

UNIVERSIDADE FEDERAL DE UBERLÂNDIA – CAMPUS MONTE CARMELO
ENGENHARIA DE AGRIMENSURA E CARTOGRÁFICA

PÂMELA INÊS DE SOUZA CASTRO

EXTRAÇÃO DE TELHADOS POR MEIO DA CLASSIFICAÇÃO ORIENTADA A
OBJETOS DE IMAGENS DE ARPS NO MUNICÍPIO DE MONTE CARMELO - MG

MONTE CARMELO

2020

PÂMELA INÊS DE SOUZA CASTRO

**EXTRAÇÃO DE TELHADOS POR MEIO DA CLASSIFICAÇÃO ORIENTADA A
OBJETOS DE IMAGENS DE ARPS NO MUNICÍPIO DE MONTE CARMELO - MG**

Trabalho apresentado como requisito para a
obtenção de aprovação na disciplina de Trabalho
de Conclusão de Curso 2 do curso de Engenharia
de Agrimensura e Cartográfica da Universidade
Federal de Uberlândia.

Orientador: Prof. Dr. Rodrigo Bezerra de Araújo
Gallis

Co-orientadora: Prof^ª. Dr^ª. Naíssa Batista da Luz

MONTE CARMELO

2020

PÂMELA INÊS DE SOUZA CASTRO

**EXTRAÇÃO DE TELHADOS POR MEIO DA CLASSIFICAÇÃO ORIENTADA A
OBJETOS DE IMAGENS DE ARPS NO MUNICÍPIO DE MONTE CARMELO - MG**

Trabalho de Conclusão de Curso, como exigência parcial
para a obtenção do Título de Bacharel em Engenharia de
Agrimensura e Cartográfica da Universidade Federal de
Uberlândia.

Aprovado em: ____/____/____

Prof. Dr. Rodrigo Bezerra de Araújo Gallis
Universidade Federal de Uberlândia

Prof^ª. Dr^ª. Naíssa Batista da Luz
Universidade Federal de Uberlândia

Prof^ª. Dr^ª. Luziane Ribeiro Indjai
Universidade Federal de Uberlândia

MONTE CARMELO

2020

AGRADECIMENTOS

Agradeço primeiramente à Deus por toda a força, saúde e sustento derramados sobre a minha vida, me permitindo chegar até aqui.

Aos meus pais, Welton e Marilza, que sempre me apoiaram e me deram forças para seguir os meus sonhos. Vocês são minha inspiração e eu sou muito grata por tudo.

Ao meu irmão Vítor, por sempre me apoiar e alegrar com suas brincadeiras.

A minha avó Rosina (*in memoriam*), que sempre comemorou com muita alegria o estudo de seus filhos e netos, mencionando que esta é a conquista mais valiosa que uma pessoa pode ter.

A minha avó Terezinha, que me apoiou e me ajudou a conquistar meus estudos.

A minha tia e madrinha Máris, por ser uma segunda mãe, sempre me apoiando e incentivando a buscar o melhor para mim.

A minha tia Gláucia, que me apoiou, incentivou e ajudou a conquistar meus estudos.

Ao meu namorado Carlos, por todo o seu amor e companheirismo, nos momentos bons e ruins, me apoiando, ajudando e alegrando os meus dias.

Aos meus orientadores, professor Dr. Rodrigo Gallis e professora Dra. Náissa Batista, por terem aceitado estar comigo neste projeto, por todo o conhecimento transmitido e por terem acreditado em mim.

A professora Dra. Luziane Indjai, por ter aceito o convite para participar como membro convidada na banca de defesa deste trabalho.

Ao coordenador do curso, professor Dr. Fernando Santil e ao técnico administrativo do curso, Guilherme Miranda por todo auxílio prestado neste momento de pandemia.

Aos demais professores do curso, que contribuíram de forma imensurável para todo o conhecimento adquirido nestes cinco anos.

Aos meus amigos da 11ª turma e demais colegas do curso de Engenharia de Agrimensura e Cartográfica, que de alguma forma fizeram parte da minha formação.

A Universidade Federal de Uberlândia – Campus Monte Carmelo e ao Laboratório de Sensoriamento Remoto e Fotogrametria (LASER), por todo o suporte prestado durante a graduação e realização deste trabalho.

RESUMO

Visando o crescente avanço das técnicas de fotogrametria digital, sensoriamento remoto, processamento digital de imagens e da visão computacional, podem ser obtidos novos mecanismos de otimização no ramo dos serviços, em especial para a área das engenharias. Com isso, este trabalho apresentou uma metodologia que visa a extração semiautomática de telhados por meio da classificação orientada a objetos utilizando o *software eCognition* e um mosaico originado de voo com ARP. O trabalho apresentou algumas inconsistências na classificação dos telhados de cerâmica, concreto, metal e fibrocimento, bem como as dificuldades que são encontradas durante os procedimentos desse tipo de classificação. O resultado obtido por meio da análise estatística demonstrou que, com base nos 30 pontos amostrados ao nível de significância de 5%, aceitou-se a hipótese de que não há diferença na média entre as coordenadas E (Leste) e N (Norte) do centroide dos polígonos vetorizados manualmente e classificados. Também foi aceita a hipótese de que não há diferença entre a média das áreas construídas dos polígonos vetorizados manualmente e classificados. Em contrapartida, analisando a área definida como representação do desempenho da classificação, conclui-se que as feições extraídas não podem ser utilizadas para fins cadastrais, devido ao erro relativo percentual encontrado nas três edificações distintas. Porém, o método poderá ser utilizado em demais atividades de identificações de edificações, como por exemplo, na detecção de novos imóveis presentes nos municípios, permitindo a atualização do banco de dados com informações importantes para o planejamento urbano e demais ações. Para a metodologia do trabalho se tornar viável, é recomendável que seja feita uma adaptação de forma a garantir a obtenção e extração das informações, aumentando a precisão e acurácia das classificações.

Palavras chaves: Extração de Telhados, Classificação Orientada a Objetos, ARP, PDI.

LISTA DE FIGURAS

Figura 1 - Voo fotogramétrico	6
Figura 2 – Faixas de voo para a sobreposição longitudinal e lateral entre fotografias	7
Figura 3 – Exemplos de marcas de sinalização	8
Figura 4 – Principais regiões do espectro eletromagnético	9
Figura 5 – Mapa de localização da área de estudo	16
Figura 6 – Fluxograma das etapas principais do projeto	17
Figura 7 – Pontos de controle coletados por meio de receptor GNSS	19
Figura 8 – Interface do software eCognition Developer 64	21
Figura 9 – Análise do fator de escala 100, 125 e 150 para a área de edificações	22
Figura 10 - Análise do fator de escala 100, 125 e 150 para a área de pavimentação	22
Figura 11 - Análise do fator de escala 100, 125 e 150 para a área de vegetação	23
Figura 12 - Exemplo da presença de telhados de cerâmicas e dos telhados metálico, de concreto ou de fibrocimento	29
Figura 13 – Mosaico da área de estudo	31
Figura 14 – Modelo Digital de Superfície da área de estudo	32
Figura 15 – Modelo Digital do Terreno	33
Figura 16 – Modelo Digital de Elevação da área de estudo	34
Figura 17 – (A) Classificação das feições edificadas com cobertura de telhas de cerâmica. (B) Zoom para exemplificar a classificação e suas inconsistências.	36
Figura 18 – (A) Classificação das feições edificadas com cobertura de telhados metálico, de concreto ou de fibrocimento. (B) Zoom para exemplificar a classificação e suas inconsistências.	37
Figura 19 – (A) Classificação dos telhados de cerâmica e dos telhados metálicos, de concreto e fibrocimento. (B) Zoom para exemplificar as classificações e suas inconsistências.	38

LISTA DE QUADROS

Quadro 1 – Parâmetros do voo	18
Quadro 2 – Classes espectrais extraídas do mosaico	25
Quadro 3 – Apresentação visual entre os polígonos classificados e os vetorizados	40

LISTA DE TABELAS

Tabela 1 – Árvore de processos para extração das feições edificadas com telhados de cerâmica	27
Tabela 2 - Árvore de processos para extração das feições edificadas com telhados metálico, de concreto ou de fibrocimento	28
Tabela 3 – Tempo de processamento para a classificação dos telhados de cerâmica	35
Tabela 4 – Tempo de processamento para a classificação dos telhados metálico, de concreto ou de fibrocimento	37
Tabela 5 - Comparação da área construída entre os polígonos classificados e vetorizados	40
Tabela 6 – Teste-t pareado para a coordenada E (Leste) do centroide dos polígonos vetorizados e classificados	41
Tabela 7 - Teste-t pareado para a coordenada N (Norte) do centroide dos polígonos vetorizados e classificados	42
Tabela 8 - Teste-t pareado para a área construída dos polígonos vetorizados e classificados	43

LISTA DE ABREVIACÕES E SIGLAS

ANAC	Agência Nacional de Aviação Civil
ARP	Aeronave Remotamente Pilotada
CTM	Cadastro Técnico Multifinalitário
FSO	<i>Feature Space Optimization</i>
GNSS	<i>Global Navigation Satellite System</i>
LASER	Laboratório de Sensoriamento Remoto e Fotogrametria
LiDAR	<i>Light Detection and Ranging</i>
MDE	Modelo Digital de Elevação
MDS	Modelo Digital de Superfície
MDT	Modelo Digital do Terreno
NDRI	<i>Normalized Difference Roof Index</i>
PDI	Processamento Digital de Imagens
RBMC	Rede Brasileira de Monitoramento Contínuo dos Sistemas GNSS
REM	Radiação Eletromagnética
SIG	Sistema de Informações Geográfica
UTM	<i>Universal Transversa de Mercator</i>

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVO.....	2
3. JUSTIFICATIVA.....	3
4. FUNDAMENTAÇÃO TEÓRICA	4
4.1. Extração de contornos de telhados	4
4.2. Cadastro técnico multifinalitário	4
4.3. Regularização fundiária.....	4
4.4. Fotogrametria	5
4.4.1. Conceitos e definições	5
4.4.2. Levantamento aerofotogramétrico	5
4.5. Sensoriamento remoto	8
4.5.1. Conceitos básicos e aplicações	8
4.5.2. Sensores	10
4.5.3. Resolução das imagens	10
4.5.3.1. <i>Resolução espacial</i>	11
4.5.3.2. <i>Resolução temporal</i>	11
4.5.3.3. <i>Resolução radiométrica</i>	12
4.5.3.4. <i>Resolução espectral</i>	12
4.6. Processamento digital de imagens.....	13
4.6.1. Segmentação de imagens	13
4.6.2. Classificação de imagens	13
4.6.3. Classificação orientada a objetos.....	14
4.7. Utilização de aeronaves remotamente pilotadas.....	15
5. MATERIAL E MÉTODOS	15
5.1. Área de estudo	15
5.2. Material.....	16
5.3. Métodos	17
5.3.1. Planejamento de campo	18
5.3.2. Aquisição dos dados	19
5.3.3. Processamento do mosaico e dos modelos	20
5.3.4. Classificação orientada a objetos.....	20

