



# Évaluation des apports de l'apprentissage profond au sein d'un service dédié à la numérisation du patrimoine

■ Maxime MÉRIZETTE

*Les scanners laser terrestres permettent d'acquérir beaucoup de données tout en présentant une rapidité et une facilité d'acquisition. Mais ceci est terni par le manque d'automatisation des traitements de nuages de points. La segmentation de nuage de points, consistant à extraire les éléments constitutifs d'un nuage, pâtit notamment de ce manque. Ce travail de fin d'études d'ingénieur, mené chez Quarta, se concentre sur les apports de l'apprentissage profond pour la réalisation d'une segmentation de nuage de points. Elle se propose de lister les différentes méthodes d'apprentissage profond permettant de travailler sur les nuages de points et teste différents algorithmes permettant de traiter les nuages de points volumineux.*

## ■ MOTS-CLÉS

Apprentissage profond, nuage de points, segmentation, jeux de données, 3D, BIM, scanner laser terrestre.

## Introduction

Au fil des années, les technologies d'acquisition de données tridimensionnelles se sont développées afin de permettre une rapidité et une simplicité d'acquisition. Mais ceci est terni par le temps de traitement nécessaire pour valoriser cette donnée (sous forme de maquette 3D ou de plan 2D) et par un manque d'automatisation. Aujourd'hui, l'utilisation de ces données tridimensionnelles n'est plus seulement réservée aux professionnels de la géomatique et de l'architecture, mais de plus en plus de corps de métier y ont recours. Ces dernières sont notamment au cœur du développement des véhicules autonomes afin de permettre aux algorithmes et donc aux véhicules de mieux comprendre l'environnement. Bien que les technologies d'acquisition de données tridimensionnelles se démocratisent et s'ouvrent aux non-initiés (BLK360, Apple LiDAR...), les traitements de ces nuages de points sont encore trop peu souvent automatisés et accessibles à ces mêmes non-initiés. La segmentation et la modélisation 3D sont aujourd'hui des tâches réservées à un public plus averti.

L'intelligence artificielle, depuis sa consécration en tant que science en 1956, n'a eu de cesse de se développer et de révolutionner certains domaines scientifiques, mais aussi notre quotidien (la prédiction automatique de texte, les assistants personnels intelligents, la reconnaissance faciale...). L'intelligence artificielle, poussée par les GAFAM (Google, Apple, Facebook, Amazon, Microsoft), les BATX (Baidu, Alibaba, Tencent, Xiaomi) et de nombreux laboratoires, est en pleine évolution et impacte

