



# Création d'un moteur de détection automatique d'objets ponctuels dans une base de données de scanner dynamique

■ Arthur PICARD

*Avec la popularisation des techniques de cartographie mobile (Mobile Mapping) le volume et la qualité des données acquises sur le terrain ont augmenté de manière exponentielle. Ces techniques permettant de réduire considérablement la durée de la phase d'acquisition de la donnée impliquent néanmoins une phase de traitement chronophage concernant l'interprétation et l'extraction de l'information souhaitée. S'il est possible de réaliser ces opérations manuellement, celles-ci impliquent un coût humain et temporel élevé. L'apparition de nouvelles techniques d'Intelligence artificielle (IA) nous laisse entrevoir de nouveaux outils de traitement automatisés capables de reconnaître la sémantique des données, et d'ainsi transférer en grande partie le temps humain que nécessite cette tâche en temps machine.*

## ■ MOTS-CLÉS

Cartographie mobile, intelligence artificielle, apprentissage profond, reconnaissance de formes.

## Contexte et objectifs de l'étude

Avec leur démocratisation, les techniques de cartographie mobile se sont peu à peu imposées comme une nouvelle manière d'acquérir une grande quantité de données en un laps de temps très court. Ces données, généralement d'une précision à l'échelle centimétrique constituent aujourd'hui le point d'entrée de nombreuses applications particulières.

Citons à titre d'exemples la réalisation de l'inventaire de l'ensemble des défauts en présence sur la chaussée, ou encore de l'ensemble de la signalisation verticale et horizontale. Bien souvent, ces cas de figure mettent en évidence une quantité d'information acquise largement supérieure à celle qu'il est nécessaire de considérer. Pour la réalisation de couches d'inventaire, un tel volume de données à interpréter, analyser et traiter implique malheureusement des oublis et/ou erreurs potentiels. Ces opérations nécessitent

par ailleurs de disposer d'un opérateur se consacrant intégralement à la tâche, ce qui implique un temps humain et ainsi un coût de revient important pour l'élaboration du livrable.

Peu de solutions (qu'elles soient libres ou commerciales) existent actuellement pour faciliter de telles opérations, et celles-ci sont peu modulables lorsqu'il s'agit de s'adapter à différents types d'objets. La plupart d'entre elles proposent par exemple une détection semi-automatique de poteaux ou de marquages au sol. Bien que les poteaux constituent un point de départ judicieux pour de nombreux objets (panneaux de signalisation, éclairage public, poteaux électriques...), il reste à réaliser une étape de tri manuel considérable une fois ce travail dégrossi.

Faisant face à ce manque de solutions dédiées de plus en plus pesant et l'apparition de nouvelles méthodes de reconnaissances de formes, cet article présente une solution ainsi qu'une méthodologie permettant

l'extraction et le positionnement de certains objets ponctuels (candélabres et panneaux de signalisation), et ce de manière totalement automatisée. Nous nous appuyons pour ce faire sur les dernières méthodes d'apprentissage profond (*Deep Learning*) pour reconnaître et extraire le "signifiant" des données et l'exploiter de manière adéquate.

Le principal objectif à atteindre consiste en l'élaboration d'une méthode permettant la détection et la reconnaissance d'objets ponctuels à partir d'une base de données de scanner dynamique, c'est-à-dire composée d'images panoramiques à 360° et de nuages de points denses.

Pour y parvenir, il sera plus spécifiquement question :

- d'extraire le plus précisément possible les objets du nuage de points sur la base de leur sémantique,
- de développer une méthode permettant de calculer le point d'insertion des objets d'intérêt en coordonnées (X, Y, Z) ; la position calculée devant se trouver dans un rayon de 10 cm autour de la position théorique.