5.3.4.1.	<i>Segmentação.....</i>	21
5.3.4.2.	<i>Otimização do espaço de recursos.....</i>	24
5.3.4.3.	<i>Classificação das edificações com telhados de cerâmica.....</i>	26
5.3.4.4.	<i>Classificação das edificações com telhados metálico, de concreto ou de fibrocimento.....</i>	28
5.3.5.	<i>Análise dos dados</i>	28
6.	RESULTADOS E DISCUSSÕES	30
6.1.	Mosaico, MDS e MDT	31
6.2.	Classificação orientada a objetos.....	35
6.2.1.	Edificação com telhados de cerâmica	35
6.2.2.	Edificação com telhados metálico, de concreto ou de fibrocimento	36
6.2.3.	Classificação orientada a objetos das edificações.....	38
6.3.	Comparação visual e quantitativa entre as edificações classificadas e vetorizadas	39
6.4.	Análise estatística entre as edificações classificadas e vetorizadas.....	41
6.4.1.	Coordenadas E e N dos centroides dos polígonos vetorizados e classificados.....	41
6.4.2.	Área construída dos polígonos vetorizados e classificados	43
7.	CONSIDERAÇÕES FINAIS	44
	REFERÊNCIAS	45

1. INTRODUÇÃO

Decorrente do avanço nas técnicas de imageamento e o aumento da diversidade de sistemas de sensores, houve também uma expansão nas opções de produtos orbitais. Com isso, o sensoriamento remoto juntamente com a fotogrametria e processamento digital de imagens (PDI) vem sendo cada vez mais utilizados em serviços executados em áreas urbanas, devido ao fato de possuir métodos que permitem demonstrar maior e melhor detalhamento sobre as feições dos objetos em alvos urbanos (RIBEIRO; KUX, 2009).

Em razão das intervenções antrópicas, as áreas urbanas sofrem contínuas mudanças em seus aspectos físicos e, dessa forma, requerem frequentes atualizações no banco de dados local. Esses dados são obtidos por meio da criação e atualização do Cadastro Técnico Multifinalitário (CTM), que permite declarar a existência de um imóvel através dos mapeamentos que são elaborados a partir das informações extraídas, tais como as suas condições físicas, características de situação, entre outras informações que geram retorno econômico que permite a sustentabilidade da prefeitura, possibilitando a cobrança de todos os imóveis cadastrados, de forma coerente com o valor da propriedade e sua localização (LOCH, 2001).

Para a criação e a atualização das bases cartográficas neste meio, podem ser utilizados dados recorrentes de fontes de imagens de satélites, imagens aéreas, varredura a laser, plantas baixas, entre outros (OLIANI; ANTUNES, 2011; LUZ; ANTUNES; RATTON, 2017).

Atualmente, os dados dessa natureza vêm sendo obtidos por meio da utilização de Aeronaves Remotamente Pilotadas (ARPs), que por sua vez, vem se destacando no mercado de trabalho por ser uma ferramenta na qual permite capturar informações em alta resolução espectral, espacial, temporal e radiométrica (POTJE et al., 2014).

Sendo assim, Arantes et al. (2018), utilizou ARPs para a atualização de área construída de imóveis urbanos, e para verificar a precisão, vetorizou manualmente as feições urbanas em um mosaico, concluindo que para as resoluções espaciais de 2, 5 e 10 cm, é possível identificar o contorno do telhado sem tantas dificuldades.

Visando então a tecnologia da ARPs e a necessidade de frequente atualização em dados de áreas urbanas, a extração automática de feições urbanas ganha espaço no ambiente de trabalho, pesquisa e educação, devido ao fato de que na maioria dos casos essa extração é realizada de forma manual, o que gera gastos excessivos e demandam tempo (FERREIRA, 2014; POTJE et al., 2014).

Oliveira e Galo (2018), combinaram dados obtidos por meio do sensor remoto ativo *Light Detection and Ranging* (LiDAR) e imagens áreas para a extração automática de telhados, conseguindo extrair melhores contornos em edificações isoladas de sombras e vegetação.

A extração semiautomática dessas feições é realizada por meio da classificação de imagens, que neste trabalho utilizou a classificação orientada a objetos. Nesta classificação, são utilizados objetos de características semelhantes, tais como, nível de cinza, características espectrais, textura, tamanho, forma, compacidade, informação do contexto dos objetos adjacentes, etc., formando assim alguns conjuntos de pixels (SARAIVA, 2013).

A partir desse classificador, torna-se possível identificar e simular o comportamento dos objetos semelhante à identificação realizada por um foto-intérprete, no qual reconhece áreas homogêneas presentes na imagem baseando nas informações espectrais e espaciais (ANTUNES; CORTESE, 2007).

Nesse contexto, este trabalho visou aplicar a classificação orientada a objetos de imagens de alta resolução espacial obtidas por ARPs com o intuito de propor uma metodologia para a extração semiautomática e identificação de contornos de telhados. Diante do exposto, o presente trabalho levantou a hipótese de se extrair de forma semiautomática telhados em áreas urbanas por meio de imagens multiespectrais de alta resolução e modelo digital de elevação (MDE), obtidas por ARPs, utilizando o *software eCognition Developer 64*.

2. OBJETIVO

O presente trabalho teve como objetivo propor uma metodologia para a realização da classificação orientada a objetos dos telhados em área urbana de uma fração do bairro Jardim Américo, localizado no município de Monte Carmelo, utilizando imagens obtidas a partir de sensores acoplados a ARPs, permitindo a adaptação de uma metodologia para a obtenção de informações relevantes ao CTM com resultados de alta qualidade. Tendo isto em vista, foram os objetivos específicos:

- Extrair contornos de telhados por meio da classificação orientada a objetos;
- Avaliar o potencial da extração de telhados utilizando as técnicas de classificação orientada a objetos.

3. JUSTIFICATIVA

Devido ao constante crescimento tecnológico do sensoriamento remoto, da fotogrametria digital, do PDI e da visão computacional, podem ser obtidos novos mecanismos de otimização no ramo dos serviços, em especial para a área das engenharias. Com isso, devido aos avanços nas tecnologias dos computadores, o armazenamento e análise de dados tridimensionais em formato digital facilita cada vez mais a visualização e interpretação das informações presentes no ambiente (MACHADO, 2006).

Essas informações auxiliam na criação ou atualização de um determinado banco de dados, como por exemplo o de um CTM. Este, quando combinado com diretrizes nacionais, se torna uma ferramenta de extrema importância no desenvolvimento das ações municipais, pois permite que sejam integralizados dados de diversas naturezas (CUNHA; ERBA, 2010).

Os dados podem ser obtidos por meio da utilização de ARPs, tecnologia na qual vem apresentando diversos resultados positivos em áreas urbanas e rurais, devido à qualidade das imagens obtidas. Estas, juntamente com a classificação orientada a objetos, se tornam grandes parceiras na criação e atualização das bases cartográficas, auxiliando na regularização fundiária dos municípios e trazendo diversos benefícios para os mesmos, tais como: fonte de renda, divisa legal, etc.

Na regularização fundiária, uma etapa importante é a identificação de área construída, que pode ser obtida por meio da extração de telhados dos imóveis edificados, para que dessa maneira, sejam realizadas corretamente as tomadas de decisão do município, a cobrança dos impostos ou quaisquer outros pontos de interesse.

O processo de extração automatizada das feições geradas por meio das atividades antrópicas (construções, por exemplo), são de extrema importância, pois permitem que os objetos da imagem sejam isolados para uma posterior análise (GALLIS, 2006).

Portanto, este trabalho se faz importante pelo fato que o mesmo testa uma metodologia semiautomática de extração de telhados em imagens digitais, que poderá permitir a obtenção de resultados rápidos de uma das etapas mais onerosas e demorada da criação e atualização de bases cartográficas em áreas urbanas, podendo o produto final ser utilizado em diversas áreas do planejamento e em tomadas de decisões.

4. FUNDAMENTAÇÃO TEÓRICA

4.1. Extração de contornos de telhados

Decorrente do desenvolvimento econômico, social e das ações naturais, ocorrem diversas alterações na cobertura terrestre, onde faz-se necessário a atualização da base cartográfica local para o auxílio do planejamento urbano, tributações, monitoramento do crescimento, avaliações de desastres naturais, entre outros (CARRILHO et al., 2018).

De acordo com Oliveira e Galo (2018), para fins de aplicações cartográficas, uma forma de adquirir e atualizar dados espaciais de um Sistema de Informações Geográficas (SIG) é por meio da extração de telhados, na qual possibilita a tomada de decisões em diversas áreas de planejamento.

Atualmente, pesquisadores das áreas de fotogrametria, sensoriamento remoto e, principalmente, da área do PDI, vêm estudando e buscando diferentes formas de se obter a extração das feições de telhados, obtidas por meio de imagens aéreas (OLIVEIRA; GALO, 2018).

4.2. Cadastro técnico multifinalitário

O cadastro técnico é o termo que apresenta tecnologias para a execução de medições de imóveis, onde são registradas diversas informações sobre o mesmo (LOCH, 2001).

O CTM é o meio onde ocorre o gerenciamento das informações sobre um determinado local, que são integradas em um banco de dados, podendo ser visualizadas de forma gráfica, auxiliando no desenvolvimento de diversas tomadas de decisão das cidades, pois é um método que permite a estruturação e organização de uma enorme quantidade de dados de diversas naturezas, tais como informações envolvendo o espaço territorial: lote, imóvel, área construída, entre outros (PEREIRA, 2009).

4.3. Regularização fundiária

Com o crescimento acelerado e contínuo da população, os centros urbanos vem sendo cada vez mais desenvolvidos sem que haja planejamento e controle do mesmo, gerando assim as ocupações irregulares (OLIVEIRA, 2019). Dessa forma, no dia 15 de março de 2018 foi

publicado o Decreto nº 9.310 que institui as normas e procedimentos gerais para a Regularização Fundiária Urbana.

Com isso, se faz necessário a atualização frequente das edificações presentes em áreas urbanas. Com o avanço da tecnologia, esse processo pode ser feito de diversas formas, e uma delas é por meio da obtenção de imagens, na qual contém informações que, após serem processadas, fornecem dados importantes para a atualização de um determinado banco de dados.

4.4. Fotogrametria

4.4.1. Conceitos e definições

Para a *American Society of Photogrammetry* (1966) a fotogrametria é definida como, “A arte, ciência e tecnologia de obtenção de informação confiável sobre objetos físicos e o meio ambiente através de processos de gravação, medição e interpretação de imagens fotográficas e padrões de energia eletromagnética radiante e outras fontes”. De acordo com Tommaselli et al., (1999), o termo fotogrametria origina-se das palavras gregas *photos*, *gramma* e *metron*, que significam luz, algo desenhado e medir, respectivamente.

