

OBSERVATION DE LA MER PAR APPRENTISSAGE PROFOND : QUELQUES EXEMPLES D'APPLICATIONS POUR PROTÉGER NOTRE BIEN COMMUN.

S. Lefèvre¹, L. Courtrai¹, M.T. Pham¹, C. Friguét¹, J.C. Burnel¹

¹ Université Bretagne Sud,
Institut de Recherche en Informatique et Systèmes Aléatoires (UMR CNRS 6074)
Campus de Tohannic, 56000 Vannes, France
sebastien.lefevre@irisa.fr

Mots-clés : vision par ordinateur ; réseaux de neurones profonds ; détection d'objet ; reconnaissance d'espèces ; suivi de la mégafaune marine

RÉSUMÉ

L'intelligence artificielle a connu un vif succès ces dernières années avec l'avènement des réseaux de neurones profonds. Ces derniers, profitant à la fois de la puissance de calcul offertes par les processeurs récents tels que les GPU, et des masses de données accumulées à l'ère du big data, ont ainsi révolutionné de nombreux domaines et notamment celui de la vision par ordinateur. Dans ce chapitre, nous présentons quelques applications de l'apprentissage profond au domaine de l'observation de l'environnement dans un contexte maritime. Nous nous intéressons en particulier à l'analyse de la mégafaune marine et décrivons les travaux réalisés dans le cadre de différents projets collaboratifs visant tous à une meilleure préservation de notre bien commun.

ABSTRACT

In the last years, artificial intelligence has become very popular thanks to the success of deep neural networks. Benefiting from both the computational power brought by recent processors such as GPUs and the massive data gathered at the Big Data era, these networks have thus led to a significant breakthrough in numerous fields including computer vision. In this chapter, we present some applications of deep learning to the field of environment observation in a marine context. We focus in particular on the marine megafauna analysis and describe research works conducted through different collaborative projects, all aiming to a better preservation of one of our common good.

1. INTRODUCTION

La mer est un écosystème particulièrement riche qui recense une grande partie de la biodiversité de notre planète. Il est primordial d'estimer précisément celle-ci, en particulier pour mesurer les effets des activités de l'homme sur son environnement. Comme nous le verrons dans ce chapitre, les progrès technologiques facilitent grandement l'observation de la mégafaune marine. Les images numériques, qu'elles soient prises de l'espace, du ciel, ou encore sous la surface de

la mer, s'avèrent une source d'information essentielle. Cependant, elles restent le plus souvent analysées manuellement, par des experts devant leur ordinateur, alors que les progrès en informatique, et notamment en vision par ordinateur, permettent d'envisager l'automatisation de ces analyses, avec pour conséquence la possibilité d'observer plus souvent et plus largement les espèces marines.

Ainsi, nous présentons dans ce chapitre les travaux en intelligence artificielle conduits par l'équipe OBELIX⁴ de l'institut de recherche en informatique et systèmes aléatoires (IRISA) dans plusieurs projets collaboratifs et multidisciplinaires, dont l'objectif commun est d'offrir des solutions automatiques d'observation de la mégafaune marine, et ce, à partir de différentes sources de données en imagerie satellite, aérienne, ou sous-marine. Les solutions sont toutes basées sur le paradigme de l'apprentissage profond, et plus précisément des réseaux de neurones profonds, qui ont profondément impacté le domaine de la vision par ordinateur en plaçant les données au cœur du processus d'analyse.

L'organisation de notre chapitre est la suivante : nous proposons tout d'abord une rapide introduction aux réseaux de neurones profonds. Nous nous intéressons ensuite au cas de l'imagerie aérienne et satellite, que nous traitons au travers de deux projets visant à détecter et recenser la mégafaune marine. Nous nous focalisons ensuite sur l'imagerie sous-marine dans le but de détecter, suivre, compter et caractériser les poissons présents dans un chalut de pêche. Nous terminons ce chapitre en identifiant les questions qui restent ouvertes dans le domaine et en proposant quelques pistes de recherche.

