# Analyse Grande Echelle de Données 3D

LabeX Bezout Math/info pour la ville 2022

Loic Landrieu

## IGN - LASTIG - ENSG - UGE



## Présentation

- Loic Landrieu: chercheur en apprentissage / vision à l'IGN.
- 3D data: indoor, urbain, inventaire forestier
- 3D Dynamique:conduite autonome (ANR ReADy3D)
- Séries Temporelles: occupation des sols
- Optimization: problèmes inverses, graphes
- Program Chair d'ISPRS Congress













## Motivation

- 2 Approche Traditionnelle
- 3 Apprentissage Profond pour la 3D
- Passage à l'échelle

# 6 Bibliography

# Motivation

- Approche Traditionnelle
- 3 Apprentissage Profond pour la 3D
- Passage à l'échelle
- Bibliography

- Nuage de points 3D: [x<sub>i</sub>, y<sub>i</sub>, z<sub>i</sub>] ∈ **R**<sup>N×3</sup> + radiométrie
- Comment obtenir un nuage de points?:
- **Photogrammetry**: stereovision, SLAM, Surface from Motion





Thevara etal 2019, mathworks, renishaw.fr, tuck mapping

- Nuage de points 3D: [x<sub>i</sub>, y<sub>i</sub>, z<sub>i</sub>] ∈ **R**<sup>N×3</sup> + radiométrie
- Comment obtenir un nuage de points?:
- **Photogrammetry**: stereovision, SLAM, Surface from Motion
- LiDAR: active sensor with lasers
- Avantages et inconvénients:
- capture la géométrie, gestion des occlusions
- capteurs spécialisés et/ou post processing, format complexe

Thevara etal 2019, mathworks, renishaw.fr, tuck mapping





- Accessibilité des données 3D:
- méthodes stéréo performante
- LiDAR précis & abordables





credit: velodynelidar, green car congress

- Accessibilité des données 3D:
- méthodes stéréo performante
- LiDAR précis & abordables
- Forte **demande** d'analyse automatique.
- Conduite autonome
- Jumeaux numérique
- Réalité virtuelle/augmentée
- Surveillance environementales
- Patrimoine digital / télé-archéologie
- Révolution méthodologique
- Précision, vitese
- Passage à l'échelle reste un defis





credit: velodynelidar, spar3d

- Accessibilité des données 3D:
- méthodes stéréo performante
- LiDAR précis & abordables
- Forte **demande** d'analyse automatique.
- Conduite autonome
- Jumeaux numérique
- Réalité virtuelle/augmentée
- Surveillance environementales
- Patrimoine digital / télé-archéologie
- Révolution méthodologique
- Précision, vitese
- Passage à l'échelle reste un defis



credit: tuck mapping solutions, clearpath robotics

#### Complexité de l'Analyse 3D

- Volume de donnée
- Absence de grille régulière
- Invariance par permutation
- Parcimonie
- Densité variable
- Artefacts d'acquisition
- Occlusions
- Apprentissage par batch



credit: Gaidon2016, Engelmann2017, Hackel2017

#### 1 Motivation

#### 2 Approche Traditionnelle

3 Apprentissage Profond pour la 3D

#### Passage à l'échelle

#### Bibliography

- Step 1: calcul de descripteur géométriques de points 3D:
- positions des 50 voisins
- matrice  $3 \times 3$  de covariance spatiale
- valeurs propres  $\lambda_1, \lambda_2, \lambda_3$
- indicateurs de dimensionalité



Demantke2011, Weimann2015

credit: landrieu et. al. , JSPRS 2017

Approche Traditionnelle

- **Step 1:** calcul de descripteur géométriques de points 3D:
- positions des 50 voisins
- matrice  $3\times 3$  de covariance spatiale
- valeurs propres  $\lambda_1, \lambda_2, \lambda_3$
- indicateurs de dimensionalité



Linéarité Planarité Diffusion

- Step 1: calcul de descripteur géométriques de points 3D:
- positions des 50 voisins
- matrice  $3 \times 3$  de covariance spatiale
- valeurs propres  $\lambda_1, \lambda_2, \lambda_3$
- indicateurs de dimensionalité
- Step 2:
- Concaténation avec radiométrie, elevation, etc...
- classification (RF, SVM, etc...)
- Step 3: régularisation spatiale (CRFs, MRFs, structured optimization, etc...)



