

Stratégies de rasterisation pour la classification de données LiDAR aéroportées par profils d’attributs morphologiques *

Florent GUIOTTE^{1,2}, Sébastien LEFÈVRE², Thomas CORPETTI¹

¹LETG-Rennes, CNRS – Univ. Rennes 2 Rennes, France

²IRISA – Univ. Bretagne Sud Vannes, France

florent.guiotte@univ-rennes2.fr, sebastien.lefevre@irisa.fr, thomas.corpetti@univ-rennes2.fr

Résumé – Cet article traite de rasterisation par représentations hiérarchiques (en particulier via les profils d’attributs morphologiques) de nuages de points 3D. Lorsque ces données proviennent d’appareils LiDAR, il est fréquent de les rasteriser pour fournir une carte d’élévation (exploitée seule ou combinée avec des images multi- ou hyperspectrales). Bien que certains travaux utilisent des profils d’attributs sur de telles données d’élévation, nous mettons ici l’accent sur plusieurs caractéristiques LiDAR rasterisées (liées aux échos, retours d’onde, etc.) et sur une description multi-échelle pour produire des cartes d’occupation du sol précises sur des zones urbaines. Nos résultats expérimentaux obtenus avec les données LiDAR de l’université de Houston indiquent de bons résultats de classification en exploitant nos rasters.

Abstract – This paper evaluates rasterization strategies and the benefit of hierarchical representations (in particular attribute profiles) to classify point clouds. When such data comes from LiDAR acquisitions, a rasterization process is often performed to build an elevation map (possibly used together with multi or hyperspectral images). While some works use attribute profiles on such elevation data, we rather focus here on several LiDAR features rasterized and on their multilevel description to produce accurate land cover maps over urban areas. Our experimental results obtained on LiDAR data from the university of Houston indicate good classification results based on our rasters.

1 Introduction

Le LiDAR aéroporté est un outil puissant d’acquisition de données altimétriques, fournissant des nuages de points 3D. Il est très populaire dans de nombreux domaines où il constitue souvent une source d’information complémentaire aux données optiques (multi- ou hyperspectrales).

Le principe de l’acquisition LiDAR est d’envoyer une impulsion laser et de récupérer le signal rétrodiffusé. Ses pics d’intensité permettent de localiser les structures rencontrées et l’intensité associée informe sur le type d’objet (un bâtiment rétrodiffuse plus que la végétation par exemple). Il en résulte des nuages de points non structurés, associés à des caractéristiques d’intensité.

En raison de cette complexité, les données LiDAR pour la cartographie des sols sont souvent simplifiées en un modèle numérique d’élévation (MNE) utilisé comme une image (étape de rasterisation). Dans cet article, nous nous concentrons sur cette étape de rasterisation en produisant différents rasters (et non seulement le MNE) à partir desquels nous générons des descriptions multi-échelles. Pour cela, nous utilisons des approches hiérarchiques et notamment les profils d’attributs morphologiques.

1.1 Classification de données LiDAR

De nombreuses méthodes ont déjà été proposées au cours de la dernière décennie pour la classification de nuages de points LiDAR. Parmi les techniques efficaces, certaines exploitent directement la structure du nuage de points 3D [1,9,11] tandis que dans de nombreuses applications, le nuage de points est d’abord rasterisé sur une grille 2D régulière sur laquelle peuvent être appliquées des approches classiques de vision par ordinateur [8]. À part quelques applications spécifiques où les points LiDAR sont fusionnés avec d’autres données (par ex. hyperspectrales [5–7,12]), l’approche usuelle consiste à calculer des caractéristiques pour décrire les nuages de points, puis d’utiliser ces caractéristiques pour classer la scène étudiée.

Alors que les premiers travaux se sont concentrés sur la caractérisation de points isolés (souvent par la hauteur et l’intensité) sans inclure d’informations relatives à leurs voisins [8], des approches plus avancées ont inclus des relations spatiales autour de chaque point pour extraire des caractéristiques géométriques homogènes [9,11,15].