2. LES RÉSEAUX DE NEURONES PROFONDS

Depuis des décennies, l'homme cherche à doter les machines d'une capacité à réfléchir, d'une intelligence. Cette question scientifique est complexe et de nombreuses définitions de l'intelligence artificielle ont été proposées dans la littérature. Dans ce chapitre, nous nous focalisons sur le domaine de la vision par ordinateur et la problématique de perception visuelle, où l'objectif d'une machine ou d'un algorithme est d'analyser et comprendre le contenu d'une image à l'instar de ce que pourrait faire ou voir un utilisateur, qu'il soit novice ou expert. Pour ce faire, les réseaux de neurones artificiels ont connu un nouvel essor lors de la dernière décennie avec l'avènement des réseaux de neurones profonds, dont les performances ont contribué à la place croissante de l'intelligence artificielle dans notre société contemporaine. Notons que le domaine de l'apprentissage profond est en pleine expansion, passant en dix ans d'un millier à cent milliers de publications scientifiques annuelles.

Bien que leur appellation traduise un souhait d'établir des modèles mathématiques et informatiques visant à imiter le fonctionnement du cerveau humain, les réseaux de neurones profonds développés ces dernières années restent encore loin d'appréhender la complexité du cerveau telle qu'elle peut être établie au regard des connaissances scientifiques actuelles en neurosciences. Les réseaux de neurones (artificiels), dont l'étude a débuté au milieu du siècle dernier avec les travaux de McCulloch et Pitts (1943) et Hebb (1949), reposent sur la définition de neurones artificiels capables de traiter une information, et de connexions entre eux pour échanger ces informations, à l'instar des neurones biologiques et des synapses. Leur mise en œuvre s'effectue au travers de fonctions mathématiques, dont les paramètres vont être déterminés lors d'une phase d'apprentissage (correspondant ainsi au phénomène de plasticité cérébrale). Vient ensuite une phase d'inférence (ou test) où le réseau, préalablement entraîné à résoudre une tâche donnée en optimisant ses paramètres, analysera le signal fourni en lui appliquant successivement les différentes fonctions mathématiques pour en déduire une information finale correspondant à la tâche visée. Profitant des technologies informatiques modernes (et notamment l'accroissement conjoint des ressources de calcul et des masses de données disponibles), les réseaux de neurones profonds

4 <http://www.irisa.fr/obelix>

ont été mis en avant notamment par les travaux de Bengio, Hinton et Le Cun (2015), lauréats du prix Turing en 2019 (l'équivalent du prix Nobel pour l'informatique). Ils consistent en un assemblage de neurones artificiels en de nombreuses couches, qui vont permettre de caractériser le signal fourni en entrée du réseau avec un niveau croissant de sémantique, jusqu'à fournir en sortie du réseau des informations complexes permettant la prise de décision. Les domaines d'application sont variés, citons par exemple la reconnaissance de la langue parlée ou écrite, les véhicules autonomes, le diagnostic médical, ou encore la prédiction des évolutions boursières ou climatiques. En vision par ordinateur, l'information fournie au réseau et traitée par les neurones au sein des différentes couches prend généralement la forme d'une image faite de pixels. L'approche la plus répandue consiste à traiter cette image au travers de filtres (dits de convolution) capables d'extraire des caractéristiques telles que les contours, la texture, la couleur principale, etc. Les neurones sont ainsi convolutifs, donnant lieu aux réseaux de neurones du même nom (Krizhevsky et al., 2017) qui restent aujourd'hui la base de la plupart des propositions scientifiques et technologiques. La convolution étant une opération linéaire locale, ne traitant qu'un voisinage de pixel, elle est souvent suivie d'une étape dite d'activation non-linéaire et complétée par une étape de sous-échantillonnage de l'image (pooling en anglais) qui élargit le contexte visuel (ou champ récepteur) considéré par le réseau. L'alternance de couches de convolutions (et d'activations non-linéaires) et de sous-échantillonnage permet de transformer l'image d'origine en un vecteur de caractéristiques. Ce dernier est finalement exploité comme le ferait un réseau de neurones artificiels classique pour prendre la décision finale (par exemple, reconnaître le contenu d'une image et décider si elle présente des éléments relatifs à notre bien commun). La figure 1 illustre le fonctionnement d'un tel réseau.




Figure 1. Illustration d'un réseau de neurones convolutifs.

Les réseaux de neurones convolutifs peuvent accomplir différentes tâches, chacune d'elles nécessitant l'élaboration d'un modèle particulier inspiré de celui présenté en figure 1 et qui a pour but la classification d'une image. Parmi les tâches les plus usuelles, on distingue notamment la segmentation sémantique, qui associe une classe à chaque pixel de l'image, la détection d'objet, qui vise à localiser chaque objet le plus souvent par une boîte englobante et à lui associer une classe, la segmentation d'instance, qui couple les deux tâches précédentes en fournissant une délimitation précise de chaque objet reconnu dans l'image, le suivi des objets dans des vidéos, la simulation d'images réalistes, etc.

