

## **CLASSIFICAÇÃO DE NUVEM DE PONTOS OBTIDAS POR RPAS: UMA FONTE DE DADOS PARA A ATUALIZAÇÃO DE DOCUMENTOS CARTOGRÁFICOS**

### *RPAS point cloud classification: A data source for cartographic documents update*

**Guilherme Gomes Pessoa**<sup>1</sup>

guilhermegpessoa@hotmail.com

**Renato César dos Santos**<sup>1</sup>

renato\_cstos@hotmail.com

**André Caceres Carrilho**<sup>1</sup>

carrilho.acc@gmail.com

**Amilton Amorim**<sup>1, 2</sup>

a.amorim@unesp.br

**Maurício Galo**<sup>1, 2</sup>

mauricio.galo@unesp.br

**Faculdade de Ciências e Tecnologia/ Universidade Estadual Paulista (FCT/UNESP)**

<sup>1</sup> Programa de Pós-Graduação em Ciências Cartográficas

<sup>2</sup> Departamento de Cartografia

Rua Roberto Simonsen, 305 – Centro Educacional, Presidente Prudente/SP

#### **Resumo:**

O uso de sistemas de aeronaves remotamente pilotadas (*Remotely Piloted Aircraft System – RPAS*) para a aquisição de dados da superfície terrestre vem crescendo nos últimos anos, devido às inovações tecnológicas, tanto às ligadas ao desenvolvimento dos RPAS, quanto de receptores GNSS, de sistemas inerciais e sensores imageadores de baixo custo. Além disso, o desenvolvimento de algoritmos de processamento e análise de imagens bem como de visão computacional possibilitaram a extração de informação tridimensional das imagens com um número reduzido de operações humanas, fornecendo novas ferramentas à comunidade cartográfica para a execução de trabalhos voltados à elaboração e atualização de documentos cartográficos. Os métodos de classificação podem ser categorizados a partir da abordagem utilizada: supervisionada ou não; por pixel ou por área; e pelo tipo de informação utilizada: radiométrica, geométrica ou ambas. Este trabalho propõe uma abordagem para a classificação de nuvens de pontos, geradas por correspondência de imagens aéreas adquiridas por RPAS. O método proposto consiste de uma classificação supervisionada por pixel, a qual baseia-se em uma árvore de decisões cujo objetivo é identificar e classificar os pontos pertencentes às construções, com base em informações de natureza geométrica e radiométrica. Os dados utilizados correspondem a um voo realizado sobre o distrito de Espigão, do município de Regente Feijó-SP, utilizando uma câmara digital com as bandas verde, vermelho e infravermelho próximo. A análise quantitativa indicou que o método proposto possibilita a discriminação dos pontos nas classes previstas, apresentando acurácia global da ordem de 98%.

**Palavras-chave:** Classificação; Nuvem de pontos; Sistema de aeronaves remotamente pilotadas.

## Abstract

The use of Remotely Piloted Aircraft Systems (RPAS) for terrestrial surface data acquisition has grown significantly in recent years due to the technological innovations related to the development of RPAS by itself, but also of GNSS receivers, inertial systems and off-the-shelf cameras. In addition, the development of image processing and analysis algorithms and computer vision allows the extraction of three-dimensional information from images with a reduced number of human operations, providing new tools to the cartographic community for the execution of works aimed at the elaboration and updating of cartographic documents. Classification methods can be categorized by the approach used: supervised or not; per pixel or per area; and by the type of information used: radiometric, geometric or both. This work proposes a method for the classification of point cloud, generated by correspondence of aerial images acquired by RPAS. The proposed method consists of a pixel supervised classification based on a decision tree, which the objective is to identify and classify the points belonging to the constructions present in the test area considering both geometric and radiometric information. The data used correspond to a flight carried out on the district of Espigão, in the city of Regente Feijó-SP, using a digital camera with the bands green, red and near infra-red. The quantitative analysis of the classification indicated that the proposed method allows the discrimination of the cloud points in the predicted classes, with an overall accuracy of approximately 98%.

**Keywords:** Classification; Point Cloud; Remotely Piloted Aircraft System.

## 1. INTRODUÇÃO

De acordo com a Constituição Federal (BRASIL, 1988) uma das competências do município é manter atualizado um sistema de informações sociais, administrativas, territoriais, cartográficas e outras de interesse do município, assegurando a sua ampla e periódica divulgação. O Estatuto da Cidade, Lei Federal nº 10.257 (BRASIL, 2001), promoveu um importante avanço da legislação urbanística brasileira com o apoio aos municípios na execução da Política Nacional de Desenvolvimento Urbano, principalmente no que se refere às propostas dos Planos Diretores municipais, que depende, de modo imprescindível, de produtos cartográficos atualizados.

Segundo Erba e Loch (2007), um bom cadastro “contribui para a distribuição equitativa de cargas tributárias, promove a segurança da propriedade e cria bases para o planejamento urbano e regional”. No intuito de criar bases para o planejamento urbano e regional, surgiu o Cadastro Técnico Multifinalitário (CTM). Segundo os mesmos autores, o CTM tem papel fundamental nas políticas e ações de planejamento e gestão urbana, com o auxílio de dados ambientais e sociais referentes aos imóveis e às pessoas que os habitam, além de considerar os aspectos econômicos, físicos e jurídicos tradicionais, entre outros.