Pode-se dizer então, que a Fotogrametria é uma técnica na qual é possível estudar e definir formas, dimensões e posições de objetos presentes no espaço, por meio de medições adquiridas por fotografias ou imagens digitais (FONTES, 2005).

As principais vantagens da fotogrametria estão relacionadas com a quantidade de informações que são obtidas por meio da fotointerpretação e também pela agilidade em realizar levantamentos de forma mais rápida (LINS, 2019).


4.4.2. Levantamento aerofotogramétrico

A etapa inicial para o mapeamento aéreo é o planejamento, onde são determinados os parâmetros que serão utilizados, visando atender a escala, precisão e os instrumentos necessários para a execução do projeto.

Para a etapa do voo, é necessário que seja determinada a área a ser levantada, bem como sua localização e a dimensão espacial, o tipo de representação cartográfica, a escala, a precisão pretendida, entre outros aspectos relevantes (REDWEIK, 2007).

Os voos são planejados de modo que a área a ser levantada possua uma cobertura formada por um conjunto de fotografias verticais, capturando de forma sucessivas, a mesma zona de superfície terrestre em duas ou mais imagens distintas, formando a sobreposição de imagens (Figura 1) (REDWEIK 2007).


Figura 1 - Voo fotogramétrico



Fonte: Redweik (2007).

Para fins de mapeamento, as linhas de voos são planejadas de maneira que as fotografias possuam uma região em comum de sobreposição, sendo a longitudinal, que geralmente cobre uma área de 60% e a lateral, que frequentemente cobre uma área de 25% a 30% (Figura 2) (REDWEIK, 2007; TOMMASELLI, 2009).

Figura 3 – Exemplos de marcas de sinalização



Fonte: Redweik (2007).

4.5. Sensoriamento remoto


4.5.1. Conceitos básicos e aplicações

Existem diversas maneiras de se obter informações sobre um objeto. De modo geral, podemos classificá-las de duas formas: direta e indireta. A coleta de dados de campo, normalmente referida como coleta *in situ* ou *in loco*, é um exemplo de forma direta. Já as coletas feitas de forma indireta, são aquelas executadas remotamente, sem ter contato com o alvo de estudo. Dessa forma, podemos citar o sensoriamento remoto como um exemplo de forma indireta. (JENSEN, 2014).

Segundo Meneses e Almeida (2012), a definição mais conhecida e clássica de sensoriamento remoto é: “Sensoriamento remoto é uma técnica de obtenção de imagens dos objetos da superfície terrestre sem que haja um contato físico de qualquer espécie entre o sensor e o objeto”. Sendo assim, os sensores captam a energia que é refletida da superfície dos alvos e armazenam as informações de forma apropriada, então essa imagem é representada em duas ou mais dimensões (QUEIROZ; GOMES, 2001). Este é um ponto extremamente importante, uma vez que a partir dessa separação, é possível estudar as variações do espectro eletromagnético para entender os processos físicos que ocorrem na obtenção de imagens (NOVO, 2010).

O espectro eletromagnético pode ser definido como “o conjunto de ondas eletromagnéticas que compõem o campo de radiação de um determinado objeto” (NOVO, 2010). As ondas conhecidas variam desde os raios gama até as ondas de rádio, conforme é mostrado na Figura (4).

Figura 4 – Principais regiões do espectro eletromagnético



Fonte: Figueiredo (2005).

As principais regiões do espectro eletromagnético utilizadas no estudo dos objetos da superfície terrestre são: a região do visível e do infravermelho. Quando essas ondas entram em contato com alvos físicos, elas podem ser refletidas ou absorvidas. A capacidade que um determinado objeto tem de refletir a radiação eletromagnética (REM), sob ele incidente é chamada de reflectância. Existem fatores de reflectância que são intrínsecos a cada objeto, e que ditam a capacidade do mesmo em refletir a REM. Estes fatores podem ser bidirecionais, quando existe mais de uma geometria em contato com o objeto. Dessa forma, a reflectância é calculada considerando o quanto de radiação é incidido sobre o objeto, e a sua capacidade de refletir esta radiação, em uma dada região espectral (PONZONI; SHIMABUKURO; KUPPLICH, 2012).

Normalmente, a REM registrada nas imagens tem como fonte primária o sol, que é o responsável por emití-la por todo espaço. A intensidade do fluxo radiante emitido pelo sol é chamado de irradiância, e outro conceito importante e complementar aos demais é a radiância. Para Ponzoni, Shimabukuro e Kuplich (2012) a radiância “é a intensidade média do fluxo radiante refletido, originando então de todas as infinitas intensidades provenientes de cada um dos infinitos pontos existentes na superfície”.

4.5.2. Sensores

Para formar as imagens com informação proveniente da reflectância dos objetos, são utilizados os sensores, que podem ser acoplados a aeronaves terrestres ou orbitais. Estes podem ser definidos como “sistemas responsáveis pela conversão da energia proveniente dos objetos em um registro na forma de imagem ou gráfico, que permite associar a distribuição da radiância ou retroespalhamento com suas propriedades físicas, químicas, biológicas ou geométricas” (NOVO, 2010).

Existem várias maneiras nas quais pode se classificar um sensor. Inicialmente, é considerado qual a fonte de energia utilizada, podendo ser classificados como ativos ou passivos. Os sensores passivos são descritos como aqueles que registram a radiação solar emitida ou refletida pelos seus respectivos alvos dispostos na superfície terrestre e podem ser definidos como aqueles que dependem de fontes externas de radiação para que possam processar as informações provenientes dos objetos. Já os sensores ativos podem ser definidos como aqueles que são capazes de produzir sua própria energia radiante, que entrará em contato com objetos da superfície. Os exemplos mais comuns são os radares e *lasers* (JENSEN, 2014).

De forma didática, os sensores também podem ser definidos como imageadores e não imageadores. A principal diferença entre esses dois tipos de sensores está no seu produto final. Isto é, um sistema imageador é apto a produzir imagens com informações espaciais e o sistema não imageador mede a intensidade de radiação proveniente dos alvos sem necessariamente gerar uma imagem. Um exemplo de sistema não imageado são os sensores que captam informações referentes à altitude (NOVO, 2010).

4.5.3. Resolução das imagens

Em sensoriamento remoto existem diversas tecnologias que são utilizadas para a obtenção de imagens. Atualmente, elas são divididas principalmente em duas categorias: a orbital e a aerofotogramétrica. Sensores são acoplados tanto a satélites, quanto às ARPs. Cada categoria apresenta suas vantagens e desvantagens, embora existam características comuns a estas e a qualquer outro meio de obtenção de imagem em sensoriamento remoto.

Independente do meio de obtenção de imagens, uma forma de abordar as potencialidades de um sensor e as características das suas imagens geradas é por meio de suas resoluções. As resoluções estão diretamente ligadas com a qualidade das imagens, sendo que a

priorização de alguma delas depende das finalidades para qual um determinado sensor está sendo desenvolvido (FIGUEIREDO, 2005).

4.5.3.1. Resolução espacial

Podemos definir a resolução espacial de uma imagem como sendo a proporção direta de área representada por cada elemento da imagem (do termo em inglês, *picture element*, ou *pixel*) em uma cena. Em outras palavras, esta representa o menor objeto possível a ser distinguido pelo sensor em questão.

Existem vários componentes que influenciam a resolução espacial de um sensor, como os detectores e distância focal do sistema óptico, que quanto maior for menor será a área de cobertura. Para que um determinado objeto seja registrado na superfície terrestre, ele terá que ter dimensões iguais, ou maiores, que os valores de resolução do terreno. Desse modo, se o objeto for menor que esse valor mínimo, ele não será detectado (NOVO, 2010).

A resolução espacial corresponde a capacidade do sensor em identificar objetos, ou seja, ela representa o menor elemento da superfície que o sensor consegue individualizar (MORAES, 2002). O valor que cada pixel representado depende da qualidade de resolução do sensor. Sensores com alta resolução espacial são capazes de imagear pequenos objetos na superfície terrestre. Da mesma forma, quanto mais baixa a resolução de um sensor menor é a sua capacidade de registrar objetos pequenos (NOVO, 2010).

4.5.3.2. Resolução temporal

Segundo JENSEN (2014), no sensoriamento remoto a resolução temporal refere-se ao tempo de revisitada de um determinado sensor, que é a frequência para registrar imagens e quando ele as registra. Esses padrões podem ser estabelecidos porque os satélites executam uma órbita heliossíncrona, que é um caso particular de uma órbita semipolar, “O plano de órbita é sempre fixo e ortogonal ao sentido de rotação da Terra” (MENESES; ALMEIDA 2012).

As resoluções espaciais e temporal estão diretamente ligadas uma a outra. Geralmente, quanto maior a resolução temporal exigida, menor é a resolução espacial alcançada. Em casos de monitoramentos contínuos de determinada área da superfície, os sensores cobrem porções pequenas da superfície. Em contrapartida, quanto maior a resolução espacial exigida, menor será a resolução temporal do sensor (JENSEN, 2014).

4.5.3.3. Resolução radiométrica

Segundo Novo (2010), a resolução radiométrica de um sensor está relacionada com a sua capacidade de perceber mudanças no nível de energia refletida ou retroespalhada que parte da superfície dos objetos. As diferenças apresentadas pela energia são contínuas, e devem ser detectadas, registradas e reproduzidas pelo sensor. Desse modo, quanto maior for a capacidade do sensor em interpretar e registrar essas diferenças de intensidade melhor será a sua resolução radiométrica.

Portanto, quanto maior a potencialidade do sensor em discriminar as discrepâncias entre a intensidade dos sinais provenientes dos objetos de estudo, maior será a sua resolução radiométrica. Quanto menor forem as diferenças entre os sinais detectados, maior resolução do sensor. (NOVO, 2010).

4.5.3.4. Resolução espectral

A resolução espectral está relacionada com os comprimentos de onda captados pelos sensores em cada uma de suas bandas. “É uma medida da largura, das faixas espectrais e da sensibilidade do sistema sensor em distinguir entre dois níveis de intensidade o sinal de retorno (resolução radiométrica)” (NOVO, 2010). Um sensor que registra imagens nos comprimentos de onda de 0,4 a 0,5 nanômetros apresenta uma resolução espectral maior que um sensor que opera com o comprimento de onda de 0,4 a 0,6. Essa diferença implica numa melhor caracterização das variações no comportamento espectral dos alvos estudados, principalmente naqueles situados em regiões menores do espectro eletromagnético.

O melhoramento da resolução espectral de sensores normalmente resulta num aumento do número de bandas do mesmo. Quanto maior o recobrimento espectral do sensor, e quanto mais subdividido for, mais bandas ele terá. Sensores com grande resolução espectral são denominados hiperespectrais, e sensores que abrangem vários canais do espectro eletromagnético são denominados multiespectrais. Uma das vantagens do aumento da resolução espectral é a possibilidade de uma melhor análise entre as interações da REM e os alvos da superfície (NOVO, 2010).