Quelle que soit la tâche à accomplir, les réseaux de neurones profonds comportent des millions, voire des milliards de paramètres, ce qui leur permet de résoudre des problèmes complexes dans le domaine de la vision par ordinateur qui nous intéresse ici. L'optimisation de ces nombreux paramètres n'est cependant possible que si la phase d'apprentissage s'appuie sur un nombre suffisamment grand d'exemples (des milliers, voire des millions d'exemples). La qualité de ces exemples, aussi appelés annotations, est particulièrement critique. Dans certains contextes, l'implication d'experts thématiques (écologues, biologistes, géographes, etc.) est donc une condition

sine qua non à la réussite du processus d'apprentissage du réseau. On comprend ici le caractère multidisciplinaire que revêtent les projets visant à appliquer l'intelligence artificielle dans les domaines de la mer et du littoral.

La complexité inhérente aux réseaux de neurones profonds, que ce soit lors de la phase d'apprentissage avec la recherche des paramètres optimaux ou lors de la phase d'inférence consistant à faire passer une image dans le réseau pour la traduire en décision, nécessite de faire appel à des matériels informatiques dédiés tels que les processeurs graphiques (ou GPU).

3. OBSERVER DEPUIS LE CIEL ET L'ESPACE

La télédétection aérienne et spatiale permet d'observer notre planète respectivement depuis le ciel et l'espace. Les survols aériens sont notamment utilisés pour acquérir des images très précises (de l'ordre d'une dizaine de centimètres par pixel, parfois moins) couvrant une zone d'étude pouvant s'étendre sur des dizaines de kilomètres. Ils servent notamment à l'IGN pour mettre à jour les bases d'informations géographiques disponibles à l'échelle nationale, ou au parc naturel régional du Golfe du Morbihan pour suivre l'activité de pêche à pied de loisirs à l'aide d'outils intelligents (Laroze et al., 2018). La démocratisation récente des drones, dont certains sont équipés de capteurs photographiques, a simplifié l'accès à la télédétection aérienne et en a multiplié les usages. À une autre échelle, les satellites d'observation de la Terre fournissent aujourd'hui des informations riches et variées quant à l'état de notre planète. Bien que certains satellites à très haute résolution spatiale (jusqu'à 30 centimètres par pixel) fournissent des observations qui se rapprochent de celles obtenues lors des campagnes aériennes, l'intérêt principal de ces capteurs en orbite réside dans leur grande couverture spatiale, permettant la cartographie à l'échelle continentale (Merciel et al., 2019), voire mondiale, et leur capacité de revisite temporelle. Ainsi, les missions Sentinel, lancées depuis 2014 par l'agence spatiale européenne (ESA) dans le cadre du programme européen Copernicus d'observation de la Terre, fournissent gratuitement aux scientifiques, aux entreprises et aux citoyens des images radar et multispectrales pour le suivi des terres, des océans et de l'atmosphère (chaque point du globe est ainsi observé tous les 5 jours).

Les possibilités offertes par la télédétection aérienne et spatiale sont nombreuses. Pour autant, elles requièrent également de concevoir des processus d'analyse automatique performants et sachant exploiter au mieux les masses de données disponibles. Suite à leur succès en vision par ordinateur, l'application des réseaux de neurones profonds à ces données d'observation de la Terre a donc motivé de nombreuses études ces dernières années, focalisées notamment sur les tâches de segmentation sémantique et de détection d'objet. Citons par exemple quelques travaux dans lesquels nous avons été impliqués : cartographie automatisée à partir d'imagerie couleur, infra-rouge et de données d'élevation (Audebert et al., 2018) ou d'imagerie hyperspectrale (Audebert et al., 2019) ; détection, reconnaissance et caractérisation de navires par imagerie radar (Dechesne et al., 2019) ; détection de changements en couplant des observations aériennes et prises au sol (Lefèvre et al., 2017) ; détection et comptage de véhicules pour en dériver des indicateurs macro-économiques (Froidevaux et al., 2020) ; ou encore suivi au plus proche des pratiques agricoles (Rußwurm et al., 2019). Dans la suite de ce chapitre, nous nous intéressons plus précisément au suivi de la mégafaune marine.