## De l'apprentissage automatique à l'intelligence artificielle

Bien que souvent perçue comme un ensemble de techniques révolutionnaires, l'intelligence artificielle ne constitue pour autant pas un concept nouveau. Ce terme, apparu pour la première fois en 1956 est initialement défini comme la "science de concevoir des machines intelligentes". Cette première définition, bien qu'au





**Intelligence Artificielle (IA) :** « Technique qui permet aux ordinateurs d'imiter l'intelligence humaine ». [Microsoft, 2019]



Figure 1. Définition de l'intelligence artificielle et de ses sous-domaines

premier abord peu précise et laissant une certaine liberté quant à son interprétation, pose toutefois un cadre à ce qui deviendra par la suite une véritable branche de l'informatique. De nos jours, l'intelligence artificielle est plutôt considérée comme un vaste panel de méthodes permettant de simuler l'intelligence humaine. Nous entendons par là que celles-ci doivent entre autres être capables de tirer des enseignements de leur expérience, de manière à accomplir avec succès certaines tâches plus ou moins complexes, et généralement fastidieuses à réaliser pour l'Homme. Parmi l'ensemble de ces méthodes, on distingue les deux grands sous-domaines que sont l'apprentissage automatique (*Machine Learning*) et l'apprentissage profond (*Deep Learning*), dont les définitions sont présentées en Figure 1.

Historiquement, les premiers fondements de l'apprentissage automatique sont posés dès la seconde moitié du XX<sup>e</sup> siècle, en particulier avec la formulation théorique du Perceptron [Rosenblatt, 1958], premier réseau de neurones arti-

fiels. L'apprentissage profond apparaît quant à lui bien plus tard, au début des années 1990, avec la mise en pratique de l'algorithme de rétropropagation du gradient de l'erreur [Rumelhart et al., 1985], permettant aux algorithmes d'apprendre à progresser par eux-mêmes.

Malgré des débuts encourageants (avec la reconnaissance de chiffres manuscrits [LeCun et al. 1989] par exemple), les réseaux de neurones profonds ne suscitent que peu d'intérêt lors de leur apparition, et sont rapidement laissés de côté par la communauté scientifique en raison de leur besoin énorme en termes de puissance de calcul. Ce n'est qu'à partir du début des années 2010 que les réseaux de neurones profonds refont surface avec de remarquables performances [Khrievsky et al., 2012], capables de surpasser les meilleures méthodes de l'état de l'art en termes de classification d'image. Depuis lors, l'apprentissage profond s'est amplement popularisé et a étendu son champ d'application, de la reconnaissance d'objets à la génération de modèles prédictifs, en passant par la reconnaissance vocale.

## Réseaux de neurones convolutifs et reconnaissance d'objets

Qu'il s'agisse de données raster ou de nuages de points, la quasi-totalité des méthodes de l'état de l'art s'appuie sur les réseaux de neurones convolutifs pour la reconnaissance de leur sémantique. Ces réseaux de neurones particuliers se rattachent à l'apprentissage profond, et sont particulièrement adaptés au traitement de données image, car dotées d'une structure régulière (sous forme de grille de pixels). Ceux-ci se construisent comme un empilement de différentes couches symbolisant les différents neurones du réseau.

De manière générale, les réseaux de neurones convolutifs permettent de répondre à 4 grandes disciplines (celles-ci sont illustrées en Figure 2) :

- la classification d'image, qui consiste à reconnaître le thème prédominant d'une image ;
- la détection d'objets, ayant pour but de délimiter l'emprise de l'objet reconnu par sa boîte englobante ;
- la segmentation sémantique d'image,



Figure 2. De gauche à droite : Classification d'image, détection d'objets, segmentation sémantique et segmentation d'instance



Figure 3. Nuage de points dense géoréférencé et photographie panoramique associée

dont l'objectif est d'associer une sémantique à chaque pixel de l'image ; – la segmentation d'instance, située à la jonction entre détection d'objets et segmentation sémantique d'images.

### Données disponibles

Pour être en mesure de sélectionner la méthode permettant la meilleure adéquation avec nos objectifs, il est essentiel d'analyser en amont les données dont nous disposons. Le type, le format et le contenu de ces dernières conditionnent en grande partie la manière de concevoir notre moteur de détection.

Comme évoqué précédemment, cette étude s'inscrit dans l'automatisation de traitements de données issues de levés de cartographie mobile. Nous disposons ainsi d'un nuage de points dense géoréférencé acquis en zone urbaine/ résidentielle associé à un ensemble de 435 photographies panoramiques à 360° dont les positions et orientations sont connues. La Figure 3 présente un extrait de ces données, tandis que le Tableau 1 précise les caractéristiques du nuage de points ayant servi de jeu de test tout au long du développement du moteur de détection.

