



HAL
open science

Fusion d'informations pour la segmentation sémantique de nuages de points d'intérieurs de bâtiments

Maxime Méritzette, Nicolas Audebert, Jérôme Verdun, Pierre Kervella

► **To cite this version:**

Maxime Méritzette, Nicolas Audebert, Jérôme Verdun, Pierre Kervella. Fusion d'informations pour la segmentation sémantique de nuages de points d'intérieurs de bâtiments. ORASIS 2023, Laboratoire LIS, UMR 7020, May 2023, Carqueiranne, France. hal-04219456

HAL Id: hal-04219456

<https://hal.science/hal-04219456v1>

Submitted on 27 Sep 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Fusion d'informations pour la segmentation sémantique de nuages de points d'intérieurs de bâtiments

Maxime Mérizette^{1,3}

Nicolas Audebert²

Jérôme Verdun¹

Pierre Kervella³

¹ CNAM - GeF ² CNAM - CEDRIC ³ Quarta

maxime.merizette@lecnam.net

Résumé

Les nuages de points contiennent non seulement la description géométrique d'une scène mais aussi des informations physiques, comme la couleur ou l'intensité LiDAR. Cette dernière est caractéristique de certains matériaux et n'est pourtant que peu exploitée dans les jeux de données de l'état de l'art. Notre objectif est d'évaluer l'apport de cette information dans la segmentation de nuages de points en intérieur par réseaux profonds. En particulier nous évaluerons la combinaison de l'intensité avec des descripteurs géométriques sur un nouveau jeu de données.

Mots Clef

Nuages de points 3D, LiDAR, apprentissage multimodal

Abstract

Point clouds contain not only the geometric description of a scene but also physical information, such as color or LiDAR intensity. The latter is typical of some materials and yet is rarely used in state-of-the-art datasets. Our goal is to assess the contribution of this information for the segmentation of indoor point clouds with deep networks. In particular we will evaluate the combination of intensity with geometric features on a new dataset.

Keywords

3D point clouds, LiDAR, multimodal learning

1 Introduction

Les récents travaux sur la segmentation des nuages de points par apprentissage profond ne se focalisent plus seulement sur le développement d'une nouvelle architecture. D'autres facteurs sont pris en considération comme l'apport d'images RGB, des stratégies d'entraînement (PointNeXt [5]), ou des caractéristiques géométriques (RepSurf [6]). Des travaux récents [3] ont déjà étudié l'impact de l'ajout et de la fusion de caractéristiques quant aux performances de la segmentation de nuages de points. L'intensité n'étant pas présente dans les jeux de données de référence de segmentation de nuages de points d'intérieurs de bâtiments, elle a été très peu étudiée. Pourtant différents matériaux répondent différemment lorsque l'intensité

de leurs retour LiDAR est mesurée. Cette information peut donc lever des ambiguïtés pour distinguer des objets différents avec une même géométrie. Pour évaluer l'apport de l'intensité, nous comparons des réseaux profonds sur un nouveau jeu de données composée de 12 classes et contenant pour chaque point 17 caractéristiques (normales, omnivariance, intensité...).

1.1 Jeu de données

Les nuages de points qui composent le jeu de données ont été acquis à l'aide des scanners Leica ScanStation P20 et Leica ScanStation P40. Le jeu de données est composé de 770 254 537 points, répartis en 12 classes (Table 1), pour une surface de près de 9500 m².

Classe	Nombre	Classe	Nombre
Poteaux	7 141 739	Mur	198 504 953
Composants ¹	5 521 163	Plafond	38 173 742
Tuyaux	17 034 783	Toit	79 082 754
Porte	7 308 954	Terminaux ²	6 970 118
Sol	78 028 308	Fenêtre	730 982
Poutre	23 194 278	Non classé	308 562 763

TABLE 1 – Répartition des points de notre jeu de données.

Chaque point contient l'information d'intensité à laquelle ont été ajoutées 16 autres caractéristiques, comme les normales, la courbure parapluie [2], ou l'omnivariance [3]. Les caractéristiques basées sur un voisinage sont calculées en considérant des sphères de 5 cm. Les points sont classés en 10 catégories d'éléments structurants (mur, sol, plafond...) et deux catégories d'objets : « Composants » et « Terminaux » selon leur usage. Le jeu de données est composé de 82 stations de scanner laser terrestre, divisé entraînement (47 stations), validation (18 stations) et test (17 stations).