3.1 PROJET DEEPTDETECT

Le projet DeepDetect, financé pour 30 mois par l'agence nationale de la recherche (ANR) et la direction générale de l'armement (DGA) dans le cadre du programme 2017 d'accompagnement spécifique des travaux de recherches et d'innovation défense (ASTRID), a pour objectifs la détection et la reconnaissance d'objets multiples sur des fonds variables par apprentissage profond. Les applications visées sont duales, et nous nous intéressons ici au cas d'utilisation civil qui consiste en la détection et la cartographie des populations de mammifères marins par imagerie satellitaire. Comme nous l'avons indiqué précédemment, les progrès de la télédétection spatiale avec no-

tamment l'amélioration de la résolution des images, l'augmentation de la couverture temporelle, et la mise à disposition gratuite des données Copernicus, offrent de nouvelles possibilités quant au suivi à large échelle des mammifères marins. Ainsi, Fretwell et al. (2014) ont montré qu'il était possible de compter automatiquement depuis l'espace les baleines présentes dans une zone de reproduction. Plus récemment, Guirado et al. (2019) ont montré que les réseaux de neurones profonds pouvaient être mobilisés pour accroître les performances de reconnaissance et analyser différentes zones géographiques.

À titre d'exemple, la figure 2 illustre les résultats que nous avons obtenus pour la détection automatique de baleines avec un réseau de neurones profond de type Faster R-CNN (Ren et al., 2017) entraîné sur une cinquantaine d'exemples pris dans une dizaine d'extraits d'images à très haute résolution spatiale. Bien que ces résultats soient convaincants, il faut souligner qu'ils ont été obtenus à partir d'images satellites à très haute résolution spatiale (30 à 50 cm par pixel) tels que les missions WorldView (DigitalGlobe) ou Pléiades (CNES / Airbus Defense and Space). Ces images, dont l'acquisition est coûteuse et doit être programmée à l'avance, ne permettent pas de couvrir de larges zones géographiques ni d'assurer un suivi dans le temps. Les images fournies par Copernicus au travers des missions Sentinel n'ont pas ces inconvénients. Néanmoins, avec une résolution spatiale 20 à 30 fois moindre que les images à très haute résolution, elles nécessitent le développement de méthodes capables de détecter de très petits objets (ainsi la baleine bleue, si grande soit-elle, n'est représentée que par quelques pixels de l'image).




Figure 2. Détection de baleines par imagerie satellite à très haute résolution spatiale.

Dans ce contexte, les travaux conduits dans le projet DeepDetect visent à apporter des éléments de réponse au travers de réseaux de neurones profonds originaux, capables de détecter de très petits objets. En particulier, nous nous sommes intéressés à des modèles qui cherchent à la fois à détecter ces objets et à améliorer la résolution de l'image (problème connu sous le nom de super-résolution). Nos travaux (Courtrai et al., 2020a ; Courtrai et al., 2020b) s'appuient sur les réseaux dits adversaires pour générer des images de meilleure résolution, et exploitent les caractéristiques

téristiques apprises par le réseau au sein d'un bloc dédié à la détection d'objet. La figure 3 illustre notre méthodologie, et les résultats obtenus sur des bases d'images de véhicules démontrent l'intérêt de l'approche. L'application à des baleines sur des images Sentinel n'a cependant pas encore pu être mise en œuvre faute d'images annotées.

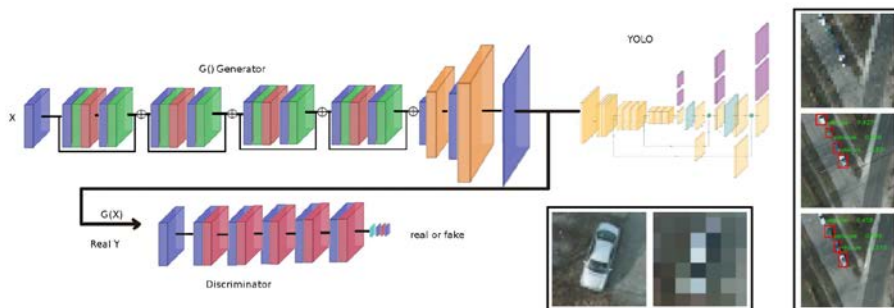


Figure 3. Réseau de neurones profond combinant des modules de super-résolution et de détection : architecture du réseau et encarts montrant la différence d'apparence visuelle d'un véhicule en haute ou basse résolution (en bas), et les résultats de détection obtenus (à droite, de haut en bas : image basse résolution 1:8, résultat théorique à partir d'une image haute résolution, et résultat conjoint de détection et super-résolution fourni par notre réseau appliqué aux images de basse résolution).

