

Recalage fondé sur des a priori géométriques de nuages de points 3D issus d'acquisitions LiDAR de scènes structurées

Julia Sanchez^{1,2} Florence Denis¹ Paul Checchin² Florent Dupont¹ Laurent Trassoudaine²

¹ Univ Lyon, LIRIS, UMR 5205 CNRS, Université Claude Bernard Lyon 1, 43, bd du 11 novembre 1918, 69622 Villeurbanne CEDEX, France

² Institut Pascal, UMR 6602, Université Clermont Auvergne, CNRS, SIGMA Clermont, F-63000 Clermont-Ferrand, France

julia.sanchez@univ-lyon1.fr

1 Résumé

L'utilisation de capteurs LiDAR pour obtenir des données 3D implique l'acquisition de scans à partir de différents points de vue. L'algorithme ICP (Iterative Closest Point) est largement utilisé pour recalibrer les scans entre eux. Cependant, cette méthode se heurte à des problèmes de minima locaux. Cet article développe une nouvelle méthode de recalage adaptée aux environnements structurés et fondée sur des caractéristiques géométriques. La transformation rigide recherchée est calculée en utilisant respectivement l'image gaussienne des nuages de points et une corrélation d'histogrammes. La comparaison de notre algorithme avec les méthodes de l'état de l'art sur deux ensembles de scans 3D montre qu'il est plus robuste à de faibles résolutions de scans, à la complexité de la scène et au bruit du capteur.

2 État de l'art

La première méthode proposée pour recalibrer des nuages de points se fondait sur la projection sur la sphère gaussienne [1]. L'idée était d'échantillonner respectivement l'image gaussienne et l'espace des rotations, puis d'évaluer la similarité des sphères après transformation par chacune des rotations. Les méthodes EGI (Extended Gaussian Sphere) et CEGI (Complex Extended Gaussian Sphere) [7] sont les dernières extensions de la méthode. Ces approches ne prennent pas en compte un chevauchement partiel.

L'algorithme ICP surpasse les méthodes précédentes. Cet algorithme attribue itérativement des correspondances entre les points de la source et les points de la cible, filtre ces correspondances et minimise la distance entre les points de chaque paire créée. Cependant, la minimisation peut mener à un minimum local. Il faut donc assurer un mouvement faible entre les scans en entrée de l'algorithme, soit en adaptant le processus d'acquisition, soit en cherchant un alignement approximatif initial avant le traitement par ICP. De nombreux travaux ont eu pour but d'améliorer la robustesse de cet algorithme [9]. Les variantes ICP *point à plan* [15] et ICP *généralisé* [12] ont été proposées pour optimiser la fonction de coût utilisée. Dans [4], l'algorithme de *Levenberg-Marquardt* est utilisé pour améliorer la convergence de la fonction. Récemment, l'algorithme Go-ICP [14] a été introduit pour régler le problème de non convexité. Il permet une alternance entre une phase ICP et un processus fondé sur une approche *branch and bound* pour réaliser une recherche dans l'espace des transformations. Cet algorithme peut se révéler très coûteux en temps de calcul.

Holz et al. [5] ont créé une chaîne de traitement intégrant ICP afin d'assurer la convergence de l'algorithme. Un alignement approximatif est tout d'abord déterminé, puis, ICP (ou une de ses variantes) est exécuté pour ajuster le résultat. Pour trouver un alignement approximatif, des points clés sont sélectionnés [2] et leur descripteur local est calculé grâce à leur voisinage [6, 11, 13]. Enfin, les points de la source et de la cible sont mis en correspondance par similarité de leur descripteur et un alignement optimal est déduit. L'erreur principale vient des fausses correspondances attribuées dans ce processus. Zhou et al. [16] ont amélioré le traitement en proposant la méthode FGR (Fast Global Registration) qui applique des poids aux correspondances dans l'optimisation pour leur donner plus ou moins d'importance suivant leur cohérence. Cette méthode présente une rapidité remarquable et la majorité des résultats atteint une bonne précision. Néanmoins, toutes les méthodes fondées sur des descripteurs nécessitent que la scène étudiée ait des détails permettant de différencier les points localement. Un autre moyen d'obtenir un recalage initial est d'utiliser RANSAC (RANdom SAMple Consensus). La méthode a tout d'abord été introduite dans [3]. Le principe est d'attribuer des correspondances aléatoires entre des ensembles de trois points provenant de chacun des nuages. Une transformation est déduite pour chaque correspondance et une évaluation permet de déterminer la meilleure. Super4PCS [8] est la dernière optimisation de l'algorithme et présente une convergence optimale. Cependant, le temps de calcul peut se révéler très important pour obtenir une précision suffisante.

Dans cet article, une méthode inspirée de considérations géométriques, au processus non itératif et suffisamment rapide pour pouvoir envisager une implémentation temps réel est présentée.

3 Méthode proposée

Nous proposons une méthode de recalage adaptée à la reconstruction d’environnements structurés. Des caractéristiques géométriques sont requises : trois murs principaux non parallèles du nuage cible doivent avoir des équivalents dans le nuage source. Cette approche délivre successivement la rotation et la translation de la transformation recherchée.