Densité moyenne	Nombre de points	498 349 258
	Densité moyenne	1 628 points / m <sup>2</sup>
Caractéristiques géométriques	Emprise au sol	0.29 km <sup>2</sup>
	Etendue X	1.026 km
	Etendue Y	1.708 km
	Etendue Z	157 m

Tableau 1. Caractéristiques principales du nuage de points test

### Conception du moteur de détection

Puisque les réseaux de neurones convolutifs appliqués aux données image constituent actuellement l'alternative la plus fiable, nous orientons notre choix vers une telle solution pour la reconnaissance de la sémantique de nos données. Plutôt que d'envisager une reconnaissance peu fiable de nos objets d'intérêt directement dans le nuage, nous choisissons d'effectuer cette étape à partir des images panoramiques dont nous disposons. De cette manière, nous entendons favoriser la bonne reconnaissance des éléments que nous souhaitons extraire, au détriment d'une approche plus directe, mais potentiellement plus coûteuse d'un point de vue calculatoire et surtout bien moins performante.

Ce point de vue présuppose néanmoins d'être en mesure de rapprocher par la suite l'information sémantique reconnue dans l'image à la géométrie correspondante dans le nuage de points dense, ce qui est amplement facilité par les informations recueillies lors de l'acquisition des données, puisque nous disposons à la fois des positions et orientations de chacune de nos prises de vues.

Comme l'illustre la Figure 4, notre méthode se compose de 4 grandes familles de traitements :

- prétraitements, segmentation d'instance des photographies panoramiques et extraction des objets d'intérêts (panneaux de signalisation et candélabres) ;
- mise en correspondance entre donnée extraite de l'imagerie panorami-




Figure 4. Architecture globale du moteur de détection

- ▶ que et géométrie associée du nuage de points ;
- filtrage des points obtenus ;
- calcul du centre des objets d'intérêts et export.

## Choix d'une approche de reconnaissance

Le choix de l'approche permettant de reconnaître la sémantique de nos données est prédéterminant pour l'ensemble du projet. Celui-ci permet de poser d'une part le point de départ de la marche à suivre et d'autre part de conditionner le niveau de précision qu'il est possible d'atteindre.

Parmi les quatre tâches de la reconnaissance d'objets, nous pouvons d'emblée éliminer la classification d'image, puisque cette discipline ne nous informe guère sur la localisation des objets détectés. La détection d'objets propose quant à elle une reconnaissance très rapide (puisque certains algorithmes tels que YOLO [Redmon et al., 2016] sont capables de détecter des objets en temps réel au sein d'un flux vidéo) et à l'échelle globale de l'image. Elle constitue donc un candidat sérieux. La segmentation

sémantique d'image permet, quant à elle, de travailler à un niveau autrement plus précis : à l'échelle du pixel. Une telle information serait très utile à notre méthode, mais elle comporte l'inconvénient de ne fournir que très peu d'informations, quant à la fiabilité des objets reconnus. Pour ces raisons, la segmentation d'instance semble constituer la meilleure alternative, puisqu'elle combine les résultats de la segmentation sémantique et de la détection d'objets. Nous portons ainsi notre choix sur ce domaine spécifique.

## Reconnaissance des objets dans l'imagerie panoramique

La première de ces phases comprend deux chaînes de traitements indépendantes : d'une part prétraitements à apporter au nuage de points, et d'autre part la segmentation d'instance de l'imagerie panoramique. Celle-ci nécessite de ce fait un soin particulier, puisque c'est à ce stade que sont reconnus les objets d'intérêt. Après avoir décomposé l'ensemble des images panoramiques en facettes de cube, nous les fournissons en

entrée à une version de l'algorithme de segmentation d'instance Mask R-CNN [He et al., 2017] que nous avons entraîné à reconnaître nos objets d'intérêt. Enfin, nous retransformons les boîtes englobantes et masques de segmentation sémantique obtenus vers le système panoramique d'origine des images, de manière à permettre une superposition correcte entre ces deux sources de données.

Les prétraitements à apporter au nuage de points consistent pour leur part à classifier le nuage de points selon deux natures : sol et sursol, et à transformer ensuite le nuage obtenu en une base de données PostGIS. La classification sol/sur sol permet d'alléger le volume de données à interroger lors de l'étape de mise en correspondance des données, tandis que la transformation du nuage en une base de données permet d'améliorer significativement la manière d'accéder aux points du nuage<sup>1</sup>.