O CTM é composto por dados geométricos e descritivos. No que se refere aos dados geométricos, deve-se considerar que o CTM necessita de uma base cartográfica atualizada. No entanto, um dos fatores limitantes para a atualização das bases cadastrais é o alto custo do mapeamento. Desta maneira, alternativas mais acessíveis devem ser consideradas, principalmente para cidades de pequeno porte. Nesse sentido, destaca-se a possibilidade de utilização de técnicas fotogramétricas aplicadas à dados obtidos por RPAS, uma vez que a logística envolvida na operação destes sistemas é mais flexível e econômica, quando comparada ao mapeamento por técnicas topográficas ou geodésicas, ou mesmo com a Fotogrametria convencional, na qual são utilizadas aeronaves tripuladas.

O imageamento por RPAS possibilita a extração de informação tridimensional a partir das imagens com um número reduzido de operações humanas, principalmente nas etapas de orientação

do bloco fotogramétrico e correspondência densa de imagens. Como ressaltado por Becker et al. (2017) a extração de informações semânticas sobre nuvem de pontos permite entender a cena, classificar e extrair objetos com alto nível de detalhamento. Apesar de existir um esforço no desenvolvimento de procedimentos automáticos de classificação, a obtenção dos resultados com a acurácia desejada permanece como um desafio, principalmente em ambientes urbanos (AWRANGJEB et al., 2010). Nesse sentido, é necessário que os algoritmos sejam robustos o suficiente para lidar com as diversas estruturas presentes na cena: as de origem natural, como a vegetação e hidrografia, e as antrópicas (construções). Segundo Sohn e Dowman (2007) dentre os fatores complicadores referentes à classificação e extração automática de construções pode-se incluir a complexidade da cena, ausência de informações e/ou oclusões, e as características dos equipamentos utilizados na aquisição dos dados. Além disso, no uso de RPAS para a aquisição da informação devem ser observados alguns detalhes adicionais, tais como: intensidade e direção do vento, condições de relevo e tamanho da área, e outros, que geralmente não costumam influenciar nos resultados dos mapeamentos fotogramétricos convencionais, executados com aeronaves tripuladas (AMORIM et al., 2016).

A complexidade da cena é um agravante, principalmente em áreas urbanas, as quais necessitam de processamentos específicos. Uma alternativa é aplicar os métodos de classificação em nuvens de pontos fotogramétricas, as quais apresentam informação radiométricas e geométricas. Dados radiométricos, obtidos a partir de imagens, estão associados às características físicas do alvo e ao nível de discretização registrado pelo sensor, enquanto que dados geométricos, obtidos a partir da nuvem de pontos, correspondem à informação tridimensional da superfície investigada, e geralmente são obtidos por técnicas de varredura a LASER aerotransportado ou técnicas fotogramétricas como a correspondência de imagens. A complementaridade dos dados geométricos e radiométricos motivou sua integração visando aprimorar a qualidade dos resultados, como pode-se ver em Hermosilla et al. (2011), Buján et al. (2012) e Malpica et al. (2013), dentre outros.

Com base no exposto, este trabalho propõe uma abordagem que combina informações geométricas e radiométricas para a classificação de nuvens de pontos geradas por correspondência de imagens aéreas adquiridas por RPAS. Destaca-se que o método consiste em uma árvore de decisão hierárquica com critérios definidos a partir de informações obtidas dos dados amostrais.

## 2. FILTRAGEM DE NUVEM DE PONTOS

As superfícies amostradas por sistemas de varredura a LASER (*Light Amplification by Stimulated Emission of Radiation*) aerotransportados ou resultantes de alguns processamentos fotogramétricos constituem em pontos 3D irregularmente espaçados, dados que são comumente denominados de nuvem de pontos. Conceitualmente, uma nuvem de pontos gerada a partir do ponto de vista aéreo pode ser considerada uma representação contínua da superfície da Terra, cuja continuidade é interrompida por objetos presentes sobre a superfície (SITHOLE e VOSSSELMAN, 2005).

A filtragem dessas nuvens de pontos tem como propósito discriminar os pontos entre pertencentes ou não ao terreno. Diversos algoritmos de filtragem realizam o processamento sobre a nuvem original (PFEIFER et al., 1998; AXELSSON, 2000; SITHOLE, 2001). Outros algoritmos

de filtragem se baseiam na adaptação de algoritmos convencionais de processamento de imagem, necessitando de uma reamostragem prévia da nuvem de pontos para uma malha regular de pontos.

Para realizar o processo de filtragem, os algoritmos baseiam-se em um modelo geométrico do terreno numa vizinhança local. Para Sithole e Vosselman (2005), os algoritmos de filtragem diferem em como eles medem descontinuidades entre superfícies da Terra e superfícies de objetos (construções, vegetação, etc.). Segundo Dal Poz (2013) é comum considerar quatro princípios de filtragem distintos:

- **Baseado na declividade:** A declividade entre dois pontos é medida e comparada a um limiar. Se este desnível exceder o limiar, então o ponto mais alto é assumido como pertencente a um objeto elevado. Nesse algoritmo é assumida a hipótese de que o terreno varia suavemente;
- **Baseado no bloco mínimo:** A função discriminante visa delimitar uma região em 3D, tendo por referência um segmento local de plano horizontal, a partir do qual, acima ou abaixo, os pontos de terreno devem ser encontrados;
- **Baseado em superfície:** É utilizada uma superfície que modela globalmente a superfície do terreno. Por exemplo, Axelsson (2000) refina progressivamente uma representação poliédrica grosseira do relevo;
- **Baseado em segmentação / agrupamento:** estes métodos levam em conta que pontos que se agrupam e que estão acima de um agrupamento adjacente, pertencem a um objeto.

