecnologias no campo das geociências e o desenvolvimento do geoprocessamento, novas técnicas como mapeamento digital, processamento digital de imagens, estruturação e análise de banco de dados geográficos, modelos digitais de terreno (MDT), modelos digitais de elevação (MDE) e fontes de dados como fotografias aéreas e LIDAR (do inglês, *Light Detection and Ranging*), tem sido amplamente empregados com o objetivo de melhorar a compreensão da dinâmica urbana.

O processamento em conjunto desses dados constitui ferramenta valiosa para o entendimento de fenômenos, como a expansão urbana, a renovação dos espaços urbanos, a verticalização, as alterações nos corredores ecológicos e nas áreas verdes, a expansão de áreas de uso coletivo, a formação de microclimas urbanos, entre outros. No âmbito do processamento digital de imagens, a classificação de imagens orientada a objetos permite a definição de classes que normalmente não seriam interpretadas por um classificador tradicional *pixel-a-pixel*. Nesse método, além dos atributos convencionalmente utilizados, como comportamento espectral, forma, textura, área, inclui-se ainda a análise de vizinhança, que busca, por meio do relacionamento entre os objetos, propor a definição dos mesmos

¹O termo aqui empregado pode ser entendido como o proposto por Erba, Oliveira e Lima (2005), como instrumento de política urbana que abrange o registro de informações sobre as diversas esferas, a saber: cartografia cadastral, aspectos tributários, jurídicos, sociais e ambientais.

(NOBREGA, 2007). Como dados de entrada, tem-se uma única imagem ou um conjunto de imagens, que são analisadas, segregadas e posteriormente impostas às regras que simulam a interpretação do mundo real. A isso, pode-se ainda adicionar os dados de levantamentos *laser*, que proporcionam a inserção de atributos da altimetria para análise dos objetos, contribuindo para o refinamento dos resultados.

Nesse cenário, questiona-se: qual será a contribuição de uma classificação tridimensional orientada a objetos que integre dados altimétricos e espectrais para elaborar mapeamentos de cobertura e uso do solo? Com o uso deste método é possível identificar e analisar as mudanças da paisagem urbana? Considerando-se esses questionamentos é que se justifica essa proposta de pesquisa.

1.1 Estrutura do trabalho

Esta pesquisa está subdividida em algumas seções. Assim, após a introdução é apresentada a justificativa que impulsiona o desenvolvimento dessa pesquisa, e posteriormente os objetivos gerais e específicos. No referencial teórico, o capítulo 4, é apresentado o arcabouço teórico que dá sustentação ao trabalho: as fontes de dados (fotografias aéreas e *laser*), segmentação, classificação e métodos de validação. Na sequência, no capítulo 5, está uma breve caracterização da área de estudo, seguida da metodologia, no capítulo 6. Após este item, são apresentados os resultados (capítulo 7), as considerações finais (capítulo 8) e as referências bibliográficas consultadas. Por fim, são apresentados anexos relevantes ao tema.

2 JUSTIFICATIVA

Com o surgimento de novas tecnologias e com a difusão do uso de dados e ferramentas geográficas acessíveis², os mapas passaram a fazer parte do cotidiano das pessoas. O seu uso antes limitado, na atualidade foi incorporado também na administração pública, que toma decisões com base no conhecimento da realidade representada, cartografada (BELO HORIZONTE, 1996; BELO HORIZONTE, 2010). Ferramentas legislativas, como os planos diretores, as leis de uso e ocupação do solo objetivam subsidiar os gestores e nortear as políticas públicas para que os objetivos acima citados sejam almejados.

Diversas instituições públicas e privadas investem recursos nas geotecnologias para o estudo das cidades, com o objetivo de propor medidas de gestão para garantir qualidade de vida para seus cidadãos e a permanência de recursos para as futuras gerações.

Nesse âmbito destacam-se o sensoriamento remoto, processamento digital de imagens e o geoprocessamento, capazes de integrar dados de diferentes fontes e produzir análises, permitindo um conhecimento amplo sobre a paisagem. Soma-se a estes o LIDAR (*Light Detection and Ranging*), cujo potencial está continuamente sendo explorado pela comunidade acadêmico-científica.

Muitos métodos já foram desenvolvidos e aplicados para o registro de objetos na superfície terrestre. Como exemplo, tem-se a aerofotogrametria, processo no qual o mapeamento é obtido por meio de fotografias aéreas que são restituídas, ou seja, interpretadas por um indivíduo que define os objetos com base em elementos como forma, dimensão e posição dos mesmos (BRANDALIZE, 2001; SOUZA, 2005; OLIANI, 2016).

Outro meio de interpretação da realidade muito utilizado é a classificação de imagens. No entanto, seu uso em áreas urbanas é limitado em função da heterogeneidade da superfície, pois a diferenciação dos objetos pela resposta espectral gera algumas confusões no processo, classificando incorretamente alguns deles (APLIN, 2003; PINHO; FEITOSA; KUX, 2005). Para isso, diversos autores sugerem o uso do método de classificação orientada a objetos e a integração de diferentes fontes de dados, como imagens e *laser*, por exemplo (MENDES; DAL POZ, 2013; FAZAN, 2014).

A grande vantagem no processo de classificação está relacionada à velocidade de obtenção de dados no formato vetorial, o baixo custo de obtenção e a possibilidade de geração de

² Como exemplo, o Google Earth.

subprodutos quando analisada em conjunto a outras fontes, como, por exemplo, as restituições aerofotogramétricas. Adiciona-se a isso a possibilidade de execução rotineira de classificações, possibilitando ainda a simulação de cenários (SOARES FILHO et al., 2008). Nesse sentido, acredita-se que a utilização de tal metodologia pode contribuir na tomada de decisões por meio de um planejador, que para implementar políticas públicas, necessita conhecer a realidade e os fenômenos a ela inerentes.

O LIDAR, por sua vez, comumente é utilizado para a geração de modelos digitais de terreno e de superfície, geração de mapas hipsométricos e de declividade. No entanto, estudos mais recentes têm explorado a utilização de tal produto na classificação de imagens, devido à possibilidade de consideração de elementos relacionados à altimetria dos objetos. Como exemplo pode-se citar a identificação de edifícios muito elevados (indicativos de uma densidade populacional muito superior àquela das edificações de apenas um pavimento), ou ainda a categorização da vegetação em diferentes extratos (herbáceas, arbustivas e arbóreas). Outros estudos, que serão abordados na seção 4.2.2, apresentam ainda metodologia para extração de contorno de elementos, como potencial do LIDAR para a geração de vetores que representem elementos como construções, vias, entre outros. Ou seja, estudiosos têm buscado incessantemente exaurir todas as possibilidades quanto à extração de informações do LIDAR cujo potencial, para fins de classificação, pretende-se explorar nessa pesquisa.

No contexto urbano, dentre as ferramentas legais utilizadas pela administração pública, destacam-se o Plano Diretor, as leis de Uso e Ocupação do Solo e Zoneamentos, que são instrumentos da política de desenvolvimento dos municípios. Esses instrumentos norteiam a atuação do poder público e da iniciativa privada na utilização do espaço, garantindo melhores condições na qualidade de vida. A legislação sobre o tema é extensa, mas podem ser citadas algumas considerações que justificam a necessidade de conhecer e entender a dinâmica do espaço urbano quanto à sua utilização, a saber:

- “- Analisar a estrutura urbana da regional e sua dinâmica buscando subsídios para a definição de formas de utilização do solo urbano que agreguem condições adequadas de ocupação e preservação ambiental, bem como a distribuição de atividades econômicas na área;
- Identificar áreas onde o controle de altimetria é necessário seja para preservação do patrimônio cultural ou ambiental, seja para manutenção da ambiência e da qualidade de vida locais;
- (...) Indicar áreas passíveis de aplicação de potencial adicional de construção e o instrumento de política urbana mais adequado para viabilizar a construção adicional em cada sub-área (se outorga onerosa do direito de construir ou se operações urbanas);

- Promover o desenvolvimento sustentável, compatibilizando o desenvolvimento social e econômico com a preservação ambiental, a partir dos princípios da justiça social e da eficiência econômica, garantindo o uso racional e equitativo dos recursos naturais, contribuindo para a melhoria da qualidade de vida e o conforto climático;
- Proteger as áreas verdes e aquelas ameaçadas de degradação, assegurando a sustentabilidade da flora e da fauna;
- Delimitar espaços apropriados que tenham características e potencialidade para se tornarem áreas verdes;
- Viabilizar a arborização dos logradouros públicos, notadamente nas regiões carentes de áreas verdes;
- Garantir maiores índices de permeabilização do solo em áreas públicas e particulares;
- Controlar as ações de decapeamento do solo e os movimentos de terra, de forma a evitar o assoreamento de represas, córregos, barragens e lagoas
- Recuperar e manter as áreas verdes, criando novos parques e praças;
- assegurar a proporção de, no mínimo, 12m² (doze metros quadrados) de área verde por munícipe, distribuídos por administração regional” (BELO HORIZONTE, 1996; BELO HORIZONTE, 2010)

Os elementos citados acima compõem parte da extensa legislação que define parâmetros para a ocupação do município de Belo Horizonte. No entanto, a cidade é muito dinâmica e apresenta problemas comuns dos grandes centros urbanos dos países em desenvolvimento, a saber: os problemas no sistema viário e na rede de transportes, a carência de serviços de saneamento básico para parte de sua população, a concentração de infraestrutura de equipamentos urbanos em determinadas áreas da cidade e a ausência em outras, entre outros. Assim, construir subsídios para orientar a tomada de decisões com base em dados de rápida obtenção e processamento constitui a motivação dessa pesquisa.

Usar e ocupar os espaços urbanos conforme a proposta dos instrumentos urbanísticos permeia à necessidade de conhecer a realidade e entender como ocorre a expansão e/ou retração dos usos nela existente. E é neste contexto que esta pesquisa se insere.

3 OBJETIVOS

O objetivo geral dessa pesquisa é elaborar uma proposta de classificação e análise de imagens com atributos tridimensionais, integrando dados provenientes de ortofoto (RGB), banda infravermelho próximo registrada e subprodutos de dados LIDAR para aplicação em áreas urbanas. Essa proposta visa auxiliar os interesses da administração pública, que para a proposição de políticas e estratégias de planejamento, necessita de subsídios para a tomada de decisões. Somam-se a isso os resultados provenientes do processamento dos dados LIDAR, que, em conjunto com imagens de satélite e/ou fotografias aéreas permite realizar o monitoramento da cidade em curtos intervalos de tempo. Ou seja, havendo disponibilidade de dados, a classificação permite aos gestores e planejadores uma visualização frequentemente atualizada das tendências do padrão de crescimento e ocupação da cidade.

Destacam-se como objetivos específicos:

- Investigar a melhor configuração de dados e regras para estabelecer a segmentação e o processo de composição dos objetos para a análise;
- Elaborar uma classificação orientada a objetos que considere atributos tridimensionais provenientes de dados LIDAR;
- Produzir um mapa de cobertura e uso do solo que possa subsidiar a gestão e o planejamento territorial urbano;
- Comparar a classificação obtida com a classificação da cobertura e uso do solo oficialmente utilizada pelas instituições públicas, aplicando-se para uma área teste de Belo Horizonte;
- Analisar a qualidade do mapa de uso do solo urbano e validar o processo de classificação para documentação e replicação do modelo.

4 REFERENCIAL TEÓRICO

O arcabouço teórico que sustenta o desenvolvimento dessa pesquisa está relacionado à integração de diferentes fontes de dados, segmentação e classificação orientada a objetos, modelagem para detecção de mudanças na cobertura e uso do solo, além do processo de validação. Esses itens serão detalhados a seguir.

4.1 Fontes de dados

Dentre as fontes de dados pertinentes ao estudo, destacam-se as fotografias aéreas ortorretificadas, bases vetoriais e os dados de perfilamento a *laser* (*light amplification by simulated emission of radiation*) ou LIDAR (*Light Detection and Ranging*).

4.1.1 Fotografias aéreas e subprodutos

O conjunto de fotografias aéreas constitui um produto proveniente de um levantamento aéreo, no qual uma câmera fotográfica aerotransportada obtém cenas da superfície terrestre. As fotografias tomadas são sequenciais e formam faixas que são percorridas por uma aeronave, de modo que haja uma sobreposição que varia de 50% a 60% de uma foto para outra ao longo da faixa e de 10 a 30% das fotografias laterais (figura 1). Essas fotografias são obtidas por ângulos diferentes, de modo que a sobreposição entre elas garante o atributo da estereoscopia, ou seja, a visualização da terceira dimensão da foto, a profundidade (CAZZETA, 2009).

A fotografia aérea constitui o produto bruto do aerolevanteamento; seu processamento permite a obtenção de diversos subprodutos, como as ortofotos e as bases vetoriais. Por meio da ortorretificação, as fotografias aéreas passam a apresentar a mesma escala para todos os objetos, isto é, a influência da diferença de altimetria onde cada objeto se encontra na superfície é eliminada (figura 2). Isso permite a obtenção de um produto de alta precisão geométrica, atributo essencial, por exemplo, para a consolidação de um banco de dados cadastral.

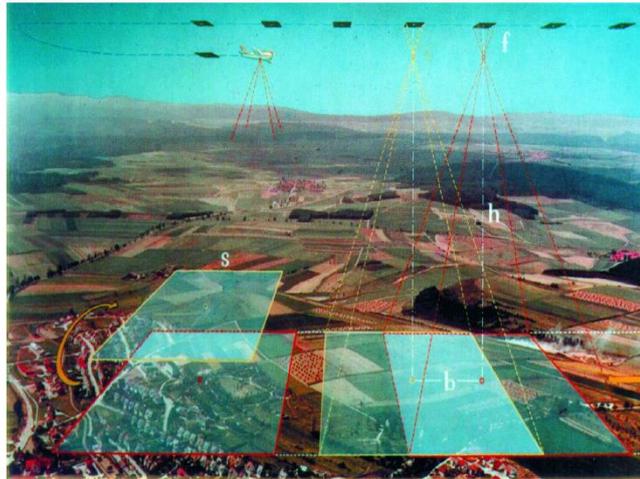


Figura 1. Esquema de representação das faixas lateralmente e longitudinalmente sobrepostas durante um voo. Fonte: CTUFES, 2016³



Figura 2. Produtos obtidos no levantamento aerofotogramétrico: (a) foto aérea e (b) foto aérea ortorretificada. Fonte: PRODABEL, 2008

De maneira semelhante, as bases vetoriais também podem ser obtidas por meio das fotografias aéreas ortorretificadas (figura 3). No processo, um fotointérprete restitui a imagem, identificando os objetos – como edificações, muros, meio-fio, árvores, - que são representados por meio de vetores, formas geométricas (pontos, linhas ou polígonos) georreferenciadas.

³ Disponível em: http://www.ltc.ufes.br/geomaticsee/aula13_geom%c3%a1tica_fotogrametria.pdf. Acesso em 31 mar 2016.



Figura 3. Base vetorial obtida por meio da interpretação de fotografias aéreas ortorretificadas.

Fonte: PRODABEL, 2008

4.1.2 LIDAR

A varredura LIDAR (*Light Detection And Ranging* ou perfilamento aéreo por *laser*) consiste em um método no qual é obtida a posição tridimensional de pontos (x, y e z). De maneira semelhante ao radar, o *laser* registra continuamente as coordenadas espaciais por meio de um sensor *laser* acoplado à aeronave (figura 4). Tal sensor emite ondas que, ao tocar a superfície, são refletidas de volta à aeronave (WEHR; LOHR, 1999; BALTSAVIAS, 1999; BRANDALIZE, 2001).

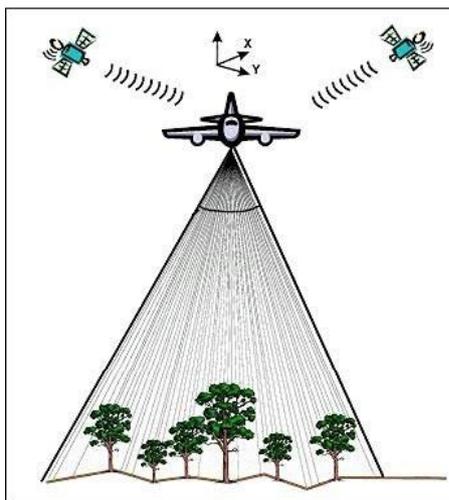


Figura 4. Esquema de obtenção de dados LIDAR. Fonte MundoGeo, 2016⁴.

⁴ Disponível em: <http://mundogeo.com/blog/2000/01/01/sistemas-laser-aertransportados-la-revolucion-de-modelos-digitales/>. Acesso em: 01 abr 2016.

O feixe captado pelo equipamento registra duas informações: a intensidade do sinal de retorno – que varia conforme o “tamanho dos objetos, em relação à projeção do feixe, bem como o material que compõe a superfície” (CAVASSIM JUNIOR; CENTENO; MITISHITA, 2005, p. 204) – a altitude e a posição (x,y) dos pontos coletados. O equipamento aerotransportado emite os raios em direção à superfície, e esta, por sua vez, reflete os raios, que retornam ao equipamento na aeronave. Sabendo-se a velocidade da luz e o tempo de retorno do raio emitido, é possível calcular a distância entre a aeronave e o obstáculo da superfície, que define a altimetria do ponto coletado. Nesse contexto, alguns equipamentos podem gerar dois tipos de altitude: a do primeiro e do segundo retorno (como é o caso do equipamento que produziu os dados *laser* utilizados nesta pesquisa). Essa diferenciação ocorre em função da diferença da altitude entre os objetos na superfície, de modo que aquele mais próximo da aeronave que transporta o sensor é responsável pela reflexão do 1º pulso (ou 1º retorno) e os objetos mais distantes da aeronave é responsável pela reflexão do 2º pulso (figura 5).

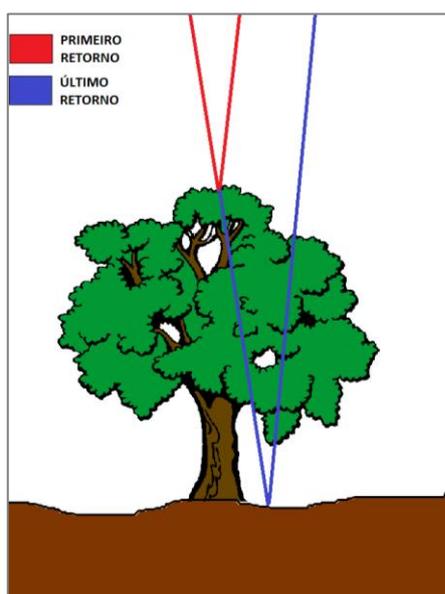


Figura 5. Primeiro e último retorno dos pulsos *laser*.

Deste modo, o sensor capta sinal tanto da superfície do terreno quanto da superfície formada pelos objetos sobre o terreno. Utilizando os dados do 1º retorno, é possível calcular o Modelo Digital de Superfície (figura 6), ou seja, o modelo que representa a superfície terrestre com todos os objetos nela presentes (como edifícios, casas, árvores, entre outros). Ao desconsiderar os pontos do 1º retorno, identificar os objetos e extraí-los e então realizar uma interpolação dos pontos do 2º retorno, é possível obter também o Modelo Digital de Terreno (MDT), correspondente ao modelo da superfície terrestre desnuda (figura 7). Por meio da subtração do MDS pelo MDT tem-se o Modelo Digital de Superfície Normalizado

(MDSn), ou seja, a altura dos objetos (FALAT, 2005). É importante ressaltar que na atualidade há ainda sistemas de múltiplos retornos, provenientes das diversas variações da altimetria da superfície. O sistema *laser* aerotransportado emite um pulso que pode registrar diversos ecos separadamente, registrados em diversas classes de distância (DRESCH, 2015; ROSA, 2014; GONÇALVES, 2012).

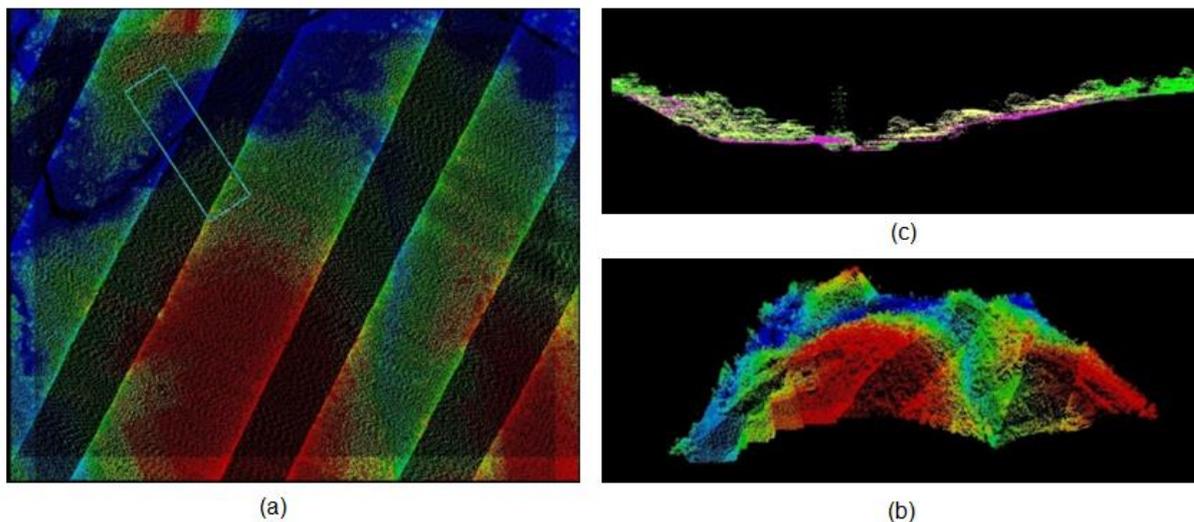


Figura 6. Modelo Digital de Superfície, obtido pelo primeiro retorno dos pulsos laser. Em (a) planta, (b) perfil, (c) visão perspectiva. Fonte: PRODABEL, 2008

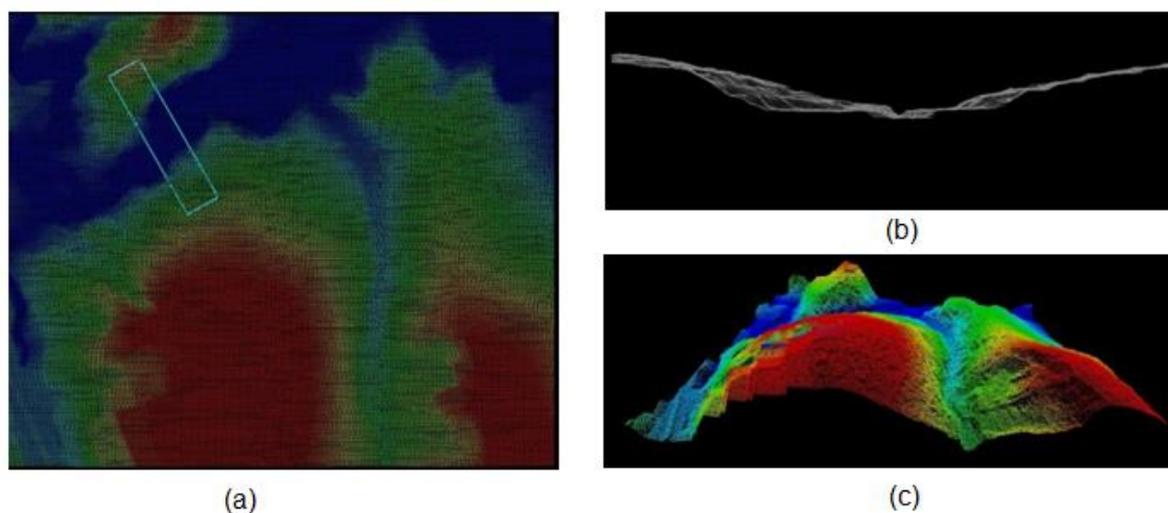


Figura 7. Modelo Digital de Terreno, obtido pela interpolação do último retorno dos pulsos *laser*. Em (a) planta, (b) perfil, e (c) visão perspectiva. Fonte: PRODABEL, 2008

As pesquisas relacionadas ao entendimento do dado *laser* e sua aplicação em áreas urbanas frequentemente empregaram os produtos como MDT's e MDE's para estudar a dimensão vertical das cidades (BOTELHO; CENTENO, 2005; CENTENO; KISHI;

MITISHITA, 2009). Deus, Santos e Fonseca (2011) apresentaram comparação de métodos de classificação da cobertura do solo urbano, integrando imagens de satélite e LIDAR. Ao abordarem as dificuldades em classificar áreas urbanas através das imagens de alta resolução espacial, mas com baixa resolução espectral, propuseram a utilização de *laser* para diferenciar objetos com base nas diferenças de altimetria. A incorporação da altimetria extraída do *laser* para a classificação melhorou a precisão do método por volta de 5%. Centeno e Mitishita (2007) apresentaram uma proposta de utilização de *laser* para geração de MDE's em áreas urbanas e a integração de *laser* scanner e sensores óticos para aplicações como correção geométrica de imagem com transformação projetiva. Araki (2005) desenvolveu uma metodologia para utilização de dados altimétricos provenientes de *laser* para aprimorar a discriminação dos tipos de cobertura, em função da dificuldade de classificação de imagens em áreas urbanas por razões relacionadas à oclusão, que gera perda de informação espectral em algumas áreas de imagens de alta resolução. Machado e Mitishita (2006) desenvolveram pesquisa para detectar automaticamente o contorno de edificações a partir de dados *laser*.

Já Mendes e Dal Poz (2013) propuseram uma integração de dados geométricos e radiométricos de varredura a *laser* com imagem aérea de alta resolução em uma classificação por redes neurais artificiais para isolamento de vias. Conforme Ferreira (2014) é possível comparar feições urbanas obtidas na classificação automática com feições homólogas provenientes de uma base cartográfica de referência, mostrando convergências e divergências entre os dois produtos. A análise de declividade pode contribuir para a determinação de bordas das edificações e, assim para a segmentação dessas feições. Castro, Debiasi e Centeno (2009) propuseram metodologia de extração de estradas em imagens de intensidade *laser* com utilização de morfologia matemática. A pesquisa utilizou como fonte de dados apenas os dados *laser*, sem integrar imagens de satélite ou fotografias aéreas. Nessa pesquisa se obtiveram bons resultados, sendo ressaltado apenas a necessidade de suavização dos contornos extraídos. Gohara et al. (2015) propôs a utilização de dados *laser* e imagens aéreas para a extração de vias urbanas na identificação das feições, obtendo-se nos resultados uma proporção alta de vias urbanas corretamente identificadas.

Na maioria dos casos, as pesquisas que aprofundam no estudo dos dados *laser* não abordam detalhadamente outros atributos do dado que não seja a altimetria. O *laser*, de forma semelhante aos sensores orbitais⁵, é capaz de registrar o comprimento de onda –

⁵ Enquanto os sensores orbitais captam imagens da Terra a bordo de um satélite, os sensores LIDAR comumente são transportados em aviões ou helicópteros. Atualmente algumas empresas já estão disponibilizando o serviço de perfilamento a *laser* utilizando VANT's (veículos aéreos não transportados, semelhantes a drones).

mas em uma faixa estreita do espectro eletromagnético, apresentando, por isso, baixa resolução espectral – e a intensidade do sinal, de modo que é possível produzir imagens com base nas diferenças do comportamento espectral dos alvos. Assim, alguns estudos consideram a intensidade, embora a diferenciação entre os elementos da superfície não seja tão bem definida como em uma imagem de satélite de alta resolução espectral.

Muitos estudos foram publicados sobre a classificação, e comumente os autores ressaltam a importância e relevância da inclusão de dados *laser* no processo de classificação. Acredita-se que a consideração de dados altimétricos permite a correção da classificação de elementos que, por apresentarem resposta espectral semelhante podem ser confundidos. Casos como estes podem ser exemplificados como relação à vegetação arbórea e rasteira, concreto e edifícios, entre outros. É consenso, portanto, entre os pesquisadores que a integração de dados *laser* e imagens no processo de classificação podem aumentar significativamente a qualidade dos resultados obtidos.

4.2 Segmentação

Na segmentação a imagem é fragmentada por meio do delineamento dos objetos ou segmentos, com base em elementos de similaridade e descontinuidade da informação proveniente do comportamento da imagem, tanto quanto aos aspectos relacionados à forma e textura quanto ao comportamento espectral que um conjunto de *pixels* pode apresentar (figura 8).

“Ela (a segmentação) extrai objetos primitivos da imagem em uma resolução arbitrária – estruturas finas ou grosseiras – e em alta qualidade. Esta técnica foi adaptada especialmente para encontrar objetos da imagem em dados texturais, como imagens SAR, imagens de satélite de alta resolução, dados aéreos ou imagens médicas” (BAATZ e SCHÄPE, 1999, p.1, tradução nossa).