<sup>1</sup> Notamment par le biais de requêtes spatiales, ce qui permet d'accéder très rapidement et de manière sélective à certains points du nuage.




Figure 5. Transformation du nuage de points vers le système de coordonnées d'une image panoramique



Figure 6. Exemple de mise en correspondance entre nuage de points et image panoramique



## Mise en correspondance avec le nuage de points

À la suite de ces prétraitements, les masques de segmentation obtenus sont mis en correspondance avec le nuage de points. Étant donné que nous connaissons les positions et orientations de l'ensemble de nos photographies panoramiques, il nous est possible de les relier au nuage de points grâce au processus présenté en *Figure 5*. L'étape A est réalisée grâce à une transformation en coordonnées homogènes, calculée à partir des positions et de l'orientation de chaque prise de vues. L'étape B consiste ensuite à calculer le jeu de coordonnées image de chaque point du nuage, de manière à être capable de reprojeter ce dernier dans l'image panoramique considérée, comme illustré en *Figure 6*.

Une fois cette mise en correspondance réalisée, ne sont finalement conservés que les points situés à l'intersection entre masques de segmentation sémantique et nuage de points.

## Filtrage des points extraits du nuage

À l'issue de ces étapes, nous obtenons un premier jeu de points correspondant de manière très probable aux objets que nous souhaitons extraire. Il est cependant très fréquent d'observer que ceux-ci sont parasités de manière significative par des points proches, mais non pertinents. Suivant ce constat, il est nécessaire de mettre en œuvre un traitement particulier nous permettant d'affiner la sélection de points obtenue, de manière à permettre par la suite un calcul précis de la position centrale de nos objets (car non perturbé par la présence de bruit).

Ce filtrage des points obtenus est réalisé sous la forme d'un seuillage, à partir d'un score permettant de traduire la probabilité qu'aurait chaque point d'appartenir à un objet d'intérêt, comme le mentionne l'*Equation 1*. Ce score permet d'éliminer significativement la présence de bruit, comme en atteste la *Figure 7*.

$$score = score_{détection} + \frac{1}{d_{plani}} + N$$

**Equation 1.** Score attribué à chaque point extrait

Les points restants sont enfin répartis en groupes grâce à un algorithme de coalescence. Nous instancions de cette manière correctement chaque objet extrait, permettant ce faisant de préparer le calcul du centre de chacun d'entre eux.


## Calcul du point d'insertion

Puisque le but de notre moteur de détection est de fournir les coordonnées des centres de nos objets avec précision, il convient de définir une méthode adéquate pour en permettre le calcul. Pour rappel, la présente étude se limite aux candélabres et aux panneaux de signalisation.

Une première approche simpliste et permettant d'obtenir des coordonnées approchées pour nos objets serait de calculer séparément le centroïde de ceux-ci dans le plan (X,Y), et de le rattacher au point le plus bas de l'objet, voire à l'altitude du sol.

Cette méthode dont l'avantage est d'être très rapide, ne nécessite que très peu de calculs. Elle peut cependant être rapidement perturbée par la présence de points erronés (*outliers*), la moyenne arithmétique n'étant pas statistiquement robuste, elle fait ressortir la nécessité de disposer de données "propres" pour le calcul du centre des objets. Calculer ces positions de cette manière nécessiterait ainsi de disposer d'objets géométriquement équilibrés pour garantir une position la plus exacte possible. Nos objets d'intérêt ne satisfaisant pas ce critère, nous ne jugeons pas judicieux d'employer cette méthode.

Qu'il s'agisse de candélabres ou de panneaux de signalisation, on dénote une particularité commune entre ces deux types d'objets : ils comprennent tous deux un mât cylindrique. En vue de section horizontale, ce mât peut ainsi être représenté par un cercle en supposant l'objet vertical, et par une ellipse en considérant un défaut de verticalité. Plutôt que de calculer le barycentre de chaque objet, nous favorisons le calcul



**Figure 7.** Influence du filtrage sur la sélection de points






Figure 8. Axe principal de l'objet, déviation de la verticale et découpage en tranches





Figure 9. Utilisation de l'ACP pour le calcul et la projection des centres de cercle dans le plan XY

des paramètres de chacun des cercles, ce qui permet d'estimer les coordonnées d'insertion de nos objets avec une plus grande fiabilité (puisque en théorie potentiellement moins sensible au bruit).