3.2 PROJET SEMMACAPE

Le projet Semmacape, piloté par l'Université Bretagne Sud, et cofinancé par l'agence de transition écologique (anciennement agence de l'environnement et de la maîtrise de l'énergie, ADEME) dans le cadre du programme Énergie Durable en 2019, porte sur le suivi et l'étude de la mégafaune marine par caractérisation automatique dans les parcs éoliens. Il vise à doter les projets d'énergies marines renouvelables d'outils automatiques pour l'analyse d'impact sur l'environnement, et en particulier sur la mégafaune marine (oiseaux, mammifères marins, tortues, grands poissons). Les données analysées consistent ici en des survols aériens, et l'objet des travaux de recherche est non seulement de démontrer la pertinence des réseaux de neurones profonds pour le suivi de la mégafaune en conditions opérationnelles, mais aussi de développer des réseaux non-supervisés, qui offrent l'intérêt de ne pas nécessiter d'annotations lors de leur phase d'entraînement.

La première campagne d'acquisition d'images vient d'être effectuée en mai 2020. Les 2500 kilomètres survolés au sein du parc naturel marin de l'estuaire de la Gironde et de la mer des Pertuis ont permis d'obtenir plus de 20 000 photos aériennes et d'observer plusieurs espèces, parmi lesquelles puffins, laridés, méduses, dauphins, marsouins ou encore requins. La figure 4 présente un extrait d'une image obtenue par le dispositif d'acquisition haute-définition déployé lors de cette campagne. Bien que le banc de dauphins soit clairement visible, on peut constater la difficulté à identifier les individus dès lors qu'ils s'éloignent de la surface, et les perturbations inhérentes aux vagues, aux gerbes d'écume et autres reflets du soleil. Élaborer un réseau de neurones profond s'affranchissant de ces difficultés pour détecter, recenser et catégoriser la mégafaune marine dans des conditions opérationnelles, reste un problème ouvert auquel cherchera à répondre le projet Semmacape qui s'achèvera en 2022.



Figure 4. Exemple d'image haute-définition (extrait) acquise lors d'un survol aérien Semmacape.

4. OBSERVER DEPUIS LES FONDS MARINS

Alors que dans la section précédente nous avons montré que l'apprentissage profond permettait le recensement automatique des espèces marines par imagerie aérienne et satellite, nous nous intéressons ici à un autre cas d'application, où les observations sont réalisées sous la surface de la mer, mis en œuvre au sein du projet Game of Trawls.

Projet Game of Trawls

Le projet Game of Trawls, piloté par l'institut français de recherche pour l'exploitation de la mer (IFREMER), est cofinancé en 2018 par le fond européen pour les affaires maritimes et la pêche (FEAMP) dans le cadre de la mesure Innovation dans la filière pêche, liée à la conservation des ressources biologiques de la mer, et par l'association interprofessionnelle France Filière Pêche. Il vise à faire profiter la filière de la pêche des dernières avancées en intelligence artificielle, en développant des chaluts de fond connectés et intelligents pour contrôler de manière active la sélectivité, l'incidence sur les écosystèmes, et identifier en temps réel les espèces capturées. En effet, en équipant les chaluts de différents capteurs (dont des caméras vidéo) connectés à des systèmes embarqués communicants avec le navire de pêche, et de dispositifs d'échappement ou d'évitement actionnables à distance, le capitaine pourra alors suivre son opération de pêche en temps réel, adapter ses captures, et ainsi limiter l'impact environnemental de son activité. Dans le projet Game of Trawls, la mise en œuvre de telles solutions passe notamment par le développement de réseaux de neurones profonds pour analyser automatiquement les flux vidéo ou les autres signaux issus des capteurs équipant le chalut, puis par le déploiement de ces réseaux dans des systèmes embarqués sur le navire, voire sur le chalut.