3.1 Recherche de la rotation

L’étape initiale consiste à projeter les deux nuages de points sur la sphère gaussienne : les normales en chaque point sont un point sur la sphère de rayon unité. Un exemple est donné Figure 1 où l’on voit que l’orientation des plans est mise en évidence par des régions plus denses. On cherche à faire correspondre les images gaussiennes de la source (S) et de la cible (C) pour en déduire la rotation. La détection des clusters de points dans l’image gaussienne est faite via un filtre par densité. Les six zones de plus forte densité sont choisies. Un *mean shift* est utilisé pour détecter les modes des clusters extraits. Les modes obtenus sont les normales des plans principaux du nuage, notés \vec{n}_i avec $i = 1, \dots, N$, N étant le nombre de normales.




Figure 1: Calcul de la rotation par mise en correspondance des sphères gaussiennes. En rouge, les axes des murs principaux utilisés.

Une fois que les normales des murs principaux sont obtenues, toutes les paires de normales $(\vec{n}_i, \vec{n}_j)_C$, $(\vec{n}_k, \vec{n}_l)_S$ avec $i \neq j$ et $k \neq l$ sont formées respectivement dans S et dans C. Toutes les correspondances entre les paires de S et de C sont d’abord établies puis filtrées. Pour ce faire, on ne garde que les correspondances pour lesquelles les angles $(\vec{n}_i, \vec{n}_j)_C$ et $(\vec{n}_k, \vec{n}_l)_S$ sont similaires.

3.2 Recherche de la translation

Trois normales $\vec{n}_a, \vec{n}_b, \vec{n}_c$, sont sélectionnées parmi les modes calculés à l’étape précédente et définissent des axes de translation a, b, c . Les axes a et b correspondent aux normales \vec{n}_a et \vec{n}_b utilisées pour réaliser la rotation. L’axe c est déduit après avoir aligné toutes les normales principales par la rotation. Il correspond à la normale de la cible \vec{n}_c la mieux alignée sur celle appartenant à S. Un exemple de sélection d’axes est donné Figure 1. Les nuages de points sont alors projetés sur chacun des axes et des histogrammes sont construits. Le maximum de la corrélation entre les histogrammes d’un même axe correspond alors au déplacement à réaliser sur l’axe étudié pour aligner les murs.

3.3 Sélection de la transformation

Des transformations sont estimées (cf. § 3.1) et on souhaite évaluer celle qui correspond au recalage étudié. Pour cela, la valeur LCP (Largest Common Pointset) [8] est utilisée pour quantifier le chevauchement des nuages de points. Cette valeur correspond au pourcentage de points de S ayant un voisin dans C. Le rayon du voisinage est défini comme la résolution du nuage de points. La résolution est ici définie comme la distance moyenne entre les points d’un nuage.

4 Validation

Pour évaluer notre méthode, deux jeux de données sont utilisés. Le premier est appelé “apartment” et est disponible en ligne sur le site de l’ASL (Autonomous System Lab) [10]. Il est référencé ici comme “DS1”. Il contient 45 nuages de 365 000 points éloignés d’au maximum 11m du scanner et ayant une résolution de 6.1cm. Les déplacements entre nuages sont faibles. Le second jeu, référencé “DS2”, a été acquis par nos soins afin de pouvoir travailler sur un environnement intérieur complexe avec une vérité terrain. Il contient 6 nuages de 9e6 points avec une distance maximale à l’origine de 70m et ayant une résolution de 3.6cm. Les déplacements entre nuages sont importants. La complexité de ce jeu de données provient 1) de ses motifs tels que des ouvertures, des arbres ou des murs courbes, 2) du nombre de points traités, 3) de sa structure car les scans ont été acquis sur deux étages avec de grands déplacements entre chaque acquisition. Les transformations d’une vérité terrain sont disponibles pour chacune d’elles. Dans DS2, elles proviennent d’un recalage réalisé avec des cibles physiques. La figure 2 présente un exemple de recalage pour des nuages de points extraits de DS2.

Pour la validation, trois critères sont sélectionnés : 1) l’erreur RMS (*Root Mean Square*) entre source et cible. Des paires sont formées entre les points de la source (après transformation par la référence) et les points de la cible, puis, la distance entre

les points d'une même paire est évaluée après recalage ; 2) le taux de réussite de recalage sur un ensemble de scans. Il est considéré correct quand l'erreur RMS est inférieure à 10 cm ; 3) le temps de calcul (processeur 8 cœurs Intel Xeon-E5620, 2.4 GHz). La méthode est comparée avec : ICP point-to-point, ICP point-to-plane, NDT et FGR. Les algorithmes ICP et NDT sont testés en utilisant la librairie PCL et FGR, Go-ICP et Super4PCS sont évalués avec le code disponible en ligne. Chaque scan a été recalé sur son prédécesseur dans l'ordre d'acquisition. Les résultats sont disponibles dans le tableau 1.