Dans ce contexte, les caractéristiques 3D locales multi-échelles (orientation principale, variabilité autour de chaque point, etc.) ont prouvé leur efficacité pour classer les scènes LiDAR [1]. Même si elles sont très efficaces, les sphères utilisées pour évaluer le voisinage des points

*Les auteurs remercient le soutien de la Région Bretagne (projet doctoral CAMLOT).

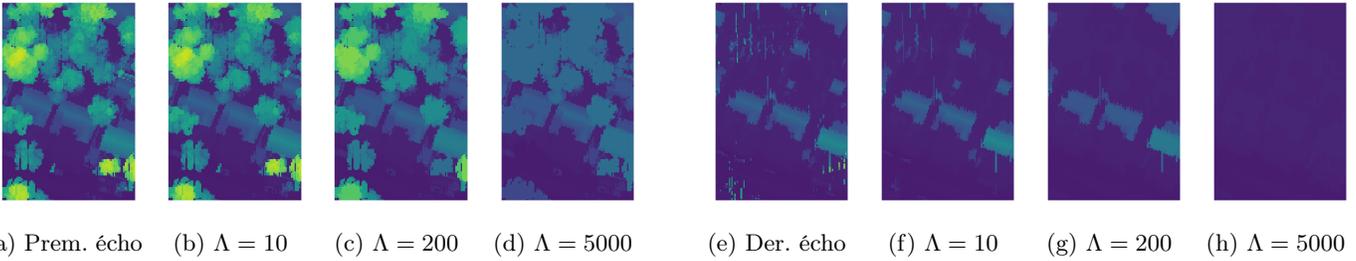


FIGURE 1 – Rasters en zone résidentielle, premier (a-b-c-d) et dernier écho (e-f-g-h) avec les rasters non filtrés (a-e), puis profil d’attributs auto-dual (SDAP) avec $\Lambda = 10$ (b-f), $\Lambda = 200$ (c-g) et $\Lambda = 5000$ (d-h).

sont isotropes (aucune orientation n’est favorisée), ce qui n’est pas optimal puisque la géométrie des objets n’est pas prise en compte. C’est pourquoi d’autres approches multi-échelles ont été proposées sur des MNE LiDAR, telles que les profils d’attributs [4] qui produisent une description multi-échelle du pixel et de son voisinage [6, 7, 12], avant de procéder à la classification.

L’idée principale qui sous-tend cette méthode est de calculer des caractéristiques spatiales multi-échelles en tenant compte de la géométrie de la scène. Notre première contribution est donc d’explorer diverses informations dérivées du nuage de points LiDAR dans le cadre des profils d’attributs.

1.2 Profils d’attributs

Les profils d’attributs (AP) morphologiques [4] permettent une description multi-échelle des données, obtenue efficacement par la représentation arborescente des ensembles de niveaux de gris avec un arbre max ou un arbre min. Ils ont été supplantés par les SDAP [3] construits à partir d’une représentation multi-échelle unique d’une image à travers l’arbre des formes. Dans cette arborescence, tous les nœuds représentent des régions de pixels adjacents. Les feuilles sont constituées des extrema locaux et la racine regroupe tous les pixels de l’image. Ensuite, des filtres successifs de l’image (ou de manière équivalente de sa représentation en arbre) sont effectués en fonction de certaines caractéristiques préalablement calculées sur chaque nœud telles que la surface, le moment d’inertie, l’écart-type des valeurs dans les composantes connexes. Les images filtrées sont finalement superposées pour former des vecteurs de description appelés SDAP. La concaténation des SDAP de différentes bandes dans un même vecteur est appelée profil d’attributs auto-dual étendu (ESDAP) [2]. Le profil d’attributs auto-dual différentiel (DSDAP) contient les mêmes informations mais exprime la différence entre les niveaux successifs des SDAP.

Les travaux antérieurs combinant AP et LiDAR ne portent que sur les MNE (cf. Sec. 1.1). Pourtant, dans les systèmes d’acquisition LiDAR récents, des informations multispectrales peuvent être extraites et la question de la description d’autres caractéristiques que le MNE reste ou-

verte. Notre seconde contribution consiste à améliorer les méthodes de classification LiDAR existantes en utilisant les SDAP et leurs dérivées pour mieux décrire les caractéristiques extraites des données LiDAR.

