
CLASSIFICAÇÃO DE PONTOS 3D UTILIZANDO O CONCEITO DE ANÁLISE DE COMPONENTES PRINCIPAIS

RENATO CÉSAR DOS SANTOS ⁽¹⁾

MAURÍCIO GALO ⁽²⁾

Universidade Estadual Paulista – UNESP
Faculdade de Ciências e Tecnologia – FCT/ Presidente Prudente - SP

⁽¹⁾ Programa de Pós-Graduação em Ciências Cartográficas - PPGCC

⁽²⁾ Departamento de Cartografia

renato_cstos@hotmail.com, galo@fct.unesp.br

RESUMO - Este artigo apresenta um procedimento para a classificação automática de um conjunto de pontos tridimensionais amostrado por um Sistema de Varredura a LASER Aerotransportado (SVLA). Nesse processo são utilizados os autovalores da matriz de variâncias e covariâncias (MVC). Para o cálculo da MVC considera-se uma vizinhança no entorno do ponto de interesse, a qual é determinada com base no conceito de entropia. A classificação é executada comparando os autovalores calculados, referentes a cada ponto e sua vizinhança, com os autovalores das estruturas ou classes pré-definidas. Como medida de similaridade utiliza-se a distância euclidiana no espaço dos autovalores. Com o intuito de analisar os resultados produzidos pelo procedimento de classificação utiliza-se um conjunto de pontos 3D, obtidos por um SVLA, referentes à região urbana do município de Presidente Prudente/SP.

ABSTRACT - This paper presents a procedure for the automatic classification of three-dimensional set of points obtained by an Airborne Laser Scanning System (SVLA). To perform the classification the eigenvalues of the variance and covariance matrix (MVC) are used and to compute the MVC is considered a neighborhood around the point of interest, which is determined based on the concept of entropy. The classification is performed by comparing the eigenvalues calculated for each point, with the eigenvalues of some predefined classes. As a similarity measure the euclidean distance in the space of eigenvalues is considered. The classification procedure is applied on a set of real data, obtained by a SVLA from a urban area of Presidente Prudente / SP.

1 INTRODUÇÃO

O Sistema de Varredura a LASER Aerotransportado (SVLA) é composto basicamente por três tecnologias: emissor e receptor LASER (*Light Amplification by Stimulated Emission of Radiation* – Amplificação da Luz por Emissão Estimulada de Radiação), o GNSS (*Global Navigation Satellite System* – Sistema Global de Navegação por Satélite) e o INS (*Inertial Navigation System* - Sistema de Navegação Inercial), que integrados permitem a geração de densas nuvens de pontos tridimensionais (EL-SHEIMY et al., 2005).

O princípio de funcionamento do SVLA baseia-se na utilização de um pulso de LASER que é disparado na direção da superfície terrestre, com o auxílio de um espelho de varredura. Ao atingir a superfície, parte do sinal emitido é refletido na direção do sensor. O sensor mede tanto a intensidade do sinal de retorno, como também o tempo decorrido entre a emissão e a captação do retorno, que é usado para calcular a distância entre o sensor e objeto (BALTSAVIAS, 1999).

O conjunto de pontos amostrado pelo sistema de varredura a LASER pode ser utilizado em diversas aplicações, como por exemplo na modelagem tridimensional de superfícies. Essa modelagem pode englobar apenas os pontos localizados sobre o terreno e/ou vegetação (de diferentes portes) bem como os pontos localizados sobre as feições antrópicas como edificações, viadutos, rodovias, etc. A modelagem que considera apenas as feições antrópicas, conhecida como modelagem tridimensional de construções, tem se tornando nos últimos anos uma importante ferramenta para diversas aplicações, tais como: seleção de entidades utilizadas no ajustamento relativo de faixas LASER (HABIB et al., 2008), extração de telhados de construções (GALVANIN e DAL POZ, 2012) e reconstrução de objetos históricos (TSAI e CHANG, 2014).

Desta forma, a extração de estruturas planas, lineares e quinas, a partir de dados obtidos por um SVLA é um passo importante nesta modelagem e por esta razão tem sido objeto de várias pesquisas.