Para que a segmentação seja feita, pode-se utilizar, dentre outras, a metodologia do crescimento de regiões ou detecção de bordas. No crescimento de regiões, os dados são agrupados desde que haja adjacência. A cada pixel é atribuído um rótulo, caracterizando assim uma região. Os pares de região adjacentes são comparados com base em um critério de similaridade, que por sua vez é baseado em um teste de hipótese da média entre as regiões. Assim, a imagem é fragmentada em um conjunto de regiões menores, que

posteriormente podem ser unidas, segundo um limiar de agregação estabelecido (BAATZ; SHÄPE, 2000).

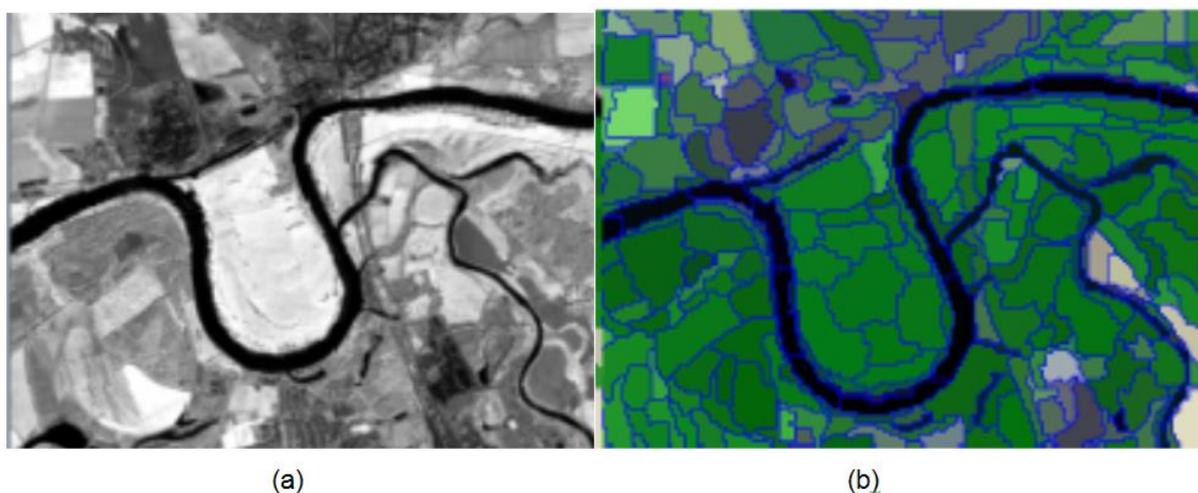


Figura 8. Segmentação de imagem de satélite. Em (a), exemplo de imagem obtida por meio de imageamento de satélite e (b) a mesma área da imagem segmentada. Fonte: Definiens, 2007.

No método de detecção de bordas utiliza-se um algoritmo que considera o gradiente dos níveis de cinza da imagem original para gerar uma imagem de intensidade dessas bordas. Nessa abordagem, busca-se localizar as bordas dos segmentos e delimitar os mesmos quando o valor do nível de cinza definido sofrer uma mudança acima de um limiar estabelecido:

“O algoritmo calcula um limiar para a perseguição de bordas. Quando ele encontra um "pixel" com valor superior ao limiar estabelecido, tem-se início o processo de perseguição da borda. Observa-se a vizinhança para identificar o próximo "pixel" de maior valor de nível digital e segue-se nesta direção até que se encontre outra borda ou a fronteira da imagem. Deste processo gera-se uma imagem binária com os valores de 1 referentes às bordas e 0, a regiões de não-bordas. A imagem binária será rotulada de modo que as porções da imagem com valores 0 constituirão regiões limitadas pelos valores 1 da imagem, constituindo a imagem rotulada” (INPE, 2006).

A segmentação deve ser executada até que a divisão em regiões homogêneas atinja uma quantidade de classes e também os limites paramétricos de heterogeneidade para *pixels* de uma mesma região. Tal heterogeneidade máxima permitida em um segmento está ligada à cor (resposta espectral) e forma (BLASCHKE et al., 2002, WOODCOCK et al., 1994). A segmentação, portanto, atinge seu objeto quando as regiões que possuem propriedades semelhantes são agrupadas.

4.2.1 Segmentação por crescimento de regiões

A técnica de segmentação por crescimento de regiões tem como objetivo agregar *pixels* ou conjunto de *pixels* em grupos maiores. Esses grupos são definidos pela conectividade espacial entre os *pixels*, os quais apresentam características em comum de similaridade pré-estabelecidos.

Uma condição do crescimento de regiões é que os *pixels* ou grupo de *pixels* só podem ser agrupados caso sejam adjacentes. A união desses elementos para a definição de uma região se dá com base em um conjunto de descritores, podendo estes serem espectrais, de textura, de forma e de contexto. Tais descritores impõem limiares que definem os limites das regiões, caso os critérios sejam atendidos, as regiões são agregadas (INPE, 2006).

A segmentação deve atender a alguns critérios: deve ser completa, de modo que todos os *pixels* pertençam a alguma região; os *pixels* de uma região devem estar conectados; as regiões devem ser disjuntas; deve haver um conjunto de propriedades que são comuns aos *pixels* de uma região; por fim, duas regiões vizinhas não podem apresentar um conjunto de propriedades comuns entre elas (COUTINHO, 2006).

No processo, alguns parâmetros devem ser ajustados. Dentre eles, destacam-se o parâmetro de escala e o critério de homogeneidade (forma e compacidade).

Conforme Definiens (2007), o parâmetro de escala “define o desvio padrão máximo dos critérios de homogeneidade em relação às camadas de imagem ponderadas para os objetos de imagem resultantes” (DEFINIENS, 2007, p. 22, tradução nossa). Assim, quanto maior o valor deste parâmetro, maiores os objetos segmentados. Dessa forma, cabe ao operador definir qual tamanho adequado para o tipo de objeto que se pretende criar.

Quanto aos critérios de homogeneidade, a forma está relacionada à homogeneidade textural dos objetos da imagem resultante e a compacidade pode ser definida como a razão da área do objeto e o raio da circunferência abrangente; ambas variando de 0 a 1.

Os objetos identificados na imagem compõem uma hierarquia na qual é possível identificar super-objetos e sub-objetos, oriundos de uma segmentação em vários níveis. As classes identificadas devem, portanto, apresentar um nível de detalhamento que pode variar de acordo com o alvo da imagem (COUTINHO, 2006). Assim, diferentes coberturas do solo podem ser detalhadas em um número variável de níveis, conforme a possibilidade de detalhamento destas. A título de exemplo, em uma cena urbana a superfície coberta de água pode ser detalhada para diferenciar a existência de piscinas e lagoas (2 níveis), enquanto a cobertura por concreto pode diferenciar um número maior de elementos, como

edificações, passeios, muros (3 níveis). Deve-se ainda considerar o estabelecimento de uma rede hierárquica na qual os elementos são separados em grupos maiores, derivando destes as subcategorias ou subníveis (figura 9).

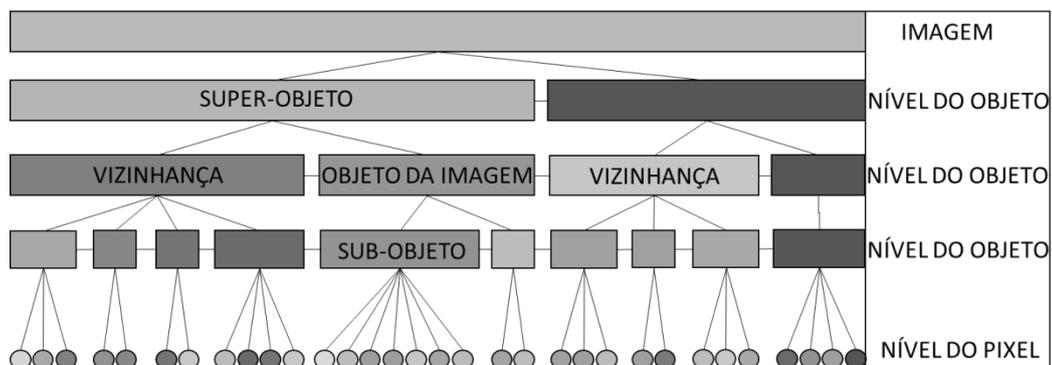


Figura 9. Hierarquia dos objetos na segmentação. Fonte: adaptado de Definiens, 2007.

Luz, Antunes e Tavares Junior (2010) exemplificam essa distribuição hierárquica comparando, por exemplo, área urbana e área rural, dois grandes grupos, sendo que no segundo é possível adentrar em um nível de detalhamento que permite subdividir áreas agrícolas e pastagens, que de maneira alguma poderiam pertencer à área urbana. Conforme os autores, a hierarquia das classes é construída de forma intuitiva utilizando-se conhecimentos a respeito do comportamento espectral dos alvos e características do elemento categorizado no nível hierárquico superior:

“Os objetivos, nessa etapa do processo, eram promover a categorização dos objetos de forma sucessiva e também explicitar as relações semânticas entre essas classes, de forma a emular o processo de reconhecimento de padrões humano” (LUZ; ANTUNES; TAVARES JUNIOR, 2010, p.435).

No processo de segmentação consideram-se alguns elementos que posteriormente poderão estar presentes também nos descritores dos objetos, ou seja, elementos relativos aos objetos identificados que permitem que estes sejam diferenciados de classe para classe, detalhados na próxima seção.

4.2.2 Descritores de classes

Os descritores de classes são propriedades dos objetos identificados na segmentação que podem contribuir no processo de classificação dos mesmos (COUTINHO, 2006; NÓBREGA, 2007). Podem ser divididos em descritores espectrais, texturais, de forma e de contexto.

Os descritores espectrais são aqueles associados aos valores espectrais das bandas de um satélite e do relacionamento com os atributos espectrais de vizinhança. Entre eles podem ser citados a média espectral, o brilho, a razão (formada pela divisão do valor médio da banda pela soma dos valores médios de todas as bandas), entre outros. Os descritores texturais são associados à variação espacial dos valores espectrais de detalhamentos dos objetos, como o grau de distribuição dos elementos da matriz, a variação da heterogeneidade local na imagem, e outros. Os descritores de forma estão associados às propriedades geométricas dos objetos identificados na imagem. Alguns exemplos destes são a área, comprimento/largura, densidade, assimetria entre outros. Os descritores de contexto (ou vizinhança) são aqueles que relacionam os objetos entre si, de acordo com a hierarquia imposta pela segmentação. São estes os descritores que relacionam super-objetos com objetos, e objetos com sub-objetos.

O peso que cada um dos descritores assume pode variar conforme o objeto a ser classificado. Alguns elementos são mais bem definidos com base na sua forma, enquanto outros na textura, ou ainda com relação à sua vizinhança. A definição da importância (ou peso) de cada um dos descritores se dá de forma empírica, experimentando diferentes valores para cada uma das classes de objetos identificadas.

4.3 Classificação

A classificação é o processo no qual se busca categorizar cada um dos *pixels* de uma imagem com base em semelhanças e padrões estabelecidos (figura 10). Isso é possível uma vez que os *pixels* (as menores unidades de representação de uma imagem) guardam informações a respeito do comportamento espectral dos objetos, que é um atributo inerente a todos os objetos da superfície que interagem com diferentes tipos de ondas eletromagnéticas. Os sensores remotos captam as ondas refletidas, emitidas pelos objetos e retroespalhadas, registrando a intensidade do brilho de cada um deles, possibilitando diferenciá-los por esse elemento. Dessa forma, quanto maior a sensibilidade do sensor em relação ao número de níveis de brilho que ele lê (resolução radiométrica) e quanto maior o número de comprimentos de onda que o sensor capta (resolução espectral), maior será a qualidade na identificação dos objetos e, por consequência, melhor a qualidade da classificação.

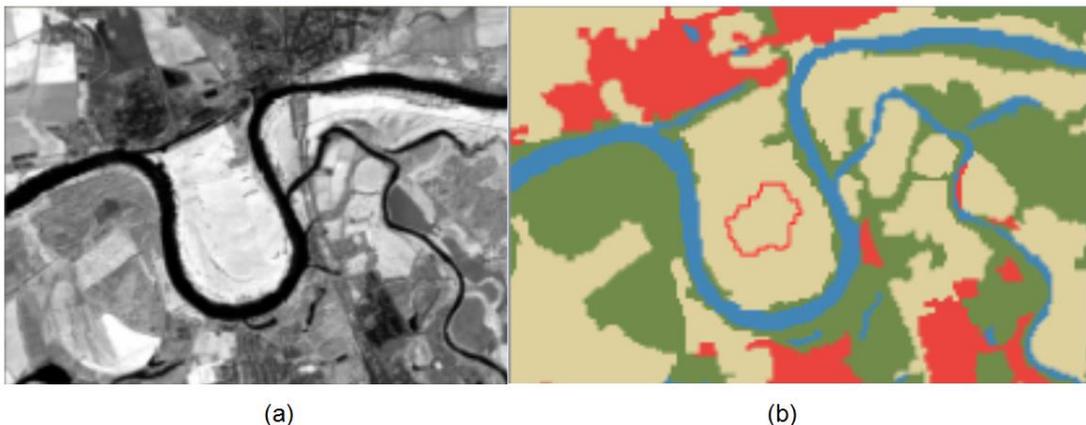


Figura 10. Exemplo de imagem de satélite classificada. Em (a), exemplo de imagem obtida por meio de imageamento de satélite e (b) a mesma área da imagem classificada. Fonte: Definiens, 2007

Quanto à abordagem, a classificação pode ser supervisionada ou não supervisionada. Neste processo, os programas de classificação definem com base em parâmetros estatísticos não só quais classes serão delimitadas, mas também quais *pixels* se inserem em cada uma dessas classes. Na classificação supervisionada, o analista identifica uma amostra de *pixels* pertencentes a uma classe por ele definida (isso corresponde à fase do treinamento), de modo que os demais *pixels* possam ser classificados pelo programa.

Quanto à análise da superfície, a classificação pode ser subdividida em *pixel-a-pixel* e orientada a objetos. A classificação *pixel-a-pixel* analisa estes elementos individualmente quanto ao comportamento espectral, agrupando-os conforme as características semelhantes. Conforme Alves e Vergara (2005):

“Uma questão não abordada na metodologia de classificação *pixel-a-pixel*, é que a aparência espectral de uma área representada por um *pixel* é influenciada pelas respostas espectrais das áreas que a circunvizinham, representadas pelos *pixels* adjacentes” (ALVES; VERGARA, 2005, p. 2573).

Tendo em vista as limitações impostas à classificação *pixel-a-pixel*, esta pesquisa irá detalhar melhor os aspectos da classificação orientada a objetos, metodologia utilizada para o desenvolvimento do trabalho.

4.3.1 Classificação orientada a objetos

A metodologia da classificação orientada a objetos baseia-se no fato de que as informações semânticas para a interpretação necessitam de mais dados do que análise *pixel-a-pixel*. Para tanto, devem ser consideradas regiões homogêneas e a relação topológica, ou de vizinhança, entre os objetos ou segmentos (ALVES; VERGARA, 2005). Neste processo, analisa-se não somente o comportamento espectral dos *pixels*, mas a relação com a sua vizinhança, apresentando vantagens topológicas significativas. Assim, atributos como forma, textura, tipologia são analisados em conjunto com o comportamento espectral para classificar os objetos ou segmentos. A proposta dessa metodologia é reproduzir a análise de um intérprete de imagens, que, em função do seu conhecimento sobre a realidade categoriza os elementos da superfície conforme um conjunto de atributos (figura 11).

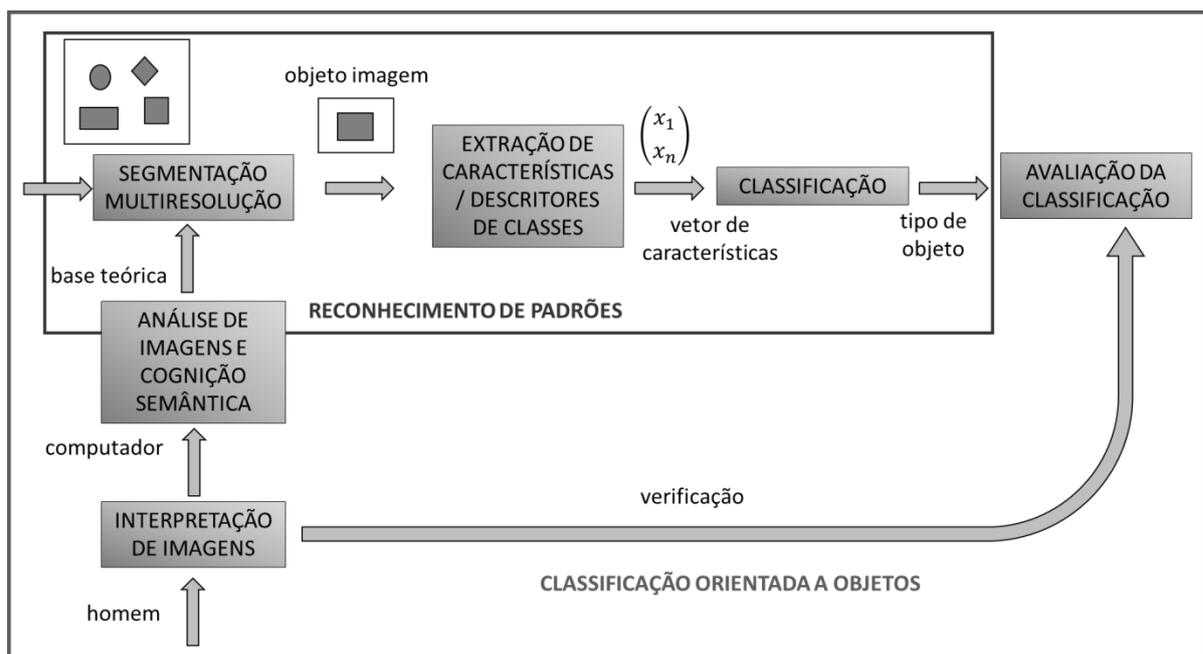


Figura 11. Etapas da classificação orientada a objeto. Fonte: adaptado de Coutinho, 2006

Blaschke et al. (2002) afirma que embora as técnicas de classificação tenham sido bem desenvolvidas para a inclusão de novos classificadores, incluindo as técnicas de integração dos atributos espectrais, é um fato que elas não tenham utilizado os conceitos espaciais. Analisando imagens de alta resolução percebe-se facilmente que um *pixel* vizinho àquele analisado pertence a mesma classe de cobertura do solo, fato que impulsionou as pesquisas nos últimos anos de metodologias de delineamento de objetos baseado nas

informações contextuais em uma imagem. É inquestionável a contribuição da metodologia de classificação orientada a objetos no estudo do monitoramento ambiental (BLASCHKE; STROBL, 2001; BLASCHKE, 2010).

Muitos estudos ressaltam as vantagens das classificações orientada a objetos que pode auxiliar no processo de identificação de segmentos em áreas urbanas. Pinho, Feitosa e Kux (2005), por meio de avaliação visual qualitativa apresentaram diferenças consideráveis entre a classificação por máxima verossimilhança e orientada a objetos, discutindo os ganhos da abordagem orientada a objetos como alternativa para redução dos problemas relacionados à heterogeneidade em áreas urbanas. Ribeiro, Santos e Centeno (2002) também propuseram teste metodológico entre dois procedimentos de classificação, utilizando os dados *laser*. Em ambas as propostas (com classificadores “vizinho mais próximo” e “fuzzy”), o autor ressalta as vantagens da classificação orientada a objetos, por considerar “fatores de forma, textura e outras variáveis espaciais que não podem ser consideradas em uma análise *pixel-a-pixel*”. Além destes, outros estudos apontam resultados similares no aspecto da redução da heterogeneidade em áreas urbanas (ANJOS; ALMEIDA; GALVÃO, 2015; DEUS; SANTOS; FONSECA, 2011, GOHARA et al., 2015).

A primeira etapa na classificação é a definição de um modelo conceitual que se encaixe na área em estudo. No entanto, deve-se ressaltar que ao definir padrões que se adequam para uma dada área, existe o risco de que o modelo se torne muito específico e opere bem somente na área estudada.

Para a classificação supervisionada por regiões, os algoritmos estatísticos mais comuns são o Bhattacharya e ClaTex. De maneira resumida, Bhattacharya mede a distância média entre as distribuições das probabilidades das classes espectrais. O segundo utiliza atributos texturais das regiões da imagem segmentada, que são agrupadas a partir de uma medida de similaridade estabelecida (INPE, 2006).

Além dos tradicionais classificadores estatísticos, há a opção de algoritmos de inteligência artificial e algoritmos baseados na lógica *fuzzy*, cujo funcionamento será detalhado no item 4.3.3.

4.3.2 Classificação por parcelas

Outra base teórica interessante que se aproxima da abordagem orientada a objetos é a proposta de classificação por parcelas (APLIN, 2003). O autor sugere que devido à heterogeneidade da superfície urbana, há grande dificuldade na classificação da cobertura e

do uso do solo. Conforme o autor, a dificuldade não se deve somente à heterogeneidade interna às cidades (devido aos diferentes tipos de uso), mas também devido à heterogeneidade externa ou entre as cidades (em função das características locais de uso e ocupação do solo). Além disso, esse mesmo autor relata que uma forma de lidar com tais heterogeneidades, portanto, é considerar as relações de contexto. Enquanto a cobertura do solo pode ser extraída diretamente do comportamento espectral dos alvos, o mesmo não ocorre com o uso. Neste sentido, “é possível inferir o uso do solo a partir da cobertura do solo, embora esta inferência será generalizada e dependerá de dados adicionais, de processamentos e análises contextuais” (APLIN, 2003, p 25, tradução nossa). Adicionalmente, Aplin afirma o que segue:

Comumente, a classificação por parcela é realizada integrando imagens de sensoriamento remoto e dados vetoriais cartográficos digitais. Este método tem o benefício adicional de que a análise pode ser realizada dentro de um sistema de informação geográfica, o meio preferido de armazenar e analisar dados espaciais pela maioria dos planejadores urbanos. Quando necessário, portanto, a classificação por parcela baseada em GIS pode ser facilmente integrada com outras tarefas e dados de planejamento urbano” (APLIN, 2003, p 30, tradução nossa).

Considerando a importância dos dados adicionais para a obtenção do uso do solo, é possível destacar o conjunto de informações que pode ser extraído dos sistemas de informações geográficas. Conforme Baatz e Schäpe (1999), os dados provenientes dos sistemas de informação geográfica tem se transformado em fonte básica para tomada de decisões, desde que estes tenham qualidade de acordo com o nível de exigência de interpretação da realidade. Desta forma, os autores enfatizam a importância da integração do sensoriamento remoto com SIG, embora apontem limitações no que se relaciona ao aspecto metodológico. Dentre os desafios desta integração, destacam a dificuldade de obtenção de geoinformação com base na análise automática de imagens, o que atualmente é alvo de diversos estudos. Outra dificuldade está na atualização dos dados provenientes de banco de dados, cuja automatização ainda é precária, necessitando primordialmente de recursos manuais.

4.3.3 Lógica *Fuzzy*

A teoria dos conjuntos *Fuzzy* ou conceitos de lógica *Fuzzy*, fundamentada por ZADEH (1965), temo como objetivo fornecer bases matemáticas para tratar informações de caráter impreciso e vago. Por esta razão, é eficiente para modelar a incerteza na definição de

parâmetros e tem resultados em diversas aplicações. Para isso, captura informações que comumente são descritas na linguagem natural, convertendo-as para o formato numérico.

Na lógica clássica dos conjuntos (Booleana) um elemento pode pertencer ou não a um conjunto, de forma que os resultados possíveis são enquadrados em um resultado verdadeiro ou falso (0 ou 1), de acordo com a proposição elaborada. Já na lógica *fuzzy* a função pode assumir um número infinito de valores em um intervalo entre $[0...1]$. Nesse sentido, um mesmo elemento pode pertencer a mais de um conjunto conforme graus de pertinência, a qual pode ser definida por uma função de pertinência.

A função de pertinência varia de acordo com parâmetros estabelecidos com base no conjunto de dados ou experiência analítica. Por exemplo, para indivíduos da classe vegetação, é possível definir uma função para que estes sejam enquadrados nas classes (ou portes) “herbáceo”, “arbustivo” e “arbóreo” (figura 12). Dessa forma, um indivíduo com altura de 3 metros é totalmente compatível com o porte arbustivo. Já valores abaixo ou acima de 3 metros apresentam grau de pertinência entre 0 e 1 para as classes herbáceo e arbustivo e arbustivo e arbóreo, respectivamente. Definição de funções de pertinência com base no conhecimento das características que definem as classes de cobertura e uso do solo constitui etapa fundamental desta pesquisa.

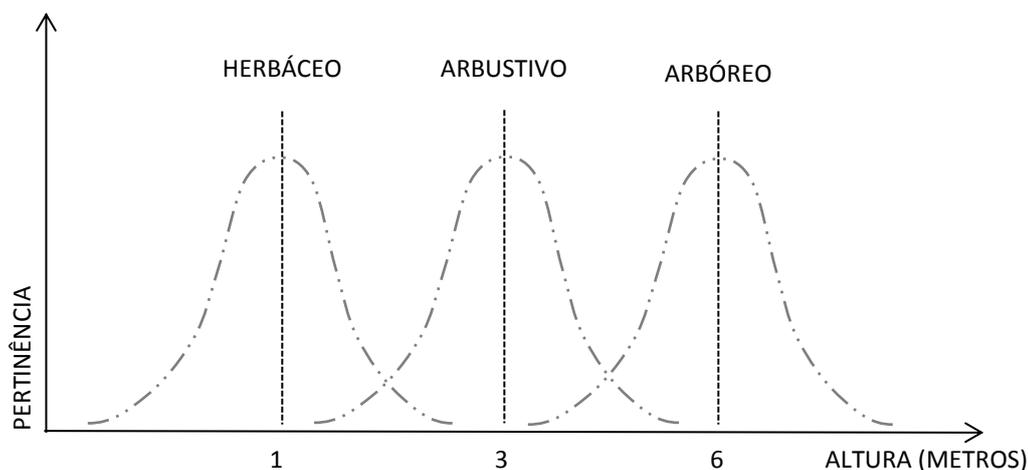


Figura 12. Função de pertinência (hipotética) para classes de vegetação.

As funções de pertinência podem assumir várias formas, dependendo do conceito que se deseja representar e do contexto em que serão utilizadas, sendo este último muito importante na definição das funções. No entanto é comum utilizar algumas funções padrão (figura 13), como, por exemplo, as funções de forma triangular, trapezoidal ou Gaussiana. Assim, após analisar os dados e iniciar a etapa de classificação, o operador deve ajustar as

funções no *software* classificador, ajustando-as para adequá-las melhor ao resultado esperado.

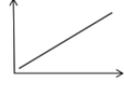
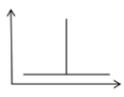
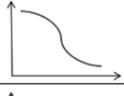
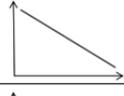
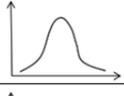
	maior que		maior que (linear)		singleton (exatamente um valor)
	menor que		menor que (linear)		gaussiana aproximada
	maior que (booleana)		intervalo linear (triangular)		aproximadamente o intervalo
	menor que (booleana)		intervalo linear (triangular invertida)		intervalo total

Figura 13. Funções de pertinência "padrão" comumente utilizadas em modelagem *fuzzy*. Adaptado de Definiens, 2007

MAMDANI (1975), baseado na teoria dos conjuntos *fuzzy* elaborou o sistema de inferência *fuzzy*, cujo objetivo é representar os experimentos da realidade (figura 14).