4.6. Processamento digital de imagens

Segundo Marques Filho e Vieira Neto (1999), o PDI é baseado em técnicas que permite realizar aplicações que possuem o objetivo de aprimorar as informações de determinada imagem para a interpretação humana e para as análises realizadas por computadores, onde são extraídas informações relevantes de uma cena.

Com a utilização de *softwares* de computação, torna-se possível a análise e manipulação dessas imagens que podem ocorrer por meio de classificações, que é o processo pelo qual são extraídas informações que permitem a compreensão e o reconhecimento de regiões ou objetos individuais contidos em uma imagem (GONZALES; WOODS; EDDINS, 2010).

4.6.1. Segmentação de imagens

A segmentação de imagens se trata do processo no qual a imagem é subdividida em partes ou objetos integrantes (NEVES; PELAES, 2001). Geralmente, a segmentação é baseada em descontinuidade e similaridade dos tons de cinza presentes nas imagens (DLUGOSZ et al., 2008). A descontinuidade é o método onde é avaliado a variação repentina dos valores de cinza, e a similaridade refere-se ao agrupamento dos *pixels* decorrentes das semelhanças existentes entre os *pixels* vizinhos (GONZALES; WINTZ, 1987).

Um fator importante no momento da segmentação da imagem é a escolha correta da escala, que influencia diretamente a obtenção dos objetos significativos (LUZ, 2011).

Portanto, esse critério deve ser escolhido e analisado com cautela, visto que se o fator de escala for baixo, terão muitos objetos identificados na segmentação com regiões contendo poucos *pixels*, e se for muito alto, terá um número menor de regiões contendo vários *pixels*, gerando então uma incoerência no momento da classificação (ALMEIDA FILHO et al., 1998).

4.6.2. Classificação de imagens

A classificação de imagens multiespectrais é feita a partir da análise dos números digitais dos *pixels*. Esses valores são representados por escalas de cinza, sendo os menores valores as tonalidades mais escuras e os valores mais altos, tonalidades mais claras. Os números digitais são definidos de acordo com a reflectância dos alvos presentes na superfície imageada, como água, tipos de vegetação, de solos, de rochas, entre outros. (CRÓSTA, 1992).

Com as classes espectrais contidas nas imagens, torna-se possível a distinção das classes de informação, que é feita por meio da classificação dessas imagens. As formas de se classificar são divididas em basicamente três tipos: manual, automática e semiautomática.

A classificação manual consiste na utilização de imagens multiespectrais de alta resolução espacial, na qual estão representadas as características do uso da terra de forma acurada para que haja uma classificação precisa das informações, porém, trata-se de um processo que exige tempo para ser executado (ANGELINI SOBRINHA, 2016).

A classificação automática se refere a associação de cada *pixel* presente na imagem a classes de informações que representam os tipos de cobertura da superfície terrestre, tais como: vegetação, solo, telhados, entre outros (CRÓSTA, 1992).

A classificação semiautomática é realizada por meio da análise feita pelo *software* escolhido e, havendo erros, a correção é realizada de forma visual por um operador (ESPÍRITO-SANTO et al., 2005). Como exemplo, na análise do tecido urbano são encontradas feições que possuem respostas espectrais semelhantes devido à composição material, como ocorre no caso de ruas, edificações e estacionamentos, por exemplo. Com isso, os *pixels* presentes nas imagens podem conter informações mistas que contribuem para o erro de classificação do *software*.

Sendo assim, classificação semiautomática é um método que agrega vantagens aos processos que foram previamente citados, oferecendo uma considerável importância à fase de edição manual (RIBEIRO; KUX, 2009).

4.6.3. Classificação orientada a objetos

A classificação orientada a objetos considera a delimitação dos objetos a partir das características espectrais semelhantes (regiões de *pixels* adquiridas a partir da segmentação da imagem), obtendo então um número significativo de variáveis a serem consideradas na classificação, como a média e a variância da resposta espectral, as dimensões e forma dos objetos, a textura dos níveis de cinza, relações espaciais entre objetos vizinhos e até mesmo o contexto no qual estão inseridos os objetos (HAY; CASTILLA, 2008).

Segundo Gonçalves, Fonseca e Caetano (2001), o processamento de imagens por meio de classificação orientada a objetos se aproxima mais dos processos cognitivos humanos e permite distinguir melhor as informações do que quando comparado com análises baseadas em *pixels*.

Considerando as semelhanças espectrais que existem nos objetos imageados na superfície, como ocorre no caso das vias que possuem a pavimentação de concreto e as

edificações com cobertura também de concreto, a classificação orientada a objetos torna possível a realização da distinção desses elementos em função de área e forma, por meio da utilização de características de semelhança, que permite analisar a vizinhança e comparar a relação entre os *pixels* (RIBEIRO; KUX, 2009).

4.7. Utilização de aeronaves remotamente pilotadas

Segundo a Agência Nacional de Aviação Civil (ANAC), as ARPs são definidas como uma aeronave não tripulada que é pilotada por meio de uma estação de pilotagem remota que tenha qualquer outra finalidade que não seja recreativa, tais como comercial, corporativa e experimental (ANAC, 2017).

Para Cândido, Silva e Paranhos Filho (2015), o uso de ARPs vem aumentando nos últimos anos devido as suas vantagens técnicas e econômicas. Há também a sua ampla facilidade de adaptar a sua utilização em projetos de diversas áreas, como o tipo de resolução, a escala e o sensor que poderá ser escolhido de forma a atender as necessidades do trabalho (MORGAN; GERGEL; COOPS, 2010).

Outro motivo significativo para o aumento do uso de ARPs nas atividades de mapeamento é a questão da resolução temporal, no qual podem ser adquiridos dados espaciais de uma determinada região com uma maior frequência de tempo e baixo custo, quando comparado com imagens de satélite (NEX; REMONDINO, 2013).


A precisão desses trabalhos depende de fatores múltiplos, tais como a qualidade e a calibração da câmara, o número e a localização dos pontos de controle no terreno, e por fim, a escolha do *software* de processamento (TAHAR; AHMAD, 2013).

5. MATERIAL E MÉTODOS

5.1. Área de estudo

A área de estudo deste trabalho (Figura 5) compreende parte de um bairro do município de Monte Carmelo, localizado na mesorregião do Triângulo Mineiro e Alto Paranaíba. Como foco do estudo, foi determinada uma fração do bairro Jardim Américo, no qual se encontra próxima a Estação de Tratamento de Esgoto (ETE) do município de Monte Carmelo.

Figura 5 – Mapa de localização da área de estudo



Fonte: A autora.

5.2. Material

Na realização deste trabalho, foram utilizados o seguinte material:


- Drone *Phantom Advanced 4*, utilizado na execução do voo;
- Software *Drone Deploy*, para planejamento do voo;
- Aplicativo *DJi Go 4 (2019)*, para controlar automaticamente o voo;
- Câmera Sony RGB com GPS integrado, utilizada para capturar as respostas espectrais dos alvos;
- Receptor GNSS - RTK (*Global Navigation Satellite System - Real Time Kinematic*), para obtenção dos pontos de controle;
- Software *TopconTools v.8.5*, para processamento dos pontos de controle;
- Software *Pix4D*, para geração do mosaico, modelo digital do terreno (MDT) e modelo digital da superfície (MDS);
- Software *eCognition Developer 64*, para a classificação orientada a objeto;

- *Software ArcMap 10.6.1*, elaboração dos mapas;
- *Software Qgis 3.14.16*, utilizado para a obtenção do MDE, visualização, manipulação dos polígonos e comparação das edificações vetorizadas e classificadas;
- *Software Excel 2019*, para a análise dos dados;
- Notebook Dell com processador Intel® Core™ i7 com 2,4GHz e RAM de 8GB, utilizado para o processamento, classificação e análise das imagens.

5.3. Métodos

Com o intuito de apresentar as etapas do trabalho de forma mais clara e compreensível, foi elaborado um fluxograma contendo as fases principais da metodologia (Figura 6).

Figura 6 – Fluxograma das etapas principais do projeto



Fonte: A autora.

5.3.1. Planejamento de campo

O voo foi executado utilizando a ARPs do modelo *Phantom Advanced 4*, equipada com uma câmara Sony RGB, com focal nominal de 8,8 mm contendo um sensor GNSS (GPS/GLONASS) integrado com a finalidade de georreferenciar cada foto com as coordenadas latitude e longitude (BARBOSA et al., 2020). A câmara conta com um sensor inercial que permite obter as informações referentes aos ângulos *roll*, *pitch* e *yaw* da orientação exterior da câmara para cada fotografia. O sensor responsável por capturar as respostas espectrais dos alvos é do tipo Semicondutor de Óxido de Metal Complementar (do termo em inglês, *Complementary Metal-Oxide Semiconductor* (CMOS)) de 1", com 12,8 mm e 9,6 mm de dimensão e 2,6 µm de tamanho do *pixel*, tendo como resultado uma resolução geométrica de 4864 x 3648 pixels (BARBOSA et al., 2020).

O plano de voo foi elaborado no *software Drone Deploy*, onde foram estabelecidos os parâmetros a serem utilizados, tais como a definição da área a ser sobrevoada, altura do voo, as sobreposições lateral e longitudinal, distância de amostra do solo (do termo em inglês *Ground Sample Distance* (GSD)), apresentados no Quadro (1). O mesmo *software* é responsável por fazer a verificação entre a conexão da base com e a ARPs, que caso esteja confirmado, permite que o voo seja iniciado (BARBOSA et al., 2020).

Quadro 1 – Parâmetros do voo

Parâmetros do voo	Valores
Altura	167 m
Área	190.000 m ²
Tempo	11 min
GSD	5 cm
Sobreposição Lateral	75%
Sobreposição Longitudinal	65%
Quantidade de fotos	176
Nº de Faixas	10
Data do levantamento	04/02/2018

Fonte: BARBOSA et al. (2020).


Os pontos de controle coletados foram planejados de forma que fossem definidos em lugares estratégicos para fácil identificação dos mesmos no mosaico, para a realização posterior do georreferenciamento do mosaico, na geração do MDT e do MDS.

5.3.2. Aquisição dos dados

Para controlar o voo, foi utilizada uma base de radiofrequência de 2400-2483GHz, a qual permite que aeronave possa atingir uma distância máxima de 7km. Essa base foi conectada ao aplicativo *DJI GO 4 (2019)* por meio de um celular com sistema operacional *Android*, e dessa forma, o voo e a tomada das fotos foram controlados automaticamente, podendo ser visualizado no celular a trajetória da aeronave (BARBOSA et al., 2020).

O levantamento dos pontos de controle foi realizado por meio da utilização de um receptor GNSS – RTK no dia 07/12/2019. No total, foram adquiridos 45 pontos distribuídos pelo bairro Jardim Américo (Figura 7).

Figura 7 – Pontos de controle coletados por meio de receptor GNSS



Fonte: A autora.

As etapas 5.3.1 Planejamento de campo, 5.3.2 Aquisição dos dados e o processamento dos pontos de controle, foram realizadas por Barbosa et al., 2020, com auxílio de equipamentos e ferramentas disponíveis no LASER da Universidade Federal de Uberlândia, no *campus* de Monte Carmelo – MG.