### 3. CLASSIFICAÇÃO

A classificação é uma das técnicas mais frequentes na extração de informações a partir de imagens. Tal técnica, consiste no reconhecimento de padrões por meio das diferenças espectrais entre os alvos (JENSEN, 2014). Basicamente, os padrões podem ser reconhecidos por análises visuais, o que necessita de grande esforço humano, ou por técnicas computacionais que, por sua vez, apresentam diversas vantagens sobre as técnicas visuais, principalmente para grandes quantidades de dados e complexidade de cena.

De acordo com Schowengerdt (2006) os métodos de classificação podem ser divididos de acordo com o processamento, em visual ou digital; conforme o conhecimento *a priori*, em supervisionado, não supervisionado e híbrido; conforme as métricas, em paramétrico ou não paramétrico; e de acordo com a abordagem, por pixel ou por regiões (objetos). Além disso, elas podem ainda fazer o uso apenas de dados radiométricos, dados geométricos ou ambos.

A abordagem supervisionada implica na necessidade da análise prévia da cena, a fim de detectar todos os tipos de alvos e colher amostras de referência para posterior treinamento do classificador (GONZALEZ e WOODS, 2000). A partir das amostras é possível estimar um conjunto de métricas e limiares, que servirão de base para a discriminação e classificação dos demais pixels da cena. A abordagem não supervisionada, consiste no método em que os pixels são inicialmente agrupados, de acordo com a similaridade entre atributos (características). Destaca-se que esse agrupamento é feito sem o conhecimento prévio da existência ou do tipo de alvo de interesse. A vantagem dessa abordagem, frente a abordagem supervisionada, é que os agrupamentos são formados com base apenas nos dados apresentados ao classificador.

Na divisão em abordagens por pixel e por região, a primeira utiliza apenas dados espectrais do pixel, desconsiderando os dados de vizinhança. Por outro lado, os classificadores por região

agrupam os pixels vizinhos com características similares e então classificam os agrupamentos formados (JENSEN, 2014).

Conforme as métricas usadas, como destacado por Richards e Jia (1999), usualmente considera-se que as classes são modeladas por uma função normal, sendo assim possível estimar a função densidade de probabilidade para cada classe e então com base na resposta de um dado pixel a essa função, associa-lo ou não a uma das classes. Destaca-se que classificadores baseados nestes princípios, por apresentarem superfícies de decisão mais complexas, possuem maior poder de discriminação que classificadores por limiarização (RICHARDS e JIA, 1999).

De modo geral, os classificadores são condicionados à critérios de decisão, os quais fazem parte de um sistema hierárquico. Esse sistema deve especificar as classes que serão extraídas bem como os critérios usados para diferencia-las.

### 3.1. Análise Temática

A confiabilidade dos resultados da classificação é dependente principalmente dos dados de entrada, do método utilizado e da complexidade da cena. Assim, é necessário que se conheça ao menos um indicativo da acurácia obtida no processo de classificação. Para analisar a qualidade da classificação uma das possibilidades é o uso da matriz de erro (CONGALTON, 1991), a qual consiste em um arranjo matricial de números que expressam o número de dados amostrais classificados em cada uma das classes, como exemplificado na Tabela 1 para n classes.

Tabela 1. Matriz de confusão na qual  $C_{i,j}$  representa a quantidade de elementos da categoria de referência i classificados na classe j.

		Dados de Referência				
		Classe 1	Classe 2	...	Classe n	Total
Dados Classificados	Classe 1	$C_{1,1}$	$C_{1,2}$	...	$C_{1,n}$	$\sum_{j=1}^n C_{1,j}$
	Classe 2	$C_{2,1}$	$C_{2,2}$	...	$C_{2,n}$	$\sum_{j=1}^n C_{2,j}$
	...	...	...	...	...	...
	Classe n	$C_{n,1}$	$C_{n,2}$	...	$C_{n,n}$	$\sum_{j=1}^n C_{n,j}$
	Total	$\sum_{i=1}^n C_{i,1}$	$\sum_{i=1}^n C_{i,2}$	...	$\sum_{i=1}^n C_{i,n}$	$\sum_{i=1}^n \sum_{j=1}^n C_{i,j}$

Fonte: Adaptado de Congalton (1991).

A partir da matriz de erros diversas métricas podem ser extraídas, dentre elas: acurácia global, índice kappa, acurácia do produtor e do usuário e os erros de omissão e comissão. De acordo com Congalton (1991), a matriz de erros é um subsídio apropriado para diversas análises. Nos casos em que as quantidades de dados de cada classe apresentam grande variação de

magnitude é possível o emprego da matriz de erros normalizada. Trata-se de uma matriz em que os valores de cada célula são iterativamente normalizados até que a soma de cada linha e cada coluna resulte em um valor unitário. Nessa matriz as células incorporam informações das linhas e das colunas a que pertencem.

A acurácia global ( $A_g$ ) é calculada pela soma do total dos pixels corretamente classificados dividida pelo número total de pixels da matriz de confusão (Equação 1). Os erros de omissão e comissão são calculados por meio das quantidades de cada coluna e linha, respectivamente. Omissão está relacionada à porcentagem de pixels omitidos de uma determinada classe, ou seja, a proporção de pixels que pertencem a uma determinada classe mas que foram classificados como pertencentes a outra (Equação 2). Comissão está relacionada à porcentagem de pixels que foram erroneamente inseridos em uma determinada classe (Equação 3).

$$A_g = \frac{\sum_{i=1}^n C_{i,i}}{\sum_{i=1}^n \sum_{j=1}^n C_{i,j}} \quad (1)$$

$$omissão_j = \frac{(\sum_{i=1}^n C_{i,j}) - C_{j,j}}{\sum_{i=1}^n C_{i,j}} \quad (2)$$

$$comissão_i = \frac{(\sum_{j=1}^n C_{i,j}) - C_{i,i}}{\sum_{j=1}^n C_{i,j}} \quad (3)$$

sendo,

$i$  e  $j$  – índices de linha e coluna dos elementos da matriz de confusão;

$C_{i,j}$  – elemento da matriz de confusão localizado na linha  $i$  e coluna  $j$ .

