

Classification d'objets urbains à partir de données LiDAR 3D terrestre par Deep-Learning

Younes ZEGAOU ¹²

Marc CHAUMONT ²³

Gérard SUBSOL ²

Philippe BORIANNE ⁴

Mustapha DERRAS ¹

1 : Berger-Levrault, Toulouse, France

2 : LIRMM, Univ. Montpellier, CNRS, France

3 : Univ. Nîmes, France

4 : AMAP, Univ. Montpellier, CIRAD, CNRS, INRIA, IRD, Montpellier, France



UNIVERSITÉ
DE MONTPELLIER



Plan :

- Présentation du contexte
- Deep-Learning et objets 3D
- Etat de l'art
- Présentation du réseau PointNet
- Expériences
- Discussion et perspectives

Présentation du contexte

- Gestion des agglomérations
- Problème du **recensement et suivi des objets urbains**
- Ex en chiffres (Montpellier) :
 - 282 000 habitants (2015)
 - >1000 km de routes et 160 km de pistes cyclables
 - 2450 rues/avenues -> environ 5 à **8000 panneaux de signalisation**
 - **~240km de caténares** (60 km de tramway)
 - Environ **40 000 arbres**

Présentation du contexte

- Gestion des agglomérations
- Problème du **recensement et suivi des objets urbains**
- Ex en chiffres (Montpellier) :
 - 282 000 habitants (2015)
 - >1000 km de routes et 160 km de pistes cyclables
 - 2450 rues/avenues -> environ 5 à **8000 panneaux de signalisation**
 - **~240km de caténares** (60 km de tramway)
 - Environ **40 000 arbres**

Comment automatiser les processus de recensement et de suivi des objets urbains?

Présentation du contexte

- Gestion des agglomérations
- Problème du **recensement et suivi des objets urbains**
- Ex en chiffres (Montpellier) :
 - 282 000 habitants (2015)
 - >1000 km de routes et 160 km de pistes cyclables
 - 2450 rues/avenues -> environ 5 à **8000 panneaux de signalisation**
 - **~240km de caténares** (60 km de tramway)
 - Environ **40 000 arbres**

Comment automatiser les processus de recensement et de suivi des objets urbains?

→ Utilisation de données 3D prises au niveau du sol

Données 3D

- Utilisation de dispositif LiDAR (Light Detection And Ranging) géolocalisé au niveau du sol
- Acquisition dynamique avec dispositif transporté (sac à dos, voiture...)
- Production de données :
 - nuages de points 3D (x, y, z)
 - images couleurs
 - en grande quantité
- Problèmes : taille des données, occultations.



LiDAR à balayage Sick

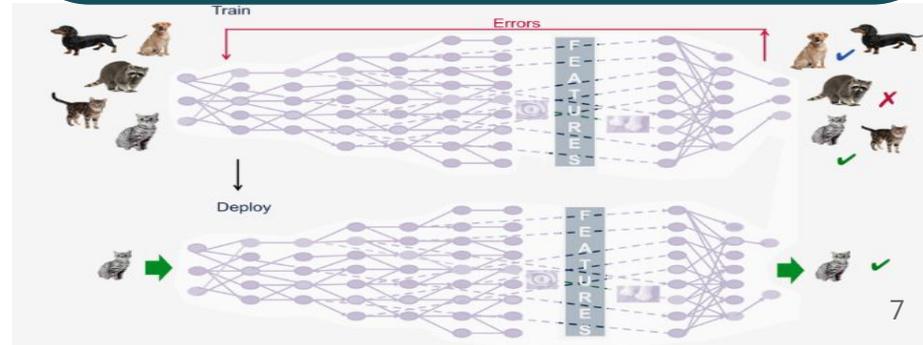
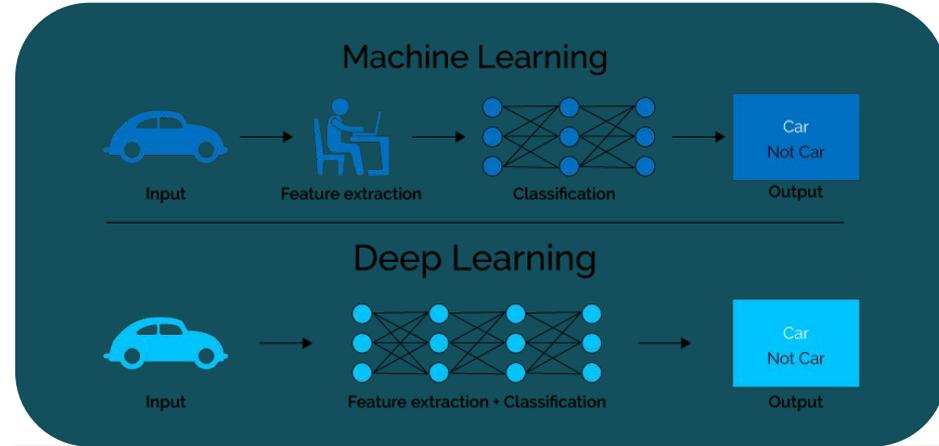


