

Registro de dados LiDAR aerotransportado através da minimização das distâncias entre ponto e plano correspondentes

Gabriel Dresch^{1,2}
Daniel Rodrigues dos Santos²

¹ Universidade Federal do Paraná - UFPR
Caixa Postal 19001 - 81531-990 - Curitiba - PR, Brasil
danielsantos@ufpr.br

² Diretoria do Serviço Geográfico - DSG
Quartel General do Exército B1 F 2º Piso-70630-901 - Brasília - DF, Brasil
dresch@dsg.eb.mil.br

Abstract. The point cloud registration is performed in order to transform acquired data from one coordinate system to another. Each point cloud produced by a laser scanner is often in a different reference system different, so registration must be done in order to put all data in the same reference system. In this paper we propose a point cloud registration method that uses point and plane surfaces extracted in overlapping strips. First, the plane surfaces are automatically extracted by RANSAC robust fitting. Then, the plan parameters are calculated by principal component analysis. After, the transformation parameters are estimated using a mathematical model that minimizes the sum of the distance error between points and corresponding planes. The rotation and translation parameters are calculated by nonlinear parametric least squares fitting. The purpose of this method is minimizes the sum of the squares of the residuals, and allows to calculate the accuracy of the obtained parameters. An experiment was conducted to evaluate the proposed method. Two overlapping LiDAR strips, whose density is 1 point / m², was used. The results showed the potential of the proposed method.

Palavras-chave: RANSAC, principal component analysis, least squares fitting, análise de componentes principais, método dos mínimos quadrados.

1. Introdução

O registro de nuvem de pontos é realizado com a finalidade de transformar os dados adquiridos de um sistema de coordenadas para outro. Frequentemente cada nuvem de pontos adquirida por um *laser scanner* está num sistema de referência distinto, devendo ser realizado o registro de modo que todos os dados estejam num mesmo sistema de referência.

O processo de registro envolve duas etapas: estimativa dos parâmetros de registro e aplicação da transformação. A estimativa dos parâmetros é realizada através da relação entre feições correspondentes entre duas nuvens de pontos. Essas feições correspondem a pontos, linhas e superfícies planas extraídas de cada nuvem de ponto. Geralmente a transformação adotada é a de corpo rígido 3D, onde são definidas as rotações e translações que relacionam os sistemas de coordenadas de duas nuvens de pontos.

A identificação de pontos correspondentes é complexa e de baixa confiabilidade, devido a natureza irregular e discreta dos dados provenientes do sistema LiDAR (Habib et al, 2010). Para contornar esse problema, foi desenvolvido o método *iterative closest point* (ICP) (Besl e Mckay, 1992), no qual são empregados pontos pseudoconjugados. O ICP é baseado no método de Horn (1987), no qual os parâmetros são obtidos em duas etapas: na primeira, são obtidos os ângulos de rotação através de quatérnios; na segunda, a rotação encontrada é empregada para determinar a translação.

Nos trabalhos mais recentes, diferentes primitivas geométricas foram empregadas nos métodos supracitados, tais como feições pontuais, lineares e superfícies planas. O principal objetivo desses métodos é minimizar o somatório da distância entre feições correspondentes extraídas em nuvens de pontos distintas.

O presente trabalho propõe um método de registro que emprega superfícies planas extraídas na área de sobreposição entre faixas obtidas por varredura LiDAR. Tal método consiste em empregar as superfícies planas e os pontos correspondentes da faixa adjacente para obtenção dos parâmetros de rotação e translação entre nuvens de pontos.

2. Metodologia

O método proposto está dividido em 2 etapas principais, a saber:

1. Extração de planos; e
2. Aplicação do modelo matemático.

O método é aplicado em duas nuvens de pontos que recobrem uma mesma região. A extração de planos é realizada com o emprego da segmentação através do algoritmo RANSAC. O vetor normal de cada plano é obtido através da análise de componentes principais aplicada na matriz variância-covariância obtida a partir dos pontos de cada plano. Já a distância do plano à origem é definida pela média do produto interno entre a normal e cada um dos pontos pertencentes ao plano.