2 Stratégies de rastérisation

2.1 Caractéristiques LiDAR

Les systèmes d’acquisition LiDAR sont généralement utilisés pour le calcul d’un MNE à partir du nuage de points non structuré. Bien qu’un MNE apporte une information utile, des caractéristiques supplémentaires peuvent être extraites et exploitées à partir du LiDAR, en particulier :

1. *L’intensité spectrale associée au premier écho dans chaque bande spectrale.*
2. *Le nombre d’échos dans chaque bande spectrale.* Certaines structures, surtout dans les zones de végétation, ne retournent pas entièrement le signal laser qui se répercute en plusieurs échos.
3. *La position du dernier écho.* Pour les signaux qui se rétrodiffusent en plusieurs échos, cela permet de détecter la position du dernier élément rencontré. Dans certaines situations (surtout avec la végétation), cela permet de détecter la surface du sol.
4. *L’intensité associée au dernier écho.*

Les deux dernières informations sont généralement moins employées. Cependant, elle peuvent aider le processus de classification puisque toutes les zones de végétation sont retirées, comme illustré sur la Figure 1a(e).

Le processus de rastérisation vise à fournir pour chaque cellule de la grille des valeurs représentatives des caractéristiques susmentionnées. Dans un souci de simplicité, nous avons choisi de moyenniser les valeurs d’intensité, d’élévation et du nombre d’échos contenues dans chaque cellule. De plus, nous remplissons les cellules potentiellement vides (donnée manquante) à l’aide d’une interpolation linéaire.

2.2 Filtrage d’attributs

Comme indiqué précédemment, nous considérons ici l’application des profils d’attributs sur différentes déclinaisons



FIGURE 2 – Classification du paysage en utilisant les DSDAP avec les caractéristiques $\{N, I, I_r, D, D_r\}$.

rastérisées des données LiDAR. Dans cet article, par souci de performance et de simplicité, nous avons choisi de filtrer toutes les caractéristiques LiDAR uniquement en fonction de l’attribut d’aire dont les valeurs ont été établies dans le contexte urbain. Plus précisément, nous considérons trois échelles dominantes :

- valeurs faibles (de 1 à 5 m^2) pour filtrer les petits objets (par ex. les lignes électriques) à l’instar d’un débruitage.
- valeurs moyennes (de 5 à 50 m^2) pour filtrer les objets de taille moyenne (voitures, arbres, etc.).
- valeurs élevées (plus de 50 m^2) pour filtrer les objets les plus gros (par ex. les bâtiments).

3 Résultats expérimentaux

3.1 Contexte

Nos stratégies ont été testées pour classer des données LiDAR multispectrales provenant de l’Université de Houston et fournies lors du *IEEE GRSS Data Fusion Contest 2018*¹. La carte de validation associée est un raster à 0,5m / pixel et nous travaillons avec 8 classes urbaines (routes, surfaces en herbe, arbres, bâtiments résidentiels, bâtiments non résidentiels, voitures et trains). La classification est opérée par forêts aléatoires (RF).

Les ESDAP ont été créés en filtrant chaque raster avec des attributs d’aire et les seuils $\Lambda = \{10, 200, 5000\}$ (cf. Sec. 2.2). Les caractéristiques mentionnées précédemment (le modèle numérique de surface (DSM) D , les intensités I et I_r du premier et dernier écho, le nombre d’échos N , et la position du dernier écho D_r) ont été testées indépendamment et combinées ensemble. À des fins de comparaison, nous avons également effectué la classification uniquement avec les rasters initiaux (sans analyse multi-échelle via les AP) pour évaluer les avantages des AP et de ses variantes.

Le caractère multi-échelle des profils d’attributs exclut le tirage aléatoire des points pour entraîner et tester un

classifieur. Nous avons donc opté pour une séparation en deux images (apprentissage et test), et choisi 10 % des points pour entraîner et évaluer notre approche. L’évaluation s’appuie sur la précision globale moyenne (OA) et le coefficient Kappa de Cohen (κ), avec 100 répétitions.