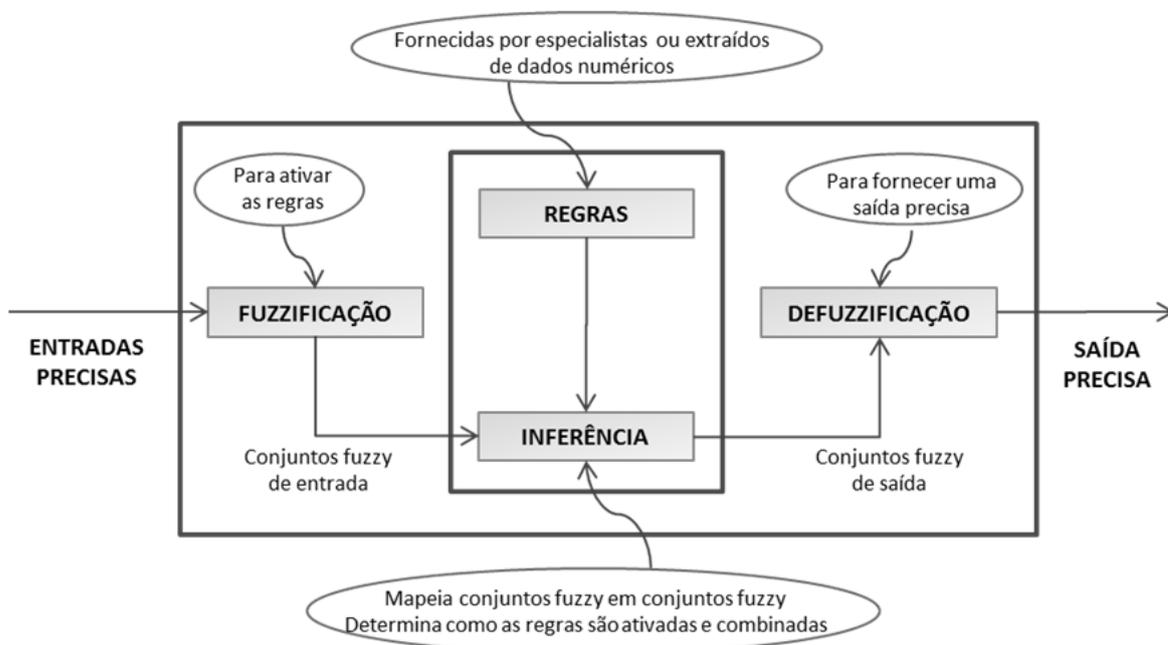


Figura 14. Sistema de inferência *fuzzy*. Adaptado de Tanscheit, 2004

Este sistema é subdividido em um processo de 4 passos: inicialmente têm-se as “entradas precisas”, que se consistem no resultado das medidas ou observações do conjunto de dados, caso mais comum das situações práticas. As entradas precisas, dentro do sistema de inferência, são transformadas em conjuntos *fuzzy*, por meio do “*fuzzyficador*”. A

“fuzzyficação” é a etapa na qual são obtidos os graus de pertinência para cada entrada que agora pertence ao conjunto *fuzzy*. Assim, para cada valor de entrada há um grau de pertinência em cada um dos conjuntos difusos. Tipo e quantidade de funções de pertinência depende de fatores como precisão, estabilidade, facilidade de implementação, entre outros. Os elementos então são submetidos a um conjunto de regras, estabelecidas pelo conhecimento especializado ou base de dados. A seguir, tem-se a etapa de inferência, que mapeia os conjuntos *fuzzy* e determina como as regras são ativadas e combinadas.

A etapa seguinte se consiste na “defuzzyficação”, na qual ocorre a conversão de um conjunto *fuzzy* a um número real, obtendo-se neste processo uma “saída precisa”. Em linhas gerais, os métodos mais comuns utilizados na “defuzzyficação” são o cálculo do centroide da área de um conjunto *fuzzy*, cálculo dos máximos ou média dos máximos.

Diversos problemas da realidade são tratados com base na teoria dos conjuntos *fuzzy*. Oliveira (2013) utilizou funções de pertinência *fuzzy* para as variáveis uso do solo, pluviometria, rede viária, declividade, densidade demográfica, hidrografia, aglomerados subnormais (comunidades), para modelagem de risco de incêndios no município de João Pessoa (PB), obtendo resultados satisfatórios quanto à modelagem e identificação de áreas mais propensas a incêndios, encontrando coeficiente de determinação acima de 85%. Silva et al. (2013) estudou a vulnerabilidade à erosão em áreas costeiras, utilizando modelagem *fuzzy* para as variáveis relacionadas às condições morfológicas, atributos naturais, processos costeiros, processos antrópicos, benfeitorias de lazer e urbanização, para classificar a vulnerabilidade à erosão do solo, e sugeriu a inserção de novas variáveis ao modelo para aprimoramento dos resultados. Guerra e Caldas (2010) propuseram uma classificação não supervisionada utilizando funções *fuzzy* para detectar áreas de savana na região de Santarém (PA), obtendo boa separabilidade desta classe.

No âmbito das classificações de imagem, a modelagem *fuzzy* é amplamente empregada e há diversos trabalhos publicados sobre o assunto. Estevam e Silva (2010), por meio de classificação orientada a objetos no *software* e-Cognition e utilizando funções de pertinência, identificaram áreas de favelas em imagens Ikonos, obtendo coeficiente kappa satisfatório (equivalente a 79%). Campos et al. (2010) propôs a automatização do processo de obtenção das funções de pertinência, uma vez que o processo manual é demorado e lento. Apresentou bons resultados do algoritmo de inteligência artificial utilizado em comparação com os ajustes manuais realizados nas funções de pertinência. Outros exemplos podem ser vistos em ANTUNES e ZULLO JUNIOR, 2007, PINHO; KUX; ALMEIDA, 2007, ROSÁRIO et al., 2007 e CADENA, 2011.

4.4 Métodos de validação

Para o objetivo desse estudo, destaca-se a metodologia utilizada para validação temática. A componente temática, conforme Ariza-López (2002), não é exclusiva dos tradicionais mapas temáticos, uma vez que o mesmo pode ser observado em mapas topográficos, cujos elementos são relacionados em função da legenda. Por esta razão, aponta, os elementos pontuais que são identificados em mapas topográficos, como exemplo construções, também podem ser estudados para analisar se a sua localização está corretamente identificada. Para que isso seja feito, é importante destacar que a comparação deve ser feita com fontes mais confiáveis de dados.

Dentre os erros mais comuns, são destacados os seguintes:

- Erro de natureza: confusão nas classes as quais os elementos pertencem;
- Erro de frequência: o número de vezes que o erro ocorre;
- Erro relacionado à importância ou magnitude: situação na qual um erro é mais importante do que o outro;
- Fonte do erro: identificação da origem ou causa do erro que permite a minimização deste.

Desta forma, existem vários métodos de validação dos dados temáticos. Para o objetivo deste trabalho, serão aprofundados os métodos relativos aos parâmetros de qualidade temática: a matriz de confusão (ou matriz de correlação) e os índices globais e por classe dela derivados.

4.4.1 Matriz de confusão

A matriz de confusão é elaborada a partir da classificação de todos os elementos da imagem em categorias, com o objetivo de analisar se o *pixel* ou segmento classificado correspondeu ao valor real, sendo este último identificado em um levantamento mais preciso ou uma fonte mais confiável, como restituições aerofotogramétricas ou levantamento de campo, por exemplo. Trata-se de uma ferramenta amplamente utilizada para avaliação de modelos estatísticos.

“A matriz de confusão é uma matriz quadrada de números definidos em linhas e colunas que expressam o número de unidades da amostra (*pixels*, grupos de *pixels* ou polígonos) atribuído a uma categoria particular relativo à categoria atual, conforme foi verificado em campo. Geralmente, as colunas representam os dados de referência, enquanto as linhas representam a classificação gerada a partir dos dados de sensoriamento remoto” (SUAREZ; CANDEIAS, 2012, p. 4).

Na estrutura da matriz, os valores das colunas correspondem aos “dados de referência”, ou a fonte mais precisa, enquanto os valores das linhas correspondem à “unidade cartográfica”, que no caso em análise trata-se de uma imagem classificada (ARIZA-LÓPEZ; BALBOA; PULIDO, 2004).

Conforme Ponzoni e Almeida (1996):

“A exatidão de mapas temáticos tem sido determinada a partir das chamadas matrizes de erros ou de contingência, as quais são constituídas por igual número de linhas e de colunas, e representam o confronto entre o resultado da classificação (visual ou digital) de um produto de sensoriamento remoto (mapa temático) e a verdade terrestre ou outra informação considerada como referência. Este confronto é realizado através de um procedimento amostral no qual um certo número de pontos ou pixels pertencentes à uma dada classe (tema) são verificados em campo ou em outro mapa, considerado como referência, no sentido de comprovar ou não a atribuição correta destes à classe em questão” (PONZONI e ALMEIDA, 1996, p. 729).

Dessa forma, por meio da matriz, é possível identificar os elementos classificados corretamente ou incorretamente, conforme a classe a qual pertencem considerando o dado de referência (figura 15). Trata-se de uma ferramenta importante, pois a sua apresentação facilita o entendimento do erro, de modo que os valores apresentados na diagonal correspondem a visão geral das classes corretamente classificadas, enquanto as demais células da matriz indicam os elementos erroneamente classificados (tabela 1).

Muitas vezes a realização de um trabalho do tipo censo (toda a população de dados) é inviável, de modo que é necessária a seleção de uma amostra representativa para que se possa inferir estimativas a respeito da população (CONGALTON, 1991; CONGALTON e GREEN, 2008). Assim, alguns fatores devem ser observados (ARIZA-LÓPEZ, 2002):

- As classes estabelecidas devem ser independentes, mutuamente excludentes e em número suficiente;
- É necessária a utilização de métodos de amostragem que excluam autocorrelação;

- Deve-se considerar a possibilidade de utilização de métodos estratificados para garantir a presença de classes minoritárias.

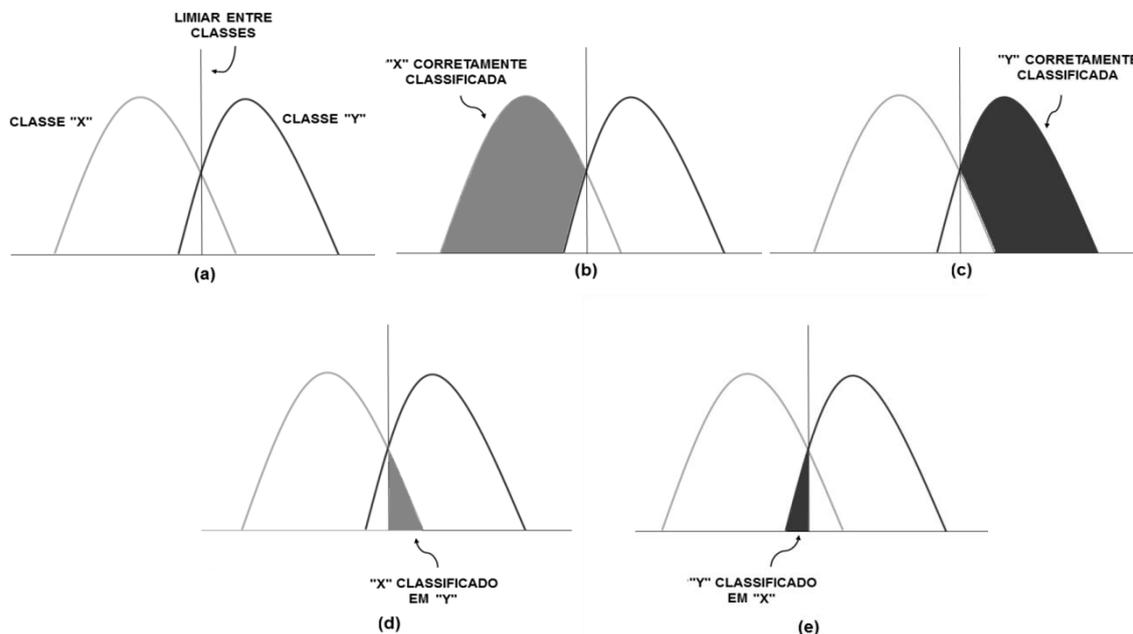


Figura 15. Gráfico explicativo da classificação de elementos em “X” e “Y”. (a) Distribuição binomial dos elementos categorizados em “X” e “Y”, com limiar entre as classes pré-estabelecido. Definido o limiar, são identificados os elementos corretamente classificados em “X” (b) e “Y” (c), bem como os elementos erroneamente classificados, sejam eles “X” classificados em “Y” (d) e “Y” classificados em “X” (e).

Tabela 1. Exemplo hipotético de matriz de confusão

		“DADOS DE REFERÊNCIA”				
		CLASSE A	CLASSE B	CLASSE C	CLASSE D	TOTAL LINHAS
UNIDADE CARTOGRÁFICA	CLASSE A	54	8	17	13	92
	CLASSE B	14	65	21	12	112
	CLASSE C	9	4	32	2	47
	CLASSE D	8	15	18	76	117
	TOTAL COLUNAS	85	92	88	103	736

Conforme Congalton (1991):

“Uma matriz de erros é um modo efetivo para representação da acurácia global e a acurácia de cada categoria, sendo claramente descritas juntamente dos erros de inclusão (ou erro de comissão) e erros de exclusão

(erros de omissão), presentes na classificação” (CONGALTON, 1991, p. 36, tradução nossa).

Dessa forma, a matriz de erros apresenta de maneira organizada os erros de omissão e comissão (ARIZA-LÓPEZ, 2002; NÓBREGA, 2007). Os erros de omissão, também denominados erros de exclusão são aqueles em que um elemento deveria estar em “A”, mas não está. Os erros de comissão ou exagero, também denominados erros de inclusão, são aqueles em que um elemento é classificado erroneamente, sendo considerado de uma classe “A”, quando deveria estar em “B”.

Para que a matriz de erros amostral represente adequadamente a população dos dados, é importante que seja definida a amostragem de maneira adequada. Nesse âmbito, se destacam as seguintes amostragens (figura 16): aleatória simples, aleatória estratificada, sistemática, sistemática não alinhada, por conglomerados, por perfis aleatórios retos, por pontos equidistantes sobre o perfil, por vias de comunicação e hierárquico.

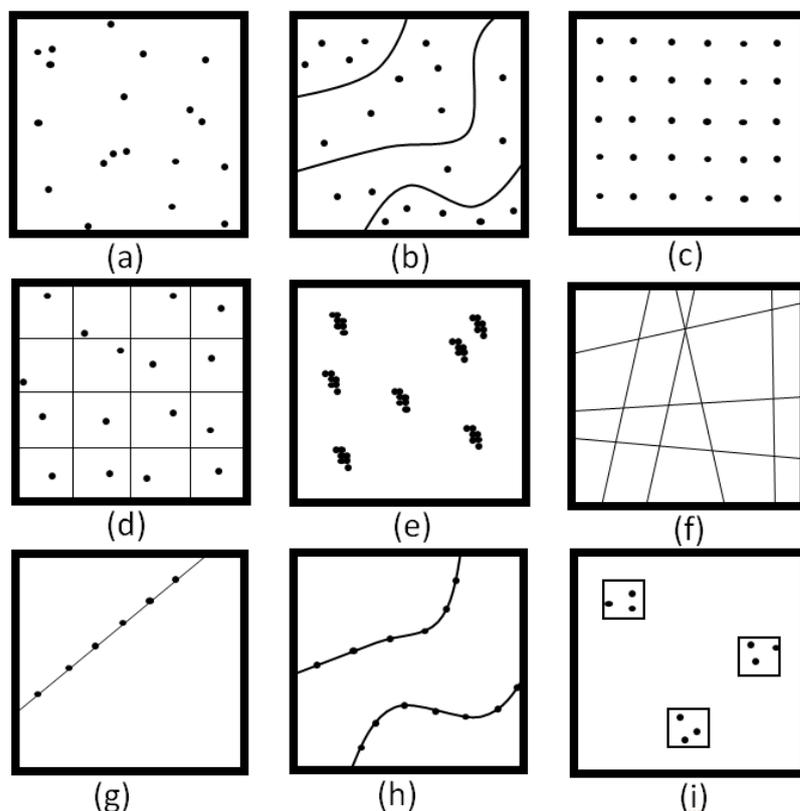


Figura 16. Tipos de amostragens: (a) aleatória simples, (b) aleatória estratificada, (c) sistemático, (d) sistemático não alinhado, (e) conglomerados, (f) perfis aleatórios retos, (g) pontos equidistantes, (h) por vias de comunicação e (i) hierárquico. Adaptado de Ariza-López, 2002.

Destas, destaca-se especialmente a que será utilizada neste estudo, a amostragem aleatória estratificada, que pode ser resumidamente definida como um subconjunto de indivíduos selecionados ao acaso a partir de estratos – no caso específico, as classes – obtidos de uma população – no caso, a imagem classificada.

Com relação ao tamanho da amostra, sejam elas células (para classificação *pixel-a-pixel*) ou polígonos (para classificação orientada a objetos), pode-se realizar um planejamento estatístico para que seja definido o número adequado. Assim, utiliza-se a equação 1 para o cálculo do tamanho da amostra (ARIZA-LÓPEZ, 2002):

$$n = \frac{\sigma^2 \cdot p \cdot q \cdot N}{e^2 (N-1) + \sigma^2 p \cdot q} \quad \text{Eq. 1}$$

Onde:

n = tamanho da amostra;

σ^2 = nível de confiança escolhido, expresso em número de desvios-padrão;

p = percentagem com a qual o fenômeno se verifica;

q = percentagem complementar (100-p);

N = tamanho da população;

e^2 = erro máximo permitido.

Assim que os estratos (ou classes) são definidos, é selecionada uma amostra simples de cada estrato. Pode-se, neste caso, optar por uma amostragem estratificada proporcional (mantendo a proporcionalidade do tamanho de cada estrato da população na amostra) ou amostragem estratificada uniforme, na qual são selecionados o mesmo número de elementos em cada estrato, independentemente do número de elementos de cada classe na população. Adota-se este último quando o objetivo é comparar diversos estratos. No caso de manutenção da proporcionalidade, deve-se inicialmente definir a proporção do estrato (h) em relação à população (N) (ARIZA-LÓPEZ, 2002), conforme equação 2:

$$h = \frac{N_h}{N} \quad \text{Eq. 2}$$

Onde:

h = proporção do estrato

N_h = tamanho do estrato na população

N = tamanho da população

A seguir, multiplica-se o tamanho total da amostra (n) pela proporção de cada estrato na população (equação 3).

$$n_h = n \cdot h \qquad \text{Eq. 3}$$

Onde:

n_h = tamanho da amostra do estrato

n = tamanho da amostra

h = proporção do estrato.

Dessa forma, é possível obter o tamanho da amostra em cada estrato, proporcional ao tamanho do estrato em relação à população.

Segundo Chagas et al. (2009, p. 322) “a matriz de confusão tem sido reconhecida como a mais importante técnica de estimativa da exatidão de produtos de dados de sensores remotos”. Neste mesmo trabalho, a matriz de confusão foi utilizada para a comparação da eficiência na classificação de imagens pelos métodos de RNA (redes neurais artificiais) e máxima verossimilhança. Rovedder (2007) empregou a matriz de confusão para o estudo de validação da classificação orientada a objetos em imagens de satélite *Ikonos*, em comparação com informações locais de referência. Gonçalves et al. (2008) aplicou a matriz de confusão para comparar imagem classificada por método não supervisionado de redes neurais auto organizáveis e métodos de agrupamentos hierárquicos como imagem de referência resultante de classificação supervisionada. Amaral et al. (2009) aplicou a técnica em um estudo comparativo de avaliação de diferentes métodos de classificação de imagens de satélite para o mapeamento de estágios de sucessão florestal. Ferreira (2009) realizou comparação de imagens classificadas por meio de matrizes de confusão para estudar o uso do solo e os padrões de vento em Belo Horizonte. No estudo, a verificação da significância das amostras foi realizada por meio do desempenho médio e a matriz de confusão de cada área escolhida como representativa das classes de cobertura do uso do solo. Fernandes et

al. (2012) empregou matriz de confusão para avaliar a acurácia da classificação orientada a objetos aplicada à caracterização da cobertura do solo no Araguaia. Esses são apenas alguns exemplos a respeito da utilização da técnica para validação de classificação de imagens, pois a literatura vinculada ao tema é bastante extensa. Indubitavelmente, a utilização da matriz de confusão se sustenta em experiências anteriores bem sucedidas.

4.4.2 Índices globais

Os índices globais derivados da matriz de confusão são parâmetros que avaliam de modo geral a qualidade da classificação em comparação com a “verdade do terreno”. O objetivo desses parâmetros é facilitar a compreensão dos resultados obtidos pela matriz, simplificando sua análise. São eles: porcentagem de acordo ou exatidão global P_a , coeficiente de acordo aleatório *a priori* Ca_{pr} , coeficiente de acordo aleatório *a posteriori* Ca_{ps} , coeficiente *Tau* de ajuste T e coeficiente *Kappa* de ajuste K . A tabela 2 apresenta as denotações necessárias para detalhamento dos cálculos dos coeficientes.

Tabela 2. Lista das siglas das variáveis relacionadas aos índices globais de qualidade temática

SIGLA	VARIÁVEL
N	Número de casos (em segmentos)
M	Número de classes
V	Número de classes “verdade terreno” ($V = M$)
C	Número de classes “unidades cartográficas” ($C = M$)
i	Filas, unidades de mapa
j	Colunas, verdade terreno
V_i	Classe verdade terreno
C_i	Classe unidade cartográfica
$x_{i,j}$	Número de casos em C_i, V_j
n_{i+}	Total de casos C_i
n_{+j}	Total de casos V_i
P_{ij}	Proporção em C_i, V_j ($= x_{ij}/N$)
P_{i+}	Proporção em C_i ($= n_{i+}/N$)
P_{+j}	Proporção em V_j ($= n_{+j}/N$)

A exatidão global P_a é a medida geral de concordância entre as duas classificações, ou seja, situação na qual ambos os classificadores identificaram um elemento como sendo pertencente a uma mesma classe. Pode ser obtida dividindo-se o somatório dos valores da diagonal principal pelo total de observações (ou tamanho da amostra), conforme a equação 4.

$$P_a = \frac{1}{N} \sum_{i=1}^M x_{i,j} = \sum_{i=1}^M P_{ij} \quad \text{Eq. 4}$$

O coeficiente de acordo aleatório a priori Ca_{pr} (equação 5) é baseado na probabilidade de ocorrência de uma classe anteriormente à classificação. Ou seja, inicialmente a probabilidade de uma classe ocorrer é igual a qualquer outra, logo:

$$Ca_{pr} = \frac{1}{M} \quad \text{Eq. 5}$$

O coeficiente *Tau* de ajuste T , baseado na probabilidade a priori de um elemento pertencer a um grupo, é uma medida do quanto um sistema de classificação escolhido pode ser melhor do que uma classificação aleatória. Pode ser calculado conforme a equação 6:

$$T = \frac{P_a - Ca_{pr}}{1 - Ca_{pr}} \quad \text{Eq. 6}$$

No entanto, na exatidão global, há uma porcentagem da probabilidade na qual os classificadores sejam concordantes em função do acaso. Para conhecer esta porcentagem, é necessário o cálculo do coeficiente aleatório a posteriori Ca_{ps} . Este coeficiente tem como base a distribuição marginal da matriz de erros.

Em um contexto de eventos independentes, onde pode não haver concordância entre a classificação dos dois classificadores, a probabilidade de ambos classificarem simultaneamente um mesmo objeto em uma mesma classe é o produto das probabilidades da ocorrência dessa classe (para a unidade cartográfica e a verdade terreno), conforme equação 7.

$$Ca_{ps} = \sum_{i=1}^M P_{i+} P_{+j} = \frac{1}{N^2} \sum_{i=j}^M n_{i+} n_{-i} \quad \text{Eq. 7}$$

Ou seja, se não há concordância entre a avaliação dos dois observadores, a probabilidade de ambos classificarem simultaneamente um objeto em uma mesma classe é dada pelo produto das probabilidades de ocorrência daquela classe.

O coeficiente *Kappa* de ajuste, por sua vez, é calculado para medir a concordância entre dois observadores ou dois instrumentos que classificam uma série de unidades observacionais conforme as classes de uma variável. Mas no cálculo deste coeficiente (equação 8) é necessário a subtração do percentual que é observado em função do acaso (Ca_{ps}).

$$K = \frac{P_a - C\alpha_{ps}}{1 - C\alpha_{ps}} \quad \text{Eq. 8}$$

Segundo Ariza-López (2002), o índice ou coeficiente *Kappa* consiste em um método estatístico de aplicação no controle da qualidade temática das classificações, fotointerpretações entre outros baseados no uso de índices de tipo global derivados da matriz de confusão. A estatística proposta pelo índice *Kappa* mede a concordância usada em escalas nominais, capazes de indicar a ideia do quanto as observações se afastam do resultado esperado, frutos do acaso, indicando assim quão verdadeiras as interpretações são (FONSECA et al., 2007).

Os valores para o índice *Kappa* (K) podem variar de -1 a 1. Quanto mais alto o valor de *Kappa*, maior será a concordância. Deste modo, temos que (MINITAB, 2016):

- $K = 1$, então a concordância é perfeita;
- $K = 0$, então a concordância é aquela que seria esperada ao acaso
- $K < 0$, então a concordância é mais fraca do que seria esperado ao acaso (resultado muito raro).

Em classificação de imagens, se fosse possível obter $K = 1$, seria o mesmo que afirmar que a superfície foi classificada corretamente em toda sua totalidade. Se $K = 0$, não haveria relação entre as classificações, isto é, entre a imagem classificada e a realidade acima da concordância de acasos. Se $K = -1$, então a classificação apresentaria resultado completamente oposto à realidade observada.

Vale ressaltar que:

“Apesar de largamente utilizado para o estudo de confiabilidade, este método estatístico apresenta limitações na medida em que não fornece informações a respeito da estrutura de concordância e discordância, muitas vezes, não considerando aspectos importantes presentes nos dados. Dessa forma, não deve ser utilizado indiscriminadamente como uma única medida de concordância e outras abordagens devem ser incorporadas com o objetivo de complementar a análise” (PERROCA; GAIDZINSKI, 2003, p. 74).

Por esta razão, os índices por classe devem ser analisados para permitir uma análise mais criteriosa com relação à distribuição dos erros da matriz de confusão.

4.4.3 Índices por classe

Os índices por classe são índices que expressam o comportamento estatístico de cada classe e estão diretamente relacionados aos erros de omissão e exagero, já detalhados no item 4.4.1. São eles a exatidão do usuário, risco do produtor, exatidão do produtor e risco do usuário.

A exatidão do usuário (*EU*) corresponde à porcentagem de elementos de uma classe que estão bem classificados. Para obter tal índice, divide-se o valor de cada célula da diagonal principal da matriz pelo total de elementos da linha correspondente à classe analisada (equação 9).

$$EU(i) = \frac{x_{ij}}{n_{i+}} \quad \text{Eq. 9}$$

O risco do produtor (*RP*), por sua vez, é o complemento da exatidão do usuário, conforme equação 10.

$$RP(i) = 1 - EU(i) \quad \text{Eq. 10}$$

A exatidão do produtor (*EP*) corresponde à porcentagem de elementos da amostra de verificação classificados de forma correta, considerando a unidade cartográfica correspondente a ela (ARIZA-LÓPEZ; BALBOA; PULIDO, 2004). Pode ser obtido dividindo-se o valor de cada célula da diagonal principal da matriz pelo total de elementos da coluna correspondente à classe analisada (equação 11):

$$EP(j) = \frac{x_{ij}}{n_{+j}} \quad \text{Eq. 11}$$

O risco do usuário (*RU*), de forma semelhante ao risco do produtor, é o complemento da exatidão do produtor (equação 12):

$$RU(j) = 1 - EP(j) \quad \text{Eq. 12}$$

A utilização dos índices por classe em conjunto com os índices globais objetiva facilitar a interpretação e análise da matriz de confusão sem negligenciar a importância de observar uma classe ou outra separadamente. Tais índices serão utilizados para avaliar a qualidade da classificação temática desse estudo.

5 ÁREA DE ESTUDO

Para o desenvolvimento dessa pesquisa, foi selecionada uma área da região Norte do município de Belo Horizonte, no Bairro Planalto (figura 17). A escolha da região se justifica em função da heterogeneidade de usos observada, que, além de edificações e prédios residenciais, conta com um centro comercial e de serviços, bem como uma área verde, a Mata do Planalto. Esta área, de propriedade privada, encontra-se anexada ao Parque Municipal do Bairro Planalto, com aproximadamente 300.000 m² que, além de área verde, possui ainda quadras de esportes e campo de futebol.