Este trabalho tem como objetivo a classificação automática de pontos 3D, amostrados por um SVLA. Nesta classificação são consideradas as seguintes estruturas: quinas, bordas, planos, etc, encontradas em construções antrópicas. Para tanto, é desenvolvido um procedimento de classificação baseado no método proposto por Gross e Jutzi (2009). A diferença entre o procedimento realizado neste trabalho e o proposto por Gross e Jutzi (2009) está no modo como a vizinhança é escolhida, que se baseia na seleção dos pontos presentes em uma esfera cujo raio é determinado utilizando o conceito de entropia (Demantke et al., 2011).

2 ANÁLISE DE COMPONENTES PRINCIPAIS E CLASSIFICAÇÃO DE OBJETOS PONTUAIS

Nesta seção serão apresentados os fundamentos da análise de componentes principais, bem como o princípio da classificação de estruturas (quinas, bordas, planos, etc) presentes em nuvens de pontos tridimensionais, gerados por diferentes técnicas, dentre elas por sistemas LASER aerotransportados.

2.1 Análise de componentes principais

A análise de componentes principais (ACP) é uma técnica amplamente utilizada em algumas aplicações, sendo os principais propósitos a redução dos dados e a sua interpretação. Em outras palavras, como pode-se ver em Johnson e Wichern (1999) e Mingoti (2005), pode-se considerar que a ideia central é obter um número reduzido de variáveis a partir da MVC (Matriz de Variâncias e Covariâncias) dos dados originais.

Associado a ACP têm-se os autovalores e os autovetores. Os autovalores ($\lambda_1, \lambda_2, \dots, \lambda_n$) representam o comprimento dos eixos das componentes principais e são medidos em unidade de variância. A cada autovalor é associado um autovetor ($\vec{e}_1, \vec{e}_2, \dots, \vec{e}_n$) de módulo unitário, sendo que estes autovetores representam as direções dos eixos das componentes principais. Os elementos de cada autovetor são fatores de ponderação que determinam a contribuição de cada variável original para gerar uma componente principal, numa combinação aditiva e linear (MINGOTI, 2005).

Seja Σ a matriz de variâncias e covariâncias (MVC) associada ao vetor das variáveis originais $\mathbf{X}^T = [X_1, X_2, \dots, X_n]$; (λ_1, \vec{e}_1), (λ_2, \vec{e}_2), ..., (λ_n, \vec{e}_n), os pares de autovalores e autovetores ortogonais padronizados associados a Σ , ordenados de modo que $\lambda_1 \geq \lambda_2 \geq \dots \lambda_n \geq 0$; a i-ésima componente principal (CP_i) é dada por (MINGOTI, 2005):

$$CP_i = \vec{e}_i^T \mathbf{X} = e_{i1} X_1 + e_{i2} X_2 + \dots + e_{in} X_n, i=1, 2, \dots, n. \tag{1}$$

Desta forma:

$$\text{Var} (CP_i) = \vec{e}_i^T \Sigma \vec{e}_i = \lambda_i \tag{2}$$

$$\text{Cov} (CP_i, CP_k) = \vec{e}_i^T \Sigma \vec{e}_k = 0 \tag{3}$$

sendo que Var (CP_i) e Cov (CP_i, CP_k) representam, respectivamente, a variância da componente principal i e a covariância entre as componentes principais i e k onde i, k = 1, 2, ..., n, com i ≠ k.

Uma forma de determinar os autovalores e autovetores da MVC é por meio da decomposição em valores singulares (SVD – *Singular Value Decomposition*) descrito em Press et al. (1992).

Dada uma nuvem de pontos de entrada, pode-se considerar um subconjunto composto por M pontos de coordenadas conhecidas (X, Y, Z). A MVC pode ser determinada levando em consideração este conjunto de M pontos vizinhos localizados no interior de uma esfera R (●) centrada no ponto de interesse p (●), como ilustra a Figura 1.

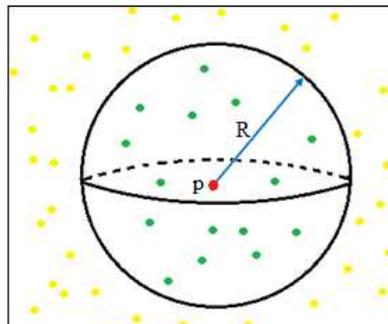


Figura 1– Esfera de raio R que delimita a vizinhança do ponto p.

