

Automatisation du traitement de données "Mobile Mapping" : extraction d'éléments linéaires et ponctuels

■ Loïc ELSHOLZ

L'évolution rapide des technologies 3D et notamment des scanners laser a permis aux différents acteurs de la topographie et du génie civil de se doter d'outils capables d'acquérir des données rapidement et en très grande quantité.

La démocratisation des systèmes "Mobile Mapping", fruits de ces progrès technologiques, entraîne la nécessité de développer des processus de traitement de masse adaptés. Dans ce contexte, nous nous sommes intéressés à l'automatisation du traitement de ce type de données, par le biais de l'extraction d'éléments linéaires et ponctuels, afin d'optimiser les rendements de production et d'améliorer la qualité et l'exhaustivité des livrables. Le présent article expose les différents développements réalisés, ayant trait au traitement d'images, à la photogrammétrie ainsi qu'à l'intelligence artificielle, et plus particulièrement à l'apprentissage profond et aux réseaux de neurones convolutifs.

Contexte et objectifs

En seulement quelques années, les systèmes de type "Mobile Mapping" sont devenus un outil incontournable en matière d'acquisition. Cette forte croissance a amené les sociétés telles que FUTURMAP, jeune entreprise spécialisée dans le traitement de données géographiques, à développer des processus spécifiques adaptés.

Le terme usuel "Mobile Mapping", cartographie mobile ou scanner dynamique en français, se rapporte au procédé de l'acquisition de données géographiques à partir d'un véhicule mobile équipé de différents systèmes de télédétection. Dans notre étude, nous nous sommes principalement intéressés à des systèmes terrestres composés de scanners laser et d'appareils photographiques, ce type d'appareillage étant la source principale des données traitées par la société en vue de la réalisation de plans.

Ces systèmes permettant d'acquérir d'énormes quantités de données en peu

MOTS-CLÉS

Cartographie mobile, traitement d'images, vision par ordinateur, détection d'objets, apprentissage automatique, apprentissage profond, réseaux de neurones convolutifs

de temps (jusqu'à plusieurs centaines de kilomètres de levé en une journée), il est primordial de mettre en œuvre des méthodes toujours plus innovantes, afin de répondre rapidement et à faible coût aux demandes des clients, tout en assurant la qualité du produit final.

Ainsi, le présent article décrit l'étude réalisée au sein de la cellule de Recherche et Développement de la

société, visant à automatiser les procédés de traitement de données de cartographie mobile, par le biais de l'extraction d'éléments linéaires et ponctuels. Nous proposons dès lors plusieurs approches, mettant notamment à profit l'analyse d'images, la photogrammétrie ainsi que l'intelligence artificielle, et plus précisément l'apprentissage profond et les réseaux de neurones convolutifs, afin d'extraire et de dessiner automatiquement une partie des éléments du plan, et d'en optimiser le contrôle.

Extraction et dessin automatiques d'éléments linéaires

Dans la plupart des plans réalisés par la société, la majeure partie du travail réside dans le dessin des éléments linéaires (bordures, bâti, marquage au sol). Ainsi, il peut être particulièrement intéressant pour la production d'obtenir une ébauche des éléments linéaires d'un projet de manière automatique. A cette fin, nous proposons une méthode permettant, à partir de nuages de points issus des systèmes de cartographie mobile, d'extraire et de




Figure 1. Système Mobile Mapping monté sur une voiture (mksurveys.com)




Figure 2. Points appartenant aux bordures et pieds de murs (classe 4)




Figure 3. Points situés entre le sol et 2 m, hors classe 4 (classe 5)

► dessiner automatiquement une partie des éléments linéaires, afin d'obtenir un canevas dans un format DAO (Dessin Assisté par Ordinateur). Le logiciel libre de système d'information géographique SAGA GIS étant déjà utilisé pour la production des ortho-images servant de base aux dessinateurs pour la réalisation des plans, celui-ci a également été retenu pour les traitements d'images nécessaires à l'extraction des linéaires.