### 1 Motivation

- Approche Traditionnelle
- 3 Apprentissage Profond pour la 3D
- Passage à l'échelle

## Bibliography

## Présentation

- Deep Learning: approche d'apprentissage machine basé sur l'usage de neurones artificiels.
- Champs d'application: Très efficace pour l'image, le son et le texte.
- Et la 3D? Est-ce vraiment plus dur?





## Deep Learning pour Analyse de Nuages de Points



Ensemble de coordonées

PointNet, Rand-LANet

Transformers

Nuages de points vus comme:



Ensemble d'image SnapNet, MVNet



Grille de voxels MinkowskiNet, Sparse-Conv OctNet



Un graphe ECC, DGCNN





fonction dans espace continu KPConv, ConvPoint

PointCNN See review by Guo *et al.* PAMI 2020

Graphe de superpoints SPG, SSP OccuSeg

### 1 Motivation

- Approche Traditionnelle
- 3 Apprentissage Profond pour la 3D

## Passage à l'échelle

#### Bibliography

- **Problème:** les méthodes précédentes sont gourmande en mémoire et compute.
- Ne peuvent être utilisées que pour quelques milliers de points.
- Stratégies Naïves:
- **Sous-échantillonage**: perte d'information.
- **Fenêtre glissante**: perte de la structure globale.



credit: tuck mapping solution

#### • Observation:

 $n_{\rm points} \gg n_{\rm objects}$ .

- Partition en superpoints avec formes simples.
- Beaucoup moins de superpoints que de points, contexte acessible par un graphe d'adjacence.









#### Landrieu&Simonovski, CVPR 2018

Step	Complexité	Algorithm	
Geometric Partition	very high	$\ell_0$ -cut pursuit	
en formes simples	10 <sup>8</sup> points		
Superpoint embedding	low	PointNet	
learning shape descriptors	subsampling to 128 points		
Contextual Segmentation	very low	ECC	
leveraging the global structure	$\sim$ 1000 vertices	with GRUs	

Pipeline



#### Partition

$$f^{\star} = \operatorname{argmin}_{f \in \mathbb{R}^{C \times m}} \sum_{i \in C} ||f_i - e_i||^2 + \sum_{(i,j) \in E} w_{i,j} [f_i \neq f_j],$$

- $e \in \mathbb{R}^{C \times m}$  : descripteurs "à la main" de la géométrie/radiométrie locales .
- $f^*$ : approximation constante par morceaux de e.
- Solution approximée efficacement avec  $\ell_0$ -cut pursuit.
- Problème: toute erreur de partition engendre une erreur de prédiction...



Landrieu & Obozinski, SIIMS 2017, Raguet & Landrieu, ICML 2018, ICML-W 2019

# Apprendre à Segmenter



Input Point Cloud



Oversegmentation



Learned Embedding



True Objects

- 1) Descripteur de points appris pour présenter de forts contrastes à l'interface entre objets...
- 2) ... qui peuvent servir d'input à un algorithme de segmentation.
- $\rightarrow$  Nécessite 5 fois moins de superpoints que l'état de l'art.

#### Landrieu&Boussaha, CVPR 2019

## Illustration



Input



Graph-LCE (ours)



Vrais objects



VCCS, Papon et al. 2013



Descripteurs



Lin et al. 2018

## Illustration



# Résultats Quantitatifs sur S3DIS:





Method	OA	mloU	
6-fold cross validation			
PointNet	78.5	47.6	
Engelmann <i>et al.</i> 2017	81.1	49.7	
PointNet++	81.0	54.5	
<u>SPG</u>	<u>85.5</u>	<u>62.1</u>	
Engelmann <i>et al.</i> 2018	84.0	58.3	
PointCNN	88.1	65.4	
ConvPoint 2019	88.1	68.2	
SSP + SPG	<u>87.9</u>	<u>68.4</u>	
PointSIFT	88.7	70.2	
MinkowskiNet	86.0	65.9	
KPConv	88.8	70.6	

Table: Etat de l'art jan 2020: **OA** : Overall Accuracy, **mAcc** : average class accuracy, **mIoU**: average class Intersection over Union.