Afin d'améliorer les résultats obtenus et également de quantifier la précision des coordonnées obtenues nous proposons de calculer plusieurs centres pour chaque objet. Nous choisissons de déterminer plusieurs paramètres de cercle par objet. Ceux-ci s'élèvent au nombre de trois :  $R$ ,  $c_x$  et  $c_y$  respectivement le rayon du cercle et les coordonnées  $X$  et  $Y$  de celui-ci. L'altitude de l'objet sera déterminée séparément, bien que celle de chaque cercle soit par la suite considérée pour pondérer le calcul de la position finale de l'objet.

Pour ce faire, il nous faut découper les objets d'intérêt en tranches d'épaisseur fixée et suivant l'axe principal de ceux-ci. En considérant des tranches perpendiculaires à cet axe, nous nous affranchissons d'un éventuel défaut de verticalité de l'objet qui induirait des décalages entre les positions du centre du cercle dans le plan  $XY$ . Le découpage en tranches de l'objet est illustré en Figure 8, tandis que la Figure 9 justifie le choix de l'axe principal de l'objet pour cette décomposition.

Suite à ce découpage en tranches, nous calculons les paramètres de chaque cercle à l'aide de l'algorithme RANSAC




Figure 10. Masques de segmentation sémantique en superposition avec leur image d'entrée

[Fischler et Bolles, 1981], algorithme d'estimation robuste permettant d'atténuer l'influence du bruit restant sur le résultat obtenu. Les coordonnées finales sont finalement obtenues par moyenne pondérée de l'ensemble des résultats pour chaque objet.

### Résultats obtenus

Notre algorithme étant constitué de 4 grands groupes de traitements (cf. Figure 4), plusieurs types de résultats sont renvoyés au fur et à mesure de l'avancée au sein de notre chaîne de traitements.




Figure 11. Points extraits suite à l'étape de filtrage

Exhaustivité	$m_{qx}$	$m_{qy}$	$m_{qz}$	$e_{x\text{moyen}}$	$e_{y\text{moyen}}$	$e_{z\text{moyen}}$
71%	3.0 cm	2.7 cm	9.1 cm	0.8 cm	0.2 cm	5.0 cm

Tableau 2. Résultats atteints par le moteur de détection (candélabres)

### ■ Masques de segmentation sémantique

La Figure 10 présente quelques masques de segmentation obtenus en superposition avec leur image d'origine. Nous remarquons immédiatement que les résultats atteints sont perfectibles, puisque ces derniers ne recouvrent pas la totalité des objets. Par ailleurs, certains d'entre eux restent non détectés. Ce manque de vrais positifs s'explique par la taille de l'image fournie en entrée. Celle-ci est systématiquement redimensionnée à une taille inférieure, ce qui entraîne une perte d'informations sur les petits objets présents dans l'image, dont nos objets d'intérêt. Puisque les objets non détectés se situent à une distance importante du lieu de prises de vues, ils n'occupent qu'une part infime de l'image, ce qui les rend moins susceptibles d'être détectés. Ce problème est malheureusement inhérent aux réseaux convolutifs. Bien qu'il puisse être atténué au moyen de paramètres adaptés (réduction de la taille des fenêtres de sous-échantillonnage, augmentation de la dimension des couches de convolution), il reste néanmoins un défi actuel de la reconnaissance d'objets.

Nous apprécions malgré tout la qualité de nos masques, dont les résultats semblent prometteurs, d'autant plus que notre modèle de détection n'a

été entraîné que sur un total d'environ 700 instances de candélabres. Notons également que certains objets détectés occupent un volume très réduit de l'image, ce qui conforte notre choix de découper les panoramiques en facettes de cube pour la détection.

### ■ Points extraits du nuage

La Figure 11 présente un extrait de candélabres et de panneaux de signalisation fournis à la suite de l'étape de filtrage. Les points résultants mettent en évidence une extraction de bonne

qualité des objets, bien que ceux-ci restent encore parfois perturbés par quelques groupes de points parasites (marqués par les ellipses rouges).