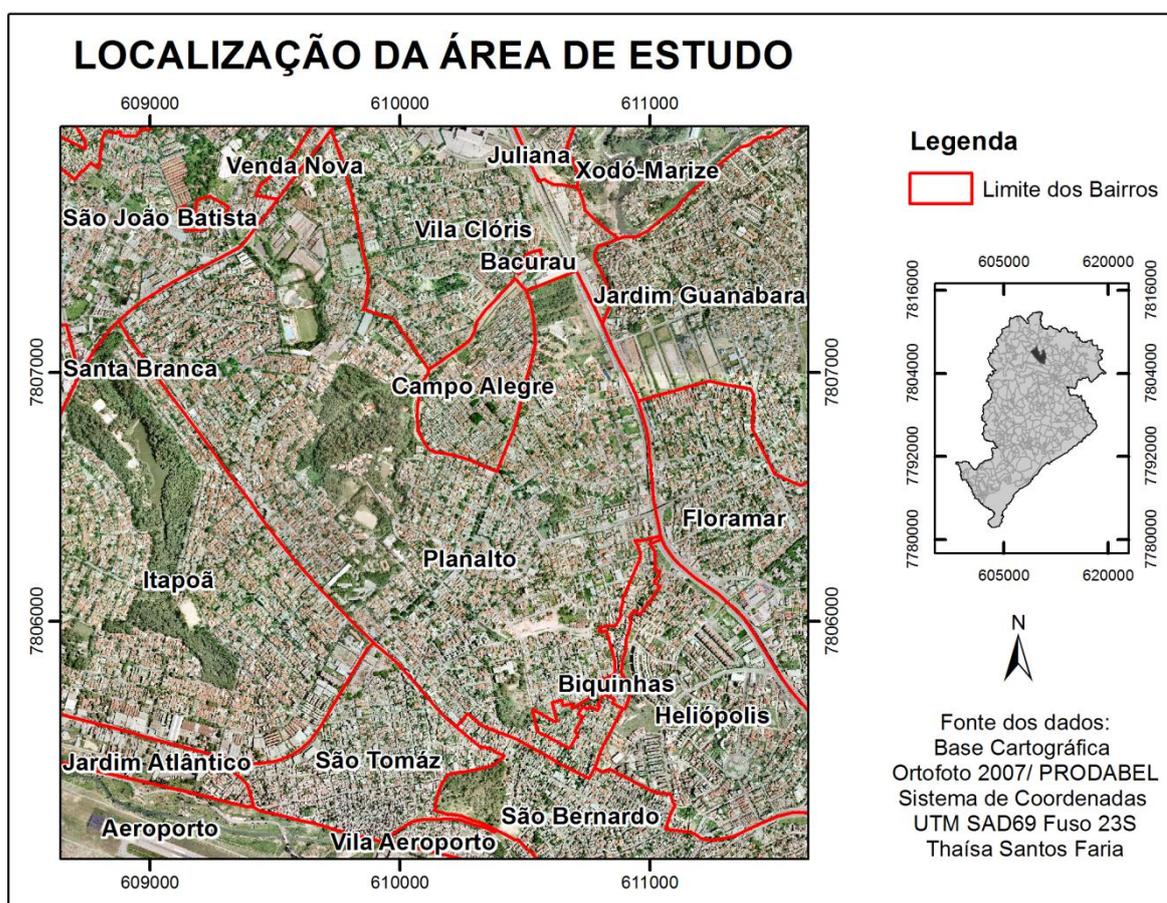


Figura 17. Mapa de localização da área de estudo (Bairro Planalto)

O crescimento experimentado pela industrialização da cidade de Belo Horizonte na década de 1950 promoveu o crescimento da região Norte do município, que na época já era alvo de investimento para a expansão da cidade. A região do entorno da Lagoa da Pampulha, que

desde sua criação foi ocupada por grupos da sociedade de maior poder aquisitivo, polarizou a região. Os moradores de baixa renda ou imigrantes do interior do estado passaram então a ocupar as regiões do entorno da Pampulha, em que o preço das propriedades não era tão alto, mas que já dispunham de uma infraestrutura de comércio e serviços. Nesse contexto, bairros como o Planalto⁶, e Vila Clóris experimentaram um crescimento razoavelmente planejado, com o surgimento de edificações de bom padrão construtivo, sem, no entanto, perder as características de bairro residencial, cuja localização está próxima à Lagoa da Pampulha e a quatorze quilômetros do centro de Belo Horizonte (RIBEIRO, 2011).

Em meados de 2010, com a transferência do Centro Administrativo do estado mineiro para o norte do município de Belo Horizonte, esta região da cidade vem experimentando uma considerável valorização. O investimento em infraestrutura do sistema viário, com obras nas Avenidas Pedro II, Cristiano Machado e Antônio Carlos, a proximidade a Shoppings, ao Mineirão (campo de futebol) e a capacidade de suprir as necessidades da população local em termos de disponibilidade de comércio e serviços, tem propiciado o surgimento de edificações residenciais de alto padrão construtivo. Um exemplo disso é a existência de um projeto para a construção de 16 prédios de 15 andares na Mata do Planalto. No entanto, a população local é contrária à essa proposta de ocupação, em função da necessidade de preservação ambiental de uma área que possui fauna e flora diversificada.

⁶ Em 1952, quarteirões da Vila Jardim Pampulha passaram a ser denominados como Bairro Planalto.

6 MATERIAIS E MÉTODOS

A metodologia para o desenvolvimento dessa pesquisa pode ser observada na figura 18 e será detalhada nos tópicos a seguir.

6.1 Recursos disponíveis

O procedimento exige utilização de recurso computacional com robustez suficiente para processar os dados. Para tanto, foi utilizado computador desktop com a seguinte configuração: microprocessador mínimo de 4 núcleos e frequência de 3.3 GHz, 16GB de memória RAM, 1 HD 1TB, 1 SSD 256GB, sistema operacional Windows.

Para cada uma das etapas foram utilizados diferentes *softwares*: para a preparação dos dados brutos, foram utilizados os *softwares* Qgis (*software* livre), ArcGIS e Envi. Para a etapa da segmentação e classificação foi utilizado o *software* eCognition. Para o refinamento e detalhamento das classes, foram utilizados os *softwares* ArcGIS e MapInfo.

Os *softwares* ArcGIS, Global Mapper e MapInfo foram disponibilizados pela Empresa de Informática e Informação do Município de Belo Horizonte (PRODABEL). ENVI foi disponibilizado para utilização pelo Instituto de Geociências da Universidade Federal de Minas Gerais (UFMG), e o eCognition pela Escola Politécnica da Universidade de São Paulo (USP).

Os dados utilizados na pesquisa (ortofoto, imagem infravermelho próximo, *laser*, base vetorial e classificação oficial) foram disponibilizados pela Empresa de Informática e Informação do Município de Belo Horizonte (PRODABEL). Os dados *raster* da Prefeitura de Belo Horizonte são organizados e disponibilizados com base em um mapeamento sistemático elaborado na forma de uma articulação com folhas na escala de 1:2.000. A nomenclatura dessas folhas é baseada na junção de uma numeração referente às linhas e colunas que compõem o mapeamento sistemático. Para que a metodologia apresentada nessa pesquisa seja replicada para as demais áreas do município, o recorte da área de estudo considerou o limite de uma folha da articulação 1:2.000 que abrange parte considerável do Bairro Planalto.

6.2 Etapas

As etapas detalhadas nas seções a seguir correspondem ao detalhamento na figura 18.

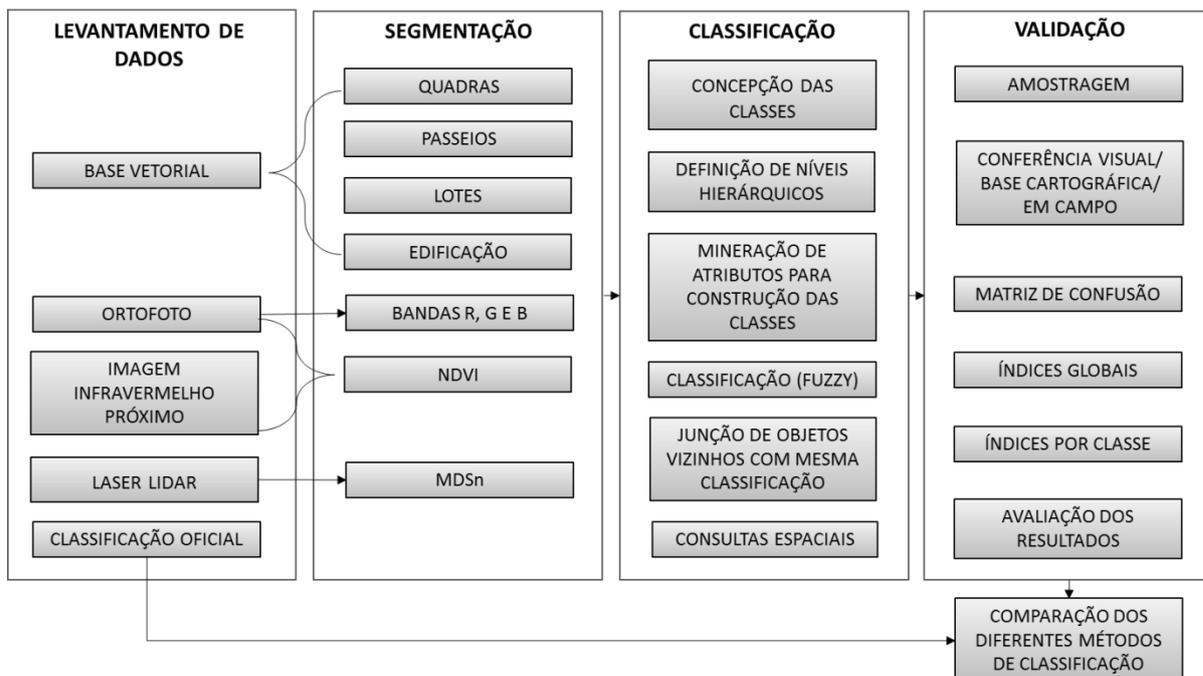


Figura 18. Fluxograma resumo da metodologia da pesquisa

6.3 Levantamento de dados

Foram coletados os seguintes dados referentes à área de estudo:

- Imagem do espectro infravermelho próximo;
- LIDAR;
- Base vetorial;
- Mapeamento temático da classificação oficial.

Os dados, cedidos pela PRODABEL/PBH, foram coletados no ano de 2015. A coleta dos dados constituiu etapa de um projeto para atualização da cartografia municipal. Os dados utilizados são provenientes de uma cobertura aerofotogramétrica digital, de varredura linear

(*pushbroom*) nas bandas R, G, B e NIR (infravermelho próximo), com resolução de 20 cm ou superior. A área total recoberta compreende o município de Belo Horizonte, cerca de 335 km². O processo de ortorretificação das imagens R, G e B foi realizado utilizando como base o modelo digital de terreno obtido pelo perfilamento a *laser scanner*. Embora as bandas R, G e B tenham sido entregues ortorretificadas, possibilitando o uso direto sem qualquer pré-processamento, a banda NIR disponível não foi ortorretificada, necessitando de um pré-processamento para ajuste do registro da imagem para permitir seu uso. As fotos disponibilizadas estão em coordenadas UTM, datum SIRGAS2000.

Por estarem ainda em fase de execução do projeto, parte dos produtos não foi completamente validada. Eventuais erros na metodologia proposta nesta pesquisa podem ser explicados pelo fato de os dados estarem ainda em fase de consolidação. Maiores detalhes e os pré-processamentos necessários são explicados nos próximos tópicos.

6.4 Banda infravermelho próximo

Embora as bandas R, G, B e NIR tenham sido obtidas em um mesmo levantamento aerofotogramétrico, apenas as três primeiras (RGB) foram ortorretificadas, não havendo necessidade de qualquer ajuste no registro das bandas para utilização. No entanto, a situação da banda NIR é diferente. Assim, foi necessário um registro desta banda para permitir sua utilização na etapa de classificação, detalhado a seguir.

6.4.1 Correção do registro da banda NIR

A correção do registro da imagem infravermelho foi executada no *software* Envi. Para isso, foi utilizada como referência a banda R ortorretificada. Por meio do emprego da ferramenta “Registro automático: imagem para imagem”, foram ajustados parâmetros de registro automático, na qual o *software* gera uma distribuição de pontos na imagem (figura 19) a ser corrigida e busca pares equivalentes na imagem de referência.

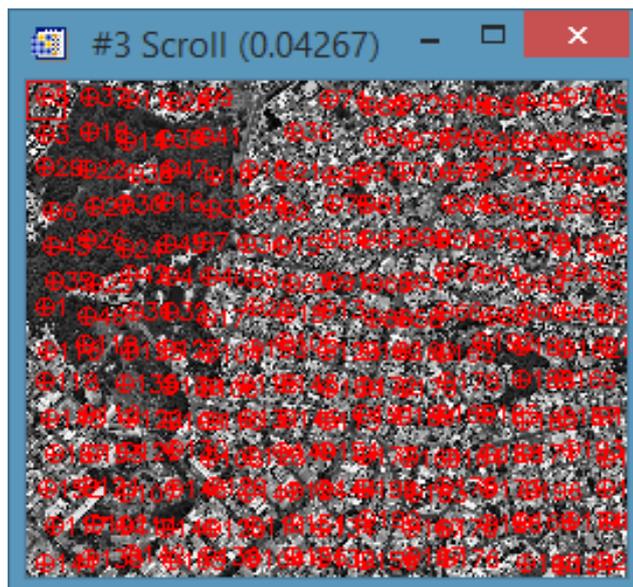


Figura 19. Distribuição dos pontos de controle utilizados para registro imagem-imagem no *software* Envi.

Após a criação destes pontos, por meio do menu “Ajustar imagem a partir dos pontos de controle”, selecionou-se qual a imagem a ser ajustada e definiu-se o parâmetro de ajuste. Neste caso, foi utilizado o método da triangulação e reamostragem pelo vizinho mais próximo. O resultado foi comparado visualmente à banda de referência para verificação dos ajustes.

6.5 LIDAR

O LIDAR disponível encontra-se em uma nuvem de pontos no formato *.las*. Como o objetivo dessa pesquisa incluiu a utilização da altura dos elementos acima do nível do solo para fins de identificação dos mesmos, foi necessário o processamento dos dados da nuvem de pontos para obtenção do modelo digital de superfície normalizado. O processamento foi realizado no *software* ArcGIS.

Os dados foram importados por meio da ferramenta “Novo conjunto de dados *.las*”. O conjunto de dados importado contém todas as informações da nuvem de pontos: coordenadas x, y, z, intensidade, número de retornos, classes, entre outros. Para filtrar apenas os pontos do terreno, utilizou-se a ferramenta “Fazer camada de conjunto de dados *.las*”. Dentre as opções de campos a serem filtrados, selecionou-se aquele que continha os pontos do terreno (modelo de terreno).

Ambas camadas foram convertidas para raster, no formato tiff (figura 20), utilizando como campo de valor a elevação. No tipo de interpolação, optou-se pelo método “*Binning*”, que converte dados de pontos em uma grade regular de polígonos, de modo que cada polígono representa uma agregação de pontos. Aos polígonos formados, ou células, foi atribuído o valor da média de z. Quanto ao tamanho da célula, com o objetivo de manter o padrão de resolução dos dados que posteriormente seriam trabalhados na classificação, utilizou-se o tamanho de 20cm.

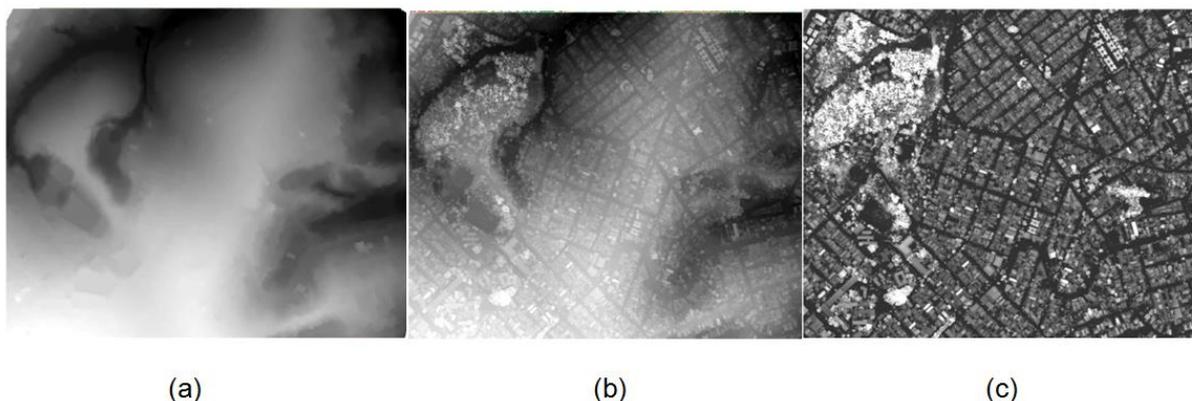


Figura 20. Etapas de processamento do LIDAR. Em (a) e (b) o modelo digital do terreno e de superfície, sucessivamente, interpolados. Em (c) o modelo digital de superfície normalizado, obtido por meio da subtração dos *rasters*.

Com os dois modelos convertidos para raster (MDT e MDS), por meio da ferramenta “Calculadora *raster*” foi possível realizar a operação aritmética de subtração das duas camadas, para obter o MDSn.

6.6 Base vetorial

A base cartográfica vetorial do município de Belo Horizonte foi utilizada como apoio em todas as etapas da metodologia de trabalho: segmentação, classificação e validação dos dados.

Foram utilizadas as camadas de quadra, lote e edificação. Por meio de operação de subtração (ferramenta “*erase*” do ArcGIS) da quadra e do lote, foi possível obter a camada vetorial em forma de polígono das calçadas.

Na etapa de segmentação, as bases vetoriais corresponderam a entradas (*inputs*) na forma de “camadas temáticas”, muito úteis na delimitação dos objetos, que são construídos respeitando os limites dos vetores.

Na classificação, as bases vetoriais foram utilizadas como parâmetros para atribuição de classificação de segmentos internos aos polígonos.

Na etapa de validação, a base cartográfica foi amplamente utilizada para confirmação da classe dos objetos. Assim, dados provenientes de restituição aerofotogramétrica e dados provenientes do cadastro tributário (que identifica se um imóvel é casa, prédio, lote vago, entre outros) foram utilizados como “dados de referência”.

6.7 Classificação oficial do uso e cobertura do solo

A classificação disponibilizada pela PRODABEL consiste em um mapeamento temático elaborado para a detecção de mudanças na cobertura e uso do solo.

O mapeamento foi realizado na escala de 1:5.000 para duas épocas distintas e a metodologia utilizada foi a fotointerpretação do conjunto de ortofotos de 2007 e imagens de satélite de 2012. A classificação oficial foi elaborada em multinível com três níveis distintos de abstração.

O nível I (figura 21) apresenta o maior grau de generalização da informação em tipos de cobertura da terra; subdividido em cinco classes:

- 1 – Superfícies Artificiais;
- 2 – Áreas de cultura;
- 3 – Espaços Abertos com pouca ou nenhuma cobertura vegetal;
- 4 – Superfícies Naturais;
- 5 – Corpos d'água

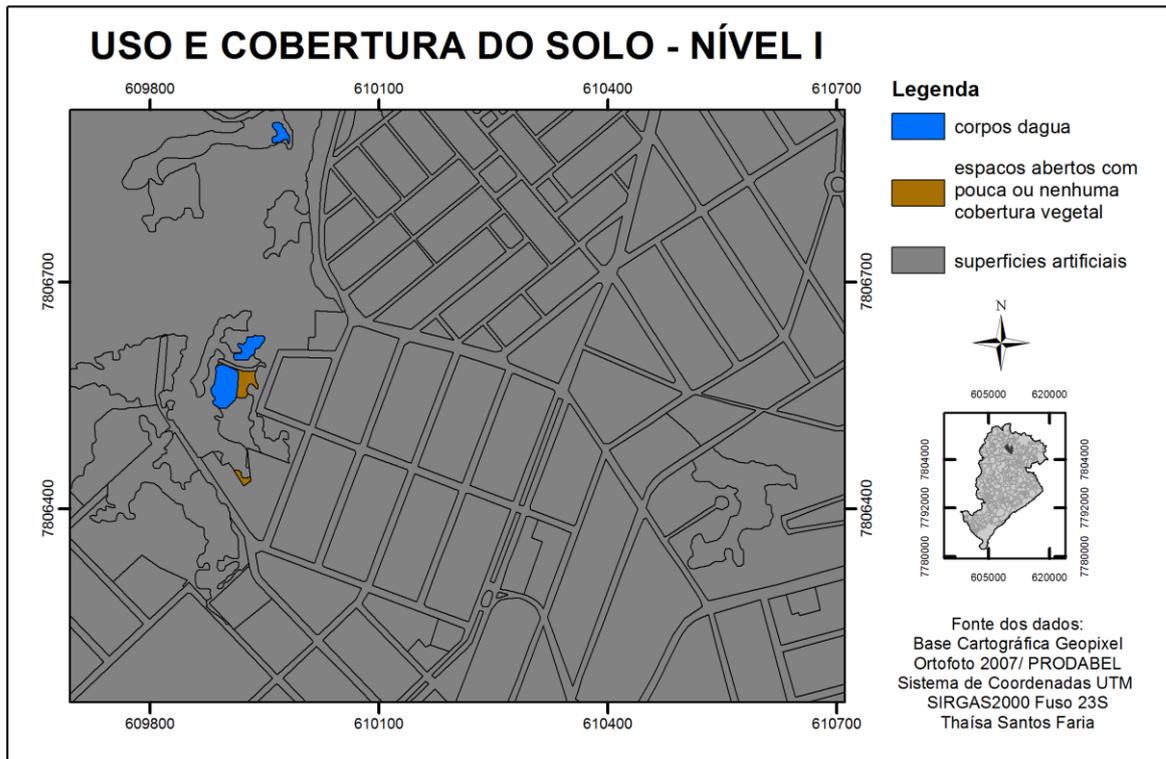


Figura 21. Mapa de cobertura e uso do solo da região do Bairro Planalto (nível I),
Belo Horizonte, 2007

O nível II (figura 22) apresenta detalhamento da atividade a que se destina o solo ou função de cada classe de cobertura da terra, identificadas no nível 1, subdividido em onze classes:

- 1 – Área edificada;
- 2 – Loteamento;
- 3 – Espaço verde urbano;
- 4 – Grande equipamento;
- 5 – Extração mineral;
- 6 – Cultura;
- 7 – Solo exposto / outros;
- 8 – Afloramento rochoso;
- 9 – Mata;
- 10 – Campo natural;
- 11 – Curso d'água, lagos, lagoas, represas.

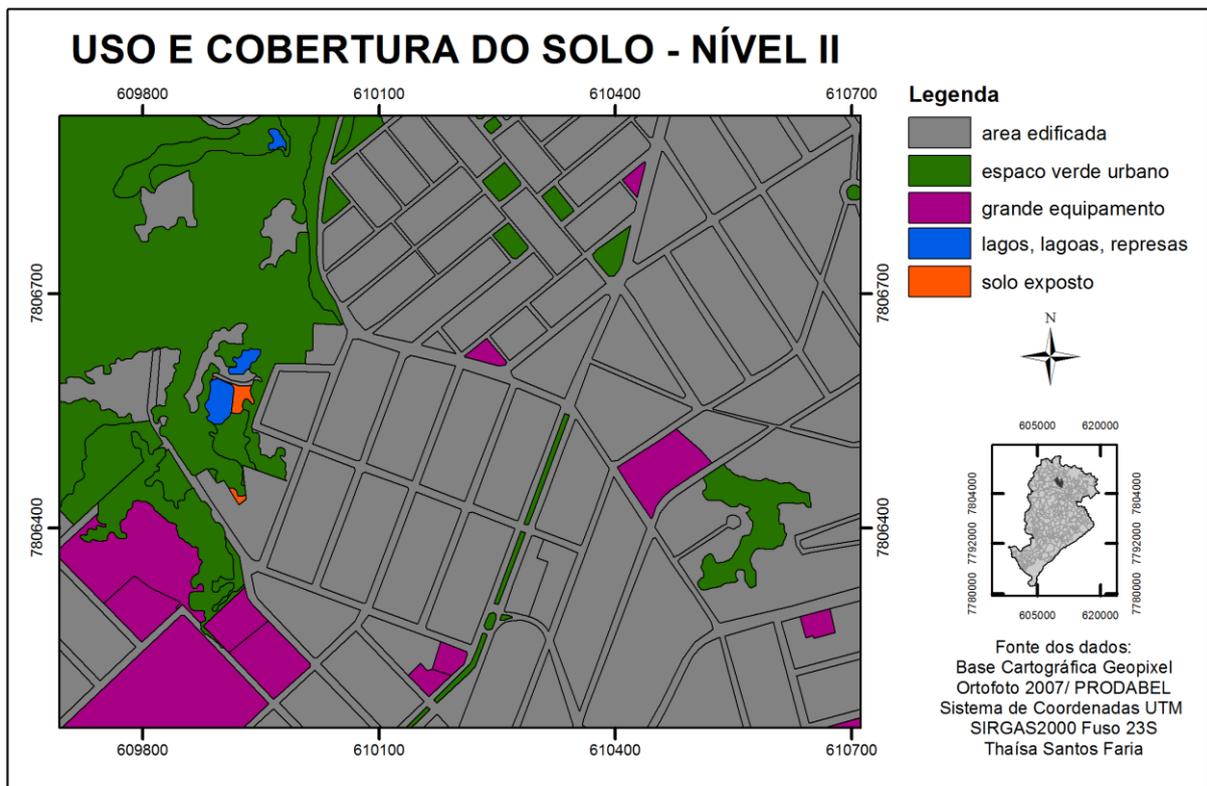


Figura 22. Mapa de cobertura e uso do solo da região do Bairro Planalto (nível II), Belo Horizonte, 2007

O nível III (figura 23) apresenta uma subdivisão e detalhamento das classes de uso da terra apontadas no nível 2, em classes de atributos. Como este tipo de informação é de difícil detecção por meio de imagens de sensores orbitais, o nível 3 foi constituído a partir de consultas e informações adicionais e agregação de dados obtidos em fontes de naturezas diversas (inventários, documentos, bases cartográficas, etc). Assim, os elementos em terceiro nível de classificação podem ser categorizados conforme segue:

1 - Para áreas edificadas:

- Quanto ao padrão as edificações: verticais ou horizontais
- Quanto à densidade de ocupação: baixa, média, alta ou muito alta
- Quanto ao estágio de ocupação: consolidada, em consolidação, rarefeita.
- Quanto ao ordenamento urbano: muito baixo, baixo, médio, alto, muito alto.

2 - Para loteamentos:

- Quanto ao ordenamento urbano: muito baixo, baixo, médio, alto, muito alto

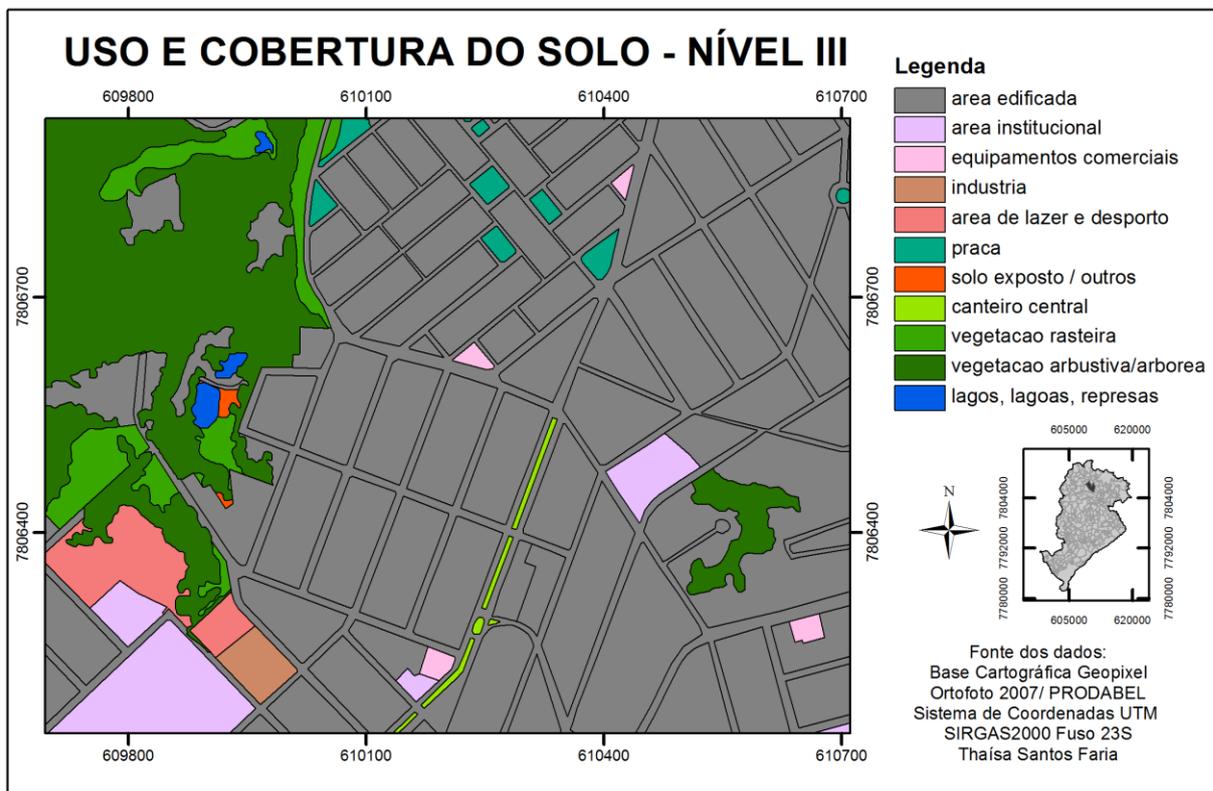


Figura 23. Mapa de cobertura e uso do solo da região do Bairro Planalto (nível III), Belo Horizonte, 2007.

3 - Para os espaços verdes urbanos:

- Categorizados como: canteiro central de vias públicas, praças, parques, faixa de servidão, vegetação rasteira, vegetação arbustiva, pastagem.