- Quel algorithme utiliser?
- Commencer par un algorithme classique (RF) comme baseline / nettoyage des données
- Puis PointNet + fenêtre glissante.
- Si besoin de plus d'expressivité, MinkowskiNet/KPconv/ConvPoint.
- Si besoin de vitesse + structure globale: SPG.

## Complementarity of 2D and 3D Modalities

- Images: texture and context
- Point Clouds: geometry
- Objective: combine both modalities
- Point cloud colorization: lose important information
- Deep Multi-View Aggregation:
- leverage viewing conditions
- from raw p.c. and images w poses
- no mesh, depth, colorization needed
- SOTA on S3DIS and KITTI360

Robert, Vallet, Landrieu, CVPR 2022



## Spatio-Temporal Helix



- Rotating LiDAR acquisitions have a complex spatio-temporal structure
- $\bullet\,$  Most methods processes full rotations at once  $\Rightarrow\,100\text{-}200\text{ms}$  latency
- We split the acquisition into slices of rotation

# Spatio-Temporal Helix



- Rotating LiDAR acquisitions have a complex spatio-temporal structure
- $\bullet\,$  Most methods processes full rotations at once  $\Rightarrow$  100-200ms latency
- We split the acquisition into slices of rotation
- Hybrid Spatio-Temporal Transformer:
- Latency  $\div$  5, model size  $\div$  50, same accuracy
- Real-time, portable, online semantic segmentation!

# Spatio-Temporal Helix



- Rotating LiDAR acquisitions have a complex spatio-temporal structure
- $\bullet\,$  Most methods processes full rotations at once  $\Rightarrow$  100-200ms latency
- We split the acquisition into slices of rotation
- Hybrid Spatio-Temporal Transformer:
- Latency  $\div$  5, model size  $\div$  50, same accuracy
- Real-time, portable, online semantic segmentation!
- A new large-scale benchmark with 10B points and useful metadata

### 1 Motivation

- Approche Traditionnelle
- 3 Apprentissage Profond pour la 3D
- Passage à l'échelle

## Bibliography

Landrieu2017 Landrieu L, Obozinski, B. (2017) Cut pursuit: Fast algorithms to learn piecewise constant functions on general weighted graphs. SIIMS Guinard2017 Guinard S, Landrieu L (2017) Weakly supervised segmentation-aided classification of urban scenes from 3D LiDAR point clouds. ISPRS Landrieu 2018 Landrieu L, Raguet H, Vallet B, Mallet C, Weinmann, M. (2017) A structured regularization framework for spatially smoothing semantic labelings of 3D point clouds. IJPRS Landrieu&Simonovski2018 Landrieu, L., & Simonovsky, M. (2018) Large-scale point cloud semantic segmentation with superpoint graphs. CVPR, Raguet2018 Raguet H, Landrieu L. (2018) Cut-Pursuit Algorithm for Regularizing Nonsmooth Functionals with Graph Total Variation. ICML Landrieu2019 Landrieu, L. & Boussaha, M. (2019) Point Cloud Oversegmentation with Graph-Structured Deep Metric Learning, CVPR. Guinard2019 Guinard S, Landrieu L, Caraffa L, Vallet B, (2019) Piecewise-Planar Approximation of Large 3D Data as Graph-Structured Optimization, ISPRS. Raguet2018 Raguet H, Landrieu L. (2019) Parallel Cut Pursuit For Minimization of the Graph Total Variation, ICML-W Loiseau2021 Loiseau R, Monnier T, Aubry M, Landrieu L, (2021) Representing Shape Collections with Alignment-Aware Linear Models, 3DV. Sulzer2021 Sulzer R, Landrieu L, Marlet R, Vallet B, (2021) Scalable Surface Reconstruction with Delaunay-Graph Neural Networks, Eurographics SGP. Kalinicheva2021 Kalinicheva E, Landrieu L, Mallet C, Chehata N, (2021) Vegetation Stratum

Occupancy Predictionfrom Airborne LiDAR 3D Point Clouds, Sylvilaser.

Qi et. al.2017a Qi, C. R., Su, H., Mo, K., & Guibas, L. J. Pointnet: Deep learning on point sets for 3d classification and segmentation. CVPR, 2017

Gaidon2016 Gaidon, A., Wang, Q., Cabon, Y., & Vig, E. Virtual worlds as proxy for multi-object tracking analysis, CVPR2016.