■ Extraction des bordures

Dans le cadre des bordures, on utilise tout d'abord les données de classification du nuage, effectuée au préalable selon une routine développée en interne. Cette étape de classification nous permet d'extraire directement la majorité des points appartenant aux catégories recherchées. Ainsi, on isole deux classes dans le nuage : la première correspondant aux bordures et pieds de murs, la deuxième concernant les autres éléments situés entre le sol et une hauteur de 2 m. Il s'agit, dans notre routine de classification spécifique, des classes 4 et 5. Les ensembles de points extraits sont ensuite convertis en grilles (ortho-images). Sur la grille correspondant à la classe 4 (cf. figure 2), on observe distinctement les bordures ainsi que les pieds de murs, mais également d'autres objets indésirables correspondant à tout élément proche de la verticale situé entre le sol et 30 cm de hauteur. Il s'agit par exemple de roues de véhicule, de bas de mobilier urbain, de pieds de panneaux de signalisation, etc. Sur la grille correspondant à la classe 5

(cf. figure 3), les éléments situés entre le sol et une hauteur de 2 m, en dehors des objets appartenant à la classe 4, sont visibles. Il s'agit ici principalement des murs et du bâti, des véhicules, et du mobilier urbain.

Afin d'éliminer les points correspondant aux pieds de murs et aux autres éléments indésirables dans la première grille, et ainsi isoler les bordures, on utilise la deuxième grille en tant que masque. En effet, la deuxième grille (classe 5) contient finalement les murs et le bâti, ainsi que la majorité des autres éléments indésirables décrits précédemment.

Ces éléments proviennent cependant de points du nuage situés à une hauteur plus élevée que ceux de la classe 4, et ne surplombent pas toujours parfaitement

les objets que nous souhaitons masquer (les pieds de murs sont parfois saillants vis-à-vis des murs, par exemple).

On utilise alors un opérateur de morphologie mathématique, la dilatation morphologique, afin d'élargir les objets présents dans la deuxième grille, pour s'assurer d'obtenir un masque permettant d'éliminer les éléments ciblés.

La figure 4 représente la superposition entre les deux grilles, en rouge la première, et en bleu la deuxième après dilatation. Après élimination des pixels ne correspondant pas aux bordures avec notre masque, on applique des procédés de fermeture et d'ouverture morphologiques afin d'obtenir des lignes homogènes, dans le but d'optimiser l'étape de vectorisation. Celle-ci est réalisée via l'algorithme de sque-




Figure 4. Superposition de la classe 4 (en rouge) et de la classe 5 après dilatation morphologique (en bleu)



lettisation de Hilditch [Hilditch, 1969], et on obtient alors un premier modèle vectoriel.

A ce stade, le modèle ayant été vectorisé à partir d'une grille échantillonnée à 5 mm de pixel, celui-ci comporte un sommet tous les 5 mm, et les lignes ont un aspect crénelé étant donné que chaque segment provient de la liaison entre deux pixels de la grille. On utilise donc un procédé de lissage disponible dans SAGA, basé sur la méthode SIA (*Smoothing via Iterative Averaging*).

Le lissage est par ailleurs paramétré de telle sorte à ne pas modifier le modèle de plus d'un centimètre, même dans le cas de courbes importantes. Ensuite, afin de réduire le nombre considérable de sommets, on utilise un processus de simplification vectorielle, en ajustant la tolérance de modification à 5 mm, une fois encore afin de conserver au maximum la précision initiale de position des éléments. On charge ensuite ce modèle dans un logiciel de DAO, afin de le nettoyer automatiquement des éléments indésirables restants, ainsi que de relier au mieux les lignes correspondant vraisemblablement à des bordures identiques. Le modèle ainsi créé contient une très large partie des bordures (~ 90 %) avec des écarts par rapport au nuage de l'ordre de 5 cm dans les cas les plus défavorables (faible densité de points, courbes fortes p. ex.), ainsi que de rares lignes erronées que l'opérateur devra éliminer manuellement, notamment en

présence d'une végétation dense, où la classification des nuages s'avère parfois inexacte. La *figure 5* illustre un exemple de tracé automatique de bordures avec notre méthode.