4 - Para os grandes equipamentos:

- Categorizados como: indústria, ETE, ETA, aterro sanitário, unidade de transporte, cemitério, área institucional, área de lazer e esporte, shopping

5 - Para extração mineral: categorizados como mineração

6 - Para cultura:

- Categorizadas como: áreas cultivadas, solo exposto/outros, solo exposto para construção civil, solo exposto por erosão

7 – Para solo exposto/outros:

- Categorizados como: solo exposto/outros, solo exposto para construção civil, solo exposto por erosão

8 - Para afloramentos rochosos: categorizados novamente como afloramentos rochosos

9 - Para matas:

- Categorizadas como: matas ou reflorestamento.

10 - Para campo natural: categorizados novamente como campo natural

11 - Para curso d'água, lagos, lagoas e represas, a classificação em terceiro nível repete a mesma categoria da classificação em segundo nível.

Quanto à unidade mínima de área mapeada, foi considerada a medida de 25 m² para classes de uso da terra das categorias de superfícies artificiais e 50 m² para as demais classes.

No que tange ao escopo dessa pesquisa, não é objetivo elaborar dois mapeamentos em épocas distintas para detecção de mudanças, mas sim propor uma metodologia alternativa à classificação de uso e cobertura do solo oficial. Dessa forma, para evitar distorções do lapso temporal em função das diferentes datas de obtenção dos dados, utilizou-se o mapeamento temático de 2012 (realizado por fotointerpretação de imagens de satélite) para comparação com os produtos resultantes do desenvolvimento dessa pesquisa.

Os passos descritos nos tópicos a seguir se consistem no procedimento de classificação propriamente dito. Com os dados preparados, iniciou-se a fase de entrada dos dados, a definição dos parâmetros para segmentação, a construção da árvore hierárquica para classificação dos segmentos, a definição de atributos descritores das classes e a classificação.

6.8 Segmentação

O *software* eCognition permitiu a criação de um projeto, que consistiu em uma área de trabalho na qual podem ser manipulados os dados, construídas árvores de processos e classificação. O primeiro passo correspondeu à entrada dos dados, os quais foram inputs para o processo, a saber:

- Imagens: bandas NIR, R, G, B e o MDSn. Todos os dados em Imagens: formato tiff, com resolução espacial de 20cm.

- Camadas temáticas: base vetorial de edificação, quadras, lotes e calçadas.

Após a inserção dos inputs no *software* eCognition, foi possível iniciar o processo de segmentação.

Uma vez que o objetivo é a extração do máximo de informações das diferentes bandas das imagens, optou-se por utilizar o algoritmo de “segmentação multirresolução”. Este algoritmo agrupa áreas de pixels com valores semelhantes em um mesmo objeto, de forma que, quanto maior a homogeneidade de uma área, maior o objeto. De forma distinta, quanto maior a heterogeneidade de uma área em termos de valores de pixels, menores os objetos formados (Definiens, 2007).

Outros elementos foram ajustados, tais como: o domínio do objeto da imagem, o peso das camadas da imagem, o uso de camadas temáticas, o parâmetro de escala e o critério de homogeneidade (forma e compacidade).

Quanto ao domínio do objeto da imagem, o operador define em qual nível a operação será executada: se no nível do pixel ou de algum objeto anteriormente segmentado (em processo de re-segmentação). Partindo da imagem bruta, optou-se por segmentar ao nível do pixel.

Os pesos das camadas da imagem podem ser definidos conforme a ponderação que se faz mediante a importância daquela banda para a delimitação do segmento. Assim, quanto maior o peso atribuído a uma banda, mais informações dela serão utilizadas para a segmentação. Dessa forma, é importante analisar cada uma das bandas utilizadas e atribuir maior peso para aquelas que permitem a maior separabilidade dos objetos conforme seu comportamento espectral. Assim, para o desenvolvimento desta pesquisa, os seguintes pesos foram atribuídos:

- Banda B e G: peso 1
- Banda R: peso 2
- Banda NIR e LIDAR: peso 3

Os maiores pesos atribuídos à banda NIR e ao LIDAR se devem ao fato de a boa separabilidade dos alvos, em especial a vegetação na primeira, e a separabilidade dos elementos em função da variação da altura, no segundo (figura 24).

O uso de camadas temáticas (base vetorial), conforme descrito no tópico 6.6, contribuiu para delimitar o crescimento dos segmentos. Sabe-se que nem sempre há bases disponíveis, mas em caso da existência das mesmas, o seu uso facilita a segmentação, pois esta poderá ser executada respeitando determinados limites territoriais pré-estabelecidos. Dentre as bases cartográficas vetoriais disponíveis, optou-se por utilizar quadras, calçadas, lotes e edificações, permitindo assim um maior refinamento dos resultados.



Figura 24. Imagens das bandas NIR (a), R (b), G (c) e B (d). A nitidez das bandas NIR e R é visivelmente superior às bandas G e B, motivo pelo qual o peso atribuído a estas bandas foi maior.

Quanto ao parâmetro de escala, o objetivo foi definir um limiar para a obtenção de uma segmentação da imagem que mais se aproximasse da realidade, de modo que fizessem sentido os objetos extraídos. Conforme detalhado no item 4.2.1, diversos valores do parâmetro de escala devem ser testados para que o operador possa definir qual o tamanho adequado. Maiores valores para este parâmetro resultam em objetos de imagem maiores, enquanto menores valores resultam em objetos de imagem menores. Vários testes (figura 25) foram executados, em busca de definir qual o valor adequado para o parâmetro de escala, obtendo-se o valor 50.

	FORMA: 0.1	FORMA: 0.5	FORMA: 0.9
ESCALA: 30			
ESCALA: 50			

Figura 25. Exemplos de testes realizados na segmentação. Neste exemplo, foram alterados os parâmetros de escala (30 e 50) e de forma (0.1, 0.5 e 0.9), no objetivo de alcançar uma segmentação que mais representasse os objetos da cena. Na imagem é possível observar que utilizando a escala com valor 30, os objetos ficam muito fragmentados. A escala com valor 50, por sua vez, agrega melhor pixels que pertencem a um mesmo objeto (como um telhado, por exemplo). No parâmetro forma, observa-se que ao atribuir o valor 0.9, os objetos ficam bem definidos, no entanto perde-se informação em função da agregação de objetos cujo comportamento espectral é diferente.

Quanto aos critérios de homogeneidade, para a área em estudo, após diversos testes, optou-se por utilizar o critério de forma 0,6 e compacidade nula. Os resultados da segmentação podem ser observados na figura 26.



Figura 26. Cena após a segmentação. Parâmetro de escala e forma, definidos nos valores de 50 e 0.6, respectivamente.

6.9 O modelo conceitual

A proposta desta classificação foi a apresentação do resultado em diversos subprodutos, sendo que cada um deles ressalta uma determinada característica da realidade mapeada. Os segmentos são os mesmos em cada mapa, no entanto o conjunto de técnicas empregadas para obtenção das classes é diferente.

Na ótica da lógica *fuzzy*, tem-se que a variável linguística do método é a classe de uso e/ou ocupação do solo, enquanto os valores assumidos para a variável linguística são as classes propriamente ditas. Os descritores das classes compreendem, portanto, as funções de pertinência.

Por se tratar de classificação em ortofoto, restrita à região visível do espectro eletromagnético, o modelo conceitual (figura 27) inicialmente separou os objetos conforme a cor que estes aparentam. Analisando visualmente a imagem, um conjunto de classes foi definido. Assim, como primeiro produto da classificação, foram consideradas as seguintes classes de ocupação do solo: vegetação, concreto, telhados de concreto/metálico, telhados

de cerâmica, telhados brancos, piscinas, água, sombras, solo exposto, pavimentação e segmentos não classificados.

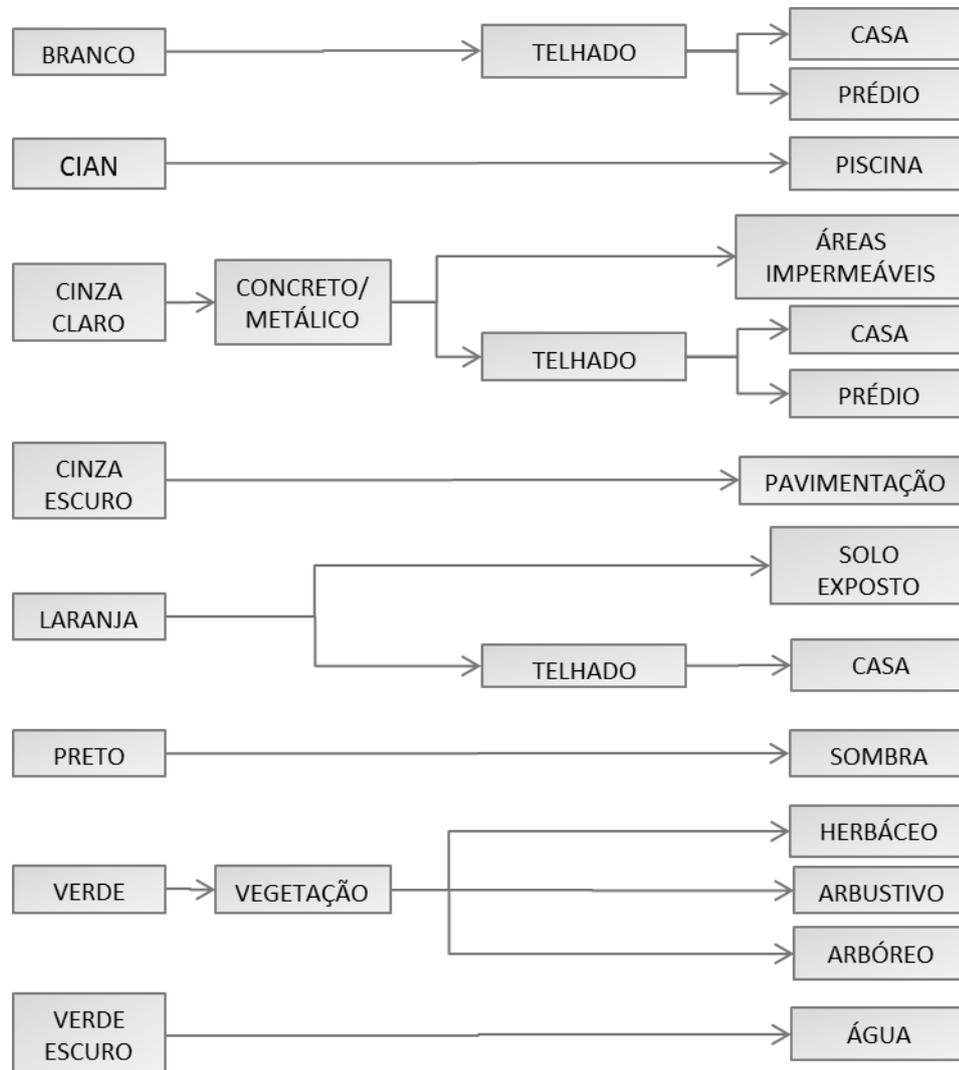


Figura 27. Modelo conceitual de classificação para implementação no eCognition.

Após a segmentação, foi possível analisar uma tabela (gerada pelo próprio *software* eCognition) com diversos atributos para cada segmento. Com base na análise exploratória desta tabela, foi possível identificar um conjunto de atributos que constituíram as funções de pertinência para cada classe, listados abaixo:

- Média das bandas R, G, B e NIR (uma vez que os pixels não são classificados isoladamente, o *software* calcula a média da banda para cada objeto);
- Média do LIDAR (altura dos objetos segmentados);
- Média da área dos segmentos;
- Relação de borda entre os segmentos em determinadas classes;

- Relação entre largura x comprimento dos segmentos.

Algumas operações entre bandas foram testadas e apresentaram bons resultados na classificação, sendo incluídas como funções de pertinência:

- NDVI (Índice Normalizado de Vegetação: $\text{média R} - \text{média NIR} / \text{média R} + \text{média NIR}$)

- Média B / Média R

- Média B + Média G / Média R + Média NIR.

As funções de pertinência por classe podem ser observadas no Anexo I.

Algumas das classes listadas anteriormente eram passíveis de maior detalhamento em função do emprego do LIDAR. Por esta razão, a vegetação foi subdividida em porte arbóreo, arbustivo e herbáceo e os telhados foram subdivididos quanto ao número de pavimentos. Os demais objetos das outras classes encontraram-se no nível do solo. Este detalhamento constitui o mapeamento quanto à altura dos objetos.

Após o processo de classificação no eCognition, os segmentos foram exportados para uma camada vetorial no formato *shapefile* e analisados em conjunto com as mesmas camadas vetoriais utilizadas no processo de segmentação. O objetivo desta etapa foi refinar os resultados para a obtenção do uso do solo. Tendo em vista o objetivo desta pesquisa, a classificação buscou caracterizar os segmentos quanto à propriedade (de uso público ou privado). Assim, os segmentos foram representados não mais somente quanto ao tipo de cobertura, mas também quanto ao uso dos mesmos, como: áreas permeáveis e impermeáveis internas aos lotes, áreas verdes, lotes vagos e calçadas permeáveis e impermeáveis. Além destas, foram mantidas, neste produto final, as classes de casas (com telhados brancos, telhados de concreto/metálico e telhados de cerâmica) prédios (com cobertura branca ou de concreto/metálica), piscinas, lagoa, sombras, vias e aqueles objetos que se mantiveram sem classificação.

O procedimento metodológico de cada etapa está descrito no tópico a seguir.

6.10 Classificação

A análise exploratória dos segmentos, abordada no tópico anterior, constituiu procedimento fundamental para a classificação. Esta fase teve como objetivo identificar padrões de comportamento nos atributos dos segmentos, para permitir a classificação dos mesmos.

Dentre os atributos, os que mais se destacaram foram utilizados para a definição de limiares na classificação.

Definido os atributos que caracterizam as classes, foram inseridas as funções *fuzzy* de pertinência (anexo I) para cada atributo selecionado para cada classe. Na figura 28 é possível observar o grau de pertinência de dois segmentos em duas classes. O resultado do processo pode ser observado na figura 29.

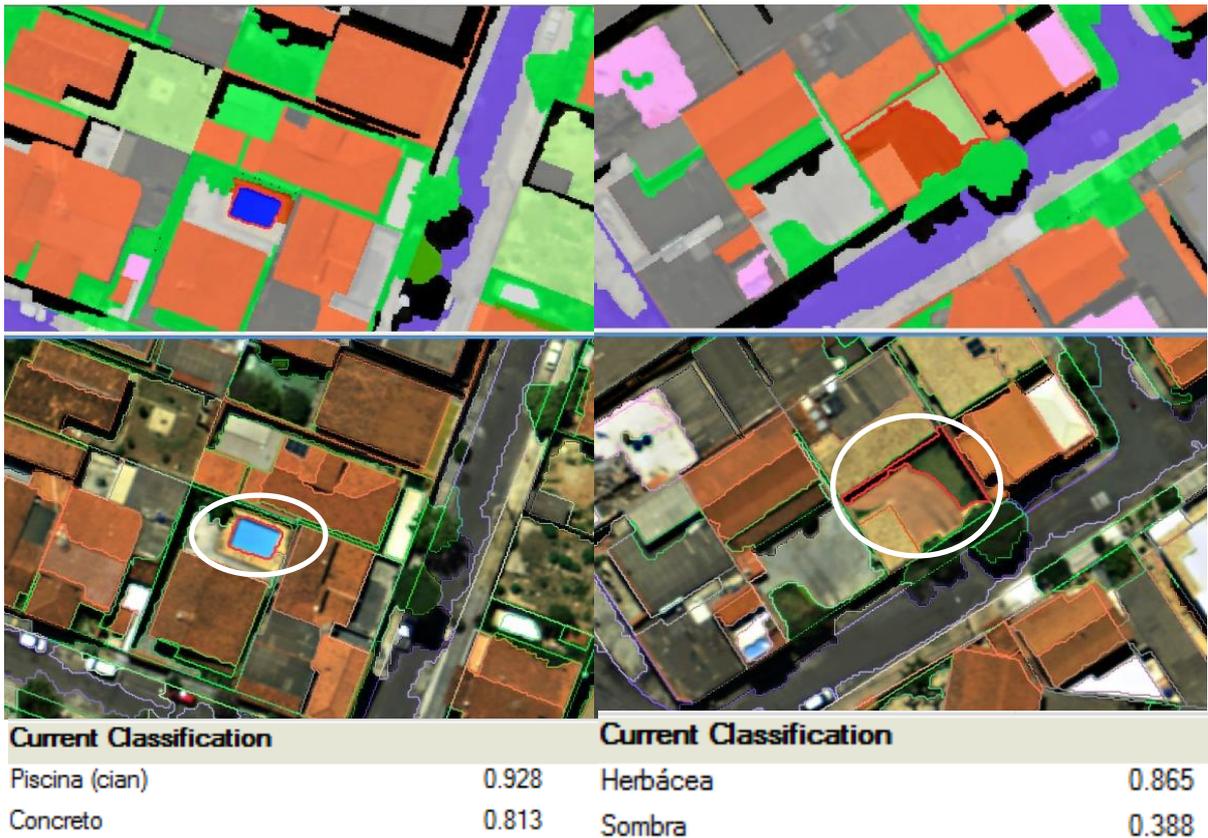


Figura 28. Grau de pertinência de dois segmentos em duas classes diferentes, onde os objetos foram atribuídos às classes Piscina e Herbácea, de acordo com o valor encontrado para o grau de pertinência.



Figura 29. Mapa de classificação resultante do processo no *software* eCognition

A utilização do LIDAR foi determinante para a classificação. Por meio da média das alturas obtidas pelo MDSn é que foi possível separar segmentos classificados como vegetação de acordo com diferentes portes (herbáceo, arbustivo e arbóreo), diferenciar telhados de cerâmica e solo exposto, bem como superfícies impermeabilizadas de telhados de concreto/metálico (figura 30 e 31).

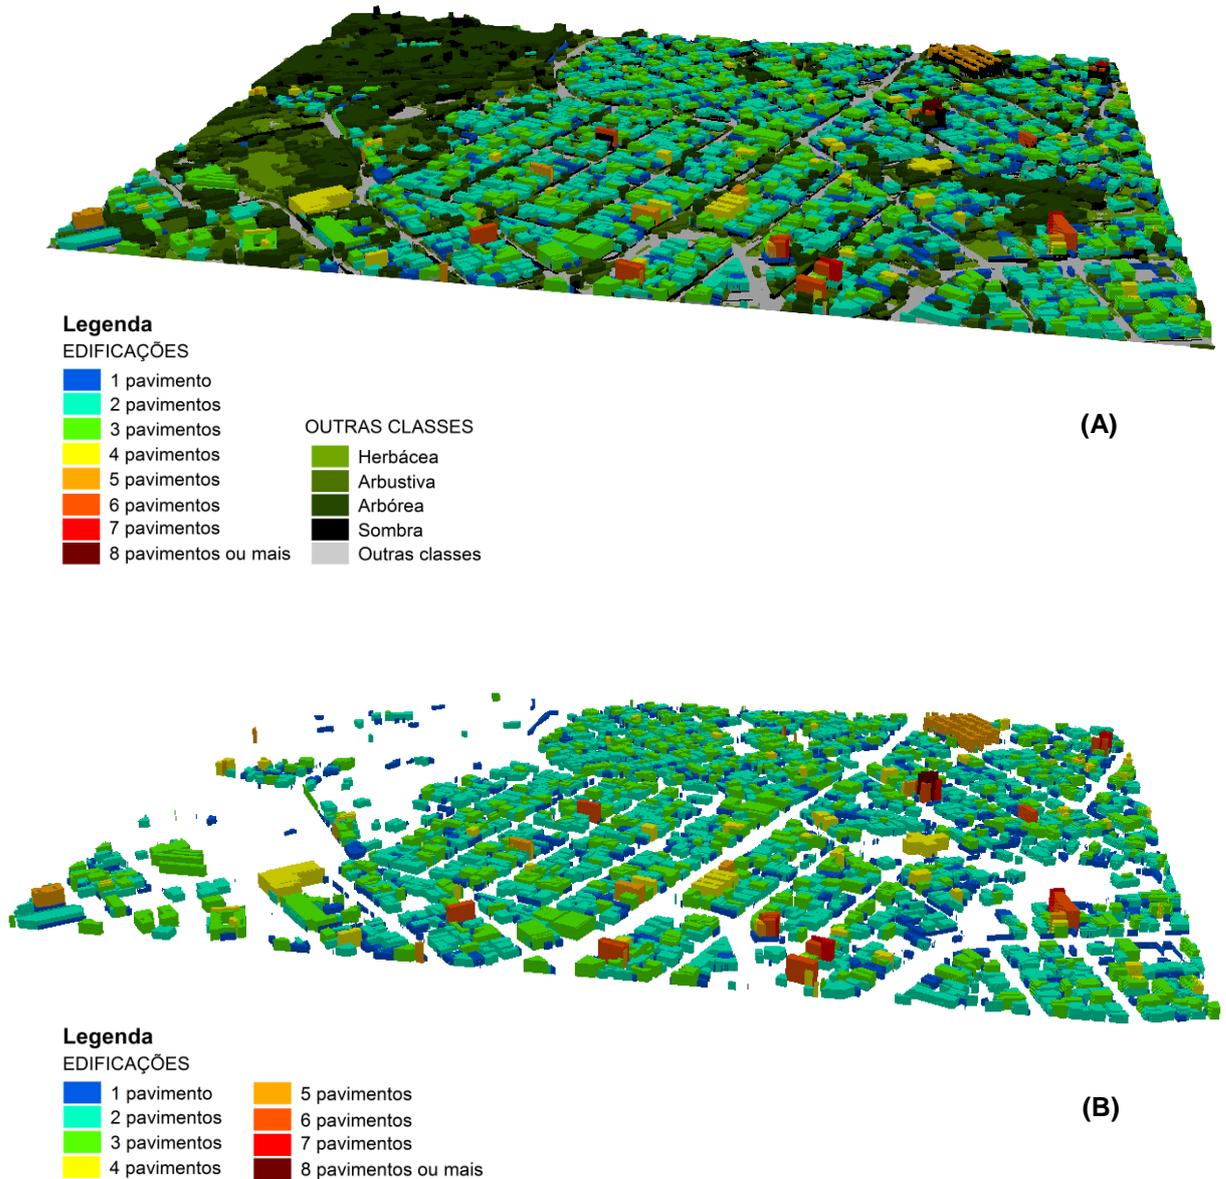


Figura 31. Representação tridimensional da altura dos objetos acima do nível do solo. Em (a) são representadas as alturas das edificações e da vegetação. Em (b), destaque apenas para edificações.

A etapa seguinte consistiu no refinamento dos resultados obtidos no eCognition, por meio do cruzamento dos segmentos classificados e a base cartográfica vetorial, como contribuição à classificação quanto ao uso do solo. Os segmentos classificados foram exportados para formato *shapefile* e os procedimentos a seguir foram executados nos *software* ArcGIS e Mapinfo.

6.11 Consulta espacial

Nem todas as classes necessitaram de refinamento, como foi o caso das edificações (casas e prédios com telhados de concreto/metálico, cerâmica ou brancas), piscinas e sombras, uma vez que o resultado obtido na classificação inicial, em termos de definição do objeto, foi satisfatório. Em outras palavras, na escala desse estudo afirmar que um objeto era uma edificação com telhado de cerâmica, por exemplo, foi suficiente. No entanto, a classificação do uso do solo necessitou de algum detalhamento para as classes de vegetação, concreto, pavimento e solo exposto.

Para isso, foram realizadas algumas operações de consulta espacial, relacionando os segmentos classificados com a base vetorial. Esta etapa tem como base alguns conceitos propostos por Aplin (2003), que considera como etapa do processo de obtenção de uso do solo o cruzamento das informações obtidas por meio da classificação multirresolução com base de dados vetoriais existentes, em ambiente SIG.

Um detalhe importante a ser ressaltado está relacionado à diferença de resolução entre a base vetorial e os segmentos. De maneira simplificada, enquanto os segmentos são compostos por um conjunto de pixels, os vetores restituídos não seguem necessariamente o delineamento pixel-a-pixel para a delimitação de um objeto. Assim, por vezes há algumas inconsistências topológicas que ocorrem em função das pequenas diferenças entre um e outro (figura 32), ocasionadas em função do uso das bases vetoriais como camadas temáticas para segmentação. Por essa razão, as consultas espaciais executadas inicialmente consideraram as relações “está contido” ou “contém”, de forma que objetos que somente “interceptam-se” não podem ser classificados sem uma análise mais criteriosa.

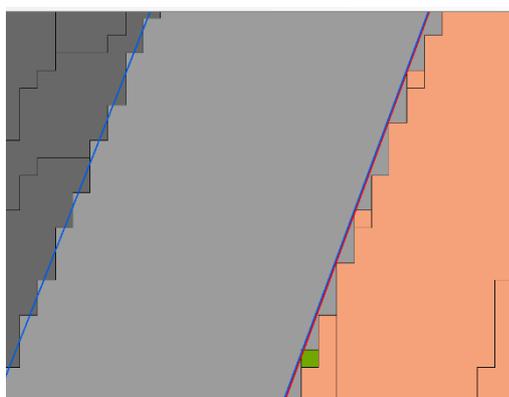
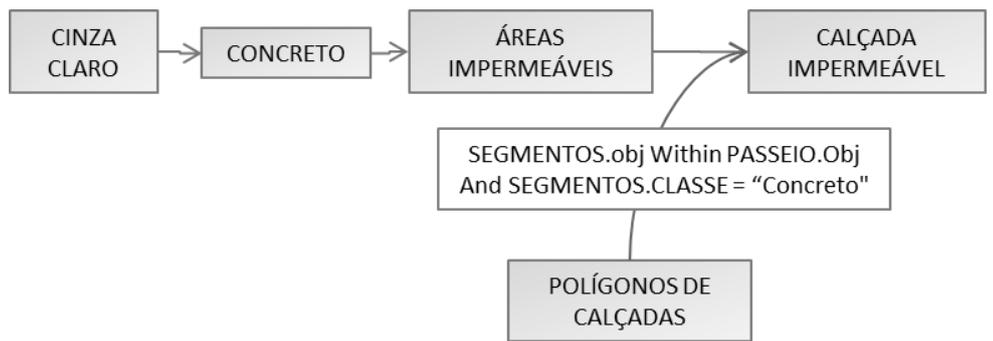
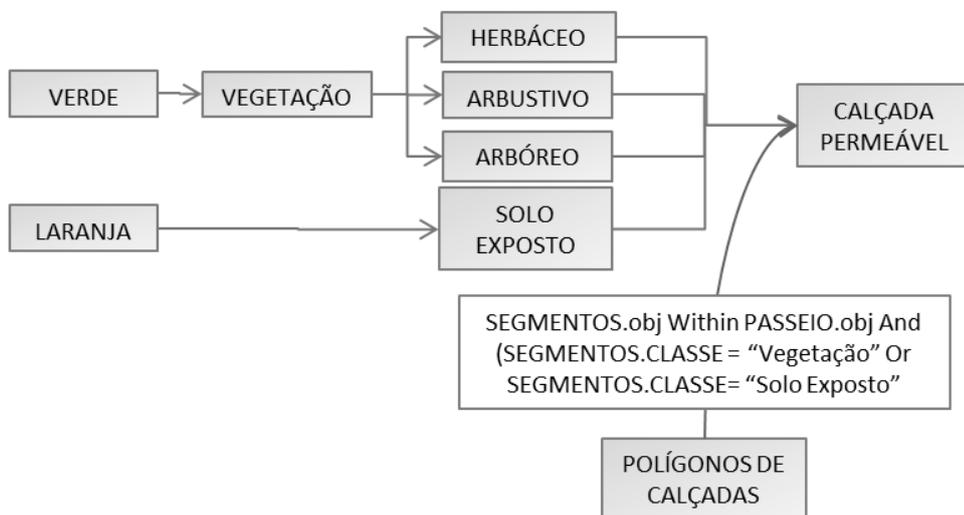


Figura 32. Detalhe das inconsistências topológicas entre os segmentos (em laranja e cinza) e os vetores (linhas em azul e vermelho)

A primeira classe extraída foram as calçadas, que podem ser subdivididas em calçada impermeável e permeável. O primeiro caso trata-se de segmentos da classe concreto e o segundo caso trata-se de segmentos das classes de vegetação ou solo exposto. Assim, segmentos dessas classes contidos em polígonos da base de calçadas, foram subdivididos conforme figura 33.