Por fim, os parâmetros de rotação e translação entre as faixas e as respectivas precisões são estimados através do método dos mínimos quadrados.

2.1 Extração de planos

2.1.1 *Random Sample Consensus* (RANSAC)

O algoritmo RANSAC foi desenvolvido por Fischler e Bolles (1981). Consiste num método para estimação de parâmetros de um modelo a partir de um conjunto de dados que apresenta uma grande quantidade de *outliers* (maior que 50%). O RANSAC é baseado na noção de conjuntos mínimos, que consiste no menor número de amostras necessárias para definir um modelo de maneira unívoca. Por exemplo, para modelar uma reta são necessários dois pontos. Já na modelagem de um plano, o conjunto mínimo é igual a três. De maneira geral, esse algoritmo é composto por dois passos realizados iterativamente:

- Estabelecimento da hipótese: um conjunto mínimo de pontos é aleatoriamente selecionado a partir de todo conjunto de dados disponível; e
- Teste: o algoritmo verifica quais elementos de todo conjunto de dados que são consistentes com o modelo estabelecido pelo conjunto mínimo. Os elementos consistentes formam um conjunto chamado de consenso.

Após a realização de todas as iterações, o modelo adotado corresponde ao modelo estabelecido pelo conjunto mínimo que apresentar o maior conjunto consenso.

O algoritmo RANSAC empregado está implementado na biblioteca C++ *Point Cloud Library* (PCL).

2.1.2 *Análise de Componentes Principais* (ACP)

A *Análise de Componentes Principais* (ACP) procura explicar a estrutura de variância-covariância de um conjunto de variáveis através de combinações lineares não correlacionadas dessas variáveis. Seu objetivo geral consiste na redução de dados e na sua interpretação. Embora todas as componentes sejam necessárias para reproduzir a variabilidade total do sistema, frequentemente grande parte dessa variabilidade pode ser explicada por um número menor de componentes principais. Além disso, a ACP frequentemente revela relações previamente desconhecidas entre as variáveis, permitindo interpretações adicionais. (Johnson e Wichern, 2007).

A ACP depende exclusivamente da matriz variância-covariância, que no caso de um conjunto de pontos com coordenadas X, Y, Z apresenta o seguinte formato:

$$\Sigma = \begin{bmatrix} \sigma_X^2 & \sigma_{XY} & \sigma_{XZ} \\ \sigma_{YX} & \sigma_Y^2 & \sigma_{YZ} \\ \sigma_{XZ} & \sigma_{YZ} & \sigma_Z^2 \end{bmatrix} \quad (1)$$

onde:

σ_i^2 = variância da coordenada i

σ_{ij} = covariância entre as variáveis i e j

A matriz Σ é simétrica e apresenta autovalores reais. Suas componentes principais são variáveis não correlacionadas que apresentam as maiores variâncias possíveis. Considerando $P = [X \ Y \ Z]^T$ um ponto qualquer representados por 3 variáveis aleatórias (X , Y e Z), as componentes principais são definidas pelas seguintes combinações lineares, a saber:

$$\begin{aligned} Y_1 &= \vec{e}_1^T P = e_{11}X + e_{21}Y + e_{31}Z \\ Y_2 &= \vec{e}_2^T P = e_{12}X + e_{22}Y + e_{32}Z \\ Y_3 &= \vec{e}_3^T P = e_{13}X + e_{23}Y + e_{33}Z \end{aligned} \quad (2)$$

$$Y = \begin{bmatrix} Y_1 \\ Y_2 \\ Y_3 \end{bmatrix} = \begin{bmatrix} e_{11} & e_{21} & e_{31} \\ e_{12} & e_{22} & e_{32} \\ e_{13} & e_{23} & e_{33} \end{bmatrix} \begin{bmatrix} X \\ Y \\ Z \end{bmatrix} = CP \quad (3)$$

A primeira componente principal (Y_1) é a combinação linear que apresenta variância máxima para $\vec{e}_1^T P$, com a restrição de que \vec{e}_1 tenha norma unitária. Já a segunda componente principal (Y_2) é a combinação linear que maximiza a variância $\vec{e}_2^T P$ com a restrição de que a norma \vec{e}_2 seja unitária e a covariância com Y_1 seja nula. Por fim, Y_3 é a combinação linear que maximiza a variância $\vec{e}_3^T P$ com a restrição de que a norma \vec{e}_3 seja unitária e também a covariância com Y_1 e Y_2 seja nula.