#### 4. MÉTODO

O método proposto consiste em um classificador supervisionado por ponto, em que o sistema de classificação se baseia na aplicação de uma sequência de limiares (decisões binárias) a fim de realizar a discriminação dos pontos de construção dos demais pontos. Para tanto, realizou-se um processo prévio de filtragem a fim de discriminar os pontos em dois conjuntos: pontos de terreno e não terreno. Na sequência, as informações radiométricas da nuvem foram utilizadas para o processo de classificação. Por fim, os resultados da classificação foram testados com base em um conjunto de pontos de verificação conhecidos. A Figura 1 mostra o fluxograma do método proposto.

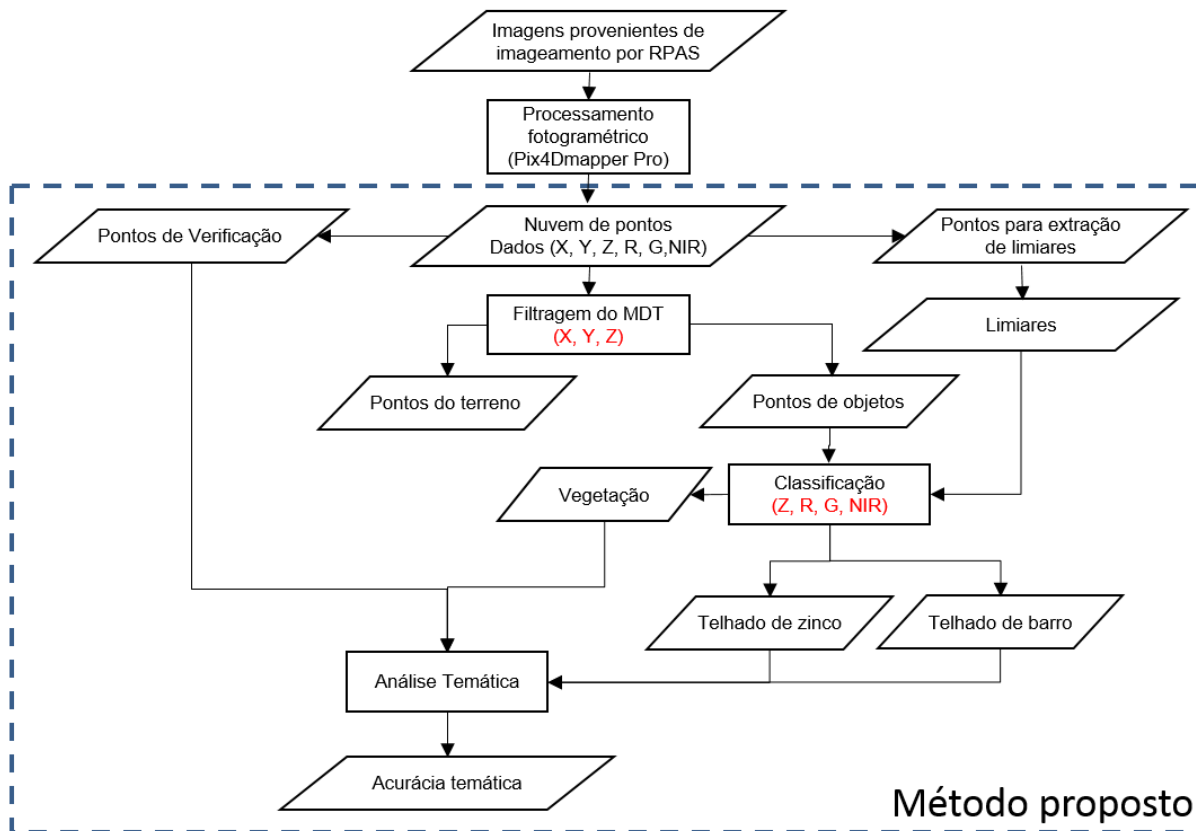


Figura 1 – Fluxograma do método proposto.

#### 4.1. Descrição dos Dados

Os dados utilizados nesse trabalho correspondem a uma nuvem de pontos obtida por meio de um processo de correspondência de imagens a partir do software *Pix4Dmapper Pro*. O conjunto de imagens foi adquirido por meio de um voo realizado sobre o distrito de Espigão, localizado no município de Regente Feijó, região oeste do Estado de São Paulo. As coordenadas UTM (Universal Transversa de Mercator) aproximadas do centro da área de estudo são: E = 463336 m, N = 7545302 m, 22S. A área selecionada é caracterizada por uma mancha urbana próxima a uma rodovia. A maioria das construções apresentam cobertura com telhas de barro ou zinco. Além disso, é possível notar a presença de vegetação nas calçadas, áreas de solo coberto por vegetação rasteira e vias pavimentadas (asfalto). A Figura 2 mostra a imagem da região de trabalho.



Figura 2 – Área selecionada.  
Fonte: *Google Earth* (2018).