sac à dos Leica



Méthode par deep-learning

- Apprentissage supervisé
- Réseau neuronal convolutif (CNN)
- Descente de gradient par rétropropagation
- En développement permanent



Généralisation aux nuages de points

- Un nuage de points est uniquement une liste de sommets (X, Y, Z) avec éventuellement des infos supplémentaires tels que la couleur RGB.
- Données non ordonnées contrairement aux images :
 - Pas de voisinage topologique
 - Aucun ordre des points de la liste
- Les convolutions ne peuvent pas être appliquées en l'état
- Problème pour la réduction de l'échantillonnage : pas de "strided convolutions"

Généralisation aux nuages de points

- Un nuage de points est uniquement une liste de sommets (X, Y, Z) avec éventuellement des infos supplémentaires tels que la couleur RGB.
- Données non ordonnées contrairement aux images :
 - Pas de voisinage topologique
 - Aucun ordre des points de la liste
- Les convolutions ne peuvent pas être appliquées en l'état
- Problème pour la réduction de l'échantillonnage : pas de "strided convolutions"

Le passage aux nuages de points est un problème non trivial.

Localisation, détection et reconnaissance



Détection :



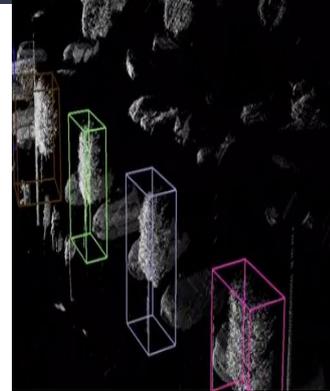
Présence d'un arbre ?
Oui/Non



Classification :



Classe de l'objet ?
Arbre/Poteau/Voiture...



Localisation :

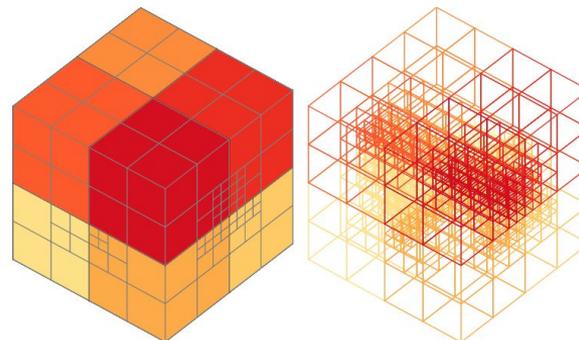
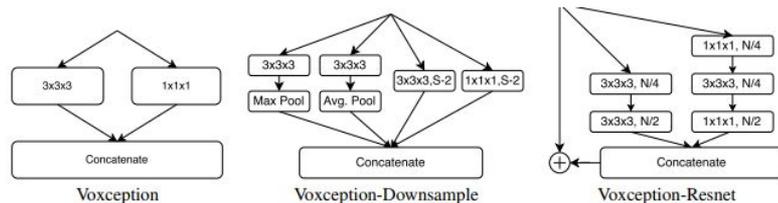


Où sont les objets urbains ?
Boîte englobante 3D + Classe 10

Etat de l'art classification de nuage de points

Voxelisation

- Voxelisation du nuage de points
- Basé sur architecture classique de traitement d'images : ResNet, VGG...
- Taille mémoire de la carte graphique, nature clairsemée des données