Considerando que a matriz Σ apresenta autovalores $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$, cada combinação linear Y_i é definida pelo autovetor \vec{e}_i associado ao autovalor λ_i . A componente principal Y_i apresenta a seguinte covariância:

$$\sigma_{Y_i}^2 = \vec{e}_i^T \Sigma \vec{e}_i = \lambda_i \quad (4)$$

Segundo o teorema dos extremos condicionados (Anton e Rorres, 2010), o valor máximo da forma quadrática $\vec{e}_i^T \Sigma \vec{e}_i$ é atingido quando \vec{e}_i corresponde ao autovetor associado ao maior autovalor de Σ . Por outro lado, quando \vec{e}_i corresponde ao autovetor associado ao menor autovalor, o valor mínimo é atingido.

No caso de um conjunto de pontos que define uma superfície plana, a direção de menor variância coincide com a direção normal ao plano. Com isso, o par de autovalor e autovetor (λ_3, \vec{e}_3) corresponde a variância λ_3 ao longo do eixo \vec{e}_3 , que define a normal do plano. Quanto menor o valor de λ_3 , mais o conjunto de pontos se aproxima de uma superfície plana. Para um plano perfeito o valor de λ_3 é igual à zero.

2.2 Modelo Matemático

O modelo matemático empregado neste trabalho é uma variação do modelo proposto por Khoshelham *et al* (2010). No presente método, são calculadas a matriz de rotação e o vetor de translação ao invés de uma transformação afim. A equação 5 apresenta o modelo matemático utilizado.

$$\vec{n}^T \cdot (\mathbf{R} \cdot \mathbf{p}' + \vec{t}) = d$$

$$[n_x, n_y, n_z] \cdot \left(\begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{32} \end{bmatrix} \cdot \begin{bmatrix} x' \\ y' \\ z' \end{bmatrix} + \begin{bmatrix} t_x \\ t_y \\ t_z \end{bmatrix} \right) = d \quad (5)$$

$$n_x(\mathbf{r}_1^T \cdot \mathbf{p}' + t_x) + n_y(\mathbf{r}_2^T \cdot \mathbf{p}' + t_y) + n_z(\mathbf{r}_3^T \cdot \mathbf{p}' + t_z) = d$$

onde \mathbf{r}_i^T corresponde a linha i da matriz de $\mathbf{R} = \begin{bmatrix} r_{11} & r_{12} & r_{13} \\ r_{21} & r_{22} & r_{23} \\ r_{31} & r_{32} & r_{32} \end{bmatrix} = \begin{bmatrix} \mathbf{r}_1^T \\ \mathbf{r}_2^T \\ \mathbf{r}_3^T \end{bmatrix}$

Cada um dos m pontos resulta numa equação que faz a associação do mesmo com o seu plano correspondente (dentro do universo de k planos existentes). A equação está na forma $F(X_a) = L_a$. Para obter os parâmetros, é necessário recorrer ao ajustamento paramétrico não linear, tendo em vista que a função $F(X_a)$ é não linear. Nesse caso, é necessário linearizá-la através da expansão em série de Taylor. A equação 6 representa forma linearizada da equação 5.

$$F(X_a) = F(X_0) + \left. \frac{\partial F}{\partial X_a} \right|_{X_a=X_0} (X_a - X_0) \quad (6)$$

onde:

$X_a = [\omega \ \varphi \ \kappa \ t_x \ t_y \ t_z]^T$ parâmetros ajustados

$X_0 = [0 \ 0 \ 0 \ 0 \ 0 \ 0]^T$ aproximação inicial dos parâmetros

$F(X_0) = L_0 = \vec{n}^T \mathbf{p}' =$ observações calculadas a partir da aproximação inicial

$$\left. \frac{\partial F}{\partial X_a} \right|_{X_a=X_0} = J = \begin{bmatrix} \frac{\partial F_1}{\partial \omega} & \frac{\partial F_1}{\partial \varphi} & \frac{\partial F_1}{\partial \kappa} & \frac{\partial F_1}{\partial t_x} & \frac{\partial F_1}{\partial t_y} & \frac{\partial F_1}{\partial t_z} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ \frac{\partial F_m}{\partial \omega} & \frac{\partial F_m}{\partial \varphi} & \frac{\partial F_m}{\partial \kappa} & \frac{\partial F_m}{\partial t_x} & \frac{\partial F_m}{\partial t_y} & \frac{\partial F_m}{\partial t_z} \end{bmatrix} = \text{matriz jacobiana de } F(X)$$

A equação 6 pode ser escrita da seguinte forma:

$$J\Delta X + L = V \quad (7)$$

onde:

$$L = L_0 - L_b$$

$$\Delta X = X_a - X_0$$

Em ajustamentos não lineares é necessária uma estimativa inicial X_0 para os valores dos parâmetros e a solução é obtida iterativamente. Tendo em vista que nos dados provenientes do LiDAR aerotransportado a discrepância entre as faixas é muito pequena, o valor inicial de cada parâmetro pode ser considerado igual a zero.

3. Experimento Realizado

Para avaliação do método proposto foi conduzido um experimento usando dados LiDAR referentes ao aerolevante realizado em dezembro de 2006, que recobre parte do bairro Bacacheri da cidade de Curitiba-PR. A área de sobreposição entre as duas faixas empregadas apresenta aproximadamente 400.000 m² sendo que cada faixa apresenta uma densidade média de 1 ponto/m². A figura 1 ilustra as imagens de elevação e intensidade da área de estudo.




Figura 1 – Imagem de Elevação (a) e Imagem Intensidade (b).

Neste experimento, o método proposto foi testado com o emprego das seguintes primitivas:

- Pontos: pontos pertencentes aos telhados das casas de uma faixa;
- Planos: planos correspondentes aos telhados das casas da faixa adjacente.

4. Análise dos Resultados

No experimento realizado, foram obtidos 70 pares de planos correspondentes. O modelo matemático proposto foi aplicado e, para fins de comparação, primeiramente os pontos de uma faixa foram aplicados sobre os planos da mesma faixa. Esses dados servem como parâmetro da melhor situação, ou seja, esses valores seriam obtidos na hipótese dos pontos de uma faixa se adequarem aos planos de outra faixa tão bem quanto os pontos que geraram os próprios planos. Para servir de parâmetro de pior caso, foi aplicado os pontos de uma faixa nos planos da faixa adjacente sem qualquer transformação. A figura 2 ilustra o histograma das discrepâncias entre os pontos de uma faixa em relação aos planos da faixa adjacente após a aplicação dos parâmetros obtidos pelo método.

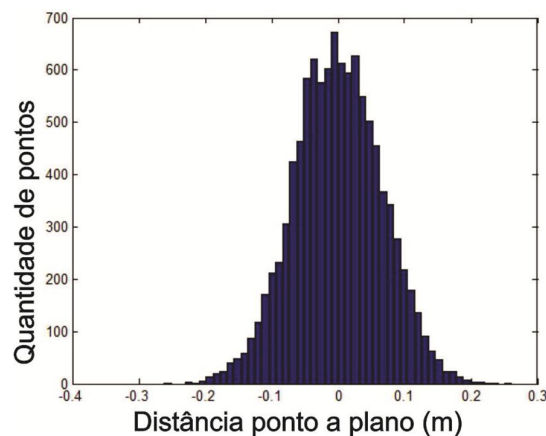


Figura 2 – Histograma dos resíduos.