A missão de voo realizada em janeiro de 2016 utilizou um RPAS *Sensefly eBee* equipado com o sistema de posicionamento baseado em receptores GNSS e um sistema inercial do tipo MEMS (*Micro Electro Mechanical Systems*). O planejamento da missão foi realizado no programa *Sensefly Emotion2*, onde foram configurados alguns parâmetros: a altura de voo de 157 m, acarretando em um *ground sample distance* (GSD) de 5,0 cm; e também as sobreposições lateral e longitudinal de 70% e 80%, respectivamente. A nuvem de pontos resultante apresenta uma densidade média de 5,32 pontos/m<sup>2</sup>, tendo um total de 266712 pontos. A Figura 3 mostra a nuvem de pontos coloridos em função da altitude e também a partir dos valores de R, G e NIR.




Figura 3 – Fonte de dados usada no trabalho: (a) Nuvem de pontos coloridos em função da altitude e (b) Nuvem de pontos contendo informação radiométrica (R, G, NIR).

Para a tomada das imagens foi utilizada uma câmara digital Cannon S110 NIR (*Near Infrared*), cujas bandas verde, vermelho e infravermelho próximo registradas pelo sensor correspondem aos comprimentos de onda 550 nm, 625 nm e 850 nm, respectivamente. Na Figura 4 são mostradas as curvas com o padrão de respostas de cada uma destas bandas, para os diferentes comprimentos de onda, para a câmara utilizada.




Figura 4 – Percentual de resposta das bandas Verde, Vermelho, Infravermelho próximo (comprimento de onda x percentual de resposta).

Fonte: Sensefly, 2014.

## 4.2. Filtragem

Este processamento foi realizado por meio da ferramenta *lasground* do software *LAStools*, a qual utiliza uma versão modificada do algoritmo de filtragem proposto por Axelsson (2000). Embora este método de filtragem tenha sido desenvolvido para dados LiDAR é possível processar nuvens de pontos obtidas por diferentes fontes, como por exemplo por correspondência de imagens.

Após a extração do Modelo Digital de Terreno (MDT) a partir do resultado da ferramenta *lasground*, e separação em pontos de terreno e não terreno (Figura 5(a)), calcula-se a altura dos pontos em relação ao MDT extraído (Figura 5(b)) por meio da ferramenta *lasheight*. Dois conjuntos de pontos resultam desta etapa, o primeiro com pontos do terreno, e o segundo com os demais pontos, isto é, de objetos (construções, vegetação, entre outros).




Figura 5 – Nuvem de pontos resultante da filtragem (a) e do cálculo de altura (b). (a) pontos de terreno (marrom) e não terreno (cinza) classificados pela ferramenta *lasground*. (b) nuvem após a aplicação da ferramenta *lasheight*, pontos coloridos de acordo com a altura.

### 4.3. Classificação

No processo de classificação foram utilizados apenas os pontos de objetos (não terreno) e foram estabelecidas as classes que seriam consideradas: construções com telhado de barro, construções com telhado de zinco e vegetação. Visto que será usado um classificador supervisionado, foram coletados 25 pontos representativos das classes estabelecidas, a fim de determinar limiares que permitam realizar a discriminação entre as classes. A distribuição dos elementos amostrais (Figura 6) foi executada por meio de interpretação visual da imagem, de modo a garantir que todas as classes fossem igualmente amostradas.




Figura 6 – Distribuição dos pontos amostrados (triângulos em vermelho) para determinação dos limiares da classificação.

A partir dos pontos amostrados, realizou-se um estudo com base nas respostas espectrais. Para cada uma das classes foram obtidas as seguintes métricas: média, e desvio padrão para cada banda, e os valores de Índice de Vegetação da Diferença Normalizada (*Normalized Difference Vegetation Index-NDVI*), estimados a partir dos valores R e NIR. Os valores da resposta (em nível digital – ND), quantizadas em 8 bits, para a média de cada banda, bem como o valor do NDVI, são apresentados no gráfico da Figura 7.

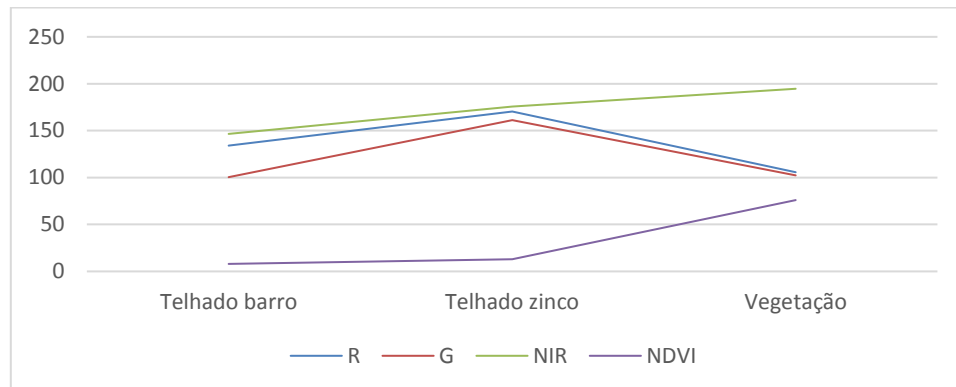


Figura 7 – Gráfico com as médias das respostas (NDs) nas três bandas espectrais capturadas pelo sensor e com o valor de NDVI para cada classe considerada.