5.3.3. Processamento do mosaico e dos modelos

Para a geração do mosaico, MDS e MDT, foi utilizado o *software Pix4D* na versão de teste com licença disponível para 15 dias. O processamento foi feito em um dispositivo *desktop* da marca *Dell* com processador Intel® Core™ i7 com 2,4GHz e RAM de 8GB, resultando em um tempo de 04h 55min e 33s, para o mosaico, 02h 47min e 53s para o MDS e 16min e 23s para o MDT, todos referenciados ao sistema de coordenadas planas e sistema de referência WGS84.


Para o georreferenciamento dos modelos acima, que também foi feito pelo *software Pix4D*, foi utilizado os 45 pontos de controle que foram processados no *software TopconTools* v.8.5, relacionando-os à base da Rede Brasileira de Monitoramento Contínuo (RBMC), presente na Universidade Federal de Uberlândia no *campus* de Monte Carmelo – MG.

A partir da obtenção dos modelos, foi realizada a subtração dos valores do MDT pelos valores do MDS, fornecendo então a altura dos objetos presentes na área. Esse processamento foi realizado no *software Qgis 3.14.16*.

5.3.4. Classificação orientada a objetos

O processo de extração das feições de edificações no *software eCognition Developer 64* (Figura 8), onde foram adicionados o mosaico e o MDE, resultado da subtração entre o MDS e MDT.

Figura 8 – Interface do *software eCognition Developer 64*




Fonte: A autora.

5.3.4.1. Segmentação

Em seguida, foi realizada a segmentação da imagem como forma de agrupá-la em conjuntos de pixels ou objetos. Para a segmentação utilizando o *software eCognition*, são definidos quatro parâmetros: fator de escala, pesos para as camadas da imagem, para forma e para a compacidade (ESPINDOLA; CÂMARA, 2007). Foram realizadas três análises envolvendo três fatores de escala para verificar em áreas distintas qual iria melhor representar os objetos em questão. As camadas espectrais da imagem receberam peso 1 (um), e para o peso da forma e da compacidade, foram utilizados os valores definidos como padrão do *software*, sendo 0,1 e 0,5, respectivamente.

Nessa análise, foram escolhidas também três áreas distintas como forma de verificar o comportamento da segmentação em cada uma delas. A primeira área envolve telhados, vegetação, asfalto e solo exposto (Figura 9).


Figura 9 – Análise do fator de escala 100, 125 e 150 para a área de edificações



Fonte: A autora.

Na Figura (9), pode-se observar que o fator de escala de 125 foi o que conseguiu atingir objetos identificadores com melhor acerto nas seleções das regiões. O fator igual a 100, por se tratar do menor fator em análise, identificou e gerou muitas regiões com poucos *pixels*, como pode ser observado nos telhados. No fator igual a 150, apesar de ficar parecida com a de 125, identificou e gerou menos regiões contendo uma quantidade maior de *pixels*, começando assim a confundir algumas classes, como por exemplo a área de solo exposto e vegetação que estão em uma região de sombra próximas ao muro do lote vago. A segunda área escolhida envolveu um foco maior no asfalto e vegetação (Figura 10).


Figura 10 - Análise do fator de escala 100, 125 e 150 para a área de pavimentação



Fonte: A autora.

Pôde-se verificar na Figura (10) que o fator de escala igual a 125 foi o que conseguiu identificar as regiões de *pixels* com melhor discriminação das classes presentes na área. A terceira e última análise foi feita em uma área onde havia uma maior presença de vegetação, incluindo árvores (Figura 11).

Figura 11 - Análise do fator de escala 100, 125 e 150 para a área de vegetação



Fonte: A autora.

Analizando a Figura (11), permitiu identificar que o fator de escala de igual a 125 apresentou uma configuração de regiões de *pixels* melhor definidos e homogêneos, como pode ser observado nas árvores aglomeradas presentes na parte inferior da área em estudo. No fator de escala igual a 100, foi gerado vários conjuntos de *pixels*, no qual pode ser interpretado como uma variedade de classes diferentes, e no fator de escala igual a 150, as regiões começaram a se mesclar, o que poderia gerar confusão no *software* no momento de classificação da imagem.

Para a definição do fator de escala, torna-se importante a avaliação de desempenho por toda a área, como forma de analisar a maneira como o *software* irá separar os objetos uns dos outros. Portanto, após as análises, ficou definido que o fator de escala a ser utilizado seria de 125, por ter representado desempenho no agrupamento dos objetos presentes na imagem.

5.3.4.2. Otimização do espaço de recursos

Em seguida, foi realizada a etapa que visou buscar atributos para discriminar os objetos presentes na imagem, já que a área de estudo contém uma grande diversidade. Para isso, é possível utilizar funções disponíveis no *software* que permitem ressaltar as classes de interesse. Como forma de otimizar este serviço, o mesmo disponibiliza uma ferramenta capaz de calcular matematicamente a melhor combinação de recursos no espaço de recursos (ECOGNITION DEVELOPER, 2018).

Foi utilizada a ferramenta de otimização do espaço de recursos (do termo em inglês *Feature Space Optimization* (FSO)), onde são indicadas as classes de interesse e a ferramenta identifica uma combinação de recursos existentes no *software* para auxiliar na discriminação dessas classes em relação às outras presentes na imagem (LEDUC, 2004).

Como a área de estudo conta com diversos tipos de telhados, árvores e demais elemento, foi necessário determinar algumas classes para representá-los de formas distintas (Quadro 2), e em seguida, foi realizada a coleta dessas amostras para representação das mesmas.

Quadro 2 – Classes espectrais extraídas do mosaico

Classes	Exemplo
Vegetação Arbórea Densa	
Vegetação Arbórea Menos Densa	
Vegetação Gramínea	
Asfalto Novo	
Asfalto Antigo	
Solo Exposto	
Telhado Metálico	
Telhado de Cerâmica	
Telhado de Concreto	
Telhado de Fibrocimento	

Fonte: A autora.

Selecionando as classes criadas, o *software eCognition Developer 64* identificou previamente 219 atributos dos objetos de imagem. Porém, foi solicitada à ferramenta a seleção de 20 atributos para a continuidade do trabalho.

Com a obtenção dos 20 atributos, foram iniciados os testes como forma de analisar quais seriam os recursos que responderiam melhor às edificações e quais seriam utilizados no processo para distinguir os demais elementos dessa classe.

Durante esse teste, foi possível identificar que os atributos que respondiam com clareza aos telhados de cerâmica, prejudicava a identificação dos telhados metálicos, de concreto ou de fibrocimento e vice-versa. Portanto, tornou-se viável a execução do processo de classificação em duas etapas distintas, sendo a primeira para a classificação dos telhados de cerâmica e a segunda para os telhados de material metálico, concreto e fibrocimento, cuja a resposta espectral se assemelha.

5.3.4.3. Classificação das edificações com telhados de cerâmica

Foram identificados por meio de tentativa e erro, os recursos capazes de extrair as feições das edificações com o telhado de cerâmica. O primeiro passo identificado foi a da classificação, onde foi utilizado o *Normalized Difference Roof Index* (NDRI), para identificar a resposta espectral dos telhados de cerâmica presente nas bandas do vermelho e do azul, como apresenta a Equação (1), resultando em um intervalo variando de -1 a 1 (PINHO, 2005).

$$\frac{(R - B)}{(R + B)} \quad (1)$$

Onde:

- R é a reflectância presente no canal da banda do vermelho;
- B é a reflectância presente no canal da banda do azul.

Como forma de auxiliar no ajuste do intervalo que melhor selecionasse as edificações, a Equação (1) foi multiplicada por 100. Como no processo de classificação foram selecionadas algumas áreas que não equivalem às edificações, fez-se necessário a realização da eliminação dessas classes distintas, sendo elas a vegetação, vias e solo exposto, por exemplo.

Para a identificação da vegetação a ser removida da classificação, foram utilizadas as bandas do visível, conforme a Equação (2), que permite identificar excessos de verde na imagem (PONTI, 2013).

$$\frac{G}{(R + G + B)} \quad (2)$$

Onde:

- G é a reflectância presente no canal da banda do verde;
- R é a reflectância presente no canal da banda do vermelho;
- B é a reflectância presente no canal da banda do azul.

Para as demais etapas de eliminação, foram utilizados alguns dos outros atributos (Média Banda 5, Razão da Banda 4, Moda (Mediana) Banda 1, Largura (*Pixel*) e Média da Banda 1) apresentados pelo FSO, onde também foram identificados intervalos de classes que permitiram distinguir os objetos das edificações. A árvore de processos foi elaborada contendo 8 etapas (Tabela 1), desde a segmentação da imagem, até a extração do vetor referente às feições edificadas com telhados de cerâmica.

Tabela 1 – Árvore de processos para extração das feições edificadas com telhados de cerâmica

Etapas	Descrição	Parâmetros
1	Segmentação	Fator de escala: 125 → Para as 5 bandas
2	Classificação	Equação (1) * 100 → Valores maiores ou iguais a 12
3	Eliminação	Média Banda 5 * 100 → Valores menores ou iguais a 160
4	Eliminação	Equação (2) → Valores maiores ou iguais a 0,33
5	Eliminação	Razão Banda 4 → Valores maiores ou iguais a 0,56
6	Eliminação	Moda (Mediana) Banda 1 → Valores menores ou iguais a 74
7	Eliminação	Média Banda 1 → Valores menores ou iguais a 106
8	Exportação	Exportar camada de vetor

Fonte: A autora.

5.3.4.4. Classificação das edificações com telhados metálico, de concreto ou de fibrocimento

Considerando que a Equação (1) permitiu selecionar e classificar os telhados com resposta espectral referentes ao material de cerâmica, foi realizado o processo inverso com os demais tipos de telhados, sendo então utilizados os valores menores ou iguais a 12.

Novamente, foram classificadas algumas áreas que não equivalem às edificações, sendo necessário realizar também a eliminação dessas classes distintas. A árvore de processos foi elaborada contendo 7 etapas (Tabela 2), desde a classificação da imagem, até a extração do vetor referente às feições edificadas com telhados metálico, de concreto ou de fibrocimento. Como a segmentação já havia sido feita, para esta segunda classificação foram feitos apenas as etapas para selecionar as edificações.

Tabela 2 - Árvore de processos para extração das feições edificadas com telhados metálico, de concreto ou de fibrocimento


Etapas	Descrição	Parâmetros
1	Classificação	Equação (1) * 100 → Valores menores que 12
2	Eliminação	Média Banda 5 * 100 → Valores menores ou iguais a 270
3	Eliminação	Equação (2) → Valores maiores ou iguais a 0,34
4	Eliminação	Razão Banda 4 → Valores maiores ou iguais a 0,38
5	Eliminação	Moda (Mediana) Banda 1 → Valores menores ou iguais a 144
6	Eliminação	Largura (pixel) → Valores maiores ou iguais a 330
7	Exportação	Exportar camada de vetor

Fonte: A autora.