A partir deste conjunto de M pontos, pode-se determinar a matriz de variâncias e covariâncias (Σ_X) por (GONZALEZ e WOODS, 2000):

$$\Sigma_X = \frac{1}{M} \sum_{j=1}^M X_j X_j^T - m_X m_X^T \tag{4}$$

$$m_X = \frac{1}{M} \sum_{j=1}^M X_j \tag{5}$$

onde m_X representa os valores médios, correspondentes ao centro de gravidade dos M pontos, que tornam os valores da MVC invariantes à translação. As coordenadas tridimensionais dos M pontos são representadas pelo vetor $X^T=[X \ Y \ Z]$. Em Gross e Jutzi (2009) a MVC é calculada utilizando o conceito de momentos.

2.2 Autovalores relacionados às estruturas de objetos analisado

Para algumas estruturas específicas podem ser determinados valores analíticos para os autovalores. Na Tabela 1 são apresentadas algumas estruturas típicas de objetos de interesse, com os respectivos autovalores analíticos e as dimensões correspondentes. Em Gross e Jutzi (2009) pode-se ver como estes valores podem ser determinados.

Tabela 1 – Autovalores e dimensão relacionados a algumas estruturas (GROSS e JUTZI, 2009).

	Estrutura	Autovalores			Dimensão		
		λ_1	λ_2	λ_3	0	1	2
	Ponto isolado	0	0	0			
	Final de linha	1/12	0	0			
	Linha	1/3	0	0			
	Meio plano	1/4	0	0			
	Plano	1/4	1/4	0			
	Quarto de plano	0,09	0	0			
	Dois planos	1/4	1/8	0,03			
	Três Planos	0,11	0,11	0,03			

2.3 Análise discriminante

Segundo Mingoti (2005) a análise discriminante é uma técnica que pode ser utilizada para a classificação de elementos de uma amostra ou população. Para a sua aplicação, é necessário que os grupos para os quais cada elemento amostral pode ser classificado sejam predefinidos. Este conhecimento permite a elaboração de uma função matemática chamada regra de classificação ou discriminação, a qual é utilizada para classificar os novos elementos amostrais nos grupos predefinidos. A classificação ou alocação pode ser definida como um conjunto de regras que são usadas para alocar novos objetos (JOHNSON e WICHERN, 1999).

Tomando os autovalores apresentados na Tabela 1 como referência, o processo de classificação do conjunto de pontos 3D pode ser executado utilizando como medida de similaridade a distância euclidiana no espaço tridimensional dos autovalores.

$$D_j^i(\lambda_1^j, \lambda_2^j, \lambda_3^j) = \sqrt{(\lambda_1^j - \lambda_1^i)^2 + (\lambda_2^j - \lambda_2^i)^2 + (\lambda_3^j - \lambda_3^i)^2} \tag{6}$$

onde D_j^i é distância entre o ponto j ($i=1, 2, \dots, m$) e a estrutura i ($i=1, 2, \dots, 8$); sendo λ_1^j, λ_2^j e λ_3^j os autovalores obtidos a partir da MVC do ponto j; e λ_1^i, λ_2^i e λ_3^i os autovalores esperados para a estrutura i, conforme Tabela 1.

Desta forma, o processo de classificação consiste em calcular para cada ponto da amostra a distância euclidiana, no espaço dos autovalores, que separa o ponto a ser classificado de cada uma das estruturas (Tabela 1). A menor

distância indica a estrutura na qual o ponto pertence. Desta forma, o ponto j é classificado como pertencente à estrutura i , tal que:

$$D_j^i(x) = \text{mínimo} \{D_j^1, D_j^2, \dots, D_j^8\} \tag{7}$$

Para refinar o processo de classificação pode-se realizar a ponderação das distâncias. Gross e Jutzi (2009) definiram empiricamente fatores de ponderação para o cálculo da distância entre o ponto a ser classificado e as diferentes estruturas (E). O fator de ponderação $p(E)$ leva em consideração a dimensão de cada estrutura ($\text{dim}(E)$) (Tabela 1), como pode ser visto na Equação 8:

$$p(E) = \frac{1}{1 + \text{dim}(E)} \tag{8}$$

2.4 Determinação da vizinhança ótima

A classificação do conjunto de pontos tridimensionais baseada nos autovalores depende diretamente da matriz de variâncias e covariâncias. Desta forma, a escolha da “vizinhança ótima”, utilizada no cálculo da MVC, está diretamente relacionada com a qualidade do processo de classificação.