(a)



(b)

Figura 33. Consulta espacial para obtenção das classes “calçada impermeável” em (a) e “calçada permeável” em (b)

Outros elementos classificados, não diretamente relacionados ao tipo de elemento classificado, mas referente ao uso do solo, corresponde à classe de lotes vagos (figura 34). Para tanto, foi realizada uma operação de consulta espacial entre lotes e edificações. A fim

de desconsiderar eventuais erros topológicos como foi explicado anteriormente, na definição da classe de lotes vagos, embora o operador utilizado tenha sido a “interseção”, considerou-se que um lote para ser vago não pode interceptar edificações cuja área seja superior a $1,5\text{m}^2$ (considerado limite de tamanho de área desprezível para o propósito e a escala da fonte de dados cartográficos, 1:1000). Dessa forma, independente de uma área ser uma superfície permeável (vegetação, solo exposto) ou impermeável (concreto), foi categorizada como lote vago, desde que dentro do mesmo não haja uma edificação cuja área seja superior a $1,5\text{m}^2$.

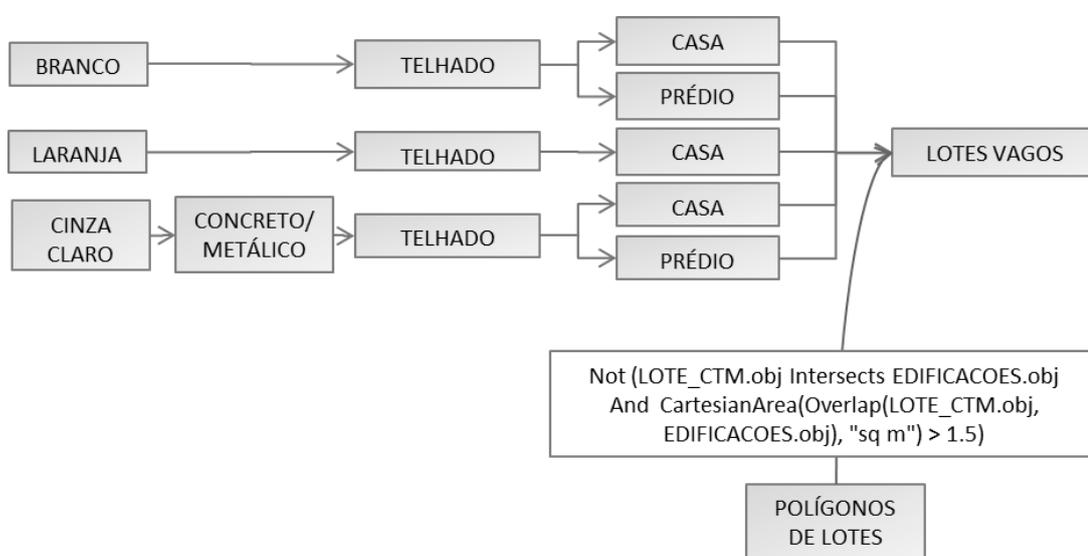
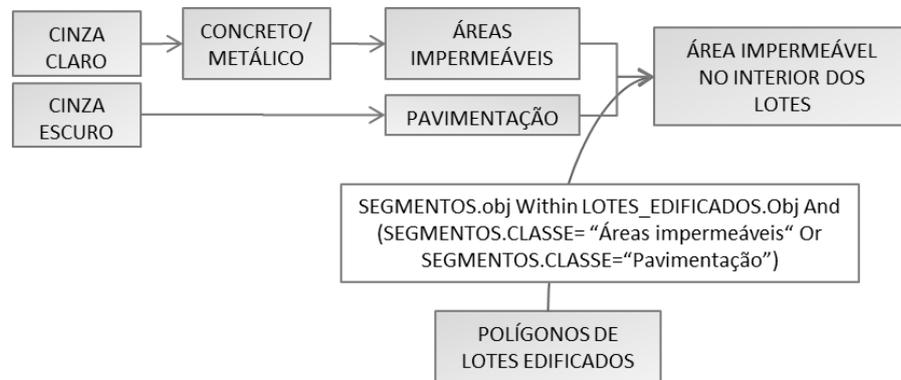


Figura 34. Consulta espacial para obtenção da classe “lote vago”

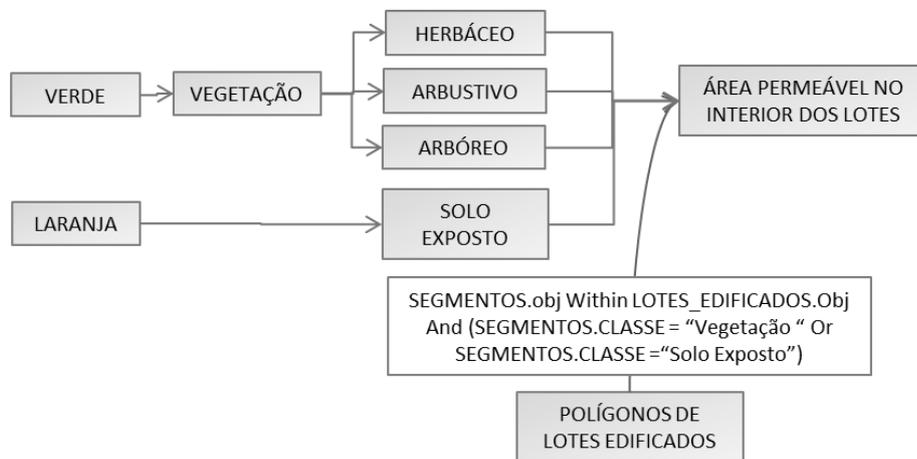
Ao separar os lotes vagos de lotes edificados, ao segundo atribuíram-se as classes “áreas permeáveis internas a lotes” e “áreas impermeáveis internas a lotes” quando, extraída a edificação, restaram as classes de solo exposto e vegetação (para a superfície permeável) e classes de concreto e pavimento (para a superfície impermeável) dentro dos polígonos de lotes (figura 35).

A seguir, obtiveram-se os segmentos de pavimentação (figura 36). Neste caso, a consulta espacial contribuiu para aumentar a acurácia da classificação realizada no eCognition, uma vez que a pavimentação por vezes foi confundida com outras superfícies impermeáveis em função das similaridades no comportamento espectral. Assim, embora um elemento possa ter sido classificado erroneamente, se o mesmo estiver localizado em áreas de arruamento, foram classificados em terceiro nível como vias. Para isso foram utilizados os polígonos de quadra e calçada. Removidos todos os segmentos já classificados e os segmentos que

estavam contidos nos polígonos de calçadas e quadras, a classe restante correspondeu aos arruamentos.



(a)



(b)

Figura 35. Consulta espacial para obtenção das classes “área impermeável no interior dos lotes” (a) e “área permeável no interior dos lotes” (b)

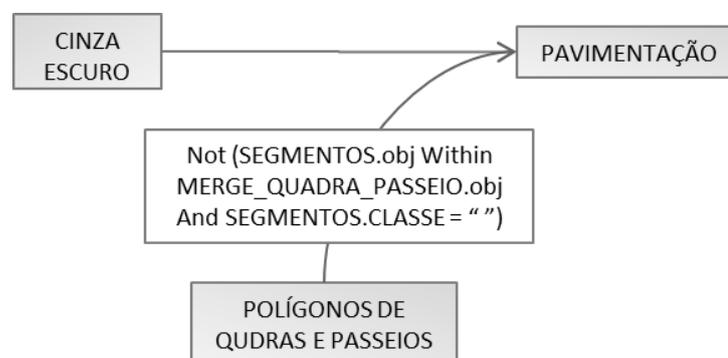


Figura 36. Consulta espacial para obtenção da classe “vias”

Após as operações de consulta espacial, restaram alguns pequenos segmentos que, conforme descrito anteriormente, são resultantes da utilização das bases vetoriais como níveis temáticos para segmentação. Para que nenhum segmento permanecesse sem classificação no terceiro subproduto, optou-se por classificar estes elementos por meio da consulta espacial utilizando o operador “interseção”, priorizando a categorização dos mesmos nas seguintes classes, conforme segue a sequência: lotes vagos, área permeável/impermeável no interior de lotes (para lotes edificadas), calçada permeável/impermeável no interior de lotes e pavimentação.

O mapeamento resultante do processo descrito anteriormente pode ser observado nas figuras 37 e 38.

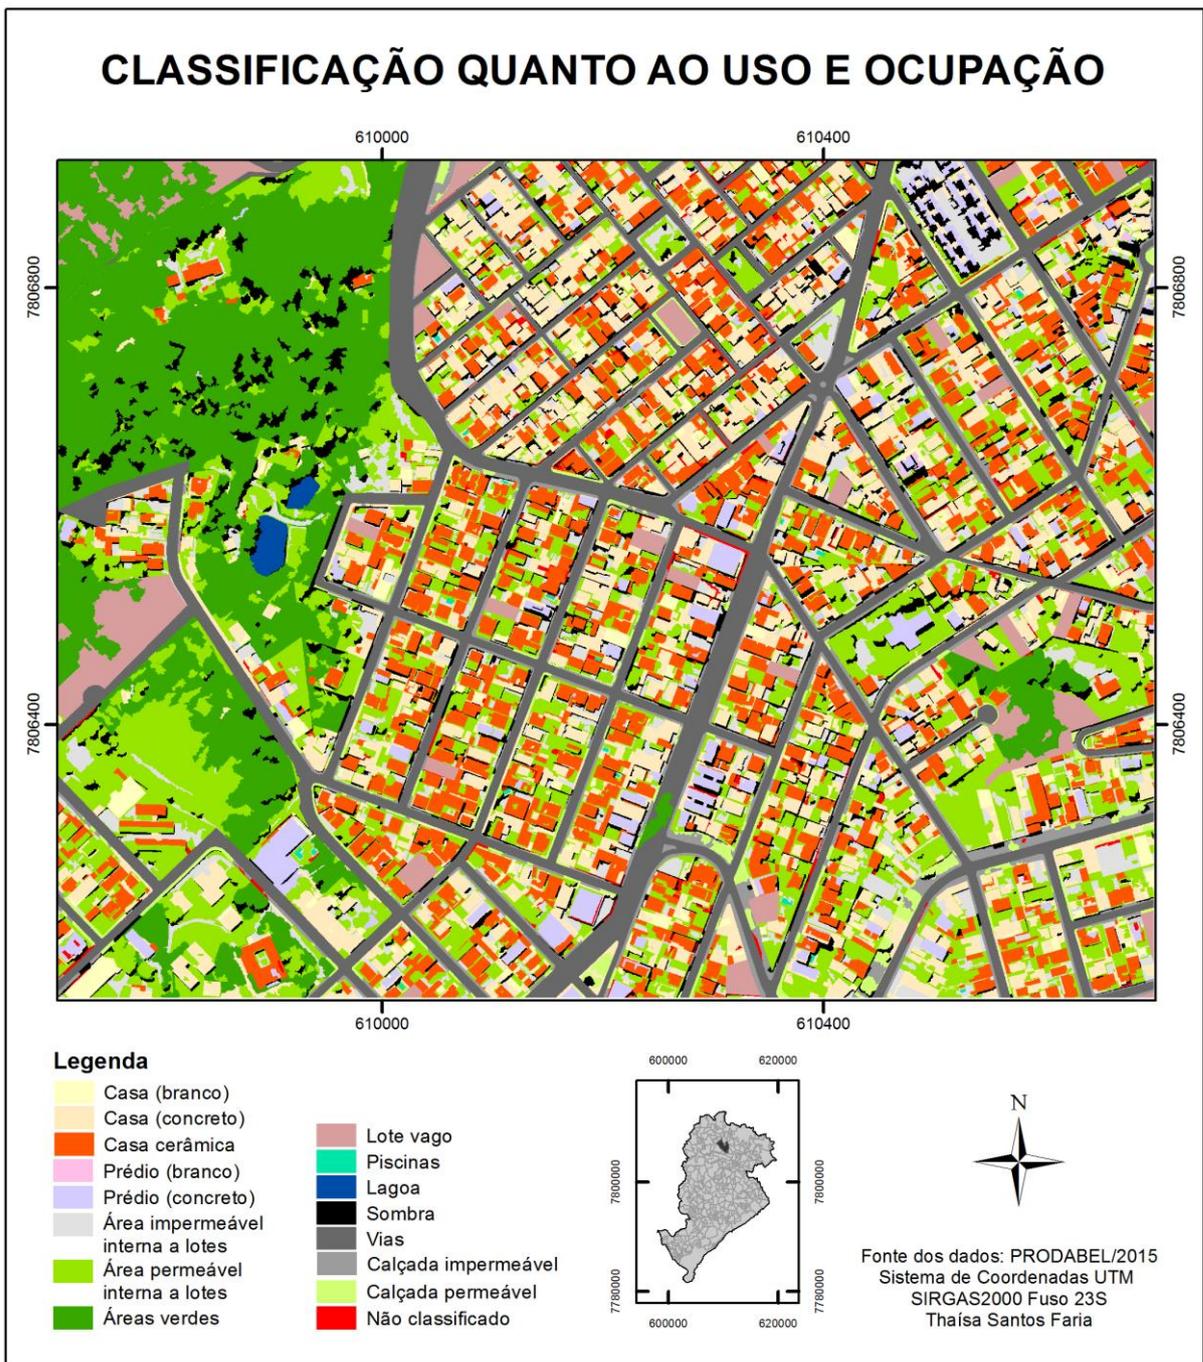


Figura 37. Mapa resultante da classificação x consulta espacial

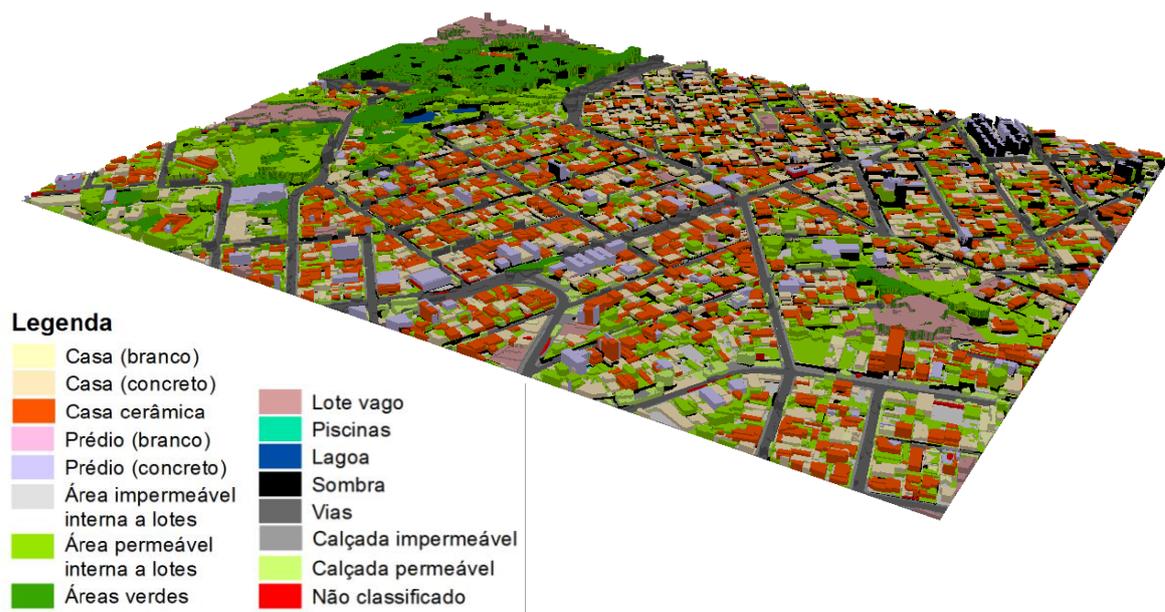


Figura 38. Representação tridimensional do resultado da classificação x consulta espacial.

6.12 Validação da classificação das imagens

A validação das imagens pode ser subdividida nas seguintes etapas:

- 1 - Cálculo do tamanho amostral;
- 2 - Conferência das amostras;
- 3 - Geração da matriz de confusão;
- 4 - Cálculo dos parâmetros de qualidade temática.

Antes de iniciar a validação há uma importante observação a ser analisada: a segmentação utilizando vetores ocasionou a delimitação de objetos muito pequenos. Com isso, surgiram segmentos inferiores a 1 m^2 , que não são significativos na escala de trabalho (figura 39). Assim, optou-se por “remover” estes objetos, por meio da ferramenta *eliminate* (ArcGIS), para aglutinar pequenos objetos a objetos maiores, pertencentes a uma mesma classe. Ainda assim, alguns objetos pequenos tiveram de ser mantidos uma vez que não havia vizinhos de uma mesma classe adjacentes a eles, impedindo a aglutinação dos mesmos. Assim, estes foram aceitos como membros da população, da qual foram extraídas as amostras.

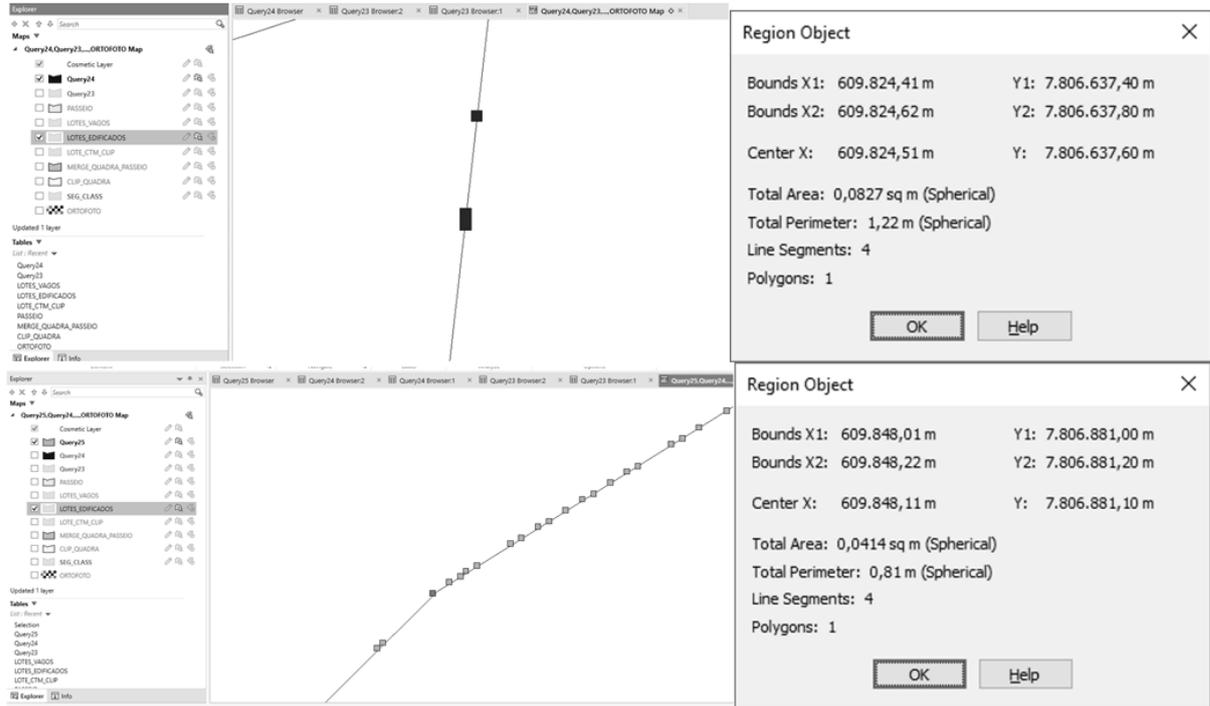


Figura 39. Exemplo de segmentos pequenos, inferiores a 1m^2

O cálculo do tamanho amostral foi realizado com base na Equação 1. Para p e q foram atribuídos o valor de 0,5, e o nível de confiança foi estabelecido em 95%. Dessa forma, foi encontrado o número de amostras igual a 384 indivíduos.

Para validar todas as classes, optou-se por utilizar a amostragem aleatória estratificada, na qual os estratos correspondem às 16 classes. Além disso, para que as amostras não estivessem concentradas apenas em determinados pontos, estas foram distribuídas sistematicamente na cena.

O percentual de amostras por estrato foi calculado conforme o percentual de cada estrato na população. Assim, a título de exemplo, se uma determinada classe abrangesse 30% da população, o mesmo deveria ocorrer na amostra, ou seja, esta mesma classe deveria representar 30% da amostra. O resultado do número de amostras por extrato pode ser observado na tabela 3.

A seleção aleatória das amostras sem qualquer critério espacial possibilitou que estas fossem selecionadas e concentradas em determinadas áreas da imagem. Assim, para que as mesmas fossem selecionadas de forma distribuída, foram necessários alguns processamentos.

Tabela 3. Número de amostras por estrato, conforme o tamanho populacional por classe

CLASSE	NÚMERO DE INDIVÍDUOS NA POPULAÇÃO	PERCENTUAL DOS ESTRATOS NA POPULAÇÃO	NÚMERO DE AMOSTRAS POR ESTRATO	GRADE REGULAR
Área impermeável interna a lotes	1493	0,06	24	5x5
Área permeável interna a lotes	6293	0,26	101	10x10
Calçada impermeável	560	0,02	9	3x3
Calçada permeável	1662	0,07	27	3x9
Casa (branco)	637	0,03	10	2x5
Casa (concreto/metálico)	3452	0,14	55	5x11
Casa cerâmica	3384	0,14	54	6x9
Lagoa	2	0,00	1*	1
Lote vago	251	0,01	4	2x2
Não classificado	775	0,03	12	3x4
Piscinas	26	0,00	1*	1
Prédio (branco)	8	0,00	81	1
Prédio (concreto/metálico)	379	0,02	6	2x3
Sombra	3773	0,16	60	6x10
Vias	1220	0,05	19	4x5
Áreas verdes	48	0,00	1*	1
TOTAL	23963	100%	383	

*Classes cujo percentual de indivíduos na população é muito pequeno, não havendo representatividade na amostra. Dessa forma, para que não ficassem sem validação, optou-se por selecionar pelo menos um indivíduo para validação.

Inicialmente, foram geradas grades regulares com número de células equivalente ou o mais próximo possível do tamanho amostral (tabela 3). Para tanto foi utilizada a ferramenta “*create fishnet*” do software ArcGIS, o que permitiu a construção de várias malhas regulares de acordo com o tamanho da amostra de cada classe.

As células das grades de cada classe receberam números sequenciais. Este mesmo número sequencial de cada célula foi atribuído aos indivíduos de cada classe na população, conforme sobreposição espacial, considerando o centroide dos objetos (figura 40). Conhecendo a posição de cada indivíduo de cada classe da população conforme a identificação entre estes e a grade regular, foi possível, por meio de tabela dinâmica no Excel, realizar sorteio aleatório dos elementos que compuseram a amostra.

Para o sorteio das amostras de forma aleatória, foi atribuído a cada indivíduo da população um identificador único e inequívoco, e utilizando a função “ALEATORIOENTRE” do Excel, foram obtidas as 384 amostras sistematizadas e proporcionais à representatividade de cada classe.

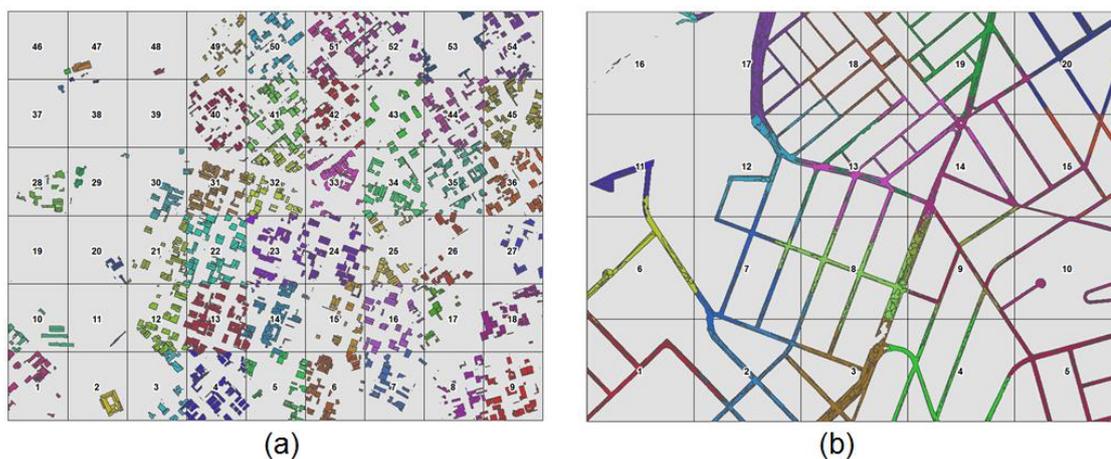


Figura 40. Exemplos de grades regulares e total de indivíduos de duas classes na população de objetos. Em (a) uma malha regular 6x9, correspondente à classe “casa com telhados de cerâmica”. Os telhados estão subdivididos em cores conforme a célula à qual os centroides dos objetos pertencem. Em (b) uma malha regular 4x5, correspondente à classe “vias”. As vias estão subdivididas em cores conforme a célula à qual os centroides dos objetos pertencem.

Cada um dos indivíduos da amostra foi conferido isoladamente. Para isso foi utilizada a combinação da conferência visual da imagem, a ferramenta Google StreetView e informações disponíveis em banco de dados (dados provenientes de restituição aerofotogramétrica, banco de dados tributário e outros). Em alguns casos isolados, não havendo possibilidade da confirmação da classe do objeto, este foi conferido em campo.

Com as amostras conferidas, foi construída a matriz de confusão apresentando as unidades cartográficas e os “dados de referência”. Os resultados da matriz e os parâmetros de qualidade temática serão apresentados no próximo capítulo.

7 RESULTADOS

A matriz de confusão pode ser observada na tabela 4. Os valores das linhas correspondem às unidades cartográficas, ou seja, o resultado obtido pela classificação, enquanto os valores nas colunas correspondem aos “dados de referência”, ou seja, as amostras conferidas conforme explicado anteriormente.

Tabela 4. Matriz de confusão obtida na validação das amostras classificadas.

Abaixo da tabela uma legenda da relação de classes

		VERDADE TERRENO																TOTAL LINHAS
		1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	
UNIDADE CARTOGRÁFICA	1	21	1	0	0	0	1	1	0	0	1	0	0	0	0	0	0	25
	2	4	61	0	1	1	9	10	0	0	3	0	0	0	11	0	0	100
	3	0	0	9	0	0	0	0	0	0	0	0	0	0	0	0	0	9
	4	0	0	8	15	0	0	0	0	0	0	0	0	0	2	0	0	25
	5	0	0	0	0	7	3	0	0	0	0	0	0	0	0	0	0	10
	6	6	7	2	0	1	29	6	0	0	2	0	0	1	0	1	0	55
	7	3	2	0	0	0	1	47	0	0	0	0	0	0	0	0	0	53
	8	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	1
	9	0	0	0	0	0	0	0	0	3	1	0	0	0	0	0	0	4
	10	3	4	0	0	0	1	2	0	0	1	0	0	0	0	1	0	12
	11	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	1
	12	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	1
	13	0	0	0	0	1	2	1	0	0	0	0	0	1	1	0	0	6
	14	0	8	0	1	0	3	3	0	0	0	0	0	0	45	0	0	60
	15	0	2	0	0	0	0	2	0	0	0	0	0	0	1	16	0	21
	16	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	1	1
TOTAL COLUNAS		37	85	19	17	10	49	72	1	3	8	1	1	2	60	18	1	384

LEGENDA DAS CLASSES			
1	Área impermeável interna a lotes	9	Lote vago
2	Área permeável interna a lotes	10	Não classificado
3	Calçada impermeável	11	Piscinas
4	Calçada permeável	12	Prédio (telhado branco)
5	Casa (telhado branco)	13	Prédio (telhado concreto/metálico)
6	Casa (telhado concreto/metálico)	14	Sombra
7	Casa (telhado cerâmica)	15	Vias
8	Lagoa	16	Áreas verdes

Para facilitar a compreensão dos resultados obtidos, foram gerados parâmetros de qualidade temática, que resumem os resultados da matriz de confusão. Os parâmetros de qualidade temática relativos aos índices globais podem ser observados na tabela 5 e os índices por classe podem ser observados na tabela 7.

Tabela 5. Índices globais obtidos com base na matriz de confusão da tabela 3. Os valores calculados com base nos resultados da matriz de confusão constituem a “porcentagem de acordo” ou “exatidão global”, “coeficiente de acordo aleatório a priori”, “coeficiente de acordo aleatório a posteriori”, “coeficiente *Tau* de ajuste” e “coeficiente *Kappa* de ajuste”

ÍNDICES GLOBAIS	
Porcentagem de acordo P_a	67%
Coeficiente de acordo aleatório a priori Ca_{pr}	0,06
Coeficiente de acordo aleatório a posteriori Ca_{ps}	0,14
Coeficiente <i>Tau</i> de ajuste T	65%
Coeficiente <i>Kappa</i> de ajuste K	62%

O coeficiente *Kappa* apresentou valor suavemente abaixo do coeficiente *Tau* e da exatidão global por subtrair no seu cálculo a porcentagem da probabilidade de concordância dos casos em função do acaso. Por esta razão, os resultados são avaliados considerando principalmente o índice *Kappa*, pois este permite uma análise mais criteriosa da qualidade geral da classificação.