A separação entre vegetação e construções foi realizada a partir do cálculo de índices espectrais, como o NDVI. Na Figura 7 é possível perceber que adotando um limiar mínimo de 20 é possível separar a vegetação das classes de construções (Telhado de barro e Telhado de zinco). A discriminação dos telhados de barro e zinco foi realizada considerando a resposta espectral dos alvos na banda Verde (G), uma vez que os pontos localizados sobre os telhados de barro apresentam valores próximos de 100 e nos telhados de zinco apresentam valores próximos a 150. Dessa forma, adotou-se o limiar de 125, de modo que pontos abaixo desse limiar foram inseridos na classe Telhado de barro e pontos acima desse limiar foram classificados como Telhado de zinco. O fluxograma da Figura 8 sintetiza o processo de classificação.

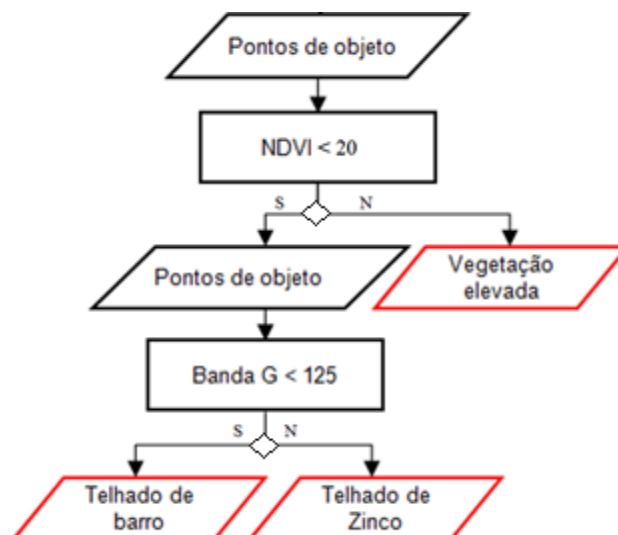


Figura 8 – Fluxograma do processo de classificação.

O experimento realizado para a validação do algoritmo considerou a nuvem de pontos da região central da área de estudo, com um total de 127234 pontos (Figura 9 (a)). O resultado da aplicação do método proposto é apresentado na Figura 9 (b). Por se tratar de uma nuvem de pontos obtida por correspondência de imagens, algumas regiões não apresentam informações (regiões em

branco), uma vez que o processo de correspondência não foi capaz de determinar pontos homólogos nestas regiões. Normalmente essa limitação está diretamente relacionada à baixa variabilidade dos alvos (superfície homogênea) ou padrão repetitivo. Neste trabalho, as regiões sem informação foram desconsideradas.

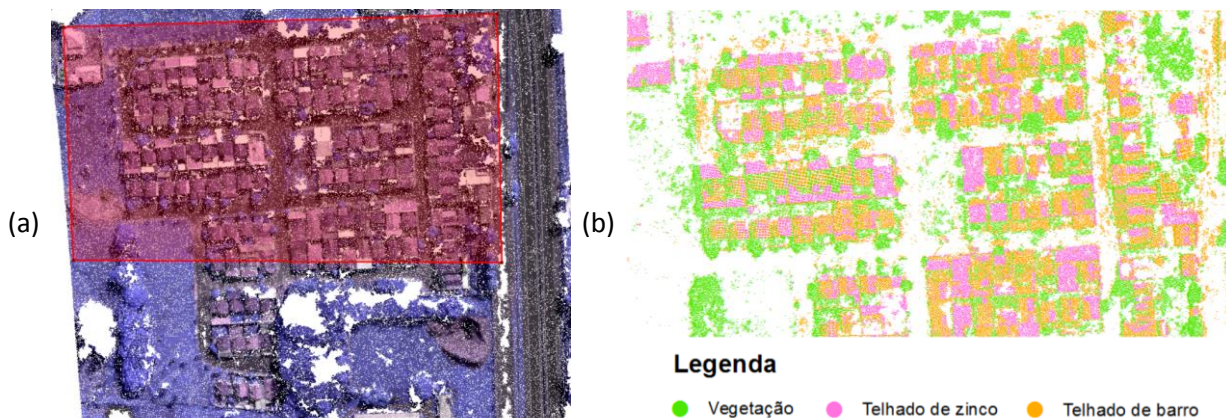


Figura 9 – (a) Área submetida a classificação destacada em vermelho. (b) resultado da aplicação do método proposto.

#### 4.4. Análise Temática da Classificação

Para a análise quantitativa da acurácia temática foram amostrados aleatoriamente cerca de 20 pontos por classe, resultando em 60 pontos (Figura 10) no total. Destaca-se que os pontos utilizados para verificação foram amostrados independentemente dos pontos amostrais utilizados no treinamento (Seção 4.3).




Figura 10 – Distribuição dos pontos de verificação.

Considerando os pontos de verificação lidos sobre feições identificáveis e o resultado do método para os pontos de verificação, proveniente da classificação, foi possível estimar a acurácia global da classificação por meio da matriz de confusão, apresentada na Tabela 2.

Tabela 2 – Matriz de confusão.

	Telhado de zinco	Telhado de barro	Vegetação	Total	Comissão
Telhado de zinco	14	9	0	23	39,1%
Telhado de barro	6	10	0	16	37,5%
Vegetação	0	1	20	21	4,7%
Total	20	20	20	60	
Omissão	30%	50%	0%		

A acurácia global da classificação foi de 73,33%. No entanto, observou-se a presença de alguns erros de classificação em classes que podem ser agrupadas, como é o caso do Telhado de barro e Telhado de zinco. Ainda com base na matriz de confusão apresentada na Tabela 2, foram calculados os erros de omissão e comissão. Os erros de omissão e comissão mostram que as classes Telhado de barro e Telhado de zinco, apresentaram erros superiores a 30%. Com base na matriz de confusão é possível verificar que as classes de telhados apresentam grande confusão. Sendo assim, as classes Telhado de barro e Telhado de zinco foram unidas para formar a classe Construção, sendo os resultados após a junção dessas classes apresentados na Figura 11 (a legenda usada é a mesma da Figura 9(b)).