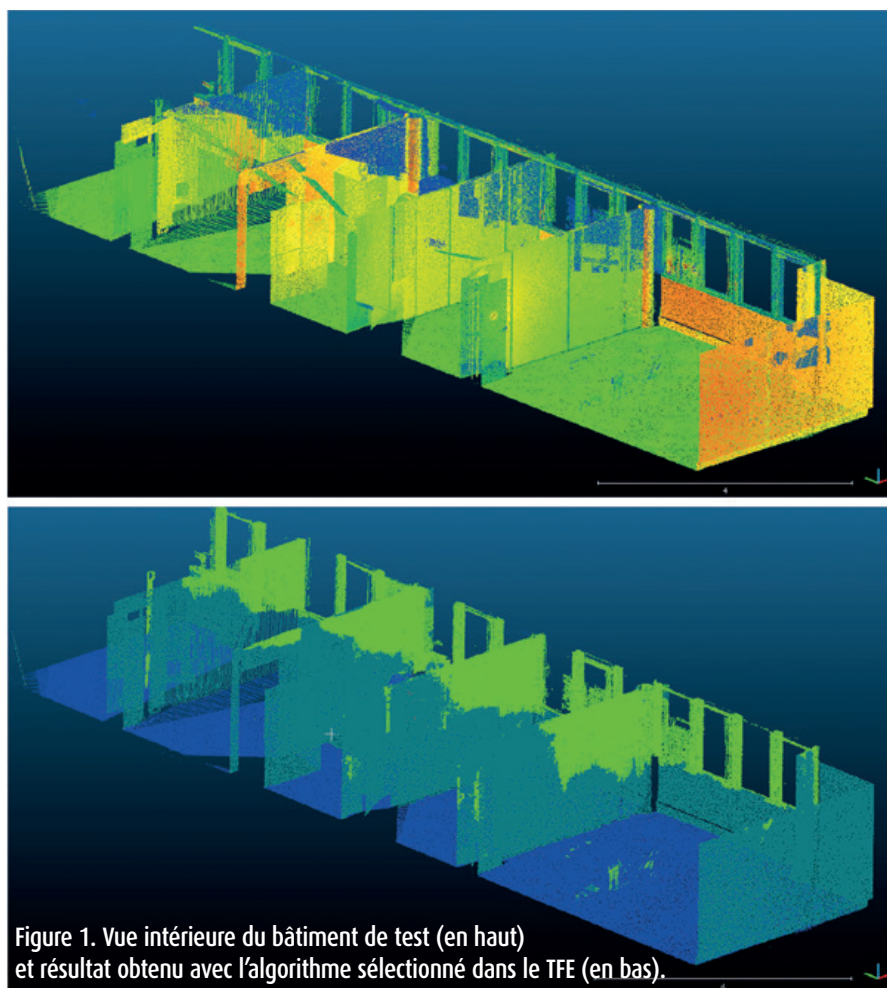


Figure 1. Vue intérieure du bâtiment de test (en haut) et résultat obtenu avec l'algorithme sélectionné dans le TFE (en bas).





de nombreux domaines. L'apprentissage profond a connu un développement fulgurant à partir de 2010 avec notamment des avancées dans le domaine de la vision par ordinateur, la compréhension du langage, la reconnaissance de la parole... Pendant des décennies, l'apprentissage profond était réservé aux personnes avec des connaissances techniques dans le domaine de l'intelligence artificielle. De plus, ces personnes devaient avoir de très bonnes connaissances sur les données qu'elles traitaient pour pouvoir créer des extracteurs de caractéristiques [LECUNY. et al., 2015]. L'apprentissage profond n'est donc pas un domaine de recherche nouveau, mais il se démocratise. En effet, depuis quelques années des outils libres de droits (*TensorFlow*, *PyTorch*, *Caffe*...) ainsi que de nombreux algorithmes préentraînés ont fait leur apparition, permettant de rendre plus accessible l'apprentissage profond. Les professionnels de la numérisation 3D cherchent donc à s'approprier l'apprentissage profond en déterminant les différentes avancées que ce domaine pourrait apporter à leur métier. À défaut d'être portée par le monde de la numérisation 3D, la recherche sur l'apprentissage profond, appliquée aux nuages de points, est poussée par le développement de la voiture autonome.

Ce travail de fin d'études s'est ainsi concentré sur l'évaluation des apports de l'apprentissage profond au sein d'un service dédié à la numérisation du patrimoine.

Pour cela, nous nous sommes intéressés à la segmentation de nuages de points et aux limites des outils existants. Pour ensuite étudier l'apprentissage profond et son application aux nuages de points. Avant de passer aux différents tests et entraînements.

## Segmentation de nuage de points

La segmentation de nuage de points facilite les traitements et la reconstruction 3D de scènes, car elle permet de déterminer les éléments constitutifs d'un nuage de points [POUX F., 2013]. Elle est définie comme "un partage/subdivision de l'ensemble des points 3D en sous-




Figure 2. Différence entre la segmentation sémantique (à gauche) et la segmentation d'instance (à droite) dans le cadre d'une image.

ensembles (sous-nuages de points) homogènes, suivant des critères prédéfinis" [LANDEST. et al., 2011]. L'objectif étant de traiter de la même manière des points appartenant à un même objet. Il existe deux types de segmentation : la segmentation sémantique (qui consiste à regrouper les points par classes) et la segmentation d'instance (qui consiste à regrouper les points par objets). La segmentation d'instance est donc plus difficile, car il faut séparer des objets appartenant à une même classe, c'est pour cela que nous nous sommes focalisés sur la segmentation sémantique lors de ce travail de fin d'études.