Demantke et al. (2011) e Yang (2013) determinam a “vizinhança ótima” utilizando o conceito de entropia. A entropia (E_f) pode ser calculada por meio dos autovalores da MVC a partir da seguinte expressão:

$$E_f = - a_1 \ln(a_1) - a_2 \ln(a_2) - a_3 \ln(a_3) \tag{9}$$

onde:

$$a_1 = \frac{\sqrt{\lambda_1} - \sqrt{\lambda_2}}{\mu}, \quad a_2 = \frac{\sqrt{\lambda_2} - \sqrt{\lambda_3}}{\mu}, \quad a_3 = \frac{\sqrt{\lambda_3}}{\mu};$$

μ – Fator de normalização dos coeficientes a_1, a_2 e a_3 ($\mu = \sqrt{\lambda_1}$).

Os coeficientes a_1, a_2 e a_3 são indicadores utilizados para descrever o comportamento da dispersão linear, planar e volumétrica, respectivamente, dentro de uma vizinhança V_p^R onde R está relacionado ao raio da esfera e p ao ponto do centro da esfera.

Esses coeficientes podem ser utilizados para classificar a vizinhança de acordo com a sua dimensionalidade, dada por $d^*(V_p^R)$, ou seja, linear (1D), planar (2D) ou volumétrica (3D) determinada por:

$$d^*(V_p^R) = \text{argmax}_{d \in \{1,2,3\}} [a_d]. \tag{10}$$

Assim os coeficientes correspondem à probabilidade de um ponto ser classificado como a_1, a_2 ou a_3 . A somatória dos três coeficientes é igual a 1 ($a_1 + a_2 + a_3 = 1$).

Uma vez que a vizinhança é delimitada por uma esfera de raio R centrada no ponto p , deve-se variar o valor do raio entre dois valores extremos (R_{\min} até R_{\max}) de forma a determinar a menor entropia. Assim, o comprimento de raio relacionado ao menor valor de entropia ($E_{f \min}$) corresponde ao raio ótimo ($R_{\text{ótimo}}$), como ilustrado na Figura 2. A região delimitada pela esfera de $R_{\text{ótimo}}$ é denominada de “vizinhança ótima”.

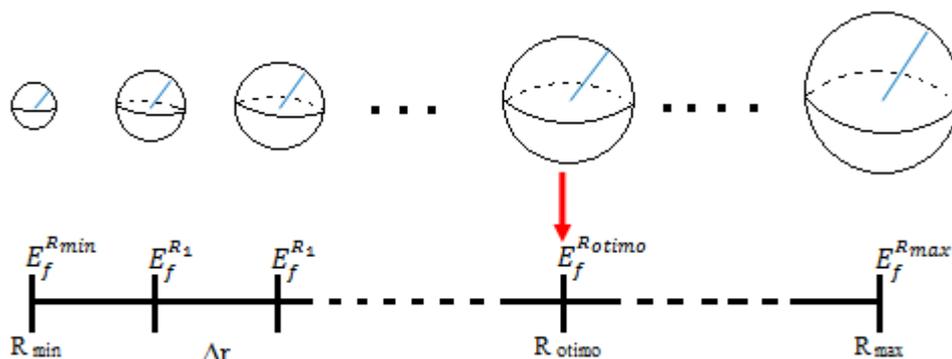


Figura 2 – Representação das entropias calculadas no intervalo R_{\min} até R_{\max} , com intervalo Δr entre os sucessivos raios. O menor valor de entropia é destacado ($E_{f \min}$).

3 METODOLOGIA

Na Figura 3 é apresentado o fluxograma com as quatro principais etapas envolvidas no processo de classificação de um ponto p com coordenadas X , Y e Z , amostrado por um Sistema de Varredura a LASER Aerotransportado. No fluxograma é destacada a etapa que diferencia o procedimento de classificação desenvolvido neste trabalho daquele proposto por Gross e Jutzi (2009).