Les travaux que nous avons réalisés lors de la première moitié du projet ont porté sur la détection des individus et la reconnaissance de leur espèce, qu'elle soit pélagique (sardines, chinchards), ou benthique (langoustines). La figure 5 illustre les résultats obtenus dans les deux cas, la caméra étant orientée soit vers l'intérieur du chalut, soit vers le fond. Bien que ces résultats soient prometteurs, il faut souligner la relative simplicité des images analysées qui ne présentent pas de caractéristiques

rière de turbidité et bénéficie d'un éclairage adéquat. A mi-parcours, les travaux restant à mener dans ce projet visent donc à tenir compte de ces conditions d'acquisition difficiles, à exploiter les informations fournies par les autres capteurs (sonar acoustique, par exemple) conjointement aux données vidéo, à caractériser les poissons (taille) et estimer leur comportement de nage pour mieux identifier leur espèce.



Figure 5. Détection et reconnaissance d'espèces pélagiques (à gauche) et benthiques (à droite).

5. CONCLUSION

Notre société et notre planète ont connu de nombreux bouleversements. L'essor de l'intelligence artificielle au travers des succès obtenus par l'apprentissage profond, et l'amélioration continue de nos capacités à observer notre environnement, peuvent être combinés et mis à profit pour analyser plus massivement le monde qui nous entoure. Dans ce chapitre, nous nous sommes focalisés sur la mégafaune marine et avons illustré dans ce contexte le potentiel de l'apprentissage profond. Pour cela, nous avons présenté quelques projets collaboratifs multidisciplinaires impliquant les chercheurs de l'équipe OBELIX de l'IRISA, et illustrant l'importance de la télédétection aérienne et spatiale, mais aussi de l'imagerie sous-marine.

Différentes perspectives à ces travaux peuvent être envisagées. D'une part, il est nécessaire de limiter la dépendance aux données de référence, généralement annotées manuellement par les utilisateurs, et pourtant nécessaires à l'entraînement des réseaux de neurones profonds. Les réseaux semi-supervisés semblent une voie prometteuse dans ce contexte (Castillo-Navarro et al., 2019). En outre, la diversification des sources de données, avec par exemple les relevés laser 3D (Guiotte et al., 2020), apporte des informations complémentaires sur les scènes étudiées, mais nécessitent de développer des réseaux capables de traiter des informations dites non structurées (comme les nuages de points). Enfin, fusionner ces différentes sources, depuis l'observation rapprochée jusqu'à celle depuis l'espace, est aujourd'hui possible (Lefèvre et al., 2017). Le développement de réseaux aptes à combiner différentes modalités ou différents points de vue (Nassar et al., 2019) est une question au cœur des problématiques scientifiques, et qu'il convient d'approfondir.

Pour conclure, en dépit des possibilités offertes par l'apprentissage profond, il ne faut pas oublier son coût énergétique et l'impact environnemental induit par le recours massif aux processeurs GPU. Une intelligence artificielle verte reste donc à inventer, pour qu'elle puisse bénéficier, sans équivoque, à notre bien commun.