### ■ Positions finales

L'ensemble des positions des objets reconnus est comparé à une vérité terrain que nous avons préalablement établie par digitalisation manuelle dans le nuage de points.

Les résultats obtenus font état de résultats satisfaisants en planimétrie, puisqu'ils atteignent une exactitude de



Figure 12. Vue SIG des résultats en sortie du moteur de détection



l'ordre de 3 cm, avec des écarts moyens inférieurs au centimètre. Néanmoins, des progrès restent encore à réaliser en ce qui concerne la composante altimétrique, puisque celle-ci se rapproche fortement de la tolérance fixée (10 cm).

## Conclusion

Cet article présente une méthode de reconnaissance, d'extraction et de positionnement de candélabres et de panneaux de signalisation dans un nuage de points basée sur une extraction de la sémantique d'images panoramiques. Il s'agit en ce sens d'une méthode hybride, s'appuyant sur une reconnaissance de la sémantique d'images transposée ensuite au nuage de points. Cette méthode a été développée et assemblée de toutes pièces en langage Python et bénéficie des performances de l'algorithme de segmentation d'instance Mask R-CNN [He et al., 2017] pour l'extraction des objets d'intérêt de l'imagerie panoramique. Elle bénéficie, ce faisant, d'une couche d'intelligence artificielle permettant d'accroître ses capacités de détection au regard de méthodes plus classiques issues de l'apprentissage automatique.

Les performances de ce moteur de détection ont été évaluées principalement pour des objets de type candélabre. Les positions finales obtenues pour ceux-ci relatent d'un taux de détection avoisinant les 70 % du jeu de données test, avec une exactitude de 4 cm en planimétrie, et 9 cm en altimétrie. Les écarts moyens constatés s'élèvent pour leur part à 1 cm en planimétrie et 5 cm en altimétrie.

Si notre algorithme répond en grande partie aux objectifs fixés, il reste néanmoins à l'étendre à de nouveaux types d'objets et à affiner ses performances en matière de segmentation d'instance, afin d'en améliorer l'exhaustivité.

La méthode décrite ici présente des résultats encourageants pour deux types d'objets distincts. Il serait toutefois intéressant d'évaluer les performances d'une telle méthode sur un plus grand ensemble d'objets, de manière à rendre réellement compte de la puissance des réseaux de neurones convolutifs. ●

## Contact

Arthur PICARD  
a.picard@ttge.fr

## Références

- [Fischler et Bolles, 1981] Fischler, M.A., Bolles, R.C. 1981. *Random Sample Consensus : a paradigm for model fitting with applications to image analysis and automated cartography*. Communications of the ACM, Vol. 24 N° 6, pp. 381-395.
- [He et al., 2017] He, K., Gkioxari, G., Dollár, P., Girshick, R. 2017. *Mask R-CNN*. *Proceedings of the IEEE International Conference on Computer Vision*, pp. 2961-2969.
- [Krizhevsky et al., 2012] Krizhevsky, A., Sutskever, I., Hinton, G. 2012. *Advances in neural information processing systems*, pp. 1095-1105.
- [LeCun et al. 1989] LeCun, Y., Boser, B., Denker, J., Henderson, D., Howard, R., Hubbard, W., Jackel, L. 1989. *Backpropagation applied to handwritten zip code recognition*. *Neural computation*, Vol. 1 N° 4, pp. 541-551.
- [Redmon et al., 2016] Redmon, J., Divvala, S., Girshick, R., Farhadi, A. 2016. *YOLO : You Only Look Once*. CVPR.
- [Rosenblatt, 1958] Rosenblatt, F. 1958. *The Perceptron : a probabilistic model for information storage organization in the brain*. *Psychological Review*, Vol. 65 N° 6, p. 386.
- [Rumelhart et al., 1985] Rumelhart, D., Hinton, G., Williams, R. 1985. *Learning internal representations by error propagation*.

## ABSTRACT

*As mobile mapping techniques become more and more popular, the volume and quality of data acquired in the field have increased in an exponential way. These techniques, which considerably reduce the duration of the data acquisition involve a time-consuming processing phase when it comes to the interpretation and extraction of the desired information. While it is possible to carry out these operations manually, they involve a high human and time cost. The emergence of artificial intelligence techniques let us see new automated processing tools having the capability of recognizing data semantics.*

## 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, EDF

**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.