VoxNet: A 3D Convolutional Neural Network for Real-Time Object Recognition

D. Maturana, S. Scherer (IROS 2015)

OctNet: Learning Deep 3D Representations at High Resolutions

G. Riegler, A. Osman, A. Geiger (CVPR 2017)

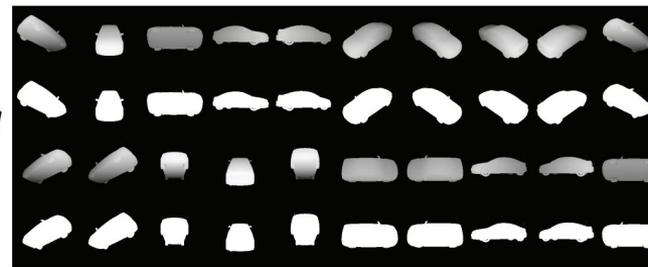
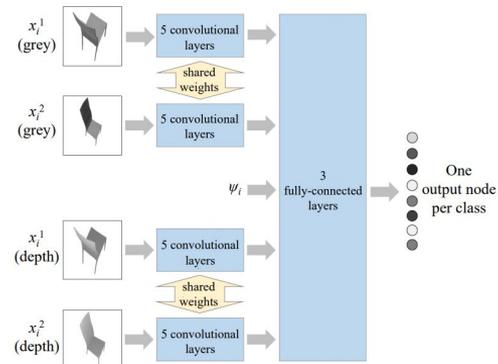
Generative and Discriminative Voxel Modeling with Convolutional Neural Networks

A. Brock, T. Lim, J.M. Ritchie, N. Weston (NIPS-WS 2016)

Etat de l'art classification de nuage de points

Multi-Vues

- Caméra virtuelle avec plusieurs points de vues différents.
- Pour chaque point de vue une image est générée :
 - image couleur/niveaux de gris
 - carte de profondeur
 - silhouette
- Choix des angles de vues
- Fonctionne bien sur les maillages mais peu adapté aux nuages de points (problème de densité)



Volumetric and Multi-View CNNs for Object Classification on 3D Data

C. R. Qi, H. Su, M. Niessner, A. Dai, M. Yan, L. J. Guibas (CVPR 2016)

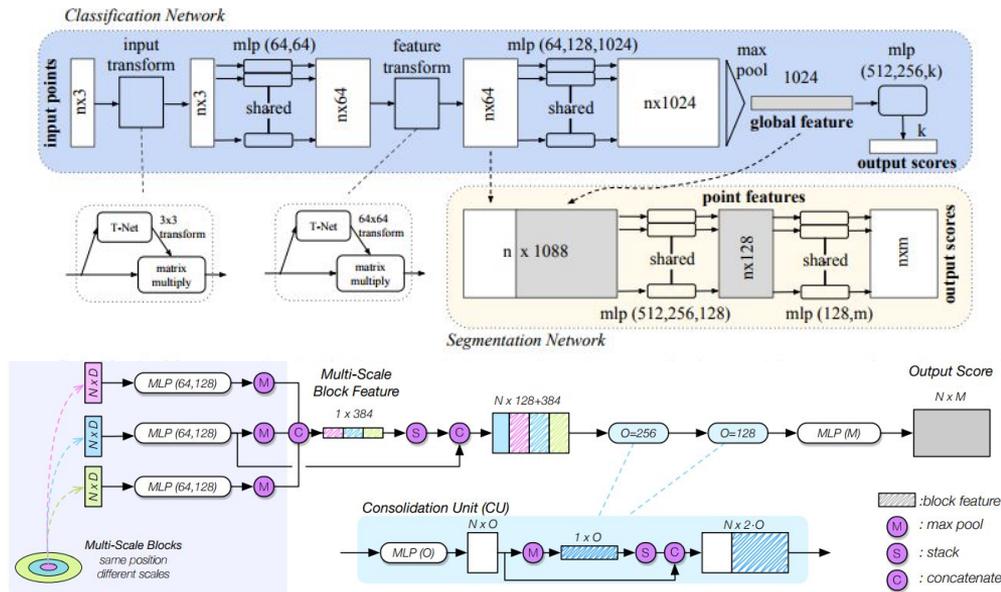
Pairwise Decomposition of Image Sequences for Active Multi-View Recognition

E. Johns, S. Leutenegger, A. J. Davison (CVPR 2016)

Etat de l'art classification de nuage de points

Coordonnées des points

- Entraînement sur nuages de points
- Apprentissage d'une transformation matricielle (pas de repère de référence)
- Invariant à l'ordre des points :
 - extraction de traits à partir des points
 - calcul du maximum dans l'espace des traits



PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation

C. R. Qi, H. Su, K. Mo, L. J. Guibas (CVPR 2017)

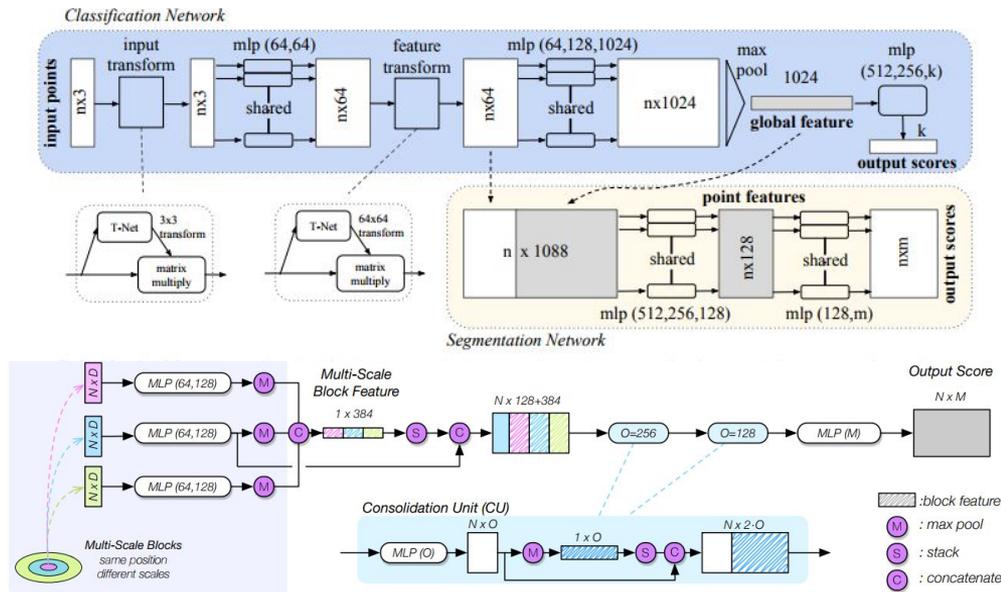
Exploring Spatial Context for 3D Semantic Segmentation of Point Clouds

F. Engelmann, T. Kontogianni, A. Hermans, B. Leibe (ICCV workshop 2017) 13

Etat de l'art classification de nuage de points

Coordonnées des points

- Entraînement sur nuages de points
- Apprentissage d'une transformation matricielle (pas de repère de référence)
- Invariant à l'ordre des points :
 - extraction de traits à partir des points
 - calcul du maximum dans l'espace des traits



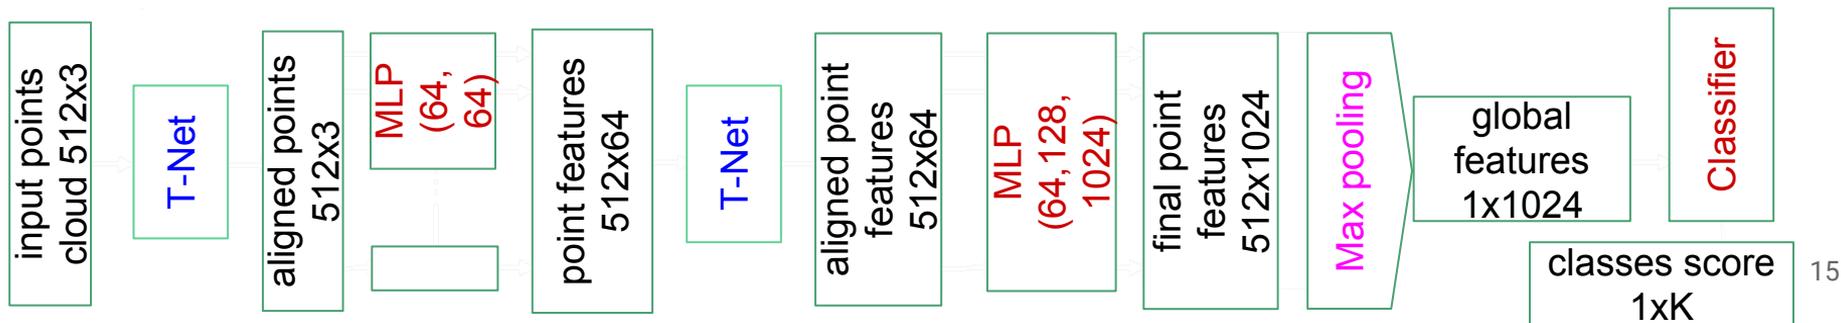
PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation

C. R. Qi, H. Su, K. Mo, L. J. Guibas CVPR 2017

Exploring Spatial Context for 3D Semantic Segmentation of Point Clouds
F. Engelmann, T. Kontogianni, A. Hermans, B. Leibe (ICCV workshop 2017) 14