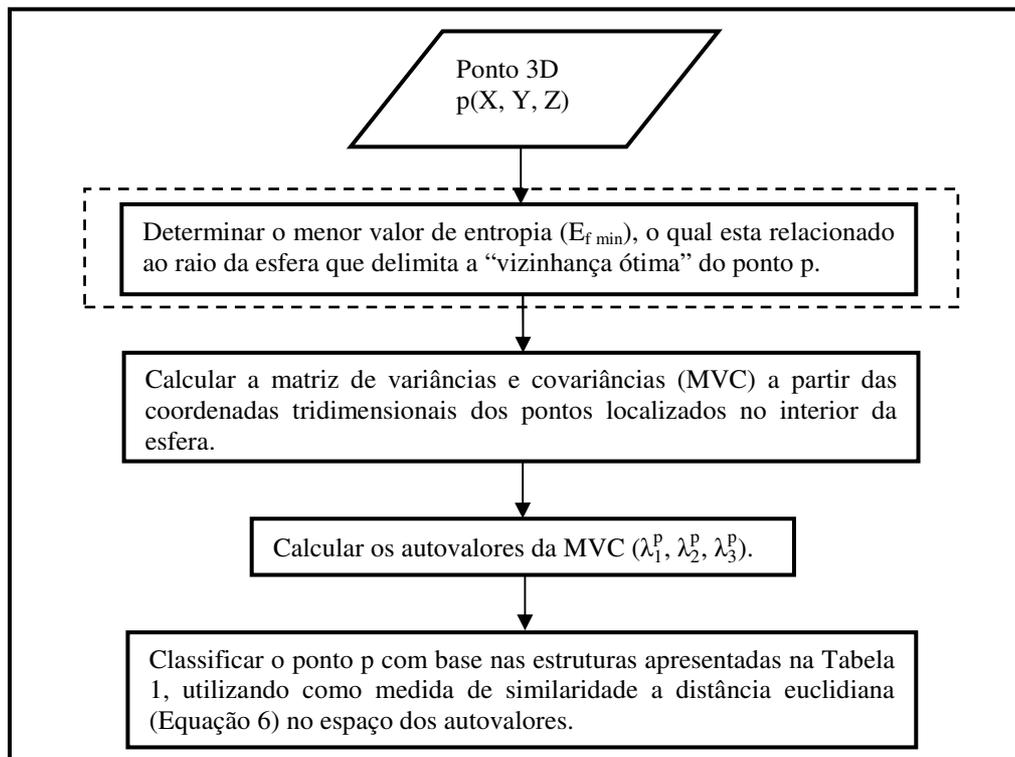


Figura 3 – Fluxograma com as etapas envolvidas na classificação de um ponto 3D.

Para realizar a classificação dos pontos amostrados o procedimento de classificação apresentado na Figura 3 deve ser executado para todos os pontos.

O processo de classificação sintetizado no fluxograma da Figura 3 foi implementado na linguagem C usando o compilador C/C++ Code::Blocks. Para a preparação dos dados do SVLA foi utilizada a biblioteca *LAStools* e para a visualização dos resultados utilizou-se os aplicativos *Scilab*, *Gnuplot* e *FugroViewer*.

4 EXPERIMENTOS E RESULTADOS

Para avaliar o procedimento de classificação implementado na linguagem C utilizou-se um conjunto dados de varredura a LASER fornecido pela empresa Sensormap Geotecnologia referente ao município de Presidente Prudente/SP. Esses dados correspondem aos arquivos das diferentes faixas LASER no formato “.LAS”. Para mais detalhes sobre a estrutura de armazenamento nesse tipo de formato pode-se consultar Samberg (2007). No caso específico deste trabalho foram utilizadas as coordenadas tridimensionais referentes aos múltiplos retornos.

O conjunto de dados amostrado pelo Sistema de Varredura a LASER Aerotransportado possui uma densidade média de oito pontos por metro quadrado (8 pts/m²). O sistema de varredura utilizado na aquisição destes dados é da marca RIEGL modelo LMS (*Laser Measurement System*) – Q680i, que possui as seguintes características:

- Frequência máxima de emissão do pulso: 400kHz;
- Comprimento de onda: 1550 nm;
- Ângulo de divergência: < 0,5 mrad;
- Ângulo de abertura (FOV): 60°;
- Frequência de varredura: 10 – 200 linhas/s;
- Número de retornos: 6 pulsos.

Devido a grande área de recobrimento das faixas LASER optou-se em executar o procedimento de classificação sobre áreas com menores dimensões. Para tanto, recortou-se duas diferentes áreas sobre as faixas LASER utilizando a função *Lasclip* da biblioteca *LASTools*. Essas áreas são todas localizadas na região urbana do município de Presidente Prudente/SP, uma vez que estas contêm feições com características similares aos tipos de estruturas apresentados na Tabela 1.