Mais les méthodes de segmentation traditionnelles telles que la segmentation par reconnaissance de formes géométriques et la segmentation par croissance de régions présentent des limitations [POUX F., 2013]. La principale limite des techniques actuelles est le réglage des paramètres et leurs impacts sur la qualité de la segmentation. Cette limite rend compliquée l'utilisation de ces méthodes, de ces outils existants pour des non-initiés. Au vu de ces dernières, des algorithmes de segmentation basés sur l'apprentissage profond ont vu le jour avec pour objectif d'obtenir de meilleures performances et de réduire le nombre de paramètres à choisir lors d'une segmentation de nuage de points.

## Apprentissage profond

L'apprentissage profond est un sous-domaine de l'apprentissage automatique (domaine qui concentre les algorithmes pouvant apprendre à partir de données d'entraînement) (cf. figure 3). L'apprentissage profond est basé sur la notion de neurones artificiels inspirés des neurones humains.

L'association de plusieurs couches de neurones permet de créer un réseau de neurones artificiels. Lors de la phase d'apprentissage, un réseau de neurones va réaliser une prédiction que l'on va comparer à la vérité terrain. Afin de tenir compte de cette erreur, les poids internes aux neurones vont être modifiés (c'est ce que l'on appelle la rétropropagation des erreurs). L'objectif de cette phase d'apprentissage est d'obtenir un modèle qui sera utilisé pour prédire de nouvelles données.

Il existe différentes formes d'apprentissage profond comme l'apprentissage supervisé et l'apprentissage non supervisé. Selon Lecun Y. et al. (2015), "la forme la plus commune de l'apprentissage automatique, qu'il soit profond ou non, est l'apprentissage supervisé". Dans cet ouvrage, les auteurs prennent comme exemple un classifieur d'images. En effet, pour entraîner un algorithme à reconnaître des objets, il faut d'abord collecter de nombreuses images et les labelliser. L'apprentissage supervisé nécessite de nombreuses données étiquetées en entrée, ce qui n'est pas le cas de l'apprentissage non supervisé. Selon ces auteurs, cet apprentissage non supervisé est un des défis à résoudre pour le développement de l'apprentissage profond, défi qui reste d'actualité en 2021.




Figure 3. : Lien entre l'intelligence artificielle, l'apprentissage automatique et l'apprentissage profond.



## Nuages de points : structures et défis

Nous pouvons distinguer deux grands désavantages à l'utilisation de données 3D en entrée d'algorithmes d'apprentissage profond, hormis le fait que les nuages de points représentent un volume de données important. Les nuages de points sont irréguliers (c'est-à-dire que certaines régions du nuage peuvent contenir plus de points que d'autres) et ils sont non ordonnés (si on permute les lignes dans le fichier de points le nuage va rester le même).

Pour faire face à ces difficultés, les chercheurs utilisent différentes façons de représenter le nuage de points (cf. figure 4). En effet, un nuage de points (cf. figure 4.1) peut être reprojeté sur des plans pour synthétiser des images (cf. figure 4.2). Il peut aussi être représenté à l'aide de voxels (cf. figure 4.3), d'un ensemble permettant les convolutions (cf. figure 4.4), d'un ensemble non ordonné de points (cf. figure 4.5) ou des graphes (cf. figure 4.6). À ces différentes méthodes, nous pouvons aussi rajouter les approches qui utilisent directement les images. Dans ce cas, les algorithmes segmentent d'abord les images avant de projeter les résultats dans le nuage de points. L'objectif des méthodes utilisant des images étant de tirer parti des performances des réseaux de neurones convolutifs.

Lors de ce travail de fin d'études, nous avons observé que le développement des méthodes basées sur les images pour la segmentation de nuage de points est plus ancien. Les méthodes travaillant sur les nuages de points sont

arrivées plus tardivement (2017). Mais aujourd'hui, ces méthodes sont très présentes dans l'état de l'art et fournissent de bonnes performances.

Les différentes représentations du nuage de points (cf. figure 4) ont amené au développement de différentes méthodes pour segmenter les nuages de points comme la représentation sphérique, la représentation de discrétisation dense, les méthodes permettant l'utilisation de réseaux de neurones récurrents (RNN)... Ces méthodes permettent de segmenter (par apprentissage profond) un nuage de points, mais elles peuvent faire apparaître un certain nombre d'inconvénients comme : un coût élevé en termes de ressources de calculs, une perte d'information, des difficultés à extraire l'interaction mutuelle entre les points...