Segundo Landis e Koch (1977) o coeficiente *Kappa* pode ser categorizado em níveis de exatidão (tabela 6). Dentro deste contexto, considerando o coeficiente *Kappa* obtido, o nível de exatidão sugere uma classificação substancial (ou muito boa).

O resultado do *Kappa* pode ter sido influenciado principalmente pelas classes cujo tamanho amostral é mais significativo (classes 2, 6, 7 e 14, denominadas “área permeável interna a lotes”, “casa com telhado de concreto”, “casa com telhado de cerâmica” e “sombra”, respectivamente), pois estas apresentaram probabilidade maior de observações concordantes entre a “verdade do terreno” e a unidade cartográfica.

Tabela 6. Nível de exatidão de uma classificação de acordo com o valor do coeficiente Kappa (Landis e Koch, 1977)

ÍNDICE KAPPA	QUALIDADE
$K < 0$	POBRE
$0 < K < 20$	FRACA
$20 \leq K \leq 40$	JUSTA
$40 \leq K \leq 60$	MODERADA
$60 \leq K \leq 80$	SUBSTANCIAL
$K > 80$	QUASE PERFEITA

A diferença entre os valores encontrados para o coeficiente de acordo aleatório a priori (6%) e o coeficiente de acordo aleatório a posteriori (14%) não foi muito alta. Os valores dos coeficientes em análise indicam que as amostras estão razoavelmente distribuídas na maior parte das classes, embora haja algumas cujo tamanho da amostra seja muito pequeno. Vale ressaltar que estes valores estão diretamente ligados ao tipo de amostragem (probabilística) adotado neste estudo.

Tabela 7. Índices por classe obtidos com base na matriz de confusão da tabela 3. São apresentados os resultados dos índices “exatidão produtor”, “risco usuário”, “exatidão usuário” e “risco produtor”

	ÍNDICES POR CLASSE			
	EXATIDÃO PRODUTOR	RISCO USUÁRIO	EXATIDÃO USUÁRIO	RISCO PRODUTOR
1	0,57	0,43	0,84	0,16
2	0,72	0,28	0,61	0,39
3	0,47	0,53	1,00	0,00
4	0,88	0,12	0,60	0,40
5	0,70	0,30	0,70	0,30
6	0,59	0,41	0,53	0,47
7	0,65	0,35	0,89	0,11
8	1,00	0,00	1,00	0,00
9	1,00	0,00	0,75	0,25
10	0,13	0,88	0,08	0,92
11	1,00	0,00	1,00	0,00
12	1,00	0,00	1,00	0,00
13	0,50	0,50	0,17	0,83
14	0,75	0,25	0,75	0,25
15	0,89	0,11	0,76	0,24
16	1,00	0,00	1,00	0,00

A existência de classes cujo tamanho da amostra é muito pequeno reforça a necessidade de analisar os índices por classe. De fato, o índice de acertos para classes com amostras muito pequenas (classes 8, 9, 11, 12 e 16, denominadas “lagoa”, “lote vago”, “piscinas”, “prédio com telhado branco” e “áreas verdes”, respectivamente) é bastante alto; tomando-as como referência poderia se afirmar que a classificação teve ótima qualidade. No entanto, é mais prudente sugerir que outros testes devem ser realizados em tamanhos de amostras maiores para permitir interpretações mais fundamentadas.

A exatidão do produtor e o risco do usuário apresentam dados importantes para analisar o erro de omissão (situação na qual um elemento, devendo pertencer a classe A, não foi classificado em A). Além disso, o termo risco do usuário implica na aceitação de um produto desqualificado. No contexto desta classificação, baixos valores para exatidão do produtor (abaixo de 60%) e consequentemente altos valores para o risco do usuário (acima de 40%) foram observados nas classes 1 (área impermeável a lotes), 3 (calçada impermeável), 6 (casa com telhado de concreto), 10 (não classificado) e 13 (prédio com telhado de concreto).

Algumas amostras da classe 1 (área impermeável interna a lotes) foram confundidas com outras superfícies cujo comportamento espectral é semelhante (edificações com telhado de concreto/metálico e edificações com telhado de cerâmica envelhecida). Este erro não era esperado em função do emprego dos dados LIDAR na classificação.

A maior parte dos elementos omitidos da classe 3 (calçada impermeável) apareceram na classe 4 (calçada permeável). Embora ambos sejam calçadas (acerto “parcial” em função do emprego de bases vetoriais no processo de classificação), a confusão se deu quanto ao tipo de superfície (vegetal e concreto).

No caso da classe 6 (casa com telhado de concreto/metálico) a maior parte dos objetos omitidos foram classificados na classe 2 (área permeável interna a lotes), erro semelhante ao que ocorreu entre as classes 1 (área impermeável interna a lotes, quanto ao emprego do LIDAR) e 3 (calçada impermeável, quanto à cobertura da superfície).

A classe 13 (prédios com telhado de concreto/metálico) teve 50% de erros, mas poucas conclusões podem ser extraídas deste fato uma vez que a classe apresenta apenas 2 amostras na “verdade terreno”.

A classe 10 (não classificado) por sua vez apresentou confusão com diversas classes (1, 2, 6 e 9, denominadas “área impermeável interna a lotes”, “área permeável interna a lotes”, “casa com telhado de concreto” e “lote vago”, respectivamente). Esta classe na verdade constitui-se do conjunto de segmentos que o algoritmo de classificação, com base nos descritores utilizados, não conseguiu definir. Pouco se conclui sobre a presença dos

elementos da classe 10 nas outras classes, uma vez que todas elas apresentam comportamento espectral bastante diversificado.

A exatidão do usuário e risco do produtor estão diretamente ligados aos erros de exagero, situação em que um objeto classificado como “A”, quando na verdade pertence à classe “B”. Além disso, o termo risco do produtor implica na rejeição de um produto qualificado. Esta situação foi mais frequente nas classes 6 (casa com telhado de concreto), 10 (não classificado) e 13 (prédio com telhado de concreto), com valores para risco do produtor equivalente a 0,47, 0,92 e 0,83, respectivamente. Ou seja, neste caso o risco do produtor indicou uma probabilidade de rejeição de 92% das amostras classificadas como “não classificado”, 83% das amostras classificadas como prédio (concreto/metálico) e 47% das amostras classificadas como casa (concreto/metálico) quando estas estão bem classificadas.

A maior parte dos elementos erroneamente identificados na classe 6 (casa com telhado de concreto/metálico), na verdade pertencem às classes 1 (área impermeável interna a lotes), 2 (área permeável interna a lotes) e 7 (casa com telhado de cerâmica). De forma semelhante aos casos anteriores, os erros podem ser explicados em função da confusão com o tipo de cobertura da superfície (impermeável) e ao emprego do LIDAR (casa com telhado de cerâmica ou concreto/metálico). A região analisada apresenta muitas moradias com telhado de cerâmica já envelhecido, que por sua vez apresenta um comportamento espectral de difícil definição.

Quanto aos elementos erroneamente identificados na classe 13 (prédio com telhado de concreto/metálico), estes pertencem principalmente às classes que também são edificações (telhado de cerâmica ou concreto/metálico). Logo, acredita-se que os erros são provenientes do limiar da função *fuzzy* estabelecido quanto ao número de pavimentos de uma edificação para que esta seja classificada como casa ou prédio. Hipoteticamente, pode-se citar o exemplo de uma edificação com 3 pavimentos, que pode ser tanto uma casa quanto um prédio. Assim, edificações com altura próxima a 3 pavimentos (entre 9 ou 10 metros) estão em uma faixa em que a função de pertinência da altura do objeto acima do nível do solo é alta tanto para a classe de casas quanto de prédios.

A classificação oficial de Belo Horizonte é muito diferente da proposta neste estudo, não somente quanto aos resultados, mas também em relação à metodologia de mapeamento e à concepção das classes (tabela 8). Na classificação oficial, à medida que aumenta o nível de detalhamento das classes, não ocorre aumento da escala de mapeamento. Nesse

sentido, o mesmo produto do nível 1 se repete nos níveis 2 e 3, agregando somente alguns elementos relacionados ao uso do solo.

Tabela 8. Comparativo entre a classificação de cobertura e uso do solo oficial e a proposta

DIFERENÇAS	CLASSIFICAÇÃO OFICIAL	CLASSIFICAÇÃO PROPOSTA
QUANTO À METODOLOGIA	manual	automática supervisionada
QUANTO À ESCALA	nível de quadras (1:5.000)	nível de edificações (1:2.000)
EXPLORA ATRIBUTOS DO COMPORTAMENTO ESPECTRAL?	não	sim
EXPLORA ATRIBUTOS TRIDIMENSIONAIS?	não	sim
UTILIZA BASES VETORIAIS?	sim (quadras e sistema viário)	sim (quadras, lotes, edificações e calçadas)
AMOSTRAGEM PARA CONFERÊNCIA?	aproximadamente 123 amostras (estratificada uniforme)	384 amostras (estratificada proporcional e sistematizada)
METODOLOGIA DE VALIDAÇÃO?	não	validação temática (Ariza-López, 2002)

A principal observação é com relação à escala: o mapeamento oficial é limitado ao mapeamento de quadras. Por não haver qualquer detalhamento internamente às quadras, informações como os diferentes padrões construtivos, a presença de áreas concretadas ou superfícies permeáveis ocupadas com diferentes extratos vegetais só aparecem de forma expressiva se o uso for predominante em um determinado quarteirão. Por exemplo, uma quadra cujo uso seja bastante diversificado, apresentando edificações como casas e prédios, áreas permeáveis de jardins ou quintais entre outros elementos são representados simplificada e como “área edificada”.

Neste contexto, ressalta-se ainda a verticalização: a classificação oficial não separa elementos de edificação conforme o tipo de uso (casas ou prédios), elemento determinante para entender a dinâmica do crescimento de uma cidade como Belo Horizonte, cujo grau de urbanização é elevado e o crescimento experimentado na atualidade ocorre principalmente devido à possibilidade de verticalizar as construções.

É possível perceber que nessa classificação os elementos relacionados ao comportamento espectral dos alvos foram ignorados (obviamente, não foi realizado qualquer processamento digital de imagens para obtenção deste produto) e os atributos provenientes de bases de dados vetoriais foram pouco explorados. Com relação a isso, a metodologia desta pesquisa também explorou pouco o conjunto de dados vetoriais disponíveis para o município de Belo Horizonte, utilizando apenas algumas camadas de dados; mas tal medida é intencional:

sabe-se que no contexto da administração pública não é recorrente a existência de mapeamento tão detalhado proveniente de restituições aerofotogramétricas e levantamentos de campo. Dessa forma, para que esta metodologia se tornasse mais aplicável em outros contextos, optou-se por extrair o máximo possível de dados dos algoritmos disponíveis no *software* de classificação, tornando o processo menos dependente da existência de base de dados vetoriais.

Assim, a aplicação de testes estatísticos para validação da classificação oficial deve ser analisada para se adequar à escala de mapeamento adotada, pois se os mesmos parâmetros adotados nessa pesquisa fossem aplicados ao mapeamento oficial, os resultados seriam bastante inferiores ao alcançado nesta pesquisa.

8 CONSIDERAÇÕES FINAIS

Em todas as etapas da metodologia da pesquisa podem ser feitas considerações que permitem avaliar os resultados alcançados e propor sugestões para melhoria do método. Abaixo serão listadas algumas considerações por etapa de desenvolvimento do trabalho.

Quanto aos materiais utilizados: conforme explicado nos resultados, a escolha do pequeno número de camadas vetoriais foi intencional. Assim, é de se esperar que os resultados podem ser melhorados caso haja um número maior de atributos a serem extraídos das bases de dados, melhorando os resultados quanto ao uso do solo.

A utilização dos dados LIDAR se mostrou bastante eficiente na separabilidade dos objetos (tanto para separar o que está no nível ou acima do solo, bem como para separar casa de prédios), embora em alguns casos tenha ocorrido confusão entre as classes. Isso pode estar ligado à importância de validação dos dados LIDAR, já que os dados da nuvem de pontos que foram cedidos não estavam validados, o que em parte pode explicar alguns erros ocorridos no modelo. Ainda assim, é importante ressaltar que explorar dados provenientes do LIDAR é essencial para fornecer bases para entendimento da dinâmica urbana no que diz respeito ao fenômeno da verticalização.

Quanto aos pequenos objetos segmentados (inferiores a 1 m²): isto é uma limitação do método. O emprego da ferramenta *eliminate* reduziu consideravelmente o número de objetos pequenos. Mas ainda assim, sugere-se buscar alternativas para minimizar o surgimento de objetos tão pequenos que geram ruídos na classificação. Neste ponto cabe inclusive analisar quais são as vantagens do emprego de bases vetoriais no processo de segmentação.

Quanto ao modelo conceitual: após a segmentação foi possível observar que há uma série de potencialidades do *software* eCognition em obter segmentos com alto nível de detalhamento. Certamente seria possível adotar um modelo conceitual que subdividisse as classes, mas é importante lembrar que o modelo deve ser coerente com o objetivo do estudo, no caso, fornecer bases para o planejamento e gestão de cidades. E, para esta finalidade, acredita-se que as classes adotadas foram satisfatórias. Outra questão a ser analisada é a adequação do modelo para que este possa ser replicado em outros cenários: sabe-se que a paisagem urbana é muito heterogênea e, por isso, difícil de ser classificada. Aumentar o número de classes e detalhar demais pode tornar o modelo muito específico, de

modo que este seja aplicado apenas no contexto estudado. Usar um modelo conceitual um pouco mais generalizado aponta que sua aplicação pode se tornar mais viável.

Quanto às classes: a classe de áreas verdes merece atenção especial, pois na metodologia sugerida alguns extratos vegetais cuja área é menor do que o limiar estabelecido não podem ser considerados como áreas verdes, mas apenas como superfícies permeáveis. Para estudos futuros sugere-se aprofundamento nos diversos usos possíveis de áreas verdes, que podem ser jardins, quintais, parques, cemitérios, praças, entre outros. Tais dados podem ser obtidos por diversos meios, como, por exemplo, através da definição de regras de relações de vizinhanças entre os segmentos. No entanto sabe-se que a categoria à qual a vegetação pode pertencer está intimamente ligada ao uso que se dá do solo, dado difícil de ser minerado, pois os usos estão intrinsecamente ligados a uma determinada região, ao padrão de ocupação, à legislação vigente quanto ao uso e ocupação do solo, entre outros fatores. Assim, a utilização de tal metodologia dificulta sua reprodução em outros mapeamentos. Outra opção é o levantamento de campo ou a utilização de camadas vetoriais disponíveis, sendo esta última bastante promissora, no caso específico da cidade de Belo Horizonte. Situação semelhante pode ser verificada nas áreas de solo exposto, que podem constituir áreas degradadas (ligadas a processos erosivos), lotes vagos, entre outros.

Quanto ao método de amostragem: a amostragem probabilística tem como base a escolha e amostras ao acaso. Assim dentre as amostras escolhidas aleatoriamente, algumas estavam localizadas no interior de lotes e isso constitui uma situação bastante delicada, uma vez que a sua conferência é limitada ao nível da rua. Dessa forma, a utilização de meios alternativos de validação (como ferramenta *Google Street View*, restituições aerofotogramétricas e dados provenientes de banco de dados) foi essencial para conferência das amostras.

No que se relaciona à validação temática, em pesquisas futuras podem ser testados outros métodos de avaliação dos resultados, bem como simulações de qualidade temática.

De modo geral, a combinação de imagens provenientes de sensores remotos e LIDAR constituem uma ferramenta valiosa para analisar imagens urbanas. Mesmo que este tipo de superfície tenha uma grande heterogeneidade, as informações oriundas do comportamento espectral dos alvos bem como a dimensão tridimensional dos mesmos podem trazer resultados bastante significativos e úteis para administração urbana para análise em macro escala. De fato, tais dados ainda não substituem levantamentos de campo e restituições aerofotogramétricas. No entanto, é inegável que o esforço, os recursos e o tempo despendido para obtenção destes últimos os tornam inviáveis para aplicações em curtos períodos de tempo, enquanto o processamento digital de imagens pode apresentar

resultados bastante promissores com menor custo e tempo. Para isto, é necessário que o analista tenha bases teóricas bem fundamentadas e entenda muito da realidade à qual está tratando.

A aplicação da metodologia proposta em imagens de diversos períodos apresenta potencialidade para extração de um enorme conjunto de informações, abaixo são listados alguns exemplos:

- Mensuração do crescimento urbano e fenômenos a ele inerentes como a verticalização, impermeabilização do solo, alteração da massa arbórea;
- Comparação entre os parâmetros urbanísticos e a lei de uso e ocupação do solo vigente com o uso e ocupação do solo de fato;
- Indicadores de desenvolvimento e qualidade urbana, por meio de identificação de elementos como padrão construtivo (ligado ao tipo de acabamento das construções) e conforto térmico (ligado ao tipo de cobertura vegetal).

Por fim, em comparação às tradicionais classificações pixel-a-pixel, a classificação orientada a objeto apresenta resultados bastante eficientes, à medida que se aproxima mais da realidade das cidades na definição de suas parcelas.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, R. A. L.; VERGARA, O. R. Identificação de alvos urbanos em imagens Ikonos, aplicando classificação orientada a segmentos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais... Goiânia: Inpe, 2005. p. 2573-2580.

AMARAL, M. V. et al. Moreia. Avaliação e comparação de métodos de classificação de imagens de satélites para o mapeamento de estágios de sucessão floresta. Revista *Árvore*, Viçosa, v. 33, n. 3, p. 575-582, 2009.

ANJOS, C. S. et al. Identificação de materiais urbanos por meio de métodos inovadores de classificação de imagens. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 17., 2015, João Pessoa. Anais... João Pessoa: Inpe, 2015. p. 4377-4384.

ANTUNES, J. F. G.; ZULLO JUNIOR, J. Aplicação de lógica fuzzy para estimativa de área plantada da cultura de soja utilizando imagens AVHRR-NOAA. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais... Florianópolis: Inpe, 2007. p. 35-42.

APLIN, P. Comparison of simulated IKONOS and SPOT HRV imagery for classifying urban áreas. In: MESEV, V (Org.). *Remotely Sensed Cities*. London: Ed. Taylor & Francis. 2003. p-24-63.

ARAKI, H. Fusão de informações espectrais, altimétrica e de dados auxiliares na classificação de imagens de alta resolução espacial. 2005. 139 f. Tese (Doutorado em Ciências da Terra) – Universidade Federal do Paraná, Curitiba, 2005.

ARIZA-LÓPEZ, F. J. A. *Calidad en La Producción Cartografica*. 2. ed. Jaen: RA-MA, 2002.

ARIZA-LÓPEZ, F. J. A. et al. *Casos Prácticos de Calidad em la Producción Cartográfica*. 1. ed. Jaén: Universid de Jaén, 2004.

BAATZ, M.; SCHÄPE, A. Object-Oriented and Multi-Scale Image Analysis in Semantic Networks. In: INTERNATIONAL SYMPOSIUM ON OPERATIONALIZATION OF REMOTE SENSING, 2., 1999, Enschede. Anais... Enschede: J. Strobl, 1999. p. x-x.

BAATZ, M.; SCHÄPE, A. Multiresolution Segmentation - an optimization approach for high quality multi-scale image segmentation. *ANGEWANDTE GEOGRAPHISCHE*

INFORMATIONSVERRARBEITUNG SIMPOSIUM, 12., 2000, Salzburg. Anais... Salzburg: J. Strobl, 2000. p. 12-23.

BALTSAVIAS, E. P. Airborne laser scanning: basic relations and formulas. Journal of Photogrammetry and Remote Sensing, Amsterdam, v. 54, n. 1, p. 199-214, 1999.

BELO HORIZONTE. Lei nº 7166, de 27 de agosto de 1996. Estabelece normas e condições para parcelamento, ocupação e uso do solo urbano no município. Lex: coletânea de legislação: edição municipal, Belo Horizonte, v.1, 1996.

BELO HORIZONTE. Lei nº 9.959 de 20 de julho de 2010. Altera as leis nº 7.166/86 - que institui o Plano Diretor do Município de Belo Horizonte - e nº 7.166/96 que estabelece normas e condições para parcelamento, ocupação e uso do solo urbano no Município. Lex: coletânea de legislação: edição municipal, Belo Horizonte, v.1, 2010.

BLASCHKE, T. et al. Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. Journal of Photogrammetry and Remote Sensing, Amsterdam, v. 20, n. 1, p. 555-579, 2000.

BLASCHKE, T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. Zeitschrift fur Geoinformationssysteme, Frankfurt A Main, v. 14, n. 6. p. 12-17, 2001.

BLASCHKE, T. Object based image analysis for remote sensing. Journal of Photogrammetry and Remote Sensing, Amsterdam, v. 20, n. 1, p. 2-16, 2010.

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, Curitiba, v. 11, n. 1. p. 71-87 2005.

BRANDALIZE, A. Perfilamento a LASER: comparação com métodos fotogramétricos. 1.ed. Curitiba: ESTEIO Engenharia e Aerolevanteamento, 2001.

CADENA, G. T. Classificação dos tipos de pavimentos das vias urbanas a partir de imagem de alta resolução espacial por meio de análise orientada a objeto. 2011. 114 f. Dissertação (Mestrado em Ciências Cartográficas), Universidade Estadual Paulista, São Paulo, 2011.

CAMPOS, V. O. et al. Otimização de classificador fuzzy para imagens de sensoriamento remoto utilizando algoritmos genéticos. Revista Inteligência Computacional Aplicada, Rio de Janeiro, v. 1, n. 3. p. 1-7, 2010.

CASTRO, F. S. P. et al. Extração de estradas em imagens de intensidade laser utilizando morfologia matemática. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. Anais... Natal: Inpe, 2009. p. 5001-5007.

CAVASSIM JUNIOR, I. et al. Utilização de dados do varredor laser na cartografia urbana. Boletim de Ciências Geodésicas, Curitiba, v. 11, n. 1. p. 201-219, 2005.

CAZZETA, V. O status de realidade das fotografias aéreas verticais no contexto dos estudos geográficos. Revista Pró-posições, Campinas, v. 30, n. 3. p. 71-86, 2009

CENTENO, J. A. S.; MITISHITA, E. A. Laser Scanner Aerotransportado No Estudo de Áreas Urbanas. In: Almeida, C. M. et al. (Org.). Geoinformação em Urbanismo: Cidade Real X Cidade Virtual. São Paulo: Ed. Oficina de Textos, 2007. p. 351-368.

CENTENO, J. A. S. et al. Aplicação de laser scanner para detecção de áreas para coleta de água de chuva. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. Anais... Natal: Inpe, 2009. p. 5009-5019.

CHAGAS, S. S. et. al. Utilização de redes neurais artificiais na classificação de níveis de degradação em pastagens. Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, v. 13, n. 3. p. 319-327, 2009.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. Remote Sensing of Environment, Amsterdam, v. 37, n. 1. p. 35-46, 1991.

CONGALTON, R. G. GREEN, K. Assessing the Accuracy of Remotely Sensed Data: Principles and Practices. Ed. 2. Boca Raton: CRC Press, 2008.

COUTINHO, A. D. S. Classificação orientada a objeto para identificação de áreas urbanas propícias a transmissão da leptospirose. 2006. 151 f. Dissertação (Mestrado em Engenharia Cartográfica), Instituto Militar de Engenharia, Rio de Janeiro, 2006.

DEFINIENS IMAGING. eCognition User Guide 7. Ed. 1. Munich: Corporate Headquarters, 2007. p.4.

DEUS, L. R. et al. Comparação de métodos de classificação da cobertura do solo urbano utilizando imagens IKONOS II com e sem o auxílio de dados LiDAR. In: WORKSHOP DE VISÃO COMPUTACIONAL, 7., 2011, Curitiba. Anais... Curitiba: UFPR, 2011. p. 213-218.

DRESCH, G. Avaliação automática da acurácia relativa de dados LIDAR aerotransportado. 2015. 106f. Dissertação (Mestrado em Ciências Geodésicas), Universidade Federal do Paraná, Curitiba, 2015.

ERBA, D. A. et al. O Cadastro Territorial: presente, passado e futuro. In: ERBA, D. et al. (Org.). Cadastro Multifinalitário como instrumento de política fiscal e urbana. Rio de Janeiro: Ed. Ministério das Cidades, 2005. p. 1-146.

ESTEVAM, E. A.; SILVA, E. A. Classificação de áreas de favelas a partir de imagens IKONOS: Viabilidade de uso de uma abordagem orientada a objeto. Revista Pesquisas em Geociências, Porto Alegre, v. 37, n. 2. p. 133-142, 2010.

FALAT, D. R. Perfilamento a laser para detecção de construções clandestinas e determinação de altura de edificações. 1.ed. Curitiba: ESTEIO Engenharia e Aerolevantamento, 2005.

FAZAN, A. J. Extração de contornos de telhado de edifícios no espaço-objeto baseada em snakes e programação dinâmica a partir de tin/laser e imagens aéreas de alta resolução. 2014. 115 f. Tese (Doutorado em Ciências Cartográficas), Universidade Estadual de São Paulo, Presidente Prudente, 2014.

FERNANDES, R. R. et al. Classificação orientada a objetos aplicada na caracterização da cobertura da terra no Araguaia. Revista Brasileira de Agropecuária, Brasília, v. 47, n. 4. p. 1251-1260, 2012.

FERREIRA, D. G. O uso do solo e os padrões de vento: o caso da cidade de Belo Horizonte, MG. 2009. 137 f. Dissertação (Mestrado em Ambiente Construído e Patrimônio Sustentável), Universidade Federal de Minas Gerais, Belo Horizonte, 2009.

FERREIRA, F. R. Segmentação do espaço urbano por meio da tecnologia LIDAR aerotransportado. 2014. 130 f. Dissertação (Mestrado em Engenharia), Universidade de São Paulo, São Paulo, 2014.

FONSECA, R. et al. Acordo inter-juízes: o caso do coeficiente Kappa. Revista do Instituto Superior de Psicologia Aplicada, Lisboa, v. 5, n. 1. p. 79-88, 2007.

GOHARA, A. A. et al. Utilização de dados laser e imagens aéreas para a extração de vias urbanas. *Colloquium Exactarum, Presidente Prudente*, v. 7, n. 2. p.17-36, 2015.

GONÇALVES, M. L. et al. Classificação não-supervisionada de imagens de sensores remotos utilizando redes neurais auto-organizáveis e métodos de agrupamentos hierárquicos. *Revista Brasileira de Cartografia*, v. 60, n. 1. p.17-29, 2008.

GONÇALVES, S. S. O. Classificação de ocupação do solo com base em dados LIDAR. 2012. 120 f. Dissertação (Mestrado em Gestão Ambiental e Ordenamento do Território) Instituto Politécnico de Viana do Castelo, Viana do Castelo, 2012.

GUERRA, C. E; CALDAS, N. S. S. Classificador fuzzy não supervisionado aplicado à detecção de biomas: uma aplicação do algoritmo FCM e dos índices de validação de clusters. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. Anais... Curitiba: Inpe, 2011. p. 7348-7355.

INPE. Manuais: Tutorial de Geoprocessamento. 2006. Disponível em: <<http://www.dpi.inpe.br/spring/portugues/manuais.html>>. Acesso em: 02 jun. 2015.

LANDIS, J. R; KOCH, G. G. The measurement of observer agreement for categorical data. *Internacional Biometrics Society*, v.33, n. 1. p.159-174, 1977.

LUZ, N. B. et al. Segmentação multirresolução e classificação orientada a objetos aplicados a imagem spot-5 para o mapeamento do uso da terra. *Revista Floresta, Curitiba*, v. 40, n. 2. p. 429-446, 2010.

MACHADO, A. M. L.; MITISHITA, E. A. Detecção automática de contornos de edificações utilizando imagem gerada por câmara digital de pequeno formato e dados Lidar. *Boletim de Ciências Geodésicas, Curitiba*, v. 12, n. 2. p.215-233, 2006.

MAMDANI, E. H.; ASSILLAN, S. An Experiment in Linguistic Synthesis with a Fuzzy Logic Controller. *International Journal of Man-Machine Studies, Amsterdam*, v. 7, n. 1, p. 1-13, 1975.

MENDES, T. S. G.; DAL POZ, A. P. Classificação de imagens aéreas de alta-resolução utilizando Redes Neurais Artificiais e dados de varredura laser. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 15., 2011, Curitiba. Anais... Curitiba: Inpe, 2011. p. 7792-7799.

MINITAB 17. Suporte ao MINITAB 17. 2016. Disponível em < <http://support.minitab.com/pt-br/minitab/17/>>. Acesso em 14 mar. 2016

NÓBREGA, R. A. A. Detecção da malha viária na periferia urbana de São Paulo utilizando imagens de alta resolução espacial e classificação orientada a objetos. 2007. 166 f. Tese (Doutorado em Engenharia), Universidade de São Paulo, São Paulo, 2007.

OLIANI, L. O. Noções de Cadastro territorial Multifinalitário - CTM. Série de Cadernos Técnicos, Curitiba: Crea-PR, v. 1, n. 1. p. 1-36, 2016.