1.2 État de l'art

Le jeu de données de référence pour la segmentation de nuages de points en intérieur est S3DIS [1]. RepSurf [6] figure parmi les algorithmes qui obtiennent les meilleurs

1. Armoire à gaz, chauffe-eau, grille d'aération, caméra...

2. Extincteur, évier, lavabo, urinoir, wc...

Entrées	Poteaux	Composants	Tuyaux	Porte	Sol	Poutre	Mur	Plafond	Toit	Terminaux	Fenêtre
N	23.7	46.6	59.7	32.9	91.4	71.3	89.2	90.5	95.7	61.2	81.6
I	23.8	47.9	50.5	33.8	77.8	68.6	90.2	89.0	94.3	76.8	82.1
I&N	25.7	42.9	54.1	28.7	85.7	71.4	89.7	89.0	95.1	75.5	79.5
I&U	23.7	45.0	51.0	34.2	62.9	68.1	90.3	87.6	90.0	78.6	80.2
N&U	23.2	50.1	56.4	18.6	69.9	70.7	87.4	89.0	91.8	59.4	76.5
I&O	27.4	50.7	54.2	36.8	86.2	72.7	90.9	88.2	96.1	79.5	81.2
N&O	25.7	54.9	55.3	22.8	76.5	65.8	88.4	88.7	93.4	53.8	79.2
I&N&U	27.0	45.2	51.4	22.7	82.8	69.1	88.6	87.0	94.4	71.2	78.0
I&N&O	22.7	53.2	48.3	27.6	79.4	69.1	90.1	89.9	94.0	74.4	78.9

TABLE 2 – IoU par classe pour PointNeXt-L sur notre jeu de test, appris pour différentes caractéristiques d’entrée.

résultats actuels sur S3DIS de part son incorporation de caractéristiques géométriques. Basé sur PointNet++ [4], Rep-Surf introduit la courbure parapluie comme caractéristique en entrée de chaque module de PointNet++. PointNeXt [5] est un autre modèle lui aussi basé sur PointNet++, dont il est une amélioration grâce à l’augmentation de données (rotations, mise à l’échelle...), et des optimiseurs adaptatifs.

2 Résultats des tests

Nos tests exploitent l’architecture PointNeXt-L [5]. L’entraînement de cet algorithme a été réalisé sur une carte graphique NVIDIA RTX A6000 (49 Go). Nous avons opté pour des lots de 32 exemples de 24 000 points chacun et 150 époques d’entraînement. De plus, les points non classés ont été ignorés dans la fonction de coût. En phase de validation, le nombre de points par lot est limité à 800 000 points. Les nuages de points en test sont sous-échantillonnés à 4 cm. Nous avons évalué l’apport des normales (N), de l’intensité (I), de la courbure parapluie (U) et de l’omnivariance (O) pour la segmentation des 12 classes. Les métriques de segmentation (Intersection sur Union (IoU), Exactitude globale (OA), Exactitude moyenne par classe (mAcc)) pour chaque modèle sont détaillés pour chaque classe dans le Tableau 2 et les métriques globales sont présentées dans le Tableau 3.

Entrées	OA	mAcc	mIoU
I	92.5	80.3	69.5
N	93.1	81.9	70.3
I&N	93.0	80.9	69.8
I&U	90.9	79.6	67.6
N&U	90.6	79.2	66.1
I&O	93.8	82.0	72.0
N&O	91.2	80.3	67.0
I&N&U	92.1	80.2	68.1
I&N&O	92.4	79.8	69.0

TABLE 3 – Métriques globales de segmentation pour PointNeXt-L sur notre jeu de données de test

3 Discussion

On observe que le modèle entraîné uniquement sur l’intensité fournit des résultats proches du modèle entraîné uni-

quement sur les normales. En effet sur le jeu de test, la mIoU est de 69.56, contre 70.30 pour le modèle entraîné à l’aide des seules normales. Le Tableau 3 montre que la fusion de l’intensité et de l’omnivariance fournit les meilleurs résultats globaux. Cependant, le modèle entraîné sur ces deux caractéristiques, ne fournit pas les meilleurs résultats sur toutes les classes. En effet, sur la classe « Sol » le modèle entraîné sur les normales permet d’obtenir les meilleurs performances (IoU = 91.44). De même, le Tableau 3 montre que la fusion de certaines caractéristiques n’améliore pas toujours les performances, comme pour la fusion de la courbure parapluie et des normales. Ceci renforce l’hypothèse que certaines caractéristiques sont plus discriminantes que d’autres. Les caractéristiques locales (linéarité, somme des valeurs propres, verticalité...) n’ont pas toutes été étudiées pour l’instant mais seront caractérisées ultérieurement. En particulier, l’information colorimétrique peut apporter une amélioration substantielle.

Références

- [1] Iro Armeni, Ozan Sener, Amir R. Zamir, et al. 3d semantic parsing of large-scale indoor spaces. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 2016.
- [2] A. Foorginejad and K. Khalili. Umbrella curvature : A new curvature estimation method for point clouds. *Procedia Technology*, 12 :347–352, 2014.
- [3] Mehmet Akif Günen. Adaptive neighborhood size and effective geometric features selection for 3d scattered point cloud classification. *Applied Soft Computing*, 115 :108196, 2022.
- [4] Charles R Qi, Li Yi, Hao Su, et al. Pointnet++ : Deep hierarchical feature learning on point sets in a metric space. *arXiv preprint arXiv :1706.02413*, 2017.
- [5] Guocheng Qian, Yuchen Li, Houwen Peng, et al. Pointnext : Revisiting PointNet++ with improved training and scaling strategies. In *Advances in Neural Information Processing Systems (NeurIPS)*, 2022.
- [6] Haoxi Ran, Jun Liu, and Chengjie Wang. Surface representation for point clouds. In *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 18920–18930, 2022.