5.3.5. Análise dos dados

A área possui aproximadamente 440 edificações e, nas mesmas, existe uma grande variedade no tipo de telhado. Dessa forma, para a apresentação dos tipos de telhados que foram classificados, a Figura (12) exemplifica por meio de um zoom a presença de telhados de cerâmicas e dos telhados metálicos, de concreto ou de fibrocimento. Para as edificações presentes na área do zoom (Figura 12B), foi utilizada a ferramenta de seleção aleatória do software *Qgis* 3.14.16, sendo selecionada uma edificação, que seria utilizada como o centroide do mapa. A partir disso, foram selecionados os imóveis limítrofes a este centroide, formando assim a área de visualização.

Figura 12 - Exemplo da presença de telhados de cerâmicas e dos telhados metálico, de concreto ou de fibrocimento



Fonte: A autora.

Para complementar a análise das classificações, foram realizados os cálculos das áreas construídas das três edificações apresentadas na Figura (12B). Essas áreas foram obtidas por meio dos polígonos originados da classificação orientada a objetos e do arquivo vetorial gerado manualmente por Barbosa et al., 2020.

Com a finalidade de analisar os valores de área construída das edificações da Figura (12B), foi calculado o erro relativo percentual utilizando a equação (3), onde foi apresentado o quanto ocorreu de erro para as áreas selecionadas para a comparação.

$$Er = \frac{|Vr - Vc|}{Vr} * 100 \quad (3)$$

Onde:

- Er é o erro relativo em porcentagem;
- Vr é o valor de referência (vetorizado manualmente);
- Vc é o valor da amostra (classificação semiautomática).

Para a realização do cálculo da área construída, foi necessário utilizar a ferramenta de dissolver geometrias e em seguida, a de transformar multipartes em parte simples, para que cada edificação pudesse ser representada de forma única. Ambas as ferramentas foram utilizadas no *software Qgis 3.14.16*.

Para a avaliação da classificação em toda a extensão da área de estudo (Figura 13A), foi realizada a análise estatística, utilizando o teste-t pareado (Equação 4) para analisar a tendência nas coordenadas E (Leste) e N (Norte) (BARBOSA et al., 2020), e nas áreas dos polígonos.

$$t_{calculado} = \frac{\bar{x}}{s_{\bar{x}}} \sqrt{n} \quad (4)$$

Onde:

- $\bar{x}$ é a média dos resíduos;
- $s_{\bar{x}}$ é o desvio padrão amostral da média dos resíduos;
- n é o tamanho da amostra de verificação.


Dessa forma, foram selecionadas 30 amostras aleatórias por meio da ferramenta de seleção aleatória. Para cada polígono, foi obtido o centroide para avaliar a tendência nas coordenadas. O arquivo foi convertido para o sistema de coordenadas cartesianas, em específico para Universal Transverso de Mercator (UTM), para a extração das coordenadas E e N das edificações vetorizadas e classificadas. Essa etapa foi realizada utilizando ferramentas presentes no *software Qgis 3.14.16*.

6. RESULTADOS E DISCUSSÕES

Decorrente das etapas realizadas neste trabalho, os resultados serão apresentados nas sessões seguintes, a fim de simplificar a demonstração dos processamentos e das análises.

6.1. Mosaico, MDS e MDT


Figura 13 – Mosaico da área de estudo



Fonte: A autora.

O mosaico apresentado por meio na Figura (13), demonstrou tamanha qualidade, permitindo uma boa visualização dos objetos presentes na área. O mesmo contou também com uma resolução espacial de 4,49 cm (GSD), o que o torna ainda mais vantajoso na utilização da metodologia deste trabalho.


Figura 14 – Modelo Digital de Superfície da área de estudo



Fonte: A autora.

O MDS apresentado na Figura (14), possibilitou observar a existência de edificações e algumas vegetações arbóreas sobre o terreno. Os objetos dispostos sobre o solo são apresentados em uma tonalidade mais escura em relação ao nível do terreno, como ocorre no caso das edificações. A resolução espacial do MDS também foi de 4,49 cm.


Figura 15 – Modelo Digital do Terreno



Fonte: A autora.

O MDT (Figura 15), permitiu que fossem analisadas as cotas do terreno, bem como as partes mais altas e mais baixas da área de estudo. Posteriormente foi possível realizar a operação de subtração envolvendo o MDS, afim de se obter a elevação dos objetos. A resolução espacial para este modelo foi a mesma dos dois modelos anteriores (4,49 cm).

Figura 16 – Modelo Digital de Elevação da área de estudo



Fonte: A autora.

O MDE (Figura 16), originado por meio da subtração do MDS e o MDT, possibilitou identificar melhor os objetos que estão presentes acima do terreno. Como apresentado, os objetos com maior elevação aparecem em tons de amarelo, laranja e vermelho, sendo referentes às árvores, edificações e demais objetos presentes. As partes referentes às vias, vegetação gramínea, ao córrego, entre outros, foram apresentadas em tonalidade verde, com exceção das áreas que sofreram distorções nas bordas, que estão apresentadas em tons de verde e amarelo.

6.2. Classificação orientada a objetos

6.2.1. Edificação com telhados de cerâmica

O processo completo de classificação dos telhados de cerâmica durou cerca de 01h 45 min e 06s (Tabela 3), o que o torna ainda mais vantajoso, pois no CTM, a extração manual das edificações demanda dias ou até mesmo meses, variando de acordo com a área do município e o número de edificações presentes no mesmo.


Tabela 3 – Tempo de processamento para a classificação dos telhados de cerâmica

Etapas	Tempo
1	01h 35min e 48,000s
2	00h 04min e 23,437s
3	00h 00min e 31,734s
4	00h 02min e 08,172s
5	00h 01min e 11,093s
6	00h 01min e 00,937s
7	00h 00min e 00,001s
8	00h 00min e 02,625s
Total	01h 45min e 06s

Fonte: A autora.

O resultado dessa classificação orientada a objetos para os telhados de cerâmica pode ser visto na Figura (17).

Figura 17 – (A) Classificação das feições edificadas com cobertura de telhas de cerâmica. (B) Zoom para exemplificar a classificação e suas inconsistências.



Fonte: A autora.

A Figura (17A) mostra que houve uma seleção quase completa dos telhados de cerâmica, com exceção da região da borda localizada no canto inferior esquerdo, onde ocorreu o efeito de distorção na imagem (MÜLLER, 2017). Na Figura (17B) foi exemplificado a classificação cobrindo a cobertura das edificações onde havia a presença de telhados de cerâmica, observados na Figura (12B). Foi possível identificar também duas pequenas inconsistências ocorridas no momento de classificação, sendo uma parte fora da área do telhado e outra faltando um pedaço do telhado (Figura 17B).

6.2.2. Edificação com telhados metálico, de concreto ou de fibrocimento

Como a segmentação foi realizada apenas uma vez, esta classificação demandou menos tempo de processamento, durando cerca de 00h 09min e 37s (Tabela 4), sendo este mais um aspecto positivo para a aplicação da classificação orientada a objetos.


Tabela 4 – Tempo de processamento para a classificação dos telhados metálico, de concreto ou de fibrocimento

Etapas	Tempo
1	00h 04min e 30,390s
2	00h 00min e 21,812s
3	00h 02min e 01,891s
4	00h 01min e 15,422s
5	00h 01min e 23,015s
6	00h 00min e 00,969s
7	00h 00min e 03,906s
Total	00h 09min e 37s

Fonte: A autora.

A classificação orientada a objetos para os telhados metálico, de concreto ou de fibrocimento pode ser vista na Figura (18).

Figura 18 – (A) Classificação das feições edificadas com cobertura de telhados metálico, de concreto ou de fibrocimento. (B) Zoom para exemplificar a classificação e suas inconsistências.




Fonte: A autora.

A Figura (18A) apresenta o restante dos telhados que não foram classificados na etapa anterior. Na Figura (18B), foi possível verificar que foram classificados objetos que não são telhados, mas que possuem a mesma textura, como no caso dos muros e o chão no fundo dos lotes.

6.2.3. Classificação orientada a objetos das edificações

A Figura (19) apresenta as duas classificações das sessões anteriores, demonstrando que algumas edificações são compostas pela presença das duas classes de telhados estudadas neste trabalho.

Figura 19 – (A) Classificação dos telhados de cerâmica e dos telhados metálicos, de concreto e fibrocimento. (B) Zoom para exemplificar as classificações e suas inconsistências.



Fonte: A autora.






Como em ambos os arquivos vetoriais haviam polígonos que não eram edificações, os mesmos foram excluídos manualmente utilizando a ferramenta de edição presente no *software Qgis 3.14.16*. Porém, foram excluídos apenas os polígonos que não faziam parte dos telhados, como alguns exemplos circulados apresentados na Figura (19B).

Em seguida, foi realizada a mesclagem dos dois arquivos, juntando os telhados de cerâmica e telhados metálico, de concreto e de fibrocimento em um único arquivo vetorial. Nesse procedimento, todos os polígonos foram agrupados em um único grupo, sendo necessário então a utilização da ferramenta de multipartes para partes simples. Essa ferramenta permitiu que cada polígono fosse representado de forma única, prosseguindo posteriormente para a avaliação da classificação.

6.3. Comparação visual e quantitativa entre as edificações classificadas e vetorizadas

Na Figura (19A) foram representados os comportamentos das classificações em relação aos tipos de telhados. No Quadro (3), estão apresentadas as mesmas três edificações da Figura (12B), sendo analisados a diferença da área dos polígonos gerados por meio da classificação e da vetorização manual, tendo seus valores apresentados na Tabela (5).

Quadro 3 – Apresentação visual entre os polígonos classificados e os vetorizados

Codificação	Edificação	Comparação
A		
B		
C		
 Classificado		 Vetorizado

Fonte: A autora.

Tabela 5 - Comparação da área construída entre os polígonos classificados e vetorizados

Codificação	Área (m ²)			Erro Relativo (%)
	Vetorizado	Classificado	Diferença Absoluta	
A	150,331	156,0827	5,7517	3,685
B	92,5296	103,0247	10,4951	10,187
C	105,2149	117,3237	12,1088	10,321

Fonte: A autora.

Por meio do Quadro (3) e da Tabela (5), foi possível identificar que a edificação de codificação A apresentou um melhor desempenho, apresentando um erro relativo percentual de 3,6% em relação ao valor real de área construída.

A edificação C apresentou de forma visual e quantitativa o maior erro apresentando, ocorrendo na classificação um erro de aproximadamente 12,10 m² a menos do que a área construída do polígono vetorizado.

6.4. Análise estatística entre as edificações classificadas e vetorizadas

6.4.1. Coordenadas E e N dos centroides dos polígonos vetorizados e classificados

A análise estatística foi realizada de forma a verificar a classificação para as edificações presentes em toda a área de estudo. A Tabela (6) apresenta os resultados do teste para as coordenadas E (Leste) do centroide dos 30 polígonos de amostra, sendo analisada as seguintes hipóteses:

- H0: Não existe diferença na média da coordenada E (Leste) entre os polígonos vetorizados e os classificados;
- H1: Há diferença na média da coordenada E (Leste) entre os polígonos vetorizados e os classificados.