■ Extraction du marquage au sol

Dans le cadre de projets routiers, il est généralement nécessaire de tracer le marquage au sol (bandes blanches principalement). Cette tâche est particulièrement laborieuse, notamment concernant les autoroutes, dont les levés sont parfois longs de plusieurs dizaines, voire centaines de kilomètres. Afin d'extraire et de dessiner automatiquement ces éléments, nous proposons une méthode s'appuyant à nouveau sur le logiciel SAGA.

Tout d'abord, on extrait du nuage classifié les points appartenant à la route, puis on transforme cet ensemble en grille d'intensité. On isole ensuite les cellules correspondant au marquage par seuillage local de l'intensité.

En effet, les valeurs d'intensité du marquage sont largement supérieures au reste de la chaussée, de par le matériau réfléchissant utilisé. A nouveau, on utilise des procédés de morphologie mathématique pour homogénéiser les lignes extraites, puis on procède à la vectorisation de la même façon que dans le cadre des bordures.

On obtient finalement un modèle contenant le marquage au sol dans un format DAO, avec des écarts moyens




Figure 6. Modèle vectoriel du marquage au sol (en rouge) superposé au nuage de points

de l'ordre de 3 cm avec le nuage. Cette méthode, performante sur la majorité des portions routières, exige cependant souvent un traitement manuel supplémentaire dans le cas des sorties autoroutières, où le marquage est plus complexe et où les lignes se divisent parfois en plusieurs éléments.

La *figure 6* illustre un exemple de tracé de marquage au sol sur autoroute avec la méthode décrite.

Extraction et dessin automatiques d'éléments ponctuels

Le tracé des éléments ponctuels (regards, plaques, coffrets, mobilier urbain, etc.) constitue la deuxième partie essentielle du travail des dessinateurs, et suscite par ailleurs la majorité des retours clients, pour cause d'oublis ou d'erreurs de nature. Nous proposons ainsi une méthode permettant d'obtenir automatiquement le tracé d'une partie des éléments ponctuels du dessin.

Il s'agit de la partie majeure de l'étude, divisée en deux points distincts : l'extraction des ponctuels sur photographies via l'apprentissage profond et les réseaux de neurones convolutifs et leur dessin automatique à l'aide, notamment, de la photogrammétrie.




Figure 5. Exemple de tracé automatique de bordures (en rouge) superposé au nuage de points



► ■ **Extraction des éléments ponctuels**

Afin d'extraire les éléments ponctuels (regards, plaques, coffrets, mobilier urbain), l'apprentissage automatique (*Machine Learning*) et plus précisément l'apprentissage profond (*Deep Learning*) a rapidement été considéré comme la méthode la plus adaptée.

En effet, il est particulièrement difficile d'extraire des objets aux caractéristiques très variables (forme, couleur dans le cas de détection sur photographie, intensité dans le cas des ortho-images issues de nuages de points) avec des techniques traditionnelles de traitement d'images. Après avoir étudié et testé certains des algorithmes d'apprentissage profond disponibles en open-source, le détecteur YOLO (*You Only Look Once*) [Redmon & Farhadi, 2016] a été retenu pour son excellent compromis entre rapidité et précision, ainsi que pour sa relative accessibilité.

Il s'agit d'un système basé sur les réseaux de neurones convolutifs (*Convolutional Neural Networks, CNN*), technologie en remarquable évolution depuis ces dix dernières années, étant actuellement à la source des algorithmes les plus performants dans de nombreux domaines de l'intelligence artificielle, et notamment en vision par ordinateur. L'architecture d'un CNN consiste en une suite de couches (*Layers*), réalisant chacune une opération transformant les données qu'elle reçoit, comme l'illustre la figure 7.

De manière succincte, la première partie d'un CNN fonctionne comme

un extracteur de caractéristiques d'images. Une image d'entraînement connue est passée à travers une succession de filtres (noyaux de convolution, sous-échantillonnage, fonctions mathématiques), créant l'équivalent de nouvelles images (*Feature Maps*) représentant une multitude de caractéristiques de l'image originale.