## Identification des algorithmes et des jeux de données permettant la segmentation de nuages de points

La finalité de ce travail de fin d'études est de prédire, à terme, des nuages de points volumineux relevés par Quarta. Pour cela, nous nous sommes concentrés sur les algorithmes développés dans ce sens lors de l'état de l'art. Il existe plusieurs algorithmes basés sur l'apprentissage profond pour réaliser une segmentation de nuage de points, mais beaucoup d'entre eux sont destinés à des nuages peu volumineux. De cet état de l'art, six algorithmes sont ressortis et nous en avons finalement choisi trois. Ces trois algorithmes utilisent trois façons de représenter le nuage de points : un algorithme est basé

sur des graphes, un autre est basé sur la notion de convolution et un autre utilise le nuage de points en tant qu'ensemble non ordonné.

Dans le cadre de l'apprentissage profond supervisé pour entraîner les algorithmes nous avons besoin de données annotées ou "labellisées". Concernant les nuages de points, l'annotation est un processus qui demande beaucoup de temps afin de classer les points dans différentes catégories. Lors de ce TFE, nous avons listé les jeux de données ouverts permettant d'entraîner des algorithmes de segmentation de nuage de points. Il en existe plusieurs, contenant un nombre différent de points (allant d'un million à un milliard de points) et relevés de différentes manières. Mais beaucoup d'entre eux concernent l'extérieur des bâtiments (arbres, routes, voitures...), ce qui est en accord avec le développement de la voiture autonome. Nous avons finalement sélectionné un jeu de données conforme aux besoins du service BIM de Quarta.

## Tests et entraînements

Les trois algorithmes que nous avons choisis disposent de modèles préentraînés sur le jeu de données ouvert. C'est-à-dire que les auteurs des algorithmes ont entraîné ces derniers sur le jeu de données ouvert et ont ensuite mis leurs modèles à disposition. Nous avons donc lancé les modèles préentraînés sur le jeu de données afin d'essayer de retrouver les performances des auteurs et ainsi valider ou non notre installation. À l'issue de ce test et au vu des résultats, deux algorithmes sur les trois ont été conservés.




Figure 4. Présentation de différentes structures permettant l'apprentissage profond sur les nuages de points.




Figure 5. Vue d'une pièce du jeu de données ouvert sélectionné lors de ce TFE.





Cette phase d'utilisation des modèles préentraînés nous a aussi permis d'avoir une notion du temps de traitement nécessaire pour réaliser une segmentation. Tout d'abord un temps de préparation (processus automatisé) de la donnée est nécessaire et celui-ci ne dépasse pas trente minutes pour les trois algorithmes que nous avons testés. Le temps de segmentation, quant à lui, va varier en fonction des algorithmes, mais aussi de l'infrastructure informatique. Mais il ne dépassera pas quelques heures sur un ordinateur dimensionné pour un service de modélisation du patrimoine.

Une fois l'installation validée, nous avons testé ces modèles préentraînés sur un nuage de points relevé par Quarta. Pour cela nous avons décidé d'utiliser un nuage de points relevé par Quarta à Rennes et composé de deux bâtiments. Un des bâtiments de ce nuage de points a été choisi comme bâtiment de test et le deuxième bâtiment a été utilisé durant la phase d'entraînement.

Nous avons choisi ce nuage de points car l'architecture de ce bâtiment est similaire à d'autres bâtiments que Quarta pourra relever dans le futur. En effet, les deux bâtiments sont rectangulaires et sans formes complexes. Ce nuage de points a été acquis début 2021 par un levé RTC360 (sur une surface de 5 000 m<sup>2</sup> de bureaux). Dans un souci de performance, nous avons sous-échantillonné ce nuage à un point tous les centimètres.

Lors de cette étape, nous avons pu observer que ces modèles préentraînés permettent d'obtenir des résultats corrects sur certaines classes (cf. figure 6). Mais les résultats sont plus mitigés sur d'autres classes (cf. figure 7 à gauche) et nous pouvons noter qu'il y a beaucoup de confusions entre la classe fenêtre

(vert clair) et la classe "non classé" (rouge).