3.2 Résultats

Dans le tableau 1, nous montrons les meilleurs résultats de classification avec 1 à 5 caractéristiques. Comme prévu [5, 6, 12], les SDAP améliorent presque systématiquement la classification par rapport à une utilisation “pixel” seule. Les performances des DSDAP permettent quant à elles d’améliorer encore plus les résultats, illustrant l’intérêt des critères différentiels.

Sur ce jeu de données, il est surprenant de constater que les intensités multispectrales donnent de meilleurs résultats que le MNE D . Cette observation est intéressante pour la séparabilité des objets en milieu urbain. Il convient également de noter qu’en ce qui concerne les positions, le dernier écho D_r apporte aussi une information utile (lignes 2, 3) quand il est combiné à des caractéristiques hiérarchiques. La capacité de ce dernier écho à identifier les bâtiments peut expliquer cette observation.

Enfin, comme on pouvait s’y attendre, la combinaison de toutes les caractéristiques (dernière ligne) permet d’obtenir la meilleure précision. Bien que la différence entre les DSDAP et les SDAP soit limitée, l’amélioration par rapport à la référence est importante et démontre la capacité des caractéristiques basées sur les AP à discriminer correctement les données LiDAR en milieu urbain.

Nous fournissons en Fig. 2 la classification obtenue en utilisant toutes les caractéristiques du DSDAP, ligne 5 du Tab. 1. Les classes sont : routes (blanc), herbe (vert), arbres (vert foncé), bâtiments résidentiels (gris clair), bâtiments non résidentiels (gris), voitures (rouge) et trains (violet). En pratique, l’image a été séparée horizontalement afin d’éviter les mélanges entre données d’entraînement et de validation. Par conséquent, certaines classes très localisées n’ont pas été apprises correctement et n’ont donc pas été correctement classées (par exemple, la pente herbeuse en bas à droite a été classée comme un bâtiment).

1. <http://www.grss-ieee.org/community/technical-committees/data-fusion/2018-ieee-grss-data-fusion-contest/>

	Description	Pixel			E-SDAPs			E-DSDAPs		
		Métrique d'évaluation	OA(%)	$\kappa(\times 100)$	d	OA(%)	$\kappa(\times 100)$	d	OA(%)	$\kappa(\times 100)$
1	I	68,36	52,18	3	72,00	57,30	12	73,28	59,25	12
2	$\{I, D_r\}$	82,26	72,84	4	86,97	79,86	16	87,93	81,46	16
3	$\{I, D, D_r\}$	84,59	76,50	5	88,21	81,80	20	89,28	83,56	20
4	$\{N, I, D, D_r\}$	85,87	78,46	8	88,92	82,90	32	90,04	84,74	32
5	$\{N, I, I_r, D, D_r\}$	86,20	78,93	11	89,05	83,09	44	90,16	84,91	44

TABLE 1 – Précision globale (OA) et Kappa (κ) avec des pixels bruts, les SDAP et DSDAP pour 1 à 5 combinaisons (la meilleure combinaison est représentée). La dimension de chaque vecteur d est également fournie.

Malgré cette difficulté, les évaluations quantitatives et les cartes qualitatives sont intéressantes et très peu bruitées avec des contours précis.

4 Conclusion

Nous avons abordé ici la classification du LiDAR multisppectral au moyen de caractéristiques rastérisées et du filtrage par attributs. Nos résultats ont montré que combiner différentes stratégies de rastérisation peut améliorer la classification avec l'utilisation des données LiDAR uniquement. De plus, la prise en compte des AP pour modéliser l'organisation spatiale multi-échelles des informations a amélioré nos résultats et permis de produire une carte précise d'occupation du sol en zone urbaine. La méthode proposée est rapide et peut être utilisée avec tout classifieur supervisé [10].