Finalement, la deuxième partie du réseau, c'est-à-dire les couches entièrement connectées (*Fully Connected Layers*), traduit les images filtrées en votes, ou poids, afin de décider de la catégorie à laquelle appartient l'image. Après avoir traité une image avec le processus précédent, les caractéristiques des filtres ainsi que les poids sont ajustés via rétro-propagation, et ainsi de suite avec l'ensemble des images présentes dans la base de données d'entraînement, jusqu'à convergence du système.

Après plusieurs tests avec des bases de données restreintes, le choix s'est porté sur la détection des objets sur photographies au détriment des ortho-images issues des nuages de points, dont les caractéristiques sont trop variables (intensité, densité) et au sein desquelles certains objets sont peu différenciables (regards, plaques) ou invisibles (coffrets encastrés dans les murs, bouches à clé dans le cas d'une densité faible).

■ **Création d'une base de données photographiques**

Afin d'entraîner le système de détection, il s'agit tout d'abord de créer une base de données photographiques contenant

CLASSES	NOMBRE D'OBJETS
Regard rond	3670
Regard carré	2119
Regard carré rond	1334
Chambre double	536
Chambre triple et plus	242
Grille	881
Bouche à clé	1086
Avaloir visitable	1010
Avaloir grille	340
Avaloir visitable grille	43
Gargouille	697
Coffret	3878
Armoire	360
Bouche incendie	279
Poubelle publique	652
Banc public	210
Signe PMR	182
Signe piste cyclable	629
TOTAL	18148

Tableau 1 : Classes choisies et nombre d'objets par classe dans la base de données

un maximum d'occurrences d'objets d'intérêt.

Cette base de données a été réalisée en interne, à l'aide des images disponibles au sein de la société, provenant de divers projets *Mobile Mapping*. Cela offre l'avantage d'entraîner l'algorithme sur des types d'images similaires à ceux qui devront être traités pour la détection.

Après avoir étudié et établi des conjectures quant au potentiel de détection de l'algorithme, 18 types d'objets ont été choisis en tant que classes pour la base de données.




Figure 7. Architecture simplifiée d'un Réseau de Neurones Convolutifs (wikipedia.org, modifié)

Ce nombre relativement élevé de classes, dont certaines sont très semblables, a été choisi afin de partir d'un haut niveau de spécification, et de permettre la réduction de celui-ci en regroupant des classes similaires, au besoin. En effet, le regroupement de classes ne demande aucun effort, contrairement à la division d'une catégorie en deux sous-catégories, opération qui nécessite une distinction manuelle. La base de données ainsi créée, dont les photographies ont été annotées à l'aide du logiciel libre *Labellmg* [Tzuta, 2018], contient 18 148 occurrences d'objets, appartenant aux 18 classes sélectionnées, comme l'illustre le *tableau 1*.

■ Entraînement et résultats

L'algorithme a été entraîné sur notre base de données, à une résolution d'image relativement faible de 416 x 416 pixels : les images d'entraînement sont ré-échantillonnées à cette résolution afin d'alléger les calculs.

En effet, les opérations sous-jacentes à l'entraînement d'un tel réseau sont extrêmement coûteuses en ressources matérielles. Les calculs matriciels, virtuellement irréalisables sur un processeur, doivent être effectués directement sur carte graphique.