A tabela 1 apresenta os resultados ordenados nas seguintes colunas:

1ª Coluna: refere-se à melhor situação, ou seja, os pontos são aplicados sobre os planos extraídos da mesma faixa a qual pertencem os pontos;

2ª Coluna: refere-se à pior situação, ou seja, os pontos são aplicados sobre os planos extraídos da faixa adjacente;

3ª Coluna: resultados do método proposto.

Tabela 1 – Comparação dos resultados.

	Situação Ideal	Pior Situação	Método Proposto
Média (m)	$-3e^{-14}$	-0,05	$-3e^{-4}$
Desvio-padrão (m)	0,0373	0,1092	0,0662
EMQ (m)	0,0373	0,1201	0,0662
Maior distância (m)	0,1366	0,4817	0,2613

Nesta tabela, a unidade de todos os valores é o metro. A sigla EMQ corresponde ao erro médio quadrático. Já na tabela 2 constam os valores dos parâmetros calculados empregando os pontos da faixa 1 nos planos da faixa 2. O desvio-padrão de cada parâmetro está entre parênteses.

Tabela 2 – Parâmetros calculados.

Parâmetros	Método Referência
t_x (cm)	32,12($\pm 0,28$)
t_y (cm)	0,47($\pm 0,25$)
t_z (cm)	6,18($\pm 0,07$)
ω (graus)	-0,0166($\pm 4e^{-4}$)
φ (graus)	-0,0082($\pm 3e^{-4}$)
κ (graus)	-0,0114($\pm 10e^{-4}$)

A figura 3 ilustra o perfil de um telhado que não foi empregado na obtenção dos parâmetros.



Figura 3 – Perfil de um telhado.

As cores representam os seguintes pontos:

- Azul: faixa 2;
- Amarelo: faixa 1;
- Roxo: faixa 1 transformada para faixa 2 com o método de referência;

5. Conclusão

O resultado obtido pelo método de registro proposto corrige a deficiência do método proposto por KHOSHELHAM *et al* (2010), ao fornecer os parâmetros de rotação entre as duas nuvens de pontos em vez de uma transformação afim.

É possível constatar na figura a discrepância entre os pontos da faixa 1 que não sofreram transformação (pontos amarelos) em relação aos demais. Os pontos roxos (pontos da faixa 1 transformados) estão mais próximos dos pontos azuis (pontos da faixa 2). Pode ser verificado que a faixa 1 está abaixo e à esquerda da faixa 2, sendo que tal deslocamento é corrigido após a transformação. O registro realizado pelo método proposto reduz as discrepâncias entre as faixas adjacentes, compatibilizando adequadamente dois conjuntos de dados.

Referências

- Anton, H.; Rorres, C. **Álgebra linear com aplicações**. 10. ed. Porto Alegre: Bookman, 2010.
- Besl, P. J.; McKay, N. D. A method of registration of 3-D shapes. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 14, n. 2, p. 239-256, 1992.
- Fischler, M. A.; Bolles, R. C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography. **Communications of the ACM**, v. 24, n. 6, p. 381-395, 1981.
- Habib, A.; Kersting A. P.; Bang, K. I.; Lee D. C. Alternative methodologies for the internal quality control of parallel LiDAR strips. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 1, p. 221-236, 2010.
- Horn, B. K. P. Closed-form solution of absolute orientation using unit quaternions. **Journal of the Optical Society of America A**, v. 4, n. 4, p. 629-642, 1987.
- Johnson, R. A.; Wichern D. W. **Applied Multivariate Statistical Analysis**. 6 ed. Upper Saddle River: Pearson Prentice Hall, 2007.
- Khoshelham, K.; Sande, C. V. D.; Soudarissanane, S. Assessment of relative accuracy of AHN-2 laser scanning data using planar features. **Sensors**, v. 10, n. 9, p. 8198-8214, 2010.