A primeira área selecionada (Área 1) corresponde a uma edificação com altura elevada (da ordem de 50 m) localizada no centro da cidade. Devido a sua altura elevada alguns pulsos LASER foram amostrados sobre as paredes laterais da edificação. Após aplicar o procedimento de classificação sobre o conjunto de pontos 3D da Área 1 (Figura 4a) onde as cores tem relação com a altura, obteve-se como resultado o conjunto de pontos classificados, como apresenta a Figura 4b.

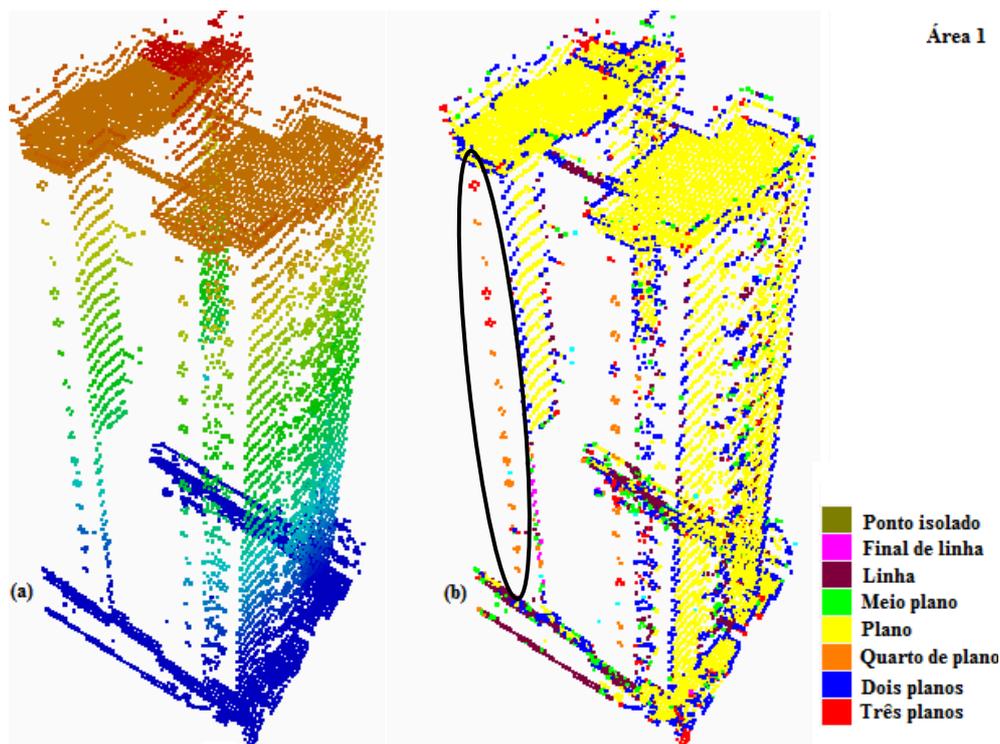


Figura 4 – Conjunto de pontos 3D referente a Área 1 antes (a) e após a execução da classificação (b).

O resultado da classificação mostra que a maioria dos pontos foram classificados como pertencente às estruturas plano e dois planos. Nas regiões com pequenas quantidades de pontos amostrados o processo de classificação pode produzir resultados incoerentes, como destacado na Figura 4b. Os pontos classificados como pertencentes às estruturas com dimensão 1 podem ser utilizados para extrair retas, ao passo que os pontos classificados na estrutura de dimensão 2 podem ser utilizados para extrair planos.

A segunda área recortada (Área 2) refere-se a duas construções localizadas no campus da FCT-UNESP. A Figura 5a mostra o conjunto de pontos tridimensionais relacionados a essa área, enquanto que a Figura 5b apresenta o conjunto de pontos referente à Área 2, após aplicação do procedimento de classificação.