Cette étape de test nous a permis de voir que les modèles préentraînés (mis à disposition par la communauté) ne permettent pas en l'état de segmenter efficacement les nuages de points relevés par Quarta. À l'issue de cette étape, nous avons donc décidé d'augmenter légèrement la taille de ce jeu de données mis à disposition par la communauté (en "open source") en rajoutant des exemples issus de nuages de points de Quarta.

### Augmentation du jeu de données et entraînement des algorithmes

Avant de rajouter des données à notre jeu de données ouvert, nous avons décidé d'entraîner les deux algorithmes sur le jeu de données ouvert. L'objectif étant de retrouver les performances des modèles préentraînés fournis par les auteurs et ainsi de valider notre processus d'entraînement. Durant cette phase d'entraînement, nous avons pu noter qu'un certain nombre de paramètres des algorithmes peuvent être à modifier pour s'adapter à l'infrastructure informa-

tique. Cette phase d'entraînement nous a permis d'estimer le temps nécessaire afin d'obtenir un modèle de segmentation des nuages de points. Ce temps d'entraînement est impacté par le fait de travailler sur processeur ou sur carte graphique, par les algorithmes utilisés (et donc par la façon de représenter le nuage de points), mais aussi par le nombre d'époques d'entraînement choisi. Ce temps d'entraînement peut aller d'une dizaine d'heures à quelques jours sur carte graphique (le temps nécessaire sur processeur étant plus long). Cette étape nous a permis d'éliminer un algorithme (au vu du temps d'entraînement et de ses performances).

Afin de tester l'impact de l'entraînement et de l'adapter aux données de Quarta nous avons décidé de rajouter des données au jeu de données ouvert. Pour cela, nous avons segmenté manuellement un bâtiment d'un nuage de points (le deuxième bâtiment du nuage de Quarta relevé à Rennes). L'objectif étant de fournir à l'algorithme des exemples similaires à ce qu'il aurait à prédire lors de la phase de test.

Nous avons ensuite entraîné l'algorithme restant sur notre nouveau jeu de données. Comme nous avons augmenté très légèrement le jeu de données, le temps d'entraînement n'a pas été considérablement modifié et est jugé parfaitement acceptable pour les contraintes opérationnelles d'un cabinet de géomètre-expert. Cet entraînement nous a permis d'obtenir un modèle. Une fois le modèle obtenu, nous sommes passés à la phase de prédiction du bâtiment de test. Là encore, le temps de






Figure 7. Vue de face du bâtiment de test avec les sols et plafonds (à gauche) et vue de dessus avec les murs (à droite). Résultats obtenus avec l'algorithme sélectionné lors de ce TFE.



Effet de  
l'augmentation




Figure 6. Vue intérieure d'une façade du bâtiment. Résultats obtenus avec l'algorithme sélectionné lors de ce TFE : avec le modèle préentraîné (à gauche) et après entraînement sur le jeu de données augmenté (à droite). (Fenêtre : vert clair, mur : vert foncé, non classé : rouge)



prédiction est similaire à celui concernant le jeu de données ouvert seul. À l'issue de cette segmentation, nous avons pu observer une amélioration de la prédiction de certaines classes et notamment des fenêtres (cf. figure 7 à droite).

Certaines classes restent encore difficiles à prédire pour l'algorithme et c'est notamment le cas des chaises (cf. figure 8). Sur la figure 8, une chaise est en rouge (non classé) alors qu'elle devrait être en jaune. De plus, nous avons pu noter des confusions entre certains objets, avec comme exemple les bureaux et les sols (cf. figure 8). De même, les escaliers qui ne sont pas présents dans le jeu de données d'apprentissage sont segmentés en tant que sols, meubles et non classés.

À l'issue de cette segmentation, nous avons pu noter que cet entraînement n'est pas parfait et qu'il reste encore de nombreuses confusions dues notamment à un manque en entrée de données annotées. De plus, nous avons choisi d'avoir un nuage de test en entrée sans formes trop complexes, mais celui-ci reste toutefois plus élaboré que les nuages issus du jeu de données ouvert.