OLIVEIRA, A. L. S. Modelagem espacial de predição de riscos de incêndios com lógica fuzzy, comparação e validação. 2013. 162 f. Dissertação (Mestrado em Ciências Geodésicas e Tecnologias da Informação), Universidade Federal de Pernambuco, Recife, 2013.

PERROCA, M. G.; GAIDZINSKI, R. R. Avaliando a confiabilidade interavaliadores de um instrumento para classificação de pacientes - coeficiente Kappa. Revista da Escola de Enfermagem da USP, São Paulo, v. 37, n. 1. p.72-80, 2003.

PINHO, C. M. D. et al. Classificação automática de cobertura do solo urbano em imagem IKONOS: comparação entre a abordagem pixel-a-pixel e orientada a objetos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12., 2005, Goiânia. Anais... Goiânia: Inpe, 2005. p. 16-21.

PINHO, C. M. D. et al. Influência de Diferentes Padrões de Ocupação do Solo Urbano na Qualidade de Mapeamentos de Cobertura do Solo em Imagens de Alta Resolução Espacial: Estudo de Caso de São José dos Campos (SP). In: BLASCHKE, T. et al. (Org.). Sensoriamento Remoto e SIG Avançados: Novos Sistemas Sensores, Métodos Inovadores. São Paulo: Ed. Oficina de Textos, 2007. p. 198-208.

PONZONI, F. J.; ALMEIDA, E. S. A estimativa do parâmetro Kappa (K) da análise multivariada discreta no contexto de um SIG. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. Anais... Salvador: Inpe, 1996. p. 729-733.

RIBEIRO, S. R. A. et al. Aplicação da metodologia de dados orientado a objeto na classificação de uma área urbanizada, utilizando uma imagem digital obtida por meio da tecnologia do laser scanner. In: SIMPÓSIO BRASILEIRO DE GEOMÁTICA, 1., 2002, Presidente Prudente. Anais... Presidente Prudente: Unesp, 2002. p. 144-149.

RIBEIRO, R. R. Histórias de Bairros de Belo Horizonte: Regional Norte. 1.ed. Belo Horizonte: Arquivo Público, 2011.

ROSA, D. M. Sistema LIDAR portátil terrestre: estudos e aplicações florestais. 2014. 31 f. Monografia (Especialização em Gestão Florestal), Universidade Federal do Paraná, Curitiba, 2014.

ROSARIO, L. S. et al. Classificação orientada a objeto no mapeamento do uso e cobertura do solo – uma aplicação da modelagem fuzzy. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. Anais... Florianópolis: Inpe, 2007. p. 6099-6101.

ROVEDDER, J. Validação da classificação orientada a objetos em imagens de satélite ikonos II e elaboração de indicadores ambientais georreferenciados no município de Torres, planície costeira do Rio Grande do sul. 2007. 93 f. Dissertação (Mestrado em Sensoriamento Remoto), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2007.

SILVA, L. M. et al. Modelagem fuzzy aplicada na detecção da vulnerabilidade à erosão costeira. Boletim de Ciências Geodésicas, Curitiba, v. 19, n. 4. p.746-764, 2013.

SOARES FILHO, B. S. et al. Nexos entre as dimensões socioeconômicas e o desmatamento: A caminho de um modelo integrado. In: BATISTELLA, M. et al. (Org.). Amazônia. São Paulo: Ed. Natureza e Sociedade em Transformação, 2008. p. x-x.

SOUZA, S. A. Processamento digital de fotografias aéreas para análise do uso do solo. 2005. 67 f. Dissertação (Mestrado em Agronomia), Universidade Estadual Paulista, Botucatu, 2005.

SUAREZ, A. F. et al. Avaliação de acurácia da classificação de dados de sensoriamento remoto para o município de maragogipe. In: SIMPÓSIO BRASILEIRO DE CIÊNCIAS GEODÉSICAS E TECNOLOGIAS DA INFORMAÇÃO, 4., 2012, Recife. Anais.... Recife: SIMGEO, 2012. p. 1-10.

TANSCHKEIT, R. Sistemas Fuzzy. Rio de Janeiro: Departamento de Engenharia Elétrica, PUC-Rio, 2004.

WEHR, A.; LOHR, U. Airborne Laser scanning an introduction and overview. Journal Of Photogrammetry and Remote Sensing, v. 54, n. 2, p. 68-82, 1999.

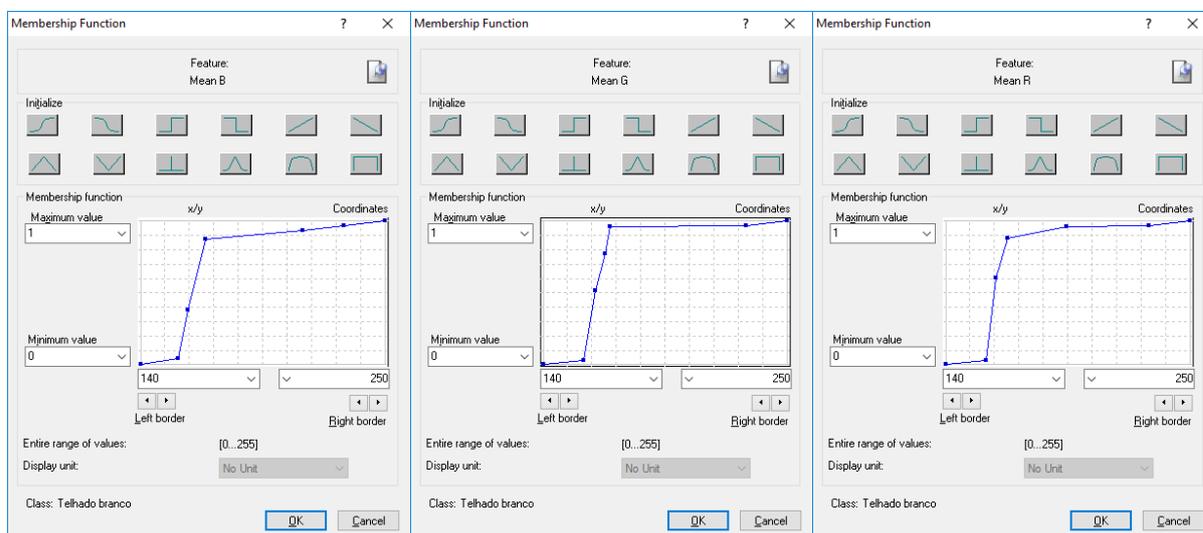
WOODCOCK, C.E.; et al. Mapping forest vegetation using Landsat TM imagery and a canopy reflectance model. *Remote Sensing of Environment*, v. 50, n. 3, p. 240-254, 1994.

ZADEH, L. A. Fuzzy sets. *Information and Control*, v. 8, n. 1, p. 338-353, 1965.

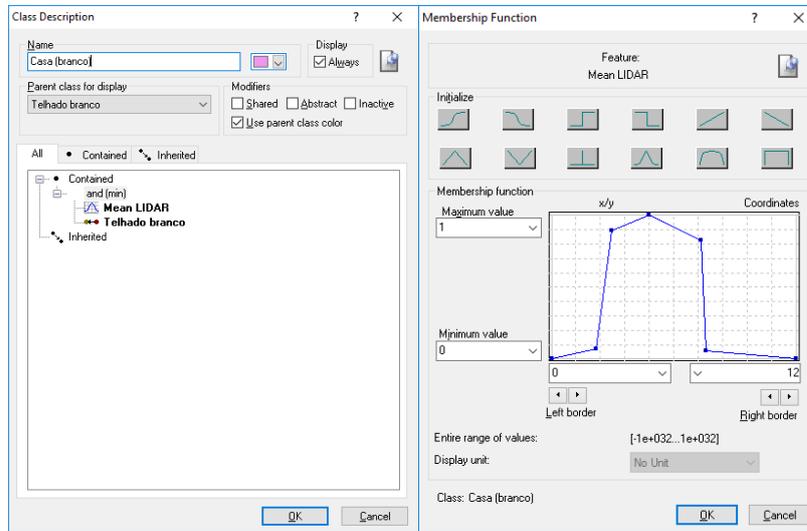
ANEXO I

Funções de pertinência *fuzzy* definidas no *software* eCognition para cada classe. Os descritores de classe (espectrais, forma, vizinhança, entre outros) dos segmentos obtidos no eCognition foram analisados com o objetivo de identificar o conjunto de características que melhor definisse as classes. Foram analisados diversos atributos, como por exemplo, média da refletância dos objetos nas bandas R, G, B e NIR, valores obtidos para operação entre bandas, tamanho (em número de *pixels*) dos objetos, relação do comprimento x largura dos objetos, média da altura dos objetos com base nos valores obtidos pelo processamento do LIDAR, entre outros. Assim, foi possível identificar o conjunto de descritores e suas respectivas funções que melhor representasse cada uma das classes. Adicionalmente, foram realizados diversos testes para customização das funções de pertinência, visando melhor adequação destas ao comportamento das classes.

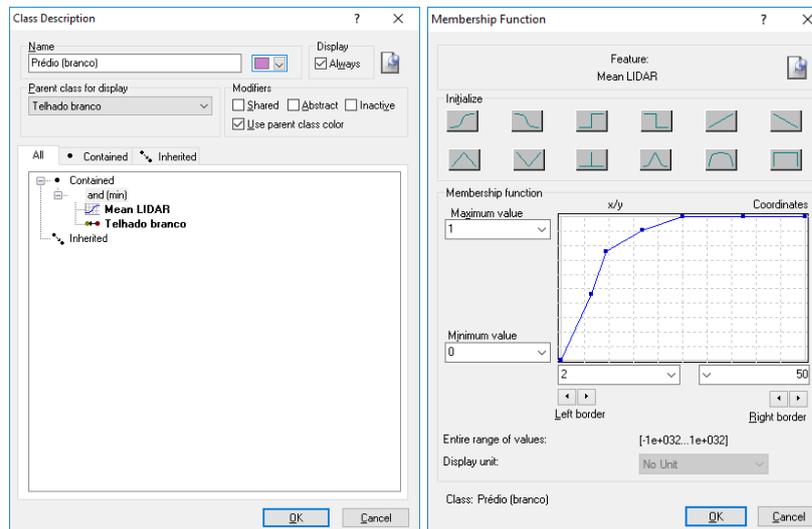
TELHADO BRANCO



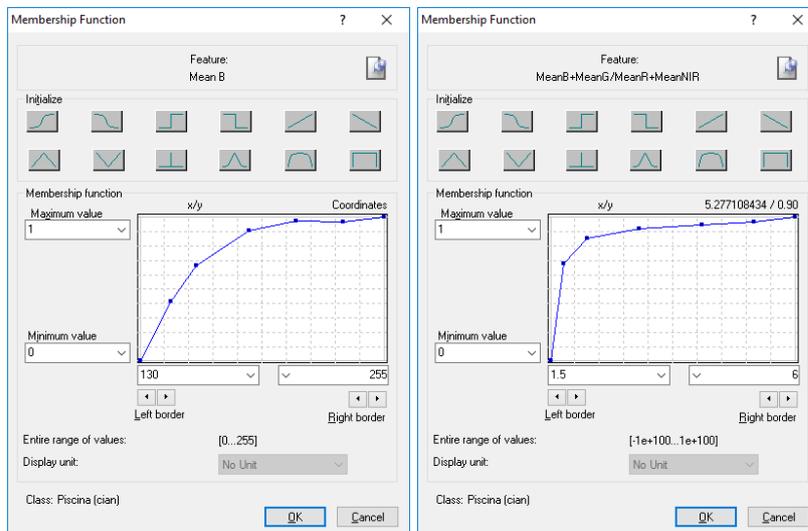
CASA (TELHADO BRANCO)



PRÉDIO (TELHADO BRANCO)



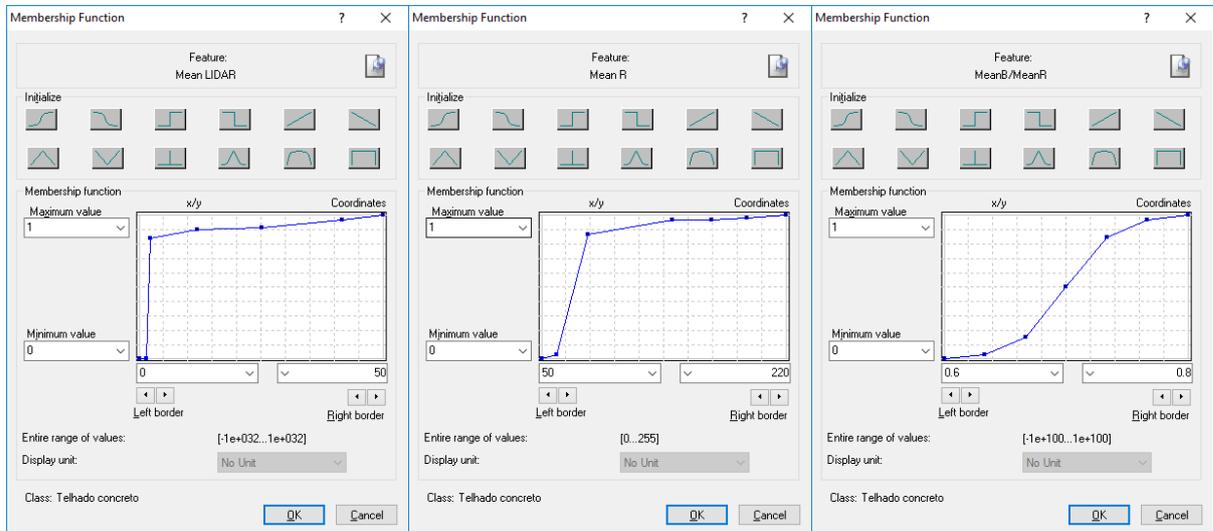
PISCINA (CIAN)



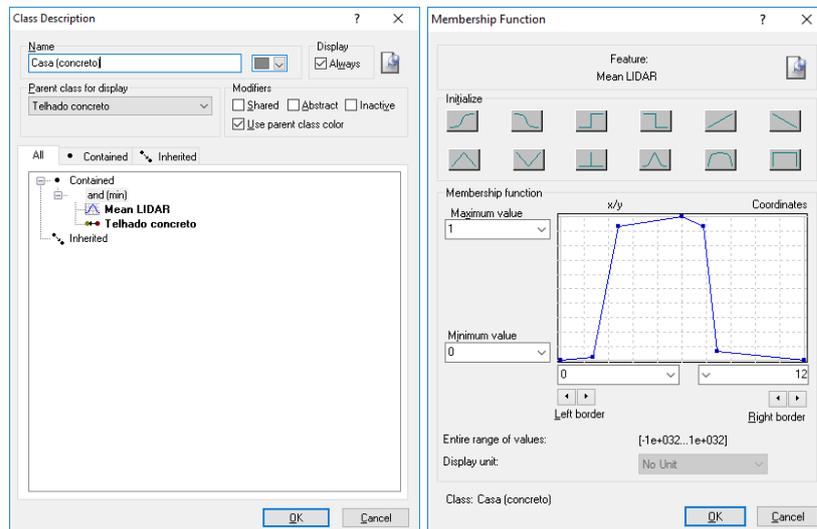
CONCRETO



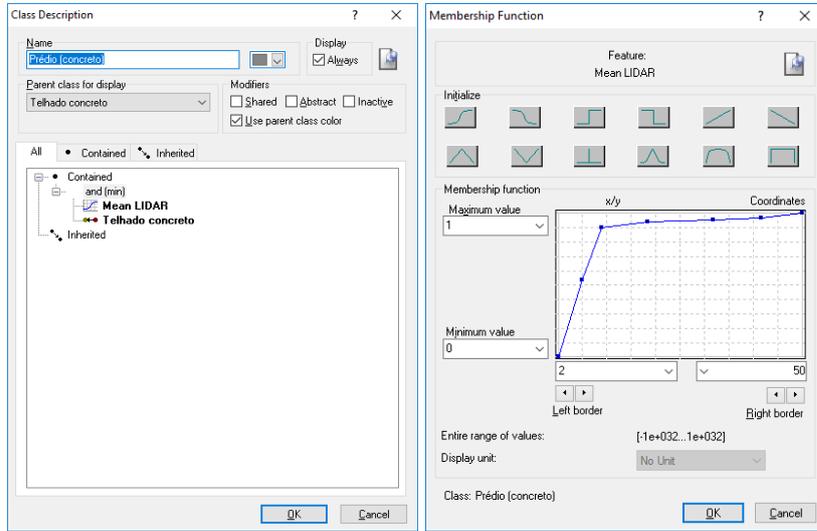
TELHADO CONCRETO/METÁLICO



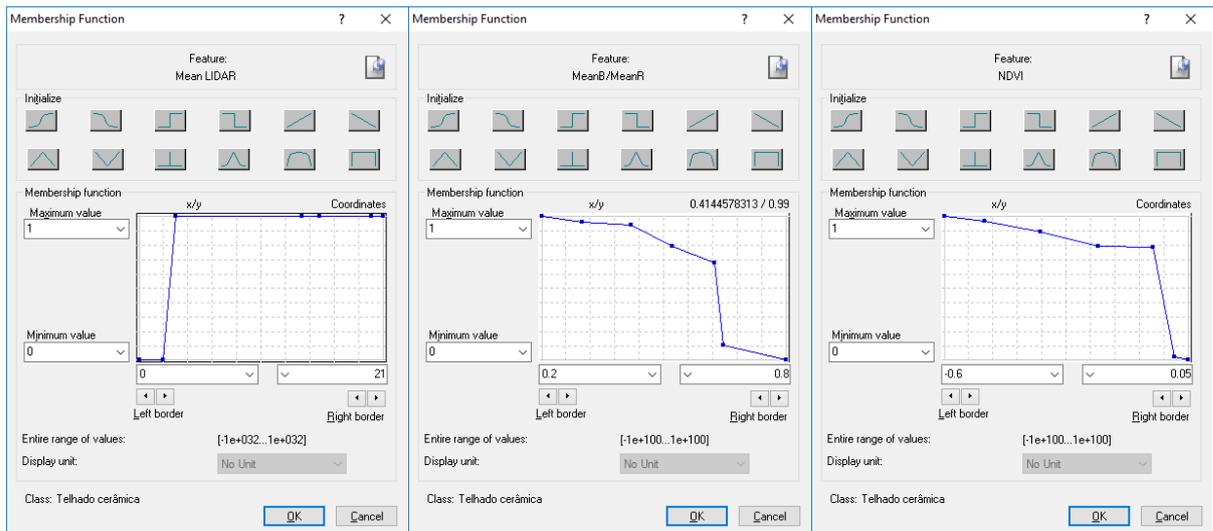
CASA (TELHADO CONCRETO)



PRÉDIO (TELHADO CONCRETO/METÁLICO)



TELHADO DE CERÂMICA

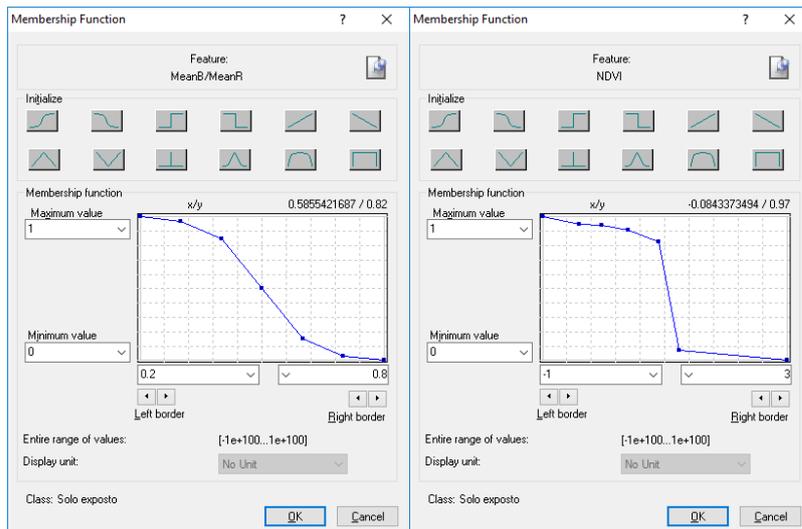
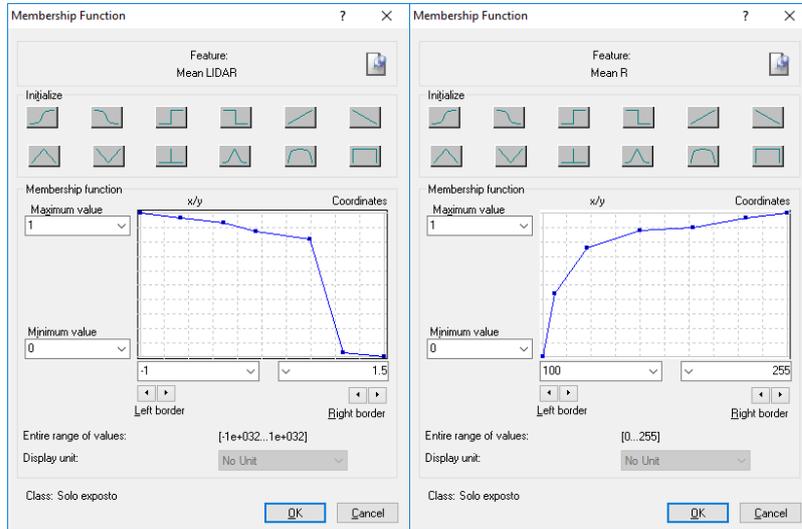


PAVIMENTAÇÃO

The image displays five screenshots of the 'Membership Function' dialog box, arranged in two rows. Each dialog box is used to define a membership function for a specific feature, with a graph showing the function's curve and various input parameters.

- Top Left:** Feature: Area. The graph shows a curve that starts at 0 at x=3000 and rises to 1 at x=19271556. The entire range of values is [0..1.9272e+007] in Pixels.
- Top Middle:** Feature: Mean G. The graph shows a curve that starts at 1 at x=80 and decreases to 0 at x=255. The entire range of values is [0..255] in No Unit.
- Top Right:** Feature: Mean LIDAR. The graph shows a curve that starts at 1 at x=0 and decreases to 0 at x=1.5. The entire range of values is [-1e+032..1e+032] in No Unit.
- Bottom Left:** Feature: NDVI. The graph shows a curve that starts at 1 at x=-10 and decreases to 0 at x=80. The entire range of values is [-1e+100..1e+100] in No Unit.
- Bottom Right:** Feature: Rel. border to Calçada impermeável. The graph shows a linear curve from 0 at x=0 to 1 at x=1. The entire range of values is [0..1] in No Unit.

SOLO EXPOSTO



SOMBRA

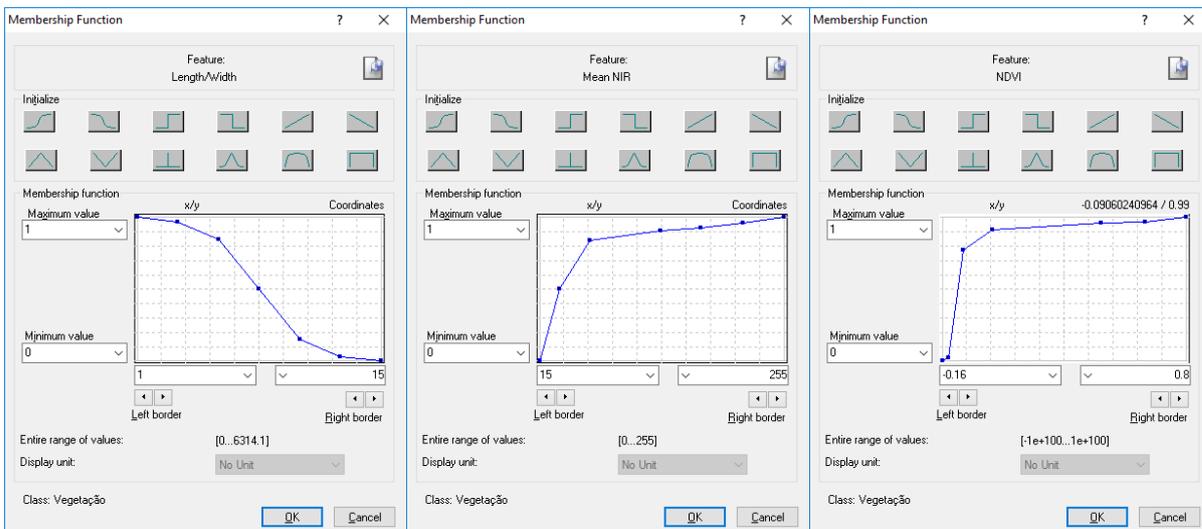
The top row shows three 'Membership Function' dialog boxes. Each dialog has a 'Feature' field, an 'Initialize' section with 12 function icons, a graph area, and control fields for 'Maximum value', 'Minimum value', 'Left border', and 'Right border'. The 'Entire range of values' and 'Display unit' are also specified.

- Feature: Area**: Maximum value: 1, Minimum value: 0, Left border: 500, Right border: 19271556, Entire range of values: [0..1.9272e+007], Display unit: Pixels.
- Feature: Mean B**: Maximum value: 1, Minimum value: 0, Left border: 13, Right border: 90, Entire range of values: [0..255], Display unit: No Unit.
- Feature: Mean G**: Maximum value: 1, Minimum value: 0, Left border: 12, Right border: 90, Entire range of values: [0..255], Display unit: No Unit.

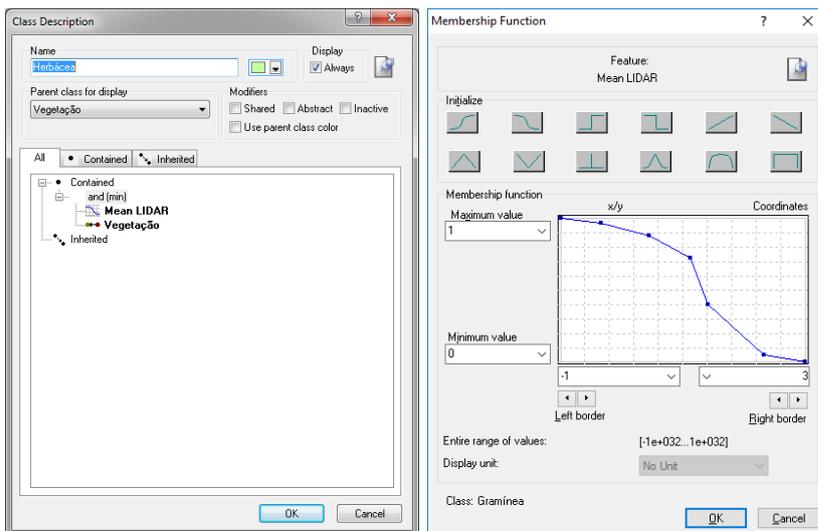
The bottom row shows two 'Membership Function' dialog boxes. Each dialog has a 'Feature' field, an 'Initialize' section with 12 function icons, a graph area, and control fields for 'Maximum value', 'Minimum value', 'Left border', and 'Right border'. The 'Entire range of values' and 'Display unit' are also specified.

- Feature: Mean R**: Maximum value: 1, Minimum value: 0, Left border: 8, Right border: 90, Entire range of values: [0..255], Display unit: No Unit.
- Feature: NDVI**: Maximum value: 1, Minimum value: 0, Left border: 0.3, Right border: 2, Entire range of values: [-1e+100..1e+100], Display unit: No Unit.

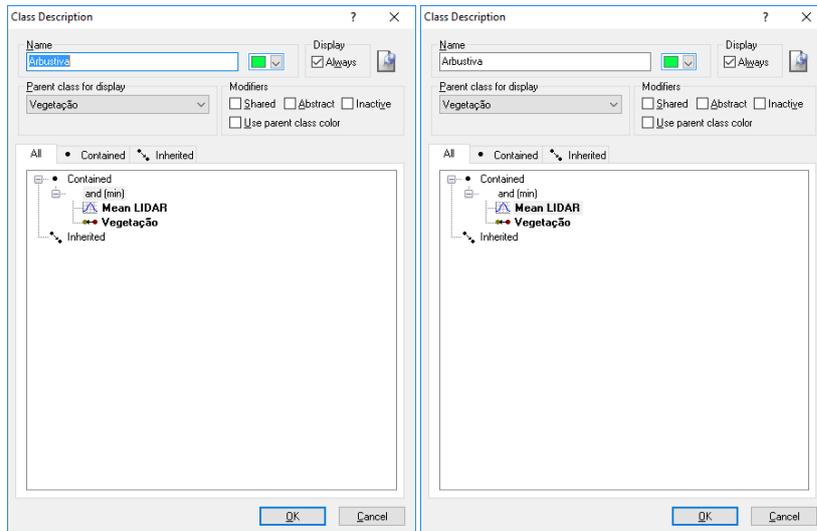
VEGETAÇÃO



HERBÁCEA



ARBUSTIVA



ARBÓREA