Réseau PointNet

- N'utilise pas de structure de données intermédiaire
- Très bonnes performances malgré le faible nombre de couches
- Le nuage de point est pris en entrée par le réseau
- T-Net pour la normalisation des systèmes de coordonnées différents
- Implémentation existante sous Tensorflow : <https://github.com/charlesq34/pointnet/>

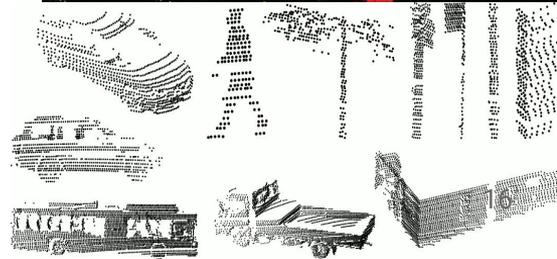
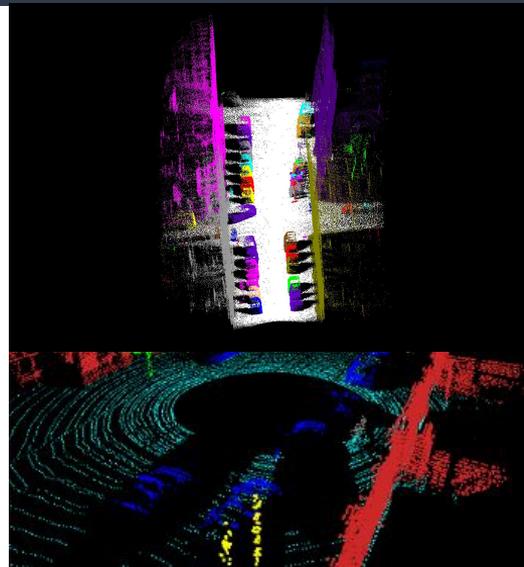


Collecte de données 3D

Pas de bases de données de référence en 3D.

Bases publiques de nuage de points d'objets urbains :

- Paris rue Madame dataset : <http://cmm.ensmp.fr/~serna/rueMadameDataset.html>
- Kevin Lai dataset : <https://sites.google.com/site/kevinlai726/datasets>
- Sydney urban dataset : <http://www-personal.acfr.usyd.edu.au/a.quadros/objects4.html>
- **Mise en ligne de notre base de données :**
www.lirmm.fr/~zegaoui



Collecte de données 3D

Acquisition avec sac à dos Leica

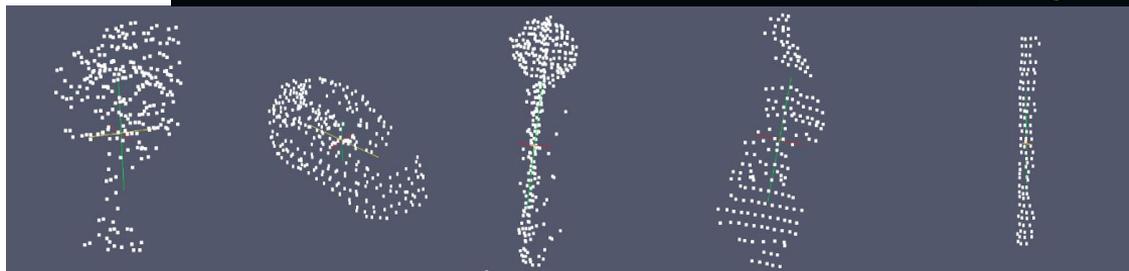
- Quelques chiffres :
 - **27 millions de points** (x, y, z) pour 200 mètres aller retour
 - infos couleurs sur les points (RGB)
 - multitude de fichiers : photos des caméras, coordonnées GPS du trajet...
 - temps de traitement, synchronisation des données, 15 min
 - taille totale du dossier : 9.17 Go
 - taille du nuage de points : 900 Mo



Classification d'objets urbains

Tests de classification de nuages de points :