Figura 11 – Resultado da classificação após a junção das classes Telhado de zinco e Telhado de barro.

Após a junção das classes mencionadas, os mesmos 60 pontos foram novamente avaliados. A matriz de confusão, considerando as novas classes, é apresentada na Tabela 3.

Tabela 3 – Matriz de confusão após a junção das classes Telhado de zinco e Telhado de barro.

	Construção	Vegetação	Total	Comissão
Construção	39	0	39	0%
Vegetação	1	20	21	4,7%
Total	40	20	60	
Omissão	2,4%	0%		

A acurácia global da classificação foi de 98,33%, valor esse superior ao estimado anteriormente (Tabela 2). No entanto, ao realizar uma análise visual sobre os resultados da classificação foi possível observar que alguns pontos foram classificados erroneamente como Vegetação. Tais erros ocorreram, em sua maioria, nas bordas dos telhados devido a existência de sombra. Exemplos dos erros citados estão apresentados na Figura 12.

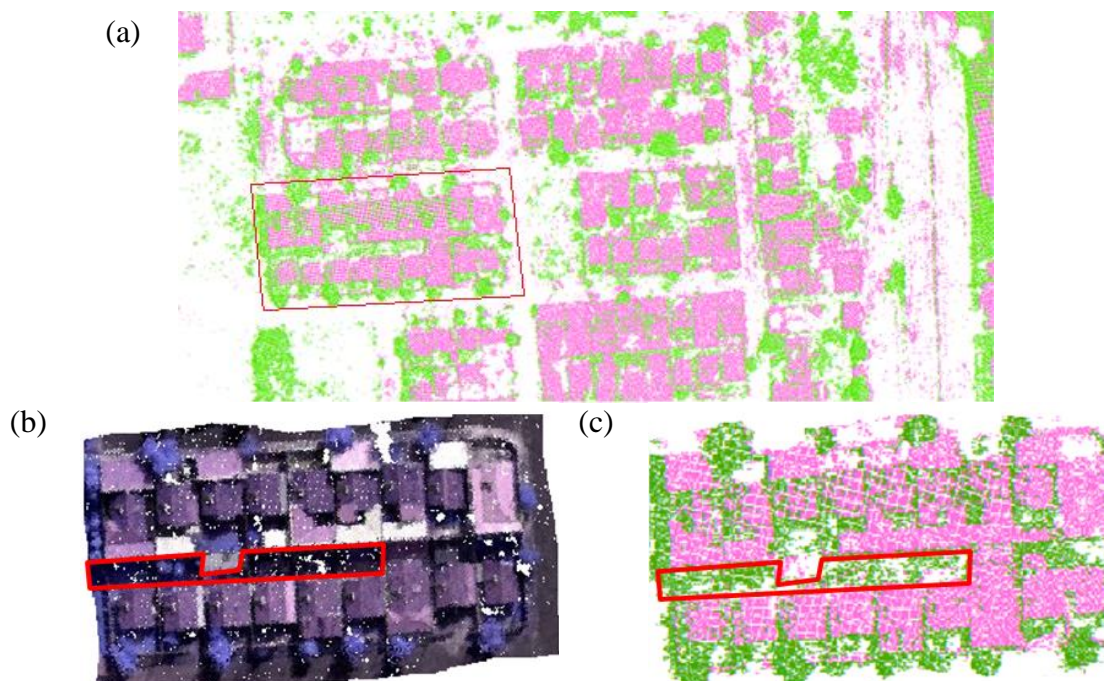


Figura 12 – Análise visual da classificação: (a) resultado da classificação; (b) recorte da nuvem R, G, NIR (composição falsa cor) e (c) recorte da nuvem classificada.

A partir de uma análise visual, observou-se que regiões de sombras influenciam diretamente os resultados da classificação. Essas regiões apresentam pouca iluminação, o que por sua vez impacta na resposta dos alvos registrada pelo sensor, principalmente para as bandas do visível (R e G) acarretando em altos valores de NDVI. Analisando a Figura 12 (b) e a Figura 12 (c) é possível perceber que as regiões de sombra foram classificadas como Vegetação. Destaca-se que, embora o resultado da matriz de confusão indique a baixa ocorrência de erros, é importante considerar que as métricas utilizadas tentam representar a qualidade da classificação em função de uma quantidade limitada de dados, o que pode implicar em uma matriz de confusão otimista, que pode ser modificada pela seleção de mais pontos de análise em região de sombras.

## 5. CONCLUSÕES

A partir da análise quantitativa da acurácia temática, observou-se que o método de classificação proposto apresenta uma certa dificuldade para discriminar os diferentes tipos de telhados. Entretanto, o agrupamento em classes mais genéricas proporcionou melhorias na acurácia global da classificação. De forma geral, a identificação de sombras em dados de sensoriamento remoto é um problema e deve ser tratado em uma fase preliminar ao processo de classificação ou então ser previsto como uma classe adicional aos alvos presentes em cena.

A adição da informação radiométrica e a possibilidade de utilização de índices radiométricos possibilitou a exploração dos dados de maneira mais efetiva, principalmente para a separação de pontos de vegetação e as demais classes. Em contrapartida, os dados geométricos tiveram papel fundamental na separação entre pontos de terreno e de não terreno, fato que possibilitou trabalhar com os dois conjuntos de forma específica.