REFERENCES

- Audebert N., Le Saux B., et Lefèvre S., Beyond RGB: very high resolution urban remote sensing with multimodal deep networks, *ISPRS Journal of Photogrammetry and Remote Sensing*, 140, (2018), pp. 20-32. <https://doi.org/10.1016/j.isprsjprs.2017.11.011>
- Audebert N., Le Saux B., et Lefèvre S., Deep learning for classification of hyperspectral data: a comparative review, *IEEE Geoscience and Remote Sensing Magazine*, 7, 2, (2019), pp. 159-173. <https://doi.org/10.1109/MGRS.2019.2912563>
- Castillo-Navarro J., Audebert N., Boulch A., Le Saux B., et Lefèvre S., What data are needed for semantic segmentation in earth observation?, dans *Joint Urban Remote Sensing Event (JURSE)*, (2019). <https://doi.org/10.1109/JURSE.2019.8809071>
- Courtrai L., Pham M.T., Burnel J.C., et Lefèvre S., Apprentissage de réseaux de neurones de super-résolution pour la détection d'objets de petite taille dans les images de télédétection, dans *Congrès Reconnaissance des Formes, Image, Apprentissage et Perception*, (2020).
- Courtrai L., Pham M.T., Friguet C., et Lefèvre S., Small object detection from remote sensing images with the help of object-focused super-resolution using Wasserstein GANs, dans *International Geosciences and Remote Sensing Symposium*, (2020).
- Dechesne C., Lefèvre S., Vadaine R., Hajduch R., et Fablet R., Ship identification and characterization in Sentinel-1 SAR images with multi-task deep learning, *Remote Sensing*, 11, 24, (2019), 2997. <https://doi.org/10.3390/rs11242997>
- Froidevaux A., Julier A., Lifschitz A., Pham M.T., Dambreville R., Lefèvre S., et Lassalle P., Vehicle detection and counting from VHR satellite images: efforts and open issues, dans *International Geosciences and Remote Sensing Symposium*, (2020). <https://arxiv.org/abs/1910.10017>
- Fretwell P.T., Staniland I.J., et Forcada J., Whales from space: counting southern right whales by satellite, *PLOS One*, 9, 2, (2014), e88655. <https://doi.org/10.1371/journal.pone.0088655>
- Guiotte F., Pham M.T., Dambreville R., Corpetti T., et Lefèvre S., Semantic segmentation of lidar points clouds: rasterization beyond digital elevation models, *IEEE Geoscience and Remote Sensing Letters*, (2020). <https://doi.org/10.1109/LGRS.2019.2958858>
- Guirado E., Tabik S., Rivas M.L., Alcaraz-Segura D., et Herrera F., Whale counting in satellite and aerial images with deep learning, *Scientific Reports*, 9, (2019), 14259. <https://doi.org/10.1038/s41598-019-50795-9>
- Hebb D.O., *The organization of behavior: a neuropsychological theory*. Wiley & Sons, (1949).
- Krizhevsky A., Sutskever I., et Hinton G.E. Imagenet classification with deep convolutional neural networks, *Communications of the ACM*, 60, 6, (2017), pp. 84-90. <https://doi.org/10.1145/3065386>
- Laroze M., Dambreville R., Friguet C., Kijak E., et Lefèvre S., Active learning to assist annotation of aerial images in environmental surveys, dans *International Conference on Content-Based Multimedia Indexing (CBMI)*, (2018). <https://doi.org/10.1109/CBMI.2018.8516511>
- Le Cun Y., Bengio Y., et Hinton G., Deep learning. *Nature*, 521, 7553, (2015), pp. 436-444. <https://doi.org/10.1038/nature14539>
- Lefèvre S., Tuia D., Wegner J.D., Produit T., et Nassar A.S., Toward Seamless Multiview Scene Analysis From Satellite to Street Level, *Proceedings of the IEEE*, 105, 10, (2017), pp. 1884-1899. <https://doi.org/10.1109/JPROC.2017.2684300>
- McCulloch W.S., et Pitts W., A logical calculus of the ideas immanent in nervous activity, *Bulletin of Mathematical Biophysics*, 5, (1943), pp. 115-133.
- Merciol F., Fauqueur L., Damodaran B.B., Rémy P.Y., Desclée B., Dazin F., Lefèvre S., Masse A., et Sannier C., Geobia at the terapixel scale: toward efficient mapping of small woody features from heterogeneous VHR scenes, *ISPRS International Journal of Geo-Information*, 8, 1, (2019), 46. <https://doi.org/10.3390/ijgi8010046>
- Nassar A.S., Lefèvre S., et Wegner J.D., Simultaneous multi-view instance detection with learned geometric soft-constraints, dans *International Conference on Computer Vision*, (2019). <https://arxiv.org/abs/1907.10892>
- Ren S., He K., Girshick R., et Sun J. Faster R-CNN: towards real-time object detection with region proposal networks, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39, 6, (2017), pp. 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Rußwurm M., Tavenard R., Lefèvre S., et Kömer M., Early classification for agricultural monitoring from satellite time series, dans *International Conference on Machine Learning AI for Social Good Workshop*, (2019). <https://arxiv.org/abs/1908.10283>

CONSEILS DE LECTURES

2 conseils de lecture :

- *Quand la machine apprend : La révolution des neurones artificiels et de l'apprentissage profond*, par Yann Le Cun ; Odile Jacob, 2019, 394 pages
 - *L'apprentissage profond*, par Ian Goodfellow, Yoshua Bengio, Aaron Courville ; traduit * de l'anglais par Quantmetry à l'aide de DeepL, solution de traduction automatique par apprentissage profond ; Massot Éditions, 2018, 768 pages
- * Pour les lecteurs pratiquant la langue de Shakespeare, il reste préférable de lire la version originale.