- Un nuage de point = un objet urbain
- Utilisation du réseau PointNet
- Sous échantillonnage à 512 points
- Objets urbains répartis en 5 classes :
 - Arbre
 - Voiture
 - Panneau/feu de signalisation
 - Poteau
 - Personne



arbre

voiture

panneau

personne

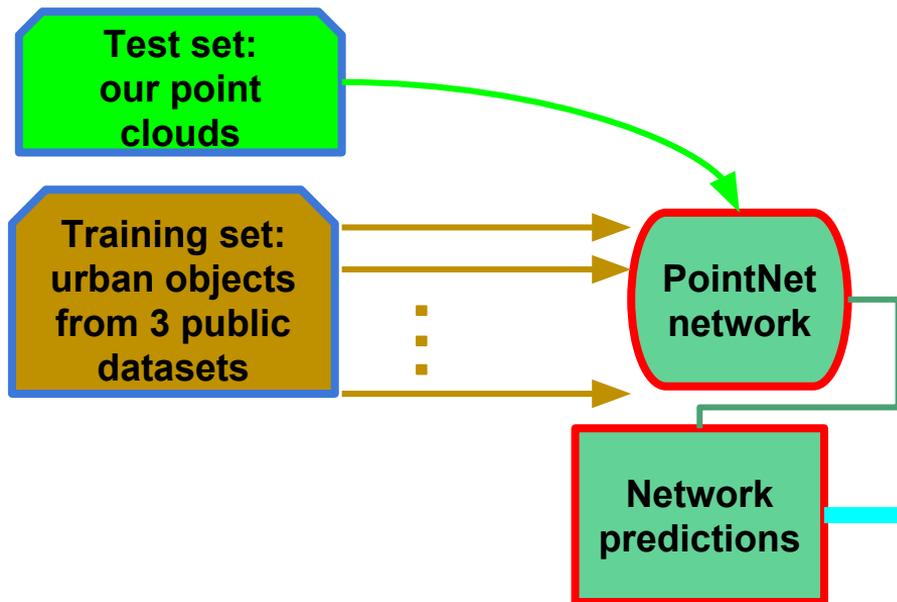
poteau

Expérience de classification :

Expérience témoin

- Entraînement sur les données publiques (727 objets)
- Evaluation de la performance du réseau sur les données Leica (174 objets)

		Ground truth				
		<i>tree</i> (75)	<i>car</i> (39)	<i>traffic sign/light</i> (8)	<i>pole</i> (23)	<i>person</i> (15)
Classification	"tree"	69	2	0	8	0
	"car"	1	33	0	0	0
	"traffic sign/light"	4	0	4	12	2
	"pole"	0	0	3	1	0
	"person"	1	0	1	0	12
	"building"	0	0	0	2	0
	"noise"	0	4	0	0	1
F measure		0.896	0.904	0.267	0.074	0.828



Expérience de classification :

Plus grande base d'apprentissage

- Utilisation d'une base de données supplémentaire : <http://npm3d.fr/paris-lille-3d>
- Nouvelle base d'apprentissage : 1668 objets

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	70	0	0	2	1
	" <i>voiture</i> "	2	39	0	0	1
	" <i>signalisation</i> "	2	0	7	10	2
	" <i>poteau</i> "	0	0	1	11	0
	" <i>piéton</i> "	0	0	1	0	11
	" <i>bâtiment</i> "	1	0	0	0	0
	" <i>bruit</i> "	0	0	0	0	0
F mesure		0.946	1.000	0.467	0.629	0.815

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Plus grande base d'apprentissage

- Conclusion : Augmenter la taille de la base d'apprentissage permet d'augmenter significativement les performances du réseau.

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	70	0	0	2	1
	" <i>voiture</i> "	2	39	0	0	1
	" <i>signalisation</i> "	2	0	7	10	2
	" <i>poteau</i> "	0	0	1	11	0
	" <i>piéton</i> "	0	0	1	0	11
	" <i>bâtiment</i> "	1	0	0	0	0
	" <i>bruit</i> "	0	0	0	0	0
F mesure		0.946	1.000	0.467	0.629	0.815

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Fusion de classes

- Fusion des classes signalisation et poteau afin d'obtenir une seule classe TSLP
- Nouvelle base d'apprentissage : 6 classes au lieu de 7

		Vérité terrain (annotations)			
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>TSLP(31)</i>	<i>piéton (15)</i>
Classification	<i>"arbre"</i>	69	3	3	0
	<i>"voiture"</i>	1	27	0	0
	<i>"TSLP"</i>	2	0	28	5
	<i>"piéton"</i>	0	0	0	9
	<i>"bâtiment"</i>	1	0	0	0
	<i>"bruit"</i>	2	9	0	1
F mesure		0.920	0.806	0.849	0.750

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	<i>"arbre"</i>	69	2	0	8	0
	<i>"voiture"</i>	1	33	0	0	0
	<i>"signalisation"</i>	4	0	4	12	2
	<i>"poteau"</i>	0	0	3	1	0
	<i>"piéton"</i>	1	0	1	0	12
	<i>"bâtiment"</i>	0	0	0	2	0
	<i>"bruit"</i>	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Fusion de classes

- Conclusion : Le réseau a tendance à confondre les classes poteau et signalisation qui sont proches géométriquement.