Trabalhos futuros devem investigar outras alternativas para o classificador. Além disso, os dados geométricos podem ser mais explorados de modo a auxiliar no processo de classificação, como o uso de máximos e mínimos locais, a estimação de medidas de entropia e o uso de métricas derivadas da matriz de covariâncias das coordenadas, por exemplo. Com o intuito de reduzir erros de classificação também é possível explorar algumas técnicas de morfologia matemática.

## Agradecimentos

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), pelo apoio a esta pesquisa por meio do Processo Nº 2014/01841-1 (auxílio à Pesquisa Regular); ao Programa de Pós-Graduação em Ciências Cartográficas (PPGCC) da FCT/UNESP pela infraestrutura fornecida; à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo suporte ao projeto número 1481349 bem como ao Conselho Nacional de Pesquisa e Desenvolvimento (CNPq) pelo suporte em projetos (Proc. 304189/2016-2).

## Referências Bibliográficas

AMORIM, A.; PESSOA, G. G.; LEMES, I. R.; KOMAZAKI, J. M.; JORGE, L. C.; GALO, M.; CAMARGO, P. de O. Utilização de VANT para o georreferenciamento de imóveis rurais. In: **Seminário Internacional UAV**. 1ª Ed. Lisboa: UNL, 2016, v.1, p. 25-36. ISBN: 9789892067261

AWRANGJEB, M.; RAVANBAKHS, M.; FRASER, C. S. Building detection from multispectral imagery and LiDAR data employing a threshold-free evaluation system. In: **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, Vol. 38, pp. 49-55. 2010.

AXELSSON, P. DEM generation from laser scanner data using adaptive TIN models. In: **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. Vol. 33, pp. 110-117. 2000.

BRASIL. **Constituição da República Federativa do Brasil**. Rio de Janeiro, Editora Freitas Bastos, 1998.

BRASIL. **Lei nº 10.257, de 10 de julho de 2001**. Regulamenta os artigos. 182 e 183 da Constituição Federal e estabelece diretrizes gerais da Política Urbana e dá outras providências. 2001.

BECKER, C.; HÄNI, N.; ROSINSKAYA, E.; D'ANGELO, E.; STRECHA, C. Classification of aerial photogrammetric 3D point clouds. In: **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Volume IV-1/W1, ISPRS Hannover Workshop, Hannover, Germany, 2017.

BUJÁN, S.; GONZÁLEZ-FERREIRO, E.; REYES-BUENO, F.; BARREIRO-FERNÁNDEZ, L.; CRECENTE, R.; MIRANDA, D. Land use classification from LiDAR data and ortho-images in a rural area. **The Photogrammetric Record**, Vol. 27, Nº 140, pp. 401–422. 2012.

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

DAL POZ, A. P. Filtragem de dados de varredura a laser: Princípios e exemplos. In: **XVI Simpósio Brasileiro de Sensoriamento Remoto**, pp. 6057-6064. 2013.

ERBA, D. A.; LOCH, C. **Cadastro Técnico Multifinalitário Rural e Urbano**. 1. ed. Cambridge: Lincoln Institute of Land Policy, v. 1000. 2007. 161 p.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de imagens digitais**. Edgard Blucher, 2000.

HERMOSILLA, T.; RUIZ, L. A.; RECIO, J. A.; ESTORNELL, J. Evaluation of automatic building approaches combining high resolution images and LiDAR data. **Remote Sensing**, Vol. 3, Nº 6, pp. 1188-1210. 2011.

JENSEN, J. R. **Remote sensing of the environment: An earth resource perspective 2/e**. Pearson Education India, 2014.

MALPICA, J. A.; ALONSO, M. C.; PAPI, F.; AROZARENA, A.; MARTÍNEZ DE AGIRRE, A. Change detection of buildings from satellite imagery and lidar data. **International journal of remote sensing**, v. 34, n. 5, p. 1652-1675, 2013.

PFEIFER, N.; KOSTLI, A.; KRAUS, K. Interpolation and filtering of laser scanner data implementation and first results. In: **International Archives of Photogrammetry and Remote Sensing**, Vol XXXII, Columbus, pp. 153-159, 1998.

RICHARDS, J. A.; JIA, X. **Remote sensing digital image analysis: an introduction**. 3. ed. New

York: Springer-Verlag. 1999.

SCHOWENGERDT, R. A. **Remote sensing: models and methods for image processing.** Academic press. 2006.

SENSEFLY. **User Manual: S110 RGB/NIR/RE camera.** Disponível em: <[http://95.110.228.56/documentUAV/camera%20manual/%5BENG%5D\\_2014\\_user\\_manual\\_sl10\\_v3.pdf](http://95.110.228.56/documentUAV/camera%20manual/%5BENG%5D_2014_user_manual_sl10_v3.pdf)>. Acesso em: 04 de julho de 2018.

SITHOLE, G. Filtering of laser altimetry data using a slope adaptive filter. In: **International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Vol. XXXIV-3/W4, Annapolis, MD, October, 2001.

SITHOLE, G.; VOSSelman, G. Filtering of airborne laser scanner data based on segmented point clouds. In: **International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, n. part 3, p. W19, 2005.

SOHN, G.; DOWMAN, I. Data fusion of high-resolution satellite imagery and LiDAR data for automatic building extraction. **ISPRS Journal of Photogrammetry and Remote Sensing**, Vol. 68, pp. 43-63. 2007.