Table 1: Evaluation sur DS1 et DS2. Leica : méthode semi-manuelle plus ICP, nd : pas de données ; x si taux de réussite insuffisant.

	DS1			DS2		
	RMSE (cm)	Taux de réussite (%)	Durée (s)	RMSE (cm)	Taux de réussite (%)	Durée (s)
ICP point-to-point	2.0	54	7.4	x	0	x
ICP point-to-plane	1.7	82	3.2	x	0	x
Normal Distribution Transform	2.4	61	5.2	x	0	x
Fast Global Registration	2.3	100	3.9	x	0	x
Leica	nd	nd	nd	2.7	100	nd
Notre méthode	1.8	100	2.4	2.9	100	24.0
Vérité terrain	1.4	100	nd	2.66	100	nd

Notre méthode est la seule qui fonctionne sur les deux jeux de données. Les méthodes fondées sur ICP ont un taux de réussite faible dès lors que les déplacements sont grands. On remarque que sur DS1, l'algorithme proposé ici atteint une meilleure précision que les autres testés (1.8 cm), en un temps plus court (2.4 s). Le tableau 1 détaille les résultats.




Figure 2: Exemple de recalage par notre méthode sur des acquisitions avec scanner Hokuyo

5 Conclusions et perspectives

Un algorithme de recalage global de scènes d'intérieur avec chevauchement partiel a été présenté. Il fonctionne sans recalage initial et peut être utilisé sur des scènes géométriques avec peu de détails car il s'affranchit d'une recherche de descripteurs locaux. Son fonctionnement non itératif permet d'obtenir un résultat fiable en un temps borné. Il présente une bonne précision pour des environnements complexes. Sa rapidité est compatible avec une implémentation en temps réel. A l'avenir, nous intégrerons cet algorithme à un travail de modélisation de scènes d'intérieur.

References

- [1] Philippe Brou. Using the Gaussian Image to Find the Orientation of Objects. *The Int. Journal of Robotics Research*, 3(4):89–125, 1984.
- [2] Silvio Filipe and Luís A. Alexandre. A Comparative Evaluation of 3D Keypoint Detectors in a RGB-D Object Dataset. In *Int. Conf. on Computer Vision Theory and Applications (VISAPP)*, volume 1, pages 476–483, 1 2014.
- [3] Martin A Fischler and Robert C Bolles. Paradigm for Model. *Communications of the ACM*, 24(6):381–395, 1981.
- [4] Andrew W Fitzgibbon. Robust Registration of 2D and 3D Point Sets. *Image and Vision Computing*, 21:1145–1153, 04 2002.
- [5] D. Holz, A. E. Ichim, F. Tombari, R. B. Rusu, and S. Behnke. Registration with the Point Cloud Library: A Modular Framework for Aligning in 3-D. *IEEE Robotics Automation Magazine*, 22(4):110–124, 12 2015.
- [6] Andrew E. Johnson and Martial Hebert. Using Spin Images for Efficient Object Recognition in Cluttered 3D Scenes. *IEEE Trans. on PAMI*, 21:433–449, 1999.
- [7] Sang Bum Kang and Katsushi Ikeuchi. Determining 3-D Object Pose Using the Complex Extended Gaussian Image. In *CVPR*, pages 580–585, 1991.
- [8] Nicolas Mellado, Dror Aiger, and Niloy J. Mitra. Super4PCS Fast Global Point Cloud Registration via Smart Indexing. *Computer Graphics Forum*, 33(5):205–215, 2014.
- [9] François Pomerleau, Francis Colas, and Roland Siegwart. A Review of Point Cloud Registration Algorithms for Mobile Robotics. *Foundations and Trends in Robotics*, 4(1):1–104, 2015.
- [10] François Pomerleau, M. Liu, Francis Colas, and Roland Siegwart. Challenging Data Sets for Point Cloud Registration Algorithms. *The Int. Journal of Robotics Research*, 31(14):1705–1711, 12 2012.
- [11] Radu Bogdan Rusu, Nico Blodow, and Michael Beetz. Fast Point Feature Histograms (FPFH) for 3D registration. *ICRA*, pages 3212–3217, 2009.
- [12] A Segal, D Haehnel, and S Thrun. Generalized-ICP. *Robotics: Science and Systems*, 5:168–176, 2009.
- [13] Federico Tombari, Samuele Salti, and Luigi Di Stefano. Unique Signatures of Histograms for Local Surface Description. In *ECCV*, pages 356–369, 2010.
- [14] Jiaolong Yang, Hongdong Li, and Yunde Jia. Go-ICP: Solving 3D Registration Efficiently and Globally Optimally. In *ICCV*, pages 1457–1464, 2013.
- [15] Zhengyou Zhang. Iterative Point Matching for Registration of Free-Form Curves and Surfaces. *Int. Journal of Computer Vision*, 13(2):119–152, 1994.
- [16] Qian-yi Zhou, Jaesik Park, and Vladlen Koltun B. Fast Global Registration. In *European Conf. on Computer Vision (ECCV)*, volume 2, pages 766–782, 10 2016.