		Vérité terrain (annotations)			
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>TSLP(31)</i>	<i>piéton (15)</i>
Classification	<i>"arbre"</i>	69	3	3	0
	<i>"voiture"</i>	1	27	0	0
	<i>"TSLP"</i>	2	0	28	5
	<i>"piéton"</i>	0	0	0	9
	<i>"bâtiment"</i>	1	0	0	0
	<i>"bruit"</i>	2	9	0	1
F mesure		0.920	0.806	0.849	0.750

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	<i>"arbre"</i>	69	2	0	8	0
	<i>"voiture"</i>	1	33	0	0	0
	<i>"signalisation"</i>	4	0	4	12	2
	<i>"poteau"</i>	0	0	3	1	0
	<i>"piéton"</i>	1	0	1	0	12
	<i>"bâtiment"</i>	0	0	0	2	0
	<i>"bruit"</i>	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Nombre de points

- Sous échantillonnage à 2048 points au lieu de 512
- Augmentation de la taille des objets de la base d'apprentissage

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	<i>"arbre"</i>	72	3	0	4	0
	<i>"voiture"</i>	0	31	0	0	0
	<i>"signalisation"</i>	1	0	5	10	2
	<i>"poteau"</i>	0	0	1	1	0
	<i>"piéton"</i>	2	0	2	0	13
	<i>"bâtiment"</i>	0	4	0	2	0
	<i>"bruit"</i>	0	1	0	6	0
F mesure		0.935	0.886	0.385	0.080	0.813

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	<i>"arbre"</i>	69	2	0	8	0
	<i>"voiture"</i>	1	33	0	0	0
	<i>"signalisation"</i>	4	0	4	12	2
	<i>"poteau"</i>	0	0	3	1	0
	<i>"piéton"</i>	1	0	1	0	12
	<i>"bâtiment"</i>	0	0	0	2	0
	<i>"bruit"</i>	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Nombre de points

- Conclusion : Le réseau possède une certaine robustesse par rapport au nombre de points des objets.

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	72	3	0	4	0
	" <i>voiture</i> "	0	31	0	0	0
	" <i>signalisation</i> "	1	0	5	10	2
	" <i>poteau</i> "	0	0	1	1	0
	" <i>piéton</i> "	2	0	2	0	13
	" <i>bâtiment</i> "	0	4	0	2	0
	" <i>bruit</i> "	0	1	0	6	0
F mesure		0.935	0.886	0.385	0.080	0.813

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Invariance aux rotations selon l'axe X

- Applications de rotations aléatoires selon un axe à la fois
- Trois bases d'apprentissage pour chaque axe de rotation.

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	63	1	0	2	0
	" <i>voiture</i> "	1	36	0	0	0
	" <i>signalisation</i> "	2	0	8	19	13
	" <i>poteau</i> "	0	0	0	0	0
	" <i>piéton</i> "	1	0	0	0	0
	" <i>bâtiment</i> "	4	0	0	2	0
	" <i>bruit</i> "	4	2	0	0	2
F mesure		0.894	0.947	0.314	0.000	0.000

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Invariance aux rotations selon l'axe Y

- Applications de rotations aléatoires selon un axe à la fois
- Trois bases d'apprentissage pour chaque axe de rotation.

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	5	0	6	0
	" <i>voiture</i> "	1	31	0	0	0
	" <i>signalisation</i> "	2	0	6	14	5
	" <i>poteau</i> "	0	0	1	2	0
	" <i>piéton</i> "	2	0	1	0	9
	" <i>bâtiment</i> "	1	0	0	1	0
	" <i>bruit</i> "	0	3	0	0	1
F mesure		0.890	0.873	0.343	0.149	0.667

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Invariance aux rotations selon l'axe Z

- Applications de rotations aléatoires selon un axe à la fois
- Trois bases d'apprentissage pour chaque axe de rotation.