Tabela 6 – Teste-t pareado para a coordenada E (Leste) do centroide dos polígonos vetorizados e classificados

Parâmetros	Coordenadas E (Leste)	
	Vetorizado	Classificado
Média	236893,4092	236893,689
Variância	36625,45718	36682,89762
Observações	30	30
Correlação de Pearson	0,999962877	
Grau de Liberdade	29	
t calculado	-0,925297401	
P(T<=t) bi-caudal	0,362447545	
t crítico bi-caudal	2,045229642	

Fonte: A autora.

Analisando os resultados da Tabela (6), foi observado o valor de t calculado = -0,9253 e o t crítico = 2,0452, ou seja, o valor de t calculado < t crítico. O valor de p também é superior

ao valor do nível de significância. Portanto, ao nível de significância de 5%, não se rejeita a hipótese H0.

A Tabela (7) apresenta os resultados do teste para as coordenadas N (Norte) do centroide dos 30 polígonos de amostra, sendo analisada as seguintes hipóteses:

- H0: Não existe diferença na média da coordenada N (Norte) entre os polígonos vetorizados e os classificados;
- H1: Há diferença na média da coordenada N (Norte) entre os polígonos vetorizados e os classificados.

Tabela 7 - Teste-t pareado para a coordenada N (Norte) do centroide dos polígonos vetorizados e classificados

Parâmetros	Coordenadas N (Norte)	
	Vetorizado	Classificado
Média	7930571,016	7930571,628
Variância	30758,98596	30653,15003
Observações	30	30
Correlação de Pearson	0,999895373	
Grau de Liberdade	29	
t calculado	-1,313184205	
P(T<=t) bi-caudal	0,199417135	
t crítico bi-caudal	2,045229642	

Fonte: A autora.

Conforme os resultados da Tabela (7), foi possível analisar que o valor de t calculado = -1,3132 e o t crítico = 2,0452, ou seja, neste caso o valor de t calculado também foi menor que o valor do t crítico (t calculado < t crítico). O valor de p é superior ao valor do nível de significância. Portanto, ao nível de significância de 5%, não se rejeita a hipótese H0 para a coordenada N dos polígonos.

Conforme análise realizada nos resultados obtidos nas Tabelas (6 e 7), devido a teste t pareado ter apresentado o valor de t calculado sendo menor que o valor da distribuição-t, conclui-se que as coordenadas planimétricas não apresentaram tendência (BARBOSA et al., 2020). Isto mostra que o método apresenta um bom desempenho posicional dos polígonos extraídos.

6.4.2. Área construída dos polígonos vetorizados e classificados

A Tabela (8) apresenta os resultados do teste estatístico para as áreas construídas dos 30 polígonos de amostra, sendo analisada as seguintes hipóteses:

- H0: Não existe diferença na média da área construída entre os polígonos vetorizados e os classificados;
- H1: Há diferença na média da área construída entre os polígonos vetorizados e os classificados.

Tabela 8 - Teste-t pareado para a área construída dos polígonos vetorizados e classificados

Parâmetros	Área (m ²)	
	Vetorizado	Classificado
Média	79,4451	131,9617667
Variância	1638,422288	24041,29453
Observações	30	30
Correlação de Pearson	0,326630282	
Grau de Liberdade	29	
t calculado	-1,958097805	
P(T≤t) bi-caudal	0,059901032	
t crítico bi-caudal	2,045229642	

Fonte: A autora.

Observando os resultados da Tabela (8), foi possível analisar que o valor de t calculado = -1,9581 e o t crítico = 2,0452, portanto, t calculado < t crítico. Como o valor de p é maior que o valor do nível de significância de 5%, não se rejeita a hipótese H0. Esses resultados mostram que por meio do teste t pareado, as áreas construídas não também não apresentaram tendências.

7. CONSIDERAÇÕES FINAIS

A utilização das tecnologias de sensoriamento remoto, fotogrametria e principalmente do PDI vem sendo cada vez mais incorporados nas áreas de engenharias. Por isso, o uso de ferramentas que contribuem para o desempenho e a qualidade dos serviços prestados é de extrema importância.

Analisando a classificação por toda a área edificada, foi obtido por meio da análise estatística que, ao nível de significância de 5%, não se rejeita a hipótese de H_0 dos três testes efetuados. Porém, analisando a classificação pela área do zoom, foi possível observar que a mesma não poderá ser utilizada para fins cadastrais, pois houve edificação que apresentou erro de aproximadamente 10% a menos de área em relação ao valor real da mesma. Esse erro pode vir a prejudicar nas tomadas de decisões das prefeituras, gerando por exemplo, a cobrança indevida dos impostos sobre o a propriedade predial e território urbano.

Visando os resultados obtidos, a metodologia utilizada neste experimento apresenta potencial para a utilização em criação e atualização de bases cartográficas, mas que ainda deve passar por adaptações para que possa ser aplicada futuramente com melhor precisão e acurácia nas classificações para o uso do produto para fins cadastrais.

Contudo, o método poderá ser utilizado em demais atividades de identificações de edificações, como por exemplo, na detecção de novos imóveis presentes nos municípios, permitindo a atualização do banco de dados com informações importantes para o planejamento urbano e demais ações.

REFERÊNCIAS

ALMEIDA FILHO, R.; NASCIMENTO, P.S.R.; BATISTA, G.T. Avaliação de técnicas de segmentação e classificação automática de imagens Landsat-TM no mapeamento do uso do solo na Amazônia. **Acta Amazônica**, v.28, n. 1, 1998, p. 41-54.

AMERICAN SOCIETY OF PHOTOGRAMMETRY. **Manual of Photogrammetry**, 3. ed. 1966, 1199p.

ANAC. **Regras da ANAC para uso de drones entram em vigor**. BRASIL. 2017. Disponível em :< <http://www.anac.gov.br/noticias/2017/regras-da-anac-para-uso-de-drones-entram-em-vigor>>. Acesso em 18 ago. 2020.

ANGELINI SOBRINHA, L. **Classificação semiautomática de imagens de satélites e suas implicações na modelação do escoamento direto em bacias urbanas**. 2016. Tese (Doutorado em Engenharia Hidráulica e Saneamento) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2016.

ANTUNES, A. F. B.; CORTESES, S. C. Determinação de áreas de ocupação irregulares por meio da análise orientada a objetos. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis, INPE, 2007. p. 481-487.

ARANTES, B. H. T. et al. Uso de drones na atualização de área construída de imóveis urbanos. **Scientia Plena**, v. 14, n. 10, 2018.

BARBOSA, R. L. et al. Mapeamento com Integração de Imagens Aéreas Obtidas com ARP e Imagens Terrestres Capturadas com Câmara Esférica. **Anuário do Instituto de Geociências – UFRJ**, v. 43, 2020, p. 63-71.

BERNARDI, H. V. F. et al. Classificação digital do uso do solo comparando os métodos “pixel a pixel” e orientada ao objeto em imagem QuickBird. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIII, 2007, Florianópolis. **Anais...** Florianópolis, INPE, 2007, p. 5595-5602.

CÂNDIDO, A. K. A. A.; SILVA, N. M.; PARANHOS FILHO, A. C. Imagens de alta resolução de veículos aéreos não tripulados (VANT) no planejamento do uso e ocupação do solo. **Anuário do Instituto de Geociências – UFRJ**, v. 38, 2015, p. 147-156.

CARRILHO, A. C. et al. Avaliação da extração automática de edificações a partir de dados lidar aerotransportado. In: COBRAC 2018, Florianópolis. **Anais...** Florianópolis, UFSC, 2018.

COELHO, L.; BRITO, J. N. **Fotogrametria digital**. Rio de Janeiro: Editora da Universidade do Estado do Rio de Janeiro, 2007. 196p.

CRÓSTA, A. P. **Processamento Digital de Imagens de Sensoriamento Remoto**. Campinas: IG/UNICAMP, 1992. p.107-133.

CUNHA, E. M. P.; ERBA, D. A. (Org.). **Manual de Apoio – CTM: Diretrizes para a criação, instituição e atualização do cadastro territorial multifinalitário nos municípios brasileiros**. Brasília: Ministério das Cidades, Brasil, 2011.

DLUGOSZ, F. L. et al. Índice para a avaliação de segmentação de imagens. **Floresta**, v. 39, n. 1, 2009.

ECOGNITION DEVELOPER, Trimble. **eCognition Developer User Guide**. 2018.

ESPINDOLA, G. M.; CÂMARA, G. Ajuste de parâmetros no algoritmo de segmentação de imagens do software eCognition. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. **Anais...** Florianópolis, INPE, 2007. p. 5739-5744.

ESPÍRITO-SANTO, F. D. B. et al. Classificação semi-automática de imagens multitemporais Landsat para a determinação dos estágios sucessionais de uma área de desflorestamento na Amazônia. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XII, 2005, Goiânia. **Anais...** Goiânia, INPE, 2005, p. 1517-1524.

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

FIGUEIREDO, D. **Conceitos básicos de sensoriamento remoto**. São Paulo, 2005, 32p.

FONTES, L. C. A. A. Fundamentos de aerofotogrametria aplicada à topografia. **Técnicas de Geomensura - Universidade Federal da Bahia**, 2005.

FREITAS, M. I. C.; PANCHER; PANCHER, A. M. **Classificação de imagens**. Sistema de Informações Geográficas. 2011.

GALLIS, R. B. A. **Extração Semi-automática da Malha Viária em Imagens Aéreas Digitais de Áreas Rurais Utilizando Otimização por Programação Dinâmica no Espaço Objeto**. 2006. Tese (Doutorado em Ciências Cartográficas) – Faculdade de Ciências e Tecnologia de Presidente Prudente, Universidade Estadual de São Paulo, Presidente Prudente, 2006.

GONÇALVES, L.; FONSECA, A. M.; CAETANO, M. Exploração de imagens de alta resolução do satélite Ikonos. In: ENCONTRO DE UTILIZADORES DE INFORMAÇÃO GEOGRÁFICA, 6., 2001, Lisboa. **Anais...** Lisboa, Série Comunicação, 2001. 22p.

GONZALES, R. C; WINTZ, P. **Digital image processing**. Reading: Addison Wesley, 1987. 431p.

GONZALEZ, R. C.; WOODS, R. E.; EDDINS, S. L. **Digital image processing using MATLAB**, MathWorks, 2010.

HAY, G. J.; CASTILLA, G. Geographic Object-Based Image Analysis (GEOBIA): A new name for a new discipline. **Object-based image analysis**. Springer, Berlin, Heidelberg, 2008. p. 75-89.

JENSEN, J. R. Remote Sensing of the Environment Na Earth Resource Perspective. **Pearson New International Edition**. 2014, 619p.