Assim como na Figura 4b, o resultado da classificação apresentado na Figura 5b mostra que a maioria dos pontos 3D foram classificados como pertencentes às estruturas plano e dois planos. Na Área 2 alguns pontos foram amostrados sobre vegetações. Uma vez que nenhuma das estruturas apresentadas na Tabela 1 se refere a classe vegetação, esses pontos foram erroneamente classificados nas diferentes estruturas existentes. Estas regiões com vegetações são destacadas na Figura 5a. Outra tipo de feição que pode ser extraída são os pontos de quinas, os quais correspondem à intersecção de três planos. Na Figura 5b são destacados (por setas) alguns pontos classificados como quinas.

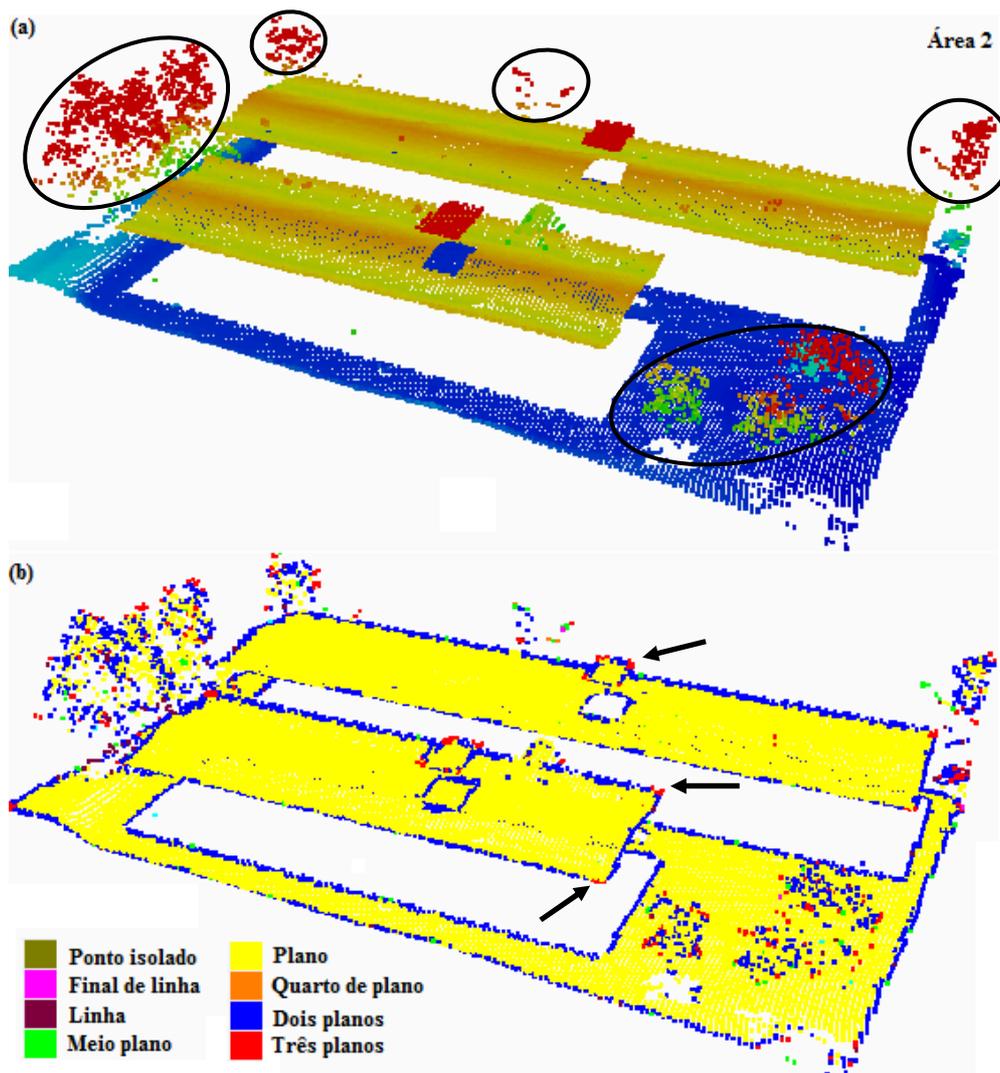


Figura 5 – Conjunto de pontos 3D referente à Área 2 antes (a) e após a execução da classificação (b).

5 CONCLUSÕES

Os experimentos mostraram que o procedimento de classificação dos pontos 3D, amostrados pelo Sistema de Varredura a LASER Aerotransportado, pode ser usado para selecionar algumas feições de interesse. Deste modo, estruturas como planos, retas, pontos de quina, dentre outros, podem ser extraídas uma vez conhecidas as coordenadas tridimensionais dos pontos.