Les différents entraînements réalisés démontrent bien l'importance du jeu de données fourni en entrée dans le cadre de l'apprentissage profond supervisé. Nous pouvons changer différents paramètres pour les algorithmes (nombre d'époques d'entraînement, taille des lots...), tester différents algorithmes,

mais au final la qualité de la segmentation dépend fortement de ce jeu de données.

## Conclusion

La segmentation de nuage de points est une étape essentielle pour la reconstruction 3D de scènes, mais les méthodes traditionnelles présentent des limites. Lors de ce TFE, différentes méthodes permettant de segmenter un nuage de points à l'aide de l'apprentissage profond ont été étudiées avant de choisir trois algorithmes pour les tests. Nous avons pu voir que la principale difficulté pour les algorithmes est de trouver un compromis entre qualité de la segmentation et consommation de ressources informatiques. À l'issue de ces tests, un algorithme fut sélectionné.

L'utilisation d'algorithmes basés sur l'apprentissage profond présente quelques difficultés, mais les performances de ces algorithmes sont supérieures à celles des méthodes traditionnelles. De plus, le processus de segmentation est totalement transparent pour l'utilisateur final : il n'y a plus aucun paramètre à régler lors de la segmentation. Les seuls paramètres à changer le seront pendant la phase d'entraînement (qui peut être réservée à un public plus averti).

Cette notion d'apprentissage automatique reste très spécifique et écartée du monde de la numérisation 3D. Mais, lors de ce TFE, nous avons pu observer que les temps d'entraînement et de prédiction (70 millions de points en cinq minutes) sont intégrables à une chaîne de traitement d'un service dédié à la numérisation du patrimoine et les résultats obtenus montrent l'intérêt de l'apprentissage profond pour la segmentation de nuages de points.

De plus, nous avons vu la nécessité d'utiliser un jeu de données de qualité et représentatif de ce que l'on souhaite segmenter dans le cadre de l'apprentissage supervisé. Or les acteurs de la numérisation du patrimoine disposent d'un nombre important de données brutes (nuages de points, images) et ont donc leurs rôles à jouer dans le domaine de la segmentation de nuages de points par apprentissage profond. ●

## Contact

Maxime MÉRIZETTE  
m.merizette@quarta.fr

## Remerciements

Ce travail de fin d'études a été réalisé au sein du service BIM de Quarta. Ce travail a fait l'objet de nombreux échanges avec mon maître de stage M. GELDOLF Jean-Baptiste que je tiens à remercier pour le temps qu'il m'a accordé et les conseils qu'il m'a donnés.

## Bibliographie

LANDES T., GRUSSENMEYER P., BOULAASSAL H., 2011, *Les principes fondamentaux de la lasergrammétrie terrestre : acquisition, traitement des données et applications*, XYZ : revue de l'Association francophone de topographie, Association Francophone de Topographie, n° 129, pages 25-38

LANDRIEU L., 2020, *Deep Learning pour l'analyse automatique de donnée 3D*, conférence IGN


LECUN Y., BENGIO Y., HINTON G., 2015, *Deep learning*, Nature, 521, pp. 436-444. Disponible sur : <https://doi.org/10.1038/nature14539>, consulté en février-mars 2021

POUX F., 2013, *Vers de nouvelles perspectives lasergramétriques : optimisation et automatisation de la chaîne de production de modèles 3D*, Ecole Supérieure des Géomètres et Topographes, 87 p.

YIN C., TANG J., YUANG T., XU Z., WANG Y., 2021, *Bridging the Gap between Semantic Segmentation and Instance Segmentation*, in IEEE Transactions on Multimedia, doi: 10.1109/TMM.2021.311454, pp. 1-14

## ABSTRACT

*Terrestrial laser scanners enable to acquire huge amount of data quite fast and more and more easily. But this is tarnished by the lack of point cloud processing automation. Point cloud segmentation, which consists of extracting the constituent elements from a point cloud, suffers in particular from this lack. This study conducted by Quarta focuses on the contributions of deep learning for the achievement of a point cloud segmentation. It proposes to list the different deep learning methods developed for point clouds and test different algorithms for processing largest ones.*



**Figure 8.** Vue du bâtiment de test avec un bureau et des chaises. Résultat obtenu avec l'algorithme sélectionné lors de ce TFE entraîné sur le jeu de données augmenté.