**Engelmann2017** Engelmann, F., Kontogianni, T., Hermans, A. & Leibe, B. Exploring spatial context for 3d semantic segmentation of point clouds. CVPR, DRMS Workshop, 2017.

Hackel2017i Timo Hackel and N. Savinov and L. Ladicky and Jan D. Wegner and K. Schindler and M. Pollefeys, SEMANTIC3D.NET: A new large-scale point cloud classification benchmark, ISPRS Annals,2017

Armeni2016 Iro Armeni and Ozan Sener and Amir R. Zamir and Helen Jiang and Ioannis Brilakis and Martin Fischer and Silvio Savarese, 3D Semantic Parsing of Large-Scale Indoor Spaces, CVPR, 2016

Demantke2011 Demantke, J., Mallet, C., David, N. & Vallet, B. Dimensionality based scale selection in 3D lidar point clouds. ISPRS Archives, 2011.

Weinmann2015 Weinmann, M., Jutzi, B., Hinz, S. & Mallet, C., Semantic point cloud interpretation based on optimal neighborhoods, relevant features and efficient classifiers. ISPRS, 2015.

Landrieu2017a Landrieu, L., Raguet, H., Vallet, B., Mallet, C., & Weinmann, M. A structured regularization framework for spatially smoothing semantic labelings of 3D point clouds. ISPRS, 2017.

**Boulch2017** Boulch, Alexandre, Le Saux, Bertrand, and Audebert, Nicolas, Unstructured Point Cloud Semantic Labeling Using Deep Segmentation Networks, 3DOR, 2017.

Wu2015 Wu, Z., Song, S. Khosla, A., Yu, F., Zhang, L., Tang, X., & Xiao, J. 3D shapenets: A deep representation for volumetric shapes. CVPR, 2015.

**Riegler2017** Riegler, G., Osman Ulusoy, A., & Geiger, A. Octnet: Learning deep 3d representations at high resolutions, CVPR, 2017.

Tchapmi2017 Tchapmi, L., Choy, C., Armeni, I., Gwak, J. & Savarese, S., Segcloud: Semantic segmentation of 3d point clouds. 3DV, 2017.

Jampani2018, Jampani Su, H., , V. Sun, D., Maji, S., Kalogerakis, E., Yang, M. H., & Kautz, J., Splatnet: Sparse lattice networks for point cloud processing. CVPR2018.

Tatarchenko2018 Tatarchenko, M., Park, J., Koltun, V., & Zhou, Q. Y. Tangent Convolutions for Dense Prediction in 3D. CVPR, 2018

**Li2018** Li, Y., Bu, R., Sun, M., Wu, W., Di, X., & Chen, B. PointCNN: Convolution On  $\chi$ -Transformed Points. NeurIPS, 2018.

**Qi2017** Qi, X., Liao, R., Jia, J., Fidler, S., & Urtasun, R. 3D Graph Neural Networks for RGBD Semantic Segmentation. In CVPR, 2017.

Simonovsky2017 Simonovsky, M., & Komodakis, N. Dynamic edge-conditioned filters in convolutional neural networks on graphs. CVPR, 2017.

**Qi et. al.2017b** Qi, C. R., Yi, L., Su, H., & Guibas, L. J. (2017). Pointnet++: Deep hierarchical feature learning on point sets in a metric space. In Advances in Neural Information Processing Systems (pp. 5099-5108).

Zhu2016 Zhu, Z., Wang, X., Bai, S., Yao, C., & Bai, X.. Deep learning representation using autoencoder for 3D shape retrieval. Neurocomputing, 2016.

Groueix2018 Groueix, T., Fisher, M., Kim, V. G., Russell, B. C., & Aubry, M. (2018). A papier-mâché approach to learning 3d surface generation. CVPR, 2018.

**Boulch2019** Boulch, A. (2019). Generalizing discrete convolutions for unstructured point clouds. arXiv:1904.02375.

Hormann2002 Hormann, K., & Reimers, M. (2002). Triangulating point clouds with spherical topology. Curve and Surface Design.

Saito2019 Saito, S., Huang, Z., Natsume, R., Morishima, S., Kanazawa, A., & Li, H. (2019). Pifu: Pixel-aligned implicit function for high-resolution clothed human digitization. CVPR.