L'entraînement de notre système à cette faible résolution a nécessité une dizaine de jours de calculs, malgré une carte graphique performante (NVIDIA GeForce GTX880M 8 Go de mémoire dédiée). L'évaluation de l'algorithme a ensuite été effectuée sur une base de données indépendante contenant environ 1 000 occurrences d'objets. De manière globale, le système a prouvé son efficacité en affichant une précision et un rappel (*recall*) de l'ordre de 70 %. Ces deux critères, essentiels à l'évaluation de la performance d'un détecteur d'objets Perry, [Kent & Berry 1955], sont définis ainsi :

La précision correspond au nombre d'éléments pertinents détectés rapporté au nombre total d'éléments détectés :

$$P_i = \frac{\text{nb. d'obj. correctement attribués à la classe } i}{\text{nb. d'obj. attribués à la classe } i}$$

Le rappel correspond au nombre d'éléments pertinents détectés au regard du nombre d'objets pertinents que possède la base de données :

$$R_i = \frac{\text{nb. d'obj. correctement attribués à la classe } i}{\text{nb. d'obj. appartenant à la classe } i}$$



Figures 8 et 9. Exemples de détections d'objets effectuées avec YOLO

La performance de la détection est par ailleurs, dans son utilisation pratique, largement améliorée par la redondance des observations, que nous expliciterons dans la suite de l'article. Les *figures 8 et 9* illustrent la détection de divers objets d'intérêt par notre système.

■ Dessin automatique des ponctuels

Afin d'obtenir les coordonnées tridimensionnelles de l'objet à partir des coordonnées images obtenues via l'algorithme YOLO, la méthode suivante a été développée : à partir des équations de colinéarité (cf. photogrammétrie générale) et des données issues du système de cartographie mobile, il est possible de calculer l'équation tridimensionnelle de la droite reliant le centre de projection de la caméra au point 3D recherché, sans toutefois connaître la distance entre le centre de projection et ce point.

On résout ensuite le problème lié à cette inconnue en utilisant le nuage de points : on recherche l'intersection entre la droite calculée et le nuage, et on obtient dès lors les coordonnées 3D du point considéré.

La précision du tracé dépend alors principalement de la précision géométrique de la détection de YOLO, du calage des photographies et de la qualité de l'orientation interne des caméras, ainsi que du calage et de la densité du nuage de points pour le calcul d'intersection.

On obtient finalement des écarts très variables entre la position dans le nuage et la position calculée de l'objet, pouvant aller jusqu'à 30 cm dans les cas les plus défavorables.

Cette faible précision est également largement améliorée grâce à l'importante redondance dans la détection.

■ Exploitation de la redondance des observations et résultats

Les systèmes de cartographie mobile disposent généralement d'au moins quatre caméras, dont la fréquence de prise de vues permet d'observer le même objet à plusieurs reprises. De plus, les levés sont le plus souvent réalisés en aller-retour, accroissant encore l'abondance d'observations.

Ainsi, on distingue en moyenne le même objet sur 6 photographies différentes, ce chiffre étant bien entendu dépendant de l'emplacement usuel de l'objet aux alentours de la voirie (plus l'objet en est éloigné, moins on obtiendra d'occurrences de celui-ci).

S'agissant de la performance de détection, cette redondance permet une nette amélioration de la précision et du rappel, atteignant respectivement des valeurs de l'ordre de 85 % dans le cas d'une utilisation pratique sur un levé de corps de rue.

En ce qui concerne la précision géométrique du dessin automatique, on regroupe les points coïncidant à un même objet à l'aide d'un algorithme de partitionnement (en l'espèce l'algorithme classique *Mean Shift Clustering*), puis on effectue un ajustement par les moindres carrés afin d'obtenir la position la plus probable de l'objet.

On observe finalement un écart moyen entre la position de l'objet dans le nuage et la position calculée de l'ordre de 6 cm, pour un écart-type de 4 cm.



▶ En l'état, ce processus de dessin automatique ne pourra donc être utilisé que dans le cadre de plans n'exigeant pas une précision élevée, tels que les Plans de Corps de Rue Simplifiés (PCRS) par exemple.

Cependant, avec l'évolution rapide des algorithmes d'apprentissage profond, des systèmes de cartographie mobile, ainsi qu'en optimisant ou en améliorant la méthode en utilisant par exemple des techniques de stéréophotographie multi-vue, il sera possible d'obtenir des résultats largement plus favorables, et ainsi d'utiliser cette méthode dans le cadre de projets plus exigeants.