D'autres améliorations pourraient être apportées. D'une part, nous pouvons extraire d'autres caractéristiques du LiDAR comme la densité de points, l'orientation à l'intérieur d'une cellule, le rapport entre les bandes spectrales, mais aussi résumer la cellule avec d'autres mesures que la valeur moyenne comme l'écart-type ou les quantiles. D'autre part, nous pouvons améliorer les AP en considérant d'autres attributs tels que ceux relatifs au moment d'inertie, en utilisant des méthodes plus avancées basées sur les AP comme [13, 14] ou même en créant des attributs spécifiques LiDAR pour les intégrer à l'arbre pendant la construction de ce dernier. Afin d'améliorer la classification des objets qui se chevauchent (par exemple, les bâtiments sous les arbres), il pourrait être intéressant d'effectuer une classification 3D. Dans cette optique, la vérité 3D au sol serait optimale pour les données LiDAR.

Références

- [1] N. Brodu and D. Lague. 3d terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion : Applications in geomorphology. *ISPRS J. Photogrammetry and Remote Sensing*, 68 :121–134, 2012.
- [2] G. Cavallaro, M. Dalla Mura, J.A. Benediktsson, and L. Bruzzone. Extended self-dual attribute profiles for the classification of hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 12(8) :1690–1694, 2015.
- [3] M. Dalla Mura, J. A. Benediktsson, and L. Bruzzone. Self-dual attribute profiles for the analysis of remote sensing images. In *ISMM*, pages 320–330, 2011.
- [4] M. Dalla Mura, J.A. Benediktsson, B. Waske, and L. Bruzzone. Morphological attribute profiles for the analysis of very high resolution images. *IEEE Transactions on Geoscience and Remote Sensing*, 48(10) :3747–3762, 2010.
- [5] B.B. Damodaran, J. Höhle, and S. Lefèvre. Attribute Profiles on Derived Features for Urban Land Cover Classification. *Photogrammetric Eng. & Remote Sensing*, 83(3) :183–193, 2017.
- [6] P. Ghamisi, J. A. Benediktsson, and S. Phinn. Land-cover classification using both hyperspectral and LiDAR data. *Int. J. of Image and Data Fusion*, 6(3) :189–215, 2015.
- [7] M. Khodadadzadeh, J. Li, S. Prasad, and A. Plaza. Fusion of Hyperspectral and LiDAR Remote Sensing Data Using Multiple Feature Learning. *IEEE J. of Sel. Top. in Applied Earth Obs. and Remote Sensing*, 8(6) :2971–2983, 2015.
- [8] S.K. Lodha, E.J. Kreps, D.P. Helmbold, and D. Fitzpatrick. Aerial LiDAR Data Classification Using Support Vector Machines (SVM). In *3DPVT*, pages 567–574, 2006.
- [9] C. Mallet, F. Bretar, M. Roux, U. Soergel, and C. Heipke. Relevance assessment of full-waveform lidar data for urban area classification. *ISPRS J. Photogrammetry and Remote Sensing*, 66(6) :S71–S84, 2011.
- [10] F. Merciol, T. Balem, and S. Lefèvre. Efficient and large-scale land cover classification using multiscale image analysis. In *ESA Conference on Big Data from Space (BiDS)*, 2017.
- [11] J. Niemeyer, F. Rottensteiner, and U. Soergel. Contextual classification of lidar data and building object detection in urban areas. *ISPRS J. Photogrammetry and Remote Sensing*, 87 :152–165, 2014.
- [12] M. Pedernana, P. R. Marpu, M. Dalla Mura, J. A. Benediktsson, and L. Bruzzone. Classification of Remote Sensing Optical and LiDAR Data Using Extended Attribute Profiles. *IEEE J. Sel. Top. in Signal Proc.*, 6(7) :856–865, 2012.
- [13] M.T. Pham, S. Lefevre, and E. Aptoula. Feature profile from attribute filtering for classification of remote sensing images. *IEEE J. of Sel. Top. in Applied Earth Obs. and Remote Sensing*, 11(1) :249–256, 2018.
- [14] M.T. Pham, S. Lefevre, and E. Aptoula. Local Feature-Based Attribute Profiles for Optical Remote Sensing Image Classification. *IEEE Transactions on Geoscience and Remote Sensing*, 56(2) :1199–1212, 2018.
- [15] M. Weinmann, B. Jutzi, S. Hinz, and C. Mallet. Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. *ISPRS J. Photogrammetry and Remote Sensing*, 105 :286–304, 2015.