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	13	0	7	0
	" <i>voiture</i> "	1	23	0	0	0
	" <i>signalisation</i> "	4	0	7	11	4
	" <i>poteau</i> "	0	0	1	4	0
	" <i>piéton</i> "	0	0	0	0	10
	" <i>bâtiment</i> "	1	1	0	1	0
	" <i>bruit</i> "	0	2	0	0	1
F mesure		0.842	0.730	0.412	0.286	0.800

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Invariance aux rotations

- Conclusion : Le réseau n'est pas invariant à la rotation des objets. Il serait intéressant d'introduire cette notion pour des petites rotations sur l'axe horizontal, par exemple pour le cas des voitures sur une pente.

Expérience de classification :

Augmentation virtuelle de la base. $K = 5$

- Simulation d'occultations par découpe des nuages de points selon k plans générés aléatoirement
- Bases d'apprentissage pour chaque valeur de k

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	58	2	0	4	0
	" <i>voiture</i> "	3	34	0	0	0
	" <i>signalisation</i> "	1	0	4	18	2
	" <i>poteau</i> "	0	0	1	1	0
	" <i>piéton</i> "	0	0	3	0	10
	" <i>bâtiment</i> "	6	3	0	0	3
	" <i>bruit</i> "	7	0	0	0	0
F mesure		0.835	0.895	0.242	0.080	0.714

Témoïn :		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Augmentation virtuelle de la base. $K = 10$

- Simulation d'occultations par découpe des nuages de points selon k plans générés aléatoirement
- Bases d'apprentissage pour chaque valeur de k

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	45	1	1	2	3
	" <i>voiture</i> "	0	12	0	1	1
	" <i>signalisation</i> "	0	0	5	14	0
	" <i>poteau</i> "	0	0	0	1	0
	" <i>piéton</i> "	0	0	2	0	8
	" <i>bâtiment</i> "	1	0	0	1	1
	" <i>bruit</i> "	29	26	0	4	2
F mesure		0.709	0.453	0.370	0.083	0.640

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Augmentation virtuelle de la base. $K = 50$

- Simulation d'occultations par découpe des nuages de points selon k plans générés aléatoirement
- Bases d'apprentissage pour chaque valeur de k

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	66	7	0	1	2
	" <i>voiture</i> "	0	12	0	0	1
	" <i>signalisation</i> "	1	0	6	16	0
	" <i>poteau</i> "	0	0	0	1	0
	" <i>piéton</i> "	0	0	2	0	10
	" <i>bâtiment</i> "	1	0	0	0	2
	" <i>bruit</i> "	7	20	0	5	0
F mesure		0.874	0.462	0.387	0.083	0.740

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Expérience de classification :

Augmentation virtuelle de la base. K = 50

- Conclusion : L'augmentation virtuelle de la base ne permet pas d'augmenter les performances du réseau.

		Vérité terrain (annotations)				
		<i>abre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	66	7	0	1	2
	" <i>voiture</i> "	0	12	0	0	1
	" <i>signalisation</i> "	1	0	6	16	0
	" <i>poteau</i> "	0	0	0	1	0
	" <i>piéton</i> "	0	0	2	0	10
	" <i>bâtiment</i> "	1	0	0	0	2
	" <i>bruit</i> "	7	20	0	5	0
F mesure		0.874	0.462	0.387	0.083	0.740

Témoin :

		Vérité terrain (annotations)				
		<i>arbre (75)</i>	<i>voiture (39)</i>	<i>signalisation (8)</i>	<i>poteau (23)</i>	<i>piéton (15)</i>
Classification	" <i>arbre</i> "	69	2	0	8	0
	" <i>voiture</i> "	1	33	0	0	0
	" <i>signalisation</i> "	4	0	4	12	2
	" <i>poteau</i> "	0	0	3	1	0
	" <i>piéton</i> "	1	0	1	0	12
	" <i>bâtiment</i> "	0	0	0	2	0
	" <i>bruit</i> "	0	4	0	0	1
F mesure		0.896	0.904	0.267	0.074	0.828

Perspectives

- Utiliser des objets 3D synthétisés simples pour l'apprentissage comme des poteaux ou des générateurs d'arbres.
- Réaliser des acquisitions LiDAR supplémentaires afin d'augmenter la taille de l'ensemble d'apprentissage.
- Passer de la classification à la localisation d'objets urbains dans des grandes scènes 3D.

Fast and Furious: Real Time End-to-End 3D Detection, Tracking and Motion Forecasting with a Single Convolutional Net

W. Luo, B. Yang, R. Urtasun (CVPR 2018)

Large-scale Point Cloud Semantic Segmentation with Superpoint Graphs

L. Landrieu, M. Simonovsky (CVPR 2018)