Processus de contrôle via projection sur photographies

Dans le cadre des projets réalisés par l'entreprise, les étapes de contrôle des plans constituent une part non négligeable du travail, et nécessitent une cellule qualité composée de personnel spécialement formé. Il est effectivement crucial pour la société de s'assurer de la qualité de ses livrables, c'est-à-dire principalement de l'exhaustivité, de l'exactitude ainsi que de la précision des plans réalisés.

En effet, dans le cas d'erreurs ou d'imprécisions dans les données livrées, la société entache non seulement sa réputation, mais est également sujette à des retours des clients, occasionnant des retards et une diminution des rendements de production.

L'optimisation des procédés de contrôle s'avère dès lors capitale, notamment au vu des quantités particulièrement importantes de données à vérifier, et de l'aspect chronophage de la tâche.

Avant la réalisation de la présente étude, un assistant qualité effectuait le contrôle de l'exhaustivité des plans sur deux écrans en comparant les éléments dessinés avec les objets présents sur les photographies, occasionnant des va-et-vient laborieux. Le contrôle de la position des éléments était ensuite effectué à même le nuage.

Malgré ces vérifications, des erreurs et oublis subsistaient bien évidemment dans le plan livré, notamment dus à des inattentions lors de la comparaison entre le plan et les photographies.

Une méthode a dès lors été développée afin de contrôler les livrables directement sur les photographies, en y projetant les éléments du plan, afin d'optimiser le contrôle et de minimiser les erreurs et oublis.

■ Méthode

On utilise à nouveau les équations de colinéarité de la photogrammétrie générale afin de transformer les coordonnées 3D des objets du plan en coordonnées-images 2D.

Pour obtenir une précision intéressante pour le contrôle, on corrige également les coordonnées calculées en prenant en compte les distorsions des caméras, selon le modèle de Brown [Brown, 1966].

La problématique restante concerne la détermination des objets contenus dans

les photographies. En effet, lorsque l'on considère une image, on ignore *a priori* quels objets y sont visibles.

Ainsi, afin d'éviter de transformer laborieusement les coordonnées 3D de l'intégralité des objets du plan en coordonnées-images 2D, et de tester pour chaque image leur appartenance, on définit pour chaque image un échantillon d'objets potentiellement projetables.

Cet échantillon est défini tout d'abord selon un seuil de distance entre les objets et la position de la caméra au moment de la prise de vues : on souhaite en effet projeter sur la photographie des objets nettement visibles par l'opérateur, c'est-à-dire relativement proches de la caméra.

Ensuite, pour chacun des objets présents dans le rayon fixé autour de la caméra, on s'assure que ceux-ci soient situés devant le capteur, en calculant le produit scalaire entre le vecteur d'orientation de la caméra et le vecteur pointant l'objet considéré.

A partir de cet échantillon, on effectue finalement la transformation 3D-2D et on teste pour chaque point sa présence ou non sur l'image : si ses coordonnées sont bel et bien comprises dans les dimensions de la photographie, celui-ci est projeté.

Enfin, via des processus propres aux logiciels DAO, on projette les blocs correspondant aux objets de manière à ce que l'échelle et la rotation soient cohérentes sur l'image, et se superposent correctement aux objets photographiés.



Figure 10. Exemple de projection automatique d'éléments du plan sur photographie



La *figure 10* illustre la projection d'objets du plan sur une photographie.

■ Résultats

Avec cette méthode, on observe finalement des écarts entre les objets projetés et les éléments sur les photographies inférieurs à 15 pixels, ce qui équivaut à un écart maximum d'environ 10 cm pour des objets situés à 10 m de la caméra (pour une caméra typique équipant les systèmes de cartographie mobile, de focale 8.2 mm).

L'assistant qualité peut alors, directement dans son logiciel DAO, faire défiler les images où sont automatiquement projetés les éléments du plan, en contrôlant l'exhaustivité ainsi que l'emplacement approximatif des objets, optimisant le temps ainsi que la qualité du contrôle.