LEDUC, F. Feature space optimization prior to fuzzy image classification. In: PROC. OF THE 7TH INTERNATIONAL CONFERENCE ON INFORMATION FUSION, 2004, Estocolmo. **Anais...** Estocolmo, 2004, p. 547-554.

LINS, B. O. L. **A utilização do vant (drone) como alternativa para atualização de regularização urbana**. 2019. 57 f. Trabalho de Conclusão de Curso (Bacharel em Engenharia de Agrimensura) – Universidade Federal de Alagoas, 2019.

LOCH, C. Cadastro Técnico Multifinalitário e Gestão Territorial. In: CONGRESSO BRASILEIRO DE ENSINO DE ENGENHARIA, 2001, Porto Alegre. **Anais...** ABENGE, CD Room. 2001.

LUZ, C. C.; ANTUNES, A. F. B.; RATTON, P. Aplicabilidade da tecnologia vant na atualização de bases de dados cartográficos. **Boletim Paranaense de Geociências**, v. 73, n. 1, 2017, p. 34-45.

LUZ, N. B. **Integração de análise orientada a objetos e árvores de decisão para classificação de sub-tipologias de floresta ombrófila mista**. 2011. Tese (Doutorado em Ciências Geodésicas) – Departamento de Ciências Geodésicas, Setor de Ciências Exatas e da Terra, Universidade Federal do Paraná, Curitiba, 2011.

MACHADO, A. M. L. **Extração automática de contornos de edificações utilizando imagem gerada por câmara digital de pequeno formato e dados LIDAR**. 2005. Tese (Doutorado em Ciências Geodésicas) - Curso de Pós-Graduação em Ciências Geodésicas, Universidade Federal do Paraná, Curitiba, 2006. 206p.

MARQUES FILHO, O.; VIEIRA NETO, H. **Processamento Digital de Imagens**. Rio de Janeiro: Brasport, 1999. ISBN 8574520098.

MENESES, P. R.; ALMEIDA, T. (Org.). **Introdução ao processamento de Imagens de Sensoriamento Remoto**. Brasília: UnB/CNPq, 2012. Disponível em: <http://www.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8>. Acesso em 11 maio 2020.

MORAES, E. C. **Capítulo 1 Fundamentos de Sensoriamento Remoto**. Brasília: Ministério da Ciência e Tecnologia, Brasil, 2002.

MORGAN, J.L.; GERGEL, S.E.; COOPS, N.C. Aerial photography: a rapidly evolving tool for ecological management. **BioScience**, v.60, n.1, 2010, p. 47-59.

MÜLLER, M. **Avaliação da qualidade de ortofotos geradas por imagens obtidas por RPAS: Implicações no cadastro técnico multifinalitário**. 2017. Trabalho de Conclusão de Curso (Bacharel em Engenharia de Agrimensura e Cartográfica) – Instituto de Geografia, Universidade Federal de Uberlândia, Monte Carmelo, 2017, 44p.

NEVES, S. C. M.; PELAES, E. G. Estudo e Implementação de Técnicas de Segmentação de Imagens. **Revista Virtual de Iniciação Acadêmica da UFPA**, v. 1, n. 2, 2001, p. 1-11.

NEX, F.; REMONDINO, R. UAV for 3D Mapping Applications: A Review. **Applied Geomatics**, v. 6, 2013, p. 1-15.

NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Edgard Blucher Ltda., 2010. 387p.

OLIANI, L. O.; ANTUNES, A. F. B. Um estudo de atualização de bases cartográficas e banco de dados cadastrais a partir de imagens orbitais de alta resolução extraídas do Google na região metropolitana de Curitiba. 2011. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XV, Curitiba. **Anais...** Curitiba, INPE, 2011, 8833p.

OLIVEIRA, G. R. K.; GALO, M. Extração de contornos de telhados de edificações através da combinação de dados LiDAR e imagens aéreas. **Revista Brasileira de Cartografia**, v. 70, n. 4, 2018, p. 1378-1408.

OLIVEIRA, J. S. **Avaliação da metodologia de demarcação de terrenos marginais e acrescidos. Estudo de caso do trecho fluminense do Rio Paraíba do Sul**. 2019. Dissertação (Mestrado em Planejamento Energético) – Programa de Pós-graduação em Planejamento Energético, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019.

PEREIRA, C. C. **A importância do Cadastro Técnico Multifinalitário para elaboração de Planos Diretores**. 2009. Dissertação (Mestrado em Engenharia Civil) – Centro Tecnológico, Universidade Federal de Santa Catarina, Florianópolis, 2009, 207p.

PINHO, C. M. D. **Análise orientada a objetos de imagens de satélite de alta resolução espacial aplicada à classificação de cobertura do solo no espaço intra-urbano: o caso de São José dos Campos – SP**. 2005. 179 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2005.

PINHO, C. M. D.; UMMUS, N. E.; NOVACK, T. Simulação do comportamento espectral de alvos urbanos em sensores multiespectrais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, 2009, Natal. **Anais...** Natal, INPE, 2009, p. 803-810.

PONTI, M. Segmentation of Low-Cost Remote Sensing Images Combining Vegetation Indices and Mean Shift. **Geoscience and Remote Sensing Letters**, v. 10, 2013, p. 67-70.

PONZONI, F.J.; SHIMABUKURO, Y.E.; KUPLICH, T.M. **Sensoriamento Remoto da Vegetação**. 2. ed. São Paulo: Oficina de Textos, 2012. v. 1, 176p.

POTJE, G. A. et al. Extração de contorno de telhados de edificações utilizando dados laser e imagens aéreas. **Colloquium Exactarum. ISSN: 2178-8332**. 2014, p. 104-119.

QUEIROZ, J. E. R.; GOMES, H. M. Introdução ao Processamento Digital de Imagens. **Revista RITA**, 2001, v. 8, n. 1.

REDWEIK, P. Fotogrametria aérea. **Departamento de Engenharia Geográfica, Geofísica e Energia - Faculdade de Ciências da Universidade de Lisboa**, 2007.

RIBEIRO, B. M. G.; KUX, H. J. H. Classificação orientada a objeto para mapeamento do uso do solo – métodos e análise de expansão urbana. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, 2009, Natal. **Anais...** Natal, INPE, 2009, p. 7893-7900.

SARAIVA, D. F. **Classificação orientada a objeto para mapeamento da vegetação sobre canga couraçada**. 2013. Monografia (Especialista em Geoprocessamento) – Universidade Federal de Minas Gerais, Belo Horizonte, 2013.

TAHAR, K. N.; AHMAD, A. An evaluation on fixed wing and multi-rotor UAV images using photogrammetric image processing. **World Academy of Science, Engineering and Technology**, 2013. p. 391.

TOMMASELLI, A. M. G. et al. Fotogrametria: aplicações a curta distância. In: FCT (40 anos), 1999, Presidente Prudente. **Anais...** Presidente Prudente, 1999, p. 147-59.

TOMMASELLI, A. M. G. Fotogrametria básica. **Presidente Prudente: UNESP**. 2009, p. 5-18.

PINHO, C. M. D.; UMMUS, M. E.; NOVACK, T. Simulação do comportamento espectral de alvos urbanos em sensores multiespectrais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, XIV, 2009, Natal. **Anais...** Natal, INPE, 2009, p. 803-810.

APÊNDICE A – COORDENADAS UTM DOS 30 PONTOS AMOSTRADOS

Edificação	Coordenadas UTM Vetorizado		Coordenadas UTM Classificado	
	E	N	E	N
1	237157,9027	7930864,7600	237157,8276	7930864,6790
2	237196,1082	7930826,2860	237195,8432	7930826,5830
3	237129,2704	7930836,8930	237129,6312	7930836,0090
4	237113,8275	7930849,1420	237114,0576	7930849,1190
5	237108,2501	7930843,7090	237108,1415	7930843,8780
6	237178,4594	7930735,5830	237178,5337	7930735,0360
7	237163,9498	7930666,8310	237163,9203	7930666,5750
8	237030,9581	7930741,1490	237033,6791	7930743,5860
9	237008,1579	7930751,6650	237008,1638	7930751,6060
10	236988,3064	7930701,5010	236988,9082	7930702,4170
11	237031,2282	7930670,5690	237031,2109	7930670,4870
12	236989,7509	7930662,6200	236989,7028	7930662,5000
13	237101,6317	7930465,4170	237103,9786	7930462,6870
14	236909,0907	7930494,8820	236913,7722	7930489,5460
15	236855,2906	7930504,7530	236852,8749	7930509,8040
16	236758,4844	7930541,5950	236760,3312	7930546,0330
17	236712,8915	7930534,8580	236712,4284	7930534,8590
18	236723,9327	7930503,6130	236724,9676	7930500,3860
19	236730,2304	7930485,6910	236727,6776	7930493,8520
20	236659,2499	7930518,2000	236657,5031	7930519,8840
21	236798,6264	7930449,9860	236798,4370	7930450,0510
22	236816,6642	7930361,6610	236813,9400	7930362,1340
23	236804,7149	7930307,5640	236804,5830	7930307,5600
24	236720,3175	7930289,6950	236720,2929	7930290,3690
25	236724,5311	7930418,6050	236724,4833	7930418,5490
26	236729,6306	7930431,2790	236730,7198	7930430,1480
27	236698,3083	7930415,1260	236698,3453	7930415,1290
28	236689,9326	7930371,3630	236692,6168	7930375,8070
29	236618,8374	7930445,0480	236617,4383	7930447,8340
30	236653,7401	7930440,4460	236656,6598	7930441,7440

Fonte: A autora.

APÊNDICE B – ÁREA CONSTRUÍDA PARA CADA UM DOS 30 PONTOS AMOSTRADOS

Edificação	Área (m²)		Resíduos (m²)
	Vetorizado	Classificado	
1	59,09	60,6748	1,5848
2	74,335	86,0211	11,6861
3	149,184	364,9849	215,8009
4	58,108	68,0282	9,9202
5	60,824	67,9398	7,1158
6	3,752	5,3297	1,5777
7	71,534	79,1519	7,6179
8	111,455	203,1257	91,6707
9	99,68	109,1424	9,4624
10	126,185	346,5011	220,3161
11	70,8	76,4809	5,6809
12	95,17	102,3637	7,1937
13	70,256	138,6308	68,3748
14	191,56	47,3383	144,2217
15	68,087	142,1975	74,1105
16	35,837	11,4673	24,3697
17	37,96	42,5129	4,5529
18	113,562	7,7152	105,8468
19	78,318	782,6559	704,3379
20	107,96	237,9948	130,0348
21	71,493	77,7407	6,2477
22	114,27	158,8759	44,6059
23	73,472	73,9344	0,4624
24	37,844	34,9504	2,8936
25	30,548	34,1586	3,6106
26	24,019	19,2086	4,8104
27	49,223	52,7	3,477
28	130,011	233,3163	103,3053
29	109,572	53,3289	56,2431
30	59,244	240,3823	181,1383

Fonte: A autora.