Mesmo considerando a complexidade dos ambientes reais onde vegetação, feições antrópicas, edificações de diferentes portes são presentes, percebe-se que algumas estruturas são bem identificadas. No entanto, o processo de classificação apresentou algumas restrições, uma vez que o mesmo deve ser executado em conjuntos de pontos amostrados sobre áreas que podem conter não apenas feições antrópicas, mas também vegetação. Se a área de interesse possuir pontos amostrados sobre a vegetação ou ao terreno, esses são erroneamente classificados em uma das estruturas definidas *a priori* (conforme Tabela 1).

Outra limitação do procedimento está relacionada com a pequena densidade de pontos amostrados em certas regiões. Essas regiões geralmente se referem às paredes dos altos edifícios como visto na Figura 4.

Para trabalhos futuros sugere-se a utilização de alguma ferramenta ou método que possibilite eliminar os pontos relacionados às vegetações e ao terreno, antes de aplicar o procedimento de classificação dos pontos 3D.

Agradecimentos

Os autores agradecem ao CNPq, pelo apoio institucional e pela bolsa de mestrado realizado junto ao PPGCC da UNESP. Os autores também agradecem à FCT-UNESP de Presidente Prudente e ao Dep. de Cartografia onde os

estudos foram desenvolvidos; e também à empresa Sensormap Geotecnologia que forneceu os dados de varredura a LASER utilizados nos experimentos.

REFERÊNCIAS

- BALTSAVIAS, E.P. Airborne laser scanning: existing systems and firms and other resources. **ISPRS Journal of Photogrammetry & Remote Sensing**, v. 54 (2 - 3), p. 164-198, 1999.
- DEMANTKE, J.; MALLETT, C.; DAVID, N., VALLET, B. Dimensionality based scale selection in 3D lidar point clouds. In: **ISPRS Workshop on Laser Scanning 2011**, Calgary - Canada, 2011.
- EL-SHEIMY, N.; VALEO, C.; HABIB, A. **Digital Terrain Modeling: acquisition, manipulation and applications**. London: Artech House, 2005, 526 p.
- GALVANIN, E. A. S.; DAL POZ, A. P. Extraction of building roof contours from LiDAR data using a Markov-Random-Field-Based approach. **IEEE Transactions on Geoscience and Remote Sensing**, vol. 50, n°.3, 2012.
- GROSS, H.; THOENNESSEN, U. Extraction of lines from laser point clouds. In: **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, Istanbul – Turkey, v. 36, p. 86-91, part 3, 2006.
- HABIB, A. F.; KERSTING, A. P.; RUIFANGA, Z.; AL-DURGHAM, M.; KIM, C.; LEE, D. C. Lidar strip adjustment using conjugate linear features in overlapping strips. In: **Proceedings of the XXI ISPRS Congress, Commission I**, Beijing - China, v.37, part B1, 2008.
- JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. New Jersey: Prentice-Hall, 1999. 816p.
- JUTZI, B.; GROSS, H. Nearest neighbor classification on LASER point clouds to gain object structures from buildings. In: **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. 2009.
- MINGOTI, S.A. **Análise de dados através de métodos de estatística multivariada - uma abordagem aplicada**. Belo Horizonte: Editora: UFMG, 2005. 295p.
- PRESS, W. H.; TEUKOLSKY, S. A.; VETTERLING, W. T.; FLANNERY, B. P. **Numerical recipes in C: the art of scientific computing**. 2nd ed. Cambridge: Cambridge University Press, 1992. p. 994.
- SAMBERG, A. An Implementation of the ASPRS LAS Standard. In: **ISPRS Workshop on Laser Scanning and SilviLaser**. p. 363-372. Finland, 2007.
- TSAI, F.; CHANG, H. Evaluations of three-dimensional building model reconstruction from LiDAR point clouds and single-view perspective imagery. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**. 2014.
- WEHR, A.; LOHR, U. Airborne laserscanning an introduction and overview. In: **ISPRS Journal of Photogrammetry and Remote Sensing**, p. 68-82, 1999.
- YANG, B.; DONG, Z. A shape-based segmentation method for mobile laser scanning point clouds. In: **ISPRS Journal of Photogrammetry and Remote Sensing**, p. 19-30, 2013.