Conclusion

Dans le cadre de cette étude concernant l'automatisation des procédés de traitement de données de cartographie mobile, plusieurs axes de recherche ont été mis en œuvre dans le but d'optimiser les rendements de production, tout en améliorant l'exhaustivité et la qualité des livrables.

Les méthodes développées quant à l'extraction et le dessin automatiques d'éléments linéaires et ponctuels permettront, une fois leur mise en production effective, une augmentation des rendements estimée à près de 50 % en ce qui concerne la réalisation de plans simples, tels que les PCRS.

Par ailleurs, le procédé de contrôle des livrables optimisé via la projection automatique des éléments du plan sur photographies, d'ores et déjà en application, a permis un accroissement des rendements de contrôle d'environ 30 %, tout en améliorant l'exhaustivité et la qualité des livrables.

Avec l'évolution des systèmes de levé, des algorithmes et des bases de données, l'avènement de la technologie de la chaîne de blocs associée à l'apprentissage automatique, ainsi qu'en s'intéressant à des procédés opérant directement au sein des nuages de points, il sera assurément possible d'améliorer encore largement les processus de traitement.

Ainsi, en ce qui concerne les plans peu exigeants, à l'instar du PCRS, on peut envisager dans un futur relativement proche, des méthodes permettant une production quasi-automatique (c'est-à-dire environ 75 %).

Dans cette optique, la société Futurmap a d'ores et déjà fait appel à un développeur, qui continuera de s'intéresser à l'apprentissage automatique, et plus particulièrement à ses applications en lien direct avec les nuages.

En effet, avec la croissance rapide des puissances de calcul, la cartographie mobile profitera immanquablement, à l'avenir, de l'adaptation des dernières technologies en matière d'intelligence artificielle, notamment basées sur les réseaux de neurones convolutifs, à des données complexes et multidimensionnelles, tels que les nuages de points. ●

Contact

Loïc ELSHOLZ
loic@futurmap.com

ABSTRACT

Key words: Mobile mapping, Image processing, Computer vision, Object detection, Machine learning, Deep learning, Convolutional neural networks

The rapid evolution of 3D technologies and particularly of laser scanners enabled the different players in the fields of civil engineering and topography to collect very large amounts of geospatial data efficiently. The democratization of Mobile Mapping Systems (MMS), result of these technological advances, leads to the necessity of developing suitable mass processing methods. In this context, our study focuses on the automation of Mobile Mapping data processing, especially through the extraction of linear and punctual elements, in order to increase production efficiency, but also quality and exhaustiveness of the deliverables. This paper describes the processes developed, based on image processing, photogrammetry as well as artificial intelligence, and more specifically deep learning and convolutional neural networks.

COMITÉ DE LECTURE D'XYZ

BOSSER Pierre,
professeur associé, ENSTA Bretagne,
Brest

BOTTON Serge,
ingénieur, ENSG Marne-la-Vallée

CLÉDAT Emmanuel,
doctorant, EPFL (Suisse)

HULLO Jean-François,
Dr.-Ing., ingénieur de recherche,
EDF Energy, Royaume-Uni

KOEHL Mathieu,
maître de conférences, INSA
Strasbourg

LEQUEUX James,
astronome émérite à l'Observatoire
de Paris

MAINAUD DURAND Hélène,
ingénieur topographe, CERN Genève

MISSIAEN Dominique,
ingénieur topographe, CERN Genève

MOPIN Irène,
ingénieur recherche, ENSTA Bretagne,
Brest

MOREL Laurent,
professeur des universités, ESGT
Le Mans

PANTAZIS N. Dimos,
professeur, TEI Athènes

POLIDORI Laurent,
directeur du CESBIO, Toulouse

REIS Olivier,
ingénieur, traducteur Sarreguemines

ROCHE Stéphane,
professeur, Université Laval, Québec

TOUZÉ Thomas,
dr. ing. géomètre, HEIG-VD

TROUILLET Michel,
ingénieur topographe, Lyon

Font partie du comité de lecture les membres du comité de rédaction et la rédaction (la directrice des publications et son adjoint, le rédacteur en chef et son adjoint), voir la liste